



KAHRAMANMARAŞ SÜTÇÜ İMAM ÜNİVERSİTESİ

e-ISSN 1309-1751

Mühendislik Bilimleri Dergisi Journal of Engineering Sciences

2025

SAYI / NUMBER : 1

CILT / VOLUME : 28



Yazışma Adresi / Corresponding Address

Kahramanmaraş Sütçü İmam Üniversitesi
Mühendislik Bilimleri Dergisi
46050, Onikişubat/Kahramanmaraş
TÜRKİYE

E - Posta

jes@ksu.edu.tr

Web

<http://jes.ksu.edu.tr/>

Bu dergi hakemli olup yılda 4 kez yayınlanır.

This journal is peer - reviewed and published 4 issues per year.



Sahibi / Owner

Prof.Dr. Alptekin YASIM
KSU Rector

Baş Editör / Editor in Chief

Prof. Dr. Mehmet ÜNSAL
munsal@ksu.edu.tr

Baş Editör Yardımcısı / Vice Editor in Chief

Assoc. Prof. Dr. Zeynep Banu ÖZGER
zeynepozger@ksu.edu.tr

Editörler / Editors

Prof. Dr. Ahmet ALKAN
Electrical and Electronics Eng.
KSU Univ. TURKEY
aalkan@ksu.edu.tr

Prof. Dr. Yücel ÖZMEN
Mechanical Eng.
Karadeniz Teknik Univ. TURKEY
yozmen@ktu.edu.tr

Prof. Dr. Özlem TURGAY
Food Eng.
KSU Univ. TURKEY
ozlem@ksu.edu.tr

Prof. Dr. Tamer RIZAOĞLU
Geological Eng.
KSU Univ., TURKEY
tamer@ksu.edu.tr

Prof. Dr. Tahir Çetin AKINCI
Electrical Eng.
İstanbul Teknik Univ, TURKEY
akincitc@itu.edu.tr

Prof. Dr. Kristina SARIC
Geological Eng.
University of Belgrade, SERBIA
kristina.saric@rgf.bg.ac.rs

Prof. Dr. Ramazan GÖKÇE
Food Eng.
Pamukkale Univ., TURKEY
rgokce@pau.edu.tr

Prof. Dr. A. Mehmet YÜCEER
Chemical Eng.
İnönü Univ., TURKEY
mehmet.yuceer@inonu.edu.tr

Assoc.Prof.Dr. Ö. Fatih KEÇECİOĞLU
Electrical and Electronics Eng.
KSU Univ. TURKEY
fkececioglu@ksu.edu.tr

Assoc.Prof.Dr. Fethullah GÖÇER
Industrial Eng.
KSU Univ. TURKEY
fgocer@ksu.edu.tr

Assoc.Prof.Dr. Erdem SELVER
Textile Eng.
KSU Univ. TURKEY
eserver@ksu.edu.tr

Assoc.Prof.Dr. Pınar CİHAN
Computer Eng.
Namık Kemal Univ. TURKEY
pkaya@nku.edu.tr

Assoc. Prof.Dr. Çağrı UZAY
Mechanical Eng.
KSU Univ., TURKEY
cagriuzay@ksu.edu.tr

Assoc.Prof.Dr. Oğuz DOĞAN
Mechanical Eng.
KSU Univ. TURKEY
oguzdogan@ksu.edu.tr

Assist.Prof.Dr. Ayşe Ruşen DURUCAN
Civil Eng.
Fırat Univ. TURKEY
ardurucan@firat.edu.tr

Assist.Prof.Dr. Yakup CUCİ
Environmental Eng.
KSU Univ. TURKEY
cuci@ksu.edu.tr

Assist. Prof. Dr. Pelin CANBAY
Computer Eng.
KSU Univ. TURKEY
pelincanbay@ksu.edu.tr

Assist. Prof. Dr. Zeynep KILIÇ
Civil Eng.
Adıyaman Univ. TURKEY
zkilic@adiyaman.edu.tr

Assist. Prof. Dr. F. Tuğçe ÇINAR KILIÇ
Civil Eng.
Adıyaman Univ. TURKEY
fcinar@ksu.edu.tr

Assist. Prof. Dr. Özdeş ÇERMİK
Language Editor
KSU Univ. TURKEY
ozdescermik@ksu.edu.tr

Res. Assist. Elif ÇELİK
Technical Manager
KSU Univ. TURKEY
elifcelik@ksu.edu.tr

Res. Assist. Sermet AYMAN
Technical Manager
KSU Univ. TURKEY
sayman@ksu.edu.tr

Res. Assist. Yalın YAMAÇ
Technical Manager
KSU Univ. TURKEY
yalinyamac@ksu.edu.tr

Res. Assist. Betül PAKÖZ
Technical Manager
KSU Univ. TURKEY
betulpakoz@ksu.edu.tr

Res. Assist. Arif ÇUTAY
Technical Manager
KSU Univ. TURKEY
arifcutay@ksu.edu.tr

Danışma Kurulu / Advisory Board

Prof. Dr. Cetin Kaya KOC
Dep. of Computer Eng.
Univ Of Cal.
Santa Barbara. USA
koc@cs.ucsb.edu

Prof. Dr. Ayhan ÖZDEMİR
Dep. of Elect. & Elcn Eng.
Sakarya Univ. Sakarya,
TURKEY
aozdemir@sakarya.edu.tr

Prof. Dr. Hüseyin AKILLI
Dep. of Mechanical Eng.
ÇU Univ.
Adana, TURKEY
hakilli@cu.edu.tr

Prof. Dr. Mehmet KORÜREK
Dep. Of Elcn & Comm Eng.
İTU Univ.
İstanbul. TURKEY
korurek@itu.edu.tr

Prof. Dr. Yasemin KORKMAZ
Dep. of Textile Eng.
KSU Univ.
TURKEY
ykorkmaz@ksu.edu.tr

Prof. Dr. Ahmet PINARBAŞI
Dep. of Mechanical Eng.
Alanya Alaaddin Keykubat
Univ. Antalya, TURKEY
apinarbasi@alanya.edu.tr

Prof. Dr. S. Serhat ŞEKER
Dep. Of Elect. Eng.
İTU Univ. İstanbul.
TURKEY
sekers@itu.edu.tr

Prof. Dr. Şerafettin EREL
Dep. of Elect. & Elcn Eng.
YBU Univ.
Ankara, TURKEY
serel@ybu.edu.tr

Assoc. Prof. Dr. Mustafa ONAT
Dep. of Computer Eng.
Marmara Univ.
İstanbul. TURKEY
monat@marmara.edu.tr

Prof. Dr. Eyüp DEBİK
Dep. of Environmental Eng.
Yıldız Technical Univ.
İstanbul. TURKEY
debik@yildiz.edu.tr

Prof. Dr. Fan MIZI
Dep. of Civil Eng.
Brunel Univ.
Uxbridge, UK
mizi.fan@brunel.ac.uk

Prof. Dr. A. Fevzi BABA
Dep. of Elect. & Elcn. Eng.
Marmara Univ. İst.,
TURKEY
fbaba@marmara.edu.tr

Dr. Amit CHAUDHRY
Dep. of Microelectronics
Panjab Univ,
Chandigarh, India
amit_chaudhry01@yahoo.com

Assoc. Prof. Dr. Nazmi EKREN
Dep. of Elect. & Elcn. Eng.
Marmara Univ.
İstanbul, TURKEY
nekren@marmara.edu.tr

Prof. Dr. Mustafa YAZICI
Dep. of Physics Education.
KSU Univ.
K.Maras. TURKEY
yazici@ksu.edu.tr

Prof. Dr. Selim AY
Dep. Of Elect. Eng.
YTU Univ.
İstanbul. TURKEY
selimay@yildiz.edu.tr

Prof. Dr. Musa GÖĞEBAKAN
Dep. of Physics
KSU Univ.
K.Maraş, TURKEY
gogebakan@ksu.edu.tr

Prof. Dr. Murat PALA
Dep. of Civil Eng.
Adiyaman Univ.
Adiyaman. TURKEY
pala@adiyaman.edu.tr

Prof. Dr. İ.Taner OKUMUŞ
Dep. of Computer Eng
KSU Univ.
K.Maraş. TURKEY
iokumus@ksu.edu.tr



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



BU SAYIYA (CİLT 28 SAYI 1) KATKI VEREN HAKEMLER

- | | |
|-----------------------------|----------------------------------|
| Meral KORKMAZ | Mustafa TUNÇ |
| Veysi KARTAL | Yuşa ŞAHİN |
| Türkay KOTAN | Yekta GEZGİNÇ |
| Elife KAYA | Nadide Gülşah GÜLENC |
| Mahmut KAYA | Özlem POLAT |
| Levent KARACAN | Mücahid GÜNAY |
| Emrullah ŞAHİN | Hasan Arda BURHAN |
| Ceyhun AKARSU | Kemal SÜLÜK |
| Nuray ALPASLAN | Yaşar VİTOŞOĞLU |
| Uğur Eren YURTCAN | Gülten GÜNEŞ |
| Arslan SARAL | Ahmet Serdar YILMAZ |
| Muharrem KARARSLAN | İpek ATIK |
| Mustafa ARTAR | Kemal Sulhi GÜNDOĞDU |
| Emrehan YAVŞAN | Erkan USLU |
| Deniz KORKMAZ | Şebnem KARAHANÇER |
| Seher ÖZKAZANÇ | Yetis Sazi MURAT |
| İsmail DİNÇER | Zeynel Abidin ERGÜLER |
| Melih GENİŞ | Kubilay Muhammed SÜNNETÇİ |
| Faruk Enes OĞUZ | İsrafil KARADÖL |
| Şekip Esat HAYBER | Salih ERMİŞ |
| Ahmet KAYABAŞI | İbrahim Çağrı BARUTÇU |
| Çağrı UZAY | Mert KARALAR |
| Ahmet ÇETİN | Onur DERSE |
| Duygun Fatih DEMİREL | Ahmet Serhan CANBOLAT |
| Mehmet KURUOĞLU | Ahmet ÖZBEK |
| Sezin GÜLERYÜZ ERGÜL | Hamza DOĞAN |
| Ömer SEÇGİN | Ahmet Levent İNANÇ |
| Adnan BOZDOĞAN | Murat YILMAZTEKİN |

Nihat Eren ÖZMEN
Gözde ALP
Yavuz CANBAY
Atakan TANTEKİN
Şehnaz ŞENER
Cem Polat ÇETİNKAYA
Cihat ENSARİOĞLU
Tufan YILMAZ
Ahmet Anıl DİNDAR
Mehmet Eren GÜLŞAN
Sevim ÖZULUKALE DEMİRBİLEK
Levent GÖKREM
Mehmet YERLİKAYA
Murat TÜRKÖZ
Uğur AVCI
Melek AKGÜL
Adnan ALDEMİR
Özge ÖZTİMUR KARADAĞ
Burcu YILMAZ
Ali SARIKAŞ
Hakan ÜÇGÜN
Emre Oğuz KÖROĞLU
Kadir ABACI

Ahmet SAYGILI
Eşref BOĞAR
Murat ÇATALKAYA
Timuçin Alp ASLAN
Cahit DÖNMEZ
Mahsum AYDIN
Erkan ÖZTÜRK
Muhammed Safa KAMER
Mehmet Alper ÇANKAYA
Şükrü KARASLAN
Alpay DORUK
Hayrettin AYAR
Kamil Bekir AFACAN
Esra TATLIOĞLU
Özgür YURTSEVER
Mustafa EKEN
Emre YİĞİT
Serdar ÇİFTÇİ
Buket ARIK
Görkem SERBES
Çağatay ERSİN
Kevser CIRIK
Hakan IŞIKER



İÇİNDEKİLER

ARAŞTIRMA MAKALESİ – RESEARCH ARTICLE

- Effect Of Seasonal-Trend Decomposition On Machine Learning-Based Suspended Sediment Load Prediction Performance
Mevsimsel-Trend Ayrıştırmasının Makine Öğrenmesi Tabanlı Askıda Sediment Yükü Tahmin Performansı Üzerindeki Etkisi 1-18
Cihangir KÖYCEĞİZ, Meral BÜYÜKYILDIZ
- Determination Of Physical, Mechanical, Thermal Properties Of Ready Thermal Insulation Plasters
Hazır Isı Yalıtım Sıvalarının Fiziksel, Mekanik, Isı Özelliklerinin Belirlenmesi 19-29
Şemsettin KILINÇARSLAN, Metin DAVRAZ, Yasemin ŞİMŞEK TÜRKER, Mehmet Ali AKBULUT
- Vitamin C Enrichment Application To Reduce The Risk Of Carcinogenic Nitrosamine Formation In Smoked Fish
Tütsülenmiş Balıklarda Kanserojen Nitrosamin Oluşum Riskini Azaltmak İçin C Vitamini Zenginleştirme Uygulaması 30-37
Aydın KILIÇ
- Radyomik Özellikler Ve Makine Öğrenmesi Teknikleriyle Meme Tümörlerinin Sınıflandırılması
Classification Of Breast Tumors Using Radiomic Features And Machine Learning Techniques 38-50
Asuman KAPLAN, Esra KAVADAR, Mehmet Ali ALTUNCU
- Kafatası Kırıklarının Teşhisinde Yapay Zekâ: Güncel Derin Öğrenme Mimari Performansları
Artificial Intelligence In Skull Fracture Diagnosis: Current Deep Learning Architecture Performances 51-64
Fidan KAYA GÜLAĞIZ, Tuğrul Hakan GENÇTÜRK, İsmail KAYA
- Makine Öğrenmesi İle Üretim Performansı Tahminlemesi
Predict Of Production Performance With Machine Learning 65-79
Semih GÖKSU, Bülent SEZEN, Yavuz Selim BALCIOĞLU
- Çorap Boyama Atıksularının Fenton Ve Elektro-Fenton Prosesleri İle Arıtımı
Treatment Of Sock Dyeing Wastewater By Fenton And Electro-Fenton Processes 80-88
İbrahim YOKSULABAKAN, Özgecan MADENLİ, Ece Ümmü DEVECİ
- Uçucu Kül Ve Guar Sakızı İle Stabilize Edilmiş Bir Kil Zeminin Mukavemet Özelliklerinin Taguchi Tekniği Kullanılarak Değerlendirilmesi
Evaluation Of The Strength Properties Of A Clay Soil Stabilized With Fly Ash And Biopolymer Using The Taguchi Technique 89-103
Mehmet Fatih YAZICI, Mehmet Fahri SARAÇ, Çağla AYDIN, Melce Begüm POLAT, Can Mustafa ÇALIK, Caner ÖZEN

Yüksek Verimli Stairmand Siklonda Sıcaklık Etkisinin İncelenmesi Investigation Of The Temperature Effect On The Stairmand High Efficiency Cyclone Nihan BABAOĞLU, Mesut ARİ	104-111
Şebeke Bağlantılı Güneş Enerjisi Santrali Yatırımı İçin Modelleme Ve Simülasyon Analizi: Iğın/Konya Örneği Modeling And Simulation Analysis For Grid Connected Solar Power Plant Installation: A Case Study Of Iğın/Konya Furkan DİNÇER	112-128
Bitki Örtüsü İndeksleri Kullanılarak Bitki Örtüsü Yoğunluklarının Araştırılması: Karatepe-Aslantaş Milli Parkı Örneği Investigation Densities Of Vegetation Using Vegetation Indices: The Case Of Karatepe-Aslantaş National Park Sevim Yasemin OTURANÇ	129-137
Trafik İşaretlerinin Tespitinde Farklı Yolo Modellerinin Karşılaştırılması The Comparison Of Different Yolo Models For Traffic Sign Detection Mehmet Fatih BEKÇİOĞULLARI, Bünyamin DİKİCİ, Hakan AÇIKGÖZ, Serkan ÖZBAY	138-150
Aktivite-Seyahat Seçimleri Ve Araç Sahipliğinin Kesikli Seçim Modelleri İle İncelenmesi Analysis Of Activity-Travel Choices And Vehicle Ownership Using Discrete Choice Models Gözde BAKİOĞLU	151-168
İgnimbritlere Ait Farklı Tane Büyüklüğüne Sahip Taş Tozu Ve Epoksi Reçine Esaslı Kompozitlerin Tuz Etkisine Bağlı Hasarlara Karşı Koruma Potansiyelinin İncelenmesi Investigation Of The Protection Potential Of Stone Powder With Different Grain Sizes Belonging To Ignimbrites And Epoxy Resin Based Of Composites Against Damage Due To Salt Effect Ahmet Cihat ARI	169-178
Emg Sinyalleri İle Derin Öğrenme Yöntemlerini Kullanarak El/Parmak Hareketi Tanıma Hand/Finger Gesture Recognition Using Deep Learning Methods With Emg Signals Mehmet İsmail GÜRSOY	179-188
Kırşehir'in Rüzgar Enerjisi Potansiyeli Ve İç Anadolu Bölgesi Kurulu Rüzgar Enerjisi Santrallerinin Güç Analizi Wind Energy Potential Of Kırşehir And Power Analysis Of Wind Energy Plants Installed In Central Anatolia Region Müjdat ÖZTÜRK, Ramazan KAYABAŞI, Oğuz TAŞDEMİR	189-201
Rüzgâr Gücü Tahmininde Uzun Kısa-Süreli Bellek: Veri Örnekleme Ve Kümelemenin Etkisi Long Short-Term Memory For Wind Power Estimation: The Effect Of Data Sampling And Clustering Volkan YAMAÇLI	202-215
Finite Element Analysis Of Excavator Bucket Design With Biomimetic Approach With Different Steels Farklı Çeliklerle Biyomimetik Yaklaşımla Ekskavatör Kepçe Tasarımının Sonlu Elemanlar Analizi Berkay KARACOR, Kaan KOÇ, Mustafa ÖZCANLI	216-229

Yönetim Araçları Seçiminde Sektör Analizi Ve Çok Kriterli Karar Verme Teknikleri Kullanımı: Hibrit Entropi-Topsis Metodu İle Sağlık Turizmi Aracı İşletmelerine Yönelik Bir Uygulama Sector Analysis And Use Of Multi-Criteria Decision-Making Techniques In The Selection Of Management Tools: An Application For Health Tourism Intermediary Businesses With Hybrid Entropy-Topsis Method Serkan ETİ, Halil YORULMAZ	230-244
Evaluation Of The Vessel With Different Stenosis Structures Using CFD Approach Farklı Darlık Yapılarına Sahip Damarın Had Yaklaşımı Kullanılarak Değerlendirilmesi Arif ÇUTAY, Özdeş ÇERMİK, Ahmet KAYA	245-257
Zeolit-Bentonit Karışımlarının Termal İletkenlik Davranışı Thermal Conductivity Behavior Of Zeolite-Bentonite Mixtures Esra GÜNERİ	258-265
Üretimde Dijital Dönüşümün Başarısını Değerlendirmek İçin Performans Ölçmeye Yönelik Bir Yaklaşım A Performance Measurement Approach For Evaluating The Success Of Digital Transformation In Manufacturing Gökçen SARAY, Bilal ERVURAL	266-284
The Effect Of Peanut Tahini Utilization On The Mineral Content Of Halva Yer Fıstığı Tahini Kullanımının Helvanın Mineral İçeriği Üzerine Etkisi Venüs KARAKUŞ, Kurban YAŞAR	285-291
Automatic Detection Of Meniscus Tears From Knee MRI Images Using Deep Learning: Yolo V8, V9, And V10 Series Diz MRI Görüntülerinden Menisküs Yırtıklarının Derin Öğrenme İle Otomatik Tespiti: Yolo V8, V9 Ve V10 Serileri Mehmet Ali ŞİMŞEK, Ahmet SERTBAŞ	292-308
Genetik Algoritma Temelli Öznitelik Seçiminin Anemi Hastalığının Tespitine Etkisi The Effect Of Genetic Algorithm Based Feature Selection On Detection Of Anaemia Disease Mehtap ÖKLÜ, Hasan BADEM	309-321
LSTM And Anfis Machine Learning Algorithms In Estimating The Sea Water Temperature In Türkiye At Various Sea Locations Türkiye’de Farklı Deniz Mevkilerindeki Deniz Suyu Sıcaklığının LSTM Ve Anfis Makine Öğrenmesi Algoritmaları Kullanılarak Tahmin Edilmesi Akın İLHAN, Sergen TÜMSE, Mehmet BİLGİLİ, Alper YILDIRIM, Beşir ŞAHİN	322-333
Sakarya Geyve Bölgesi Dere Sedimanlarının Ağır Metal İçerikleri: Olası Zenginleşme Ve Kirlenme Kaynakları Heavy Metal Contents Of Stream Sediments In The Sakarya-Geyve Region: Potential Enrichment And Contamination Sources Mustafa Haydar TERZİ, Mehmet Barış DURGUN, Gökhan DEMİRELA	334-349
Investigation Of Precipitation Data Of Diyarbakir Province With Different Trend Analysis Methods Diyarbakır İline Ait Yağış Verilerinin Farklı Trend Analizi Yöntemleri İle İncelenmesi Burak GÜL	350-368

- Kaplamalı Ve Kaplamasız Kesici Takımlarla İşlenen Inconel 718 İş Parçasının Yüzey Pürüzlülük Değerlerinin Anfis İle Modellenmesi** 369-379
Anfis Modeling Of Surface Roughness Values Of Inconel 718 Workpiece Machined With Coated And Uncoated Cutting Tools
Hüseyin GÜRBÜZ, Şehmus BADAY
- Structural Investigation Of Pneumatic Grippers For Handling Automotive Parts Using Finite Element Analysis And Topology Optimization** 380-390
Otomotiv Parçalarının Taşınmasında Pnömatik Tutucular: Yapısal İnceleme, Sonlu Elemanlar Analizi Ve Topoloji Optimizasyon
Ömer ARAT, Ahmet DURAN, Barış ERMAN, Ali KİBAR
- Farklı Kat Adetlerine Sahip Betonarme Yapıların Burulma Davranışının Değerlendirilmesi** 391-402
Evaluation Of Torsional Behaviour Of Reinforced Concrete Structures With Different Story Numbers
Dilara TURSUN, Ömer Faruk TAŞ, Erkut SAYIN
- Dalgacık Dönüşümü Tabanlı Naive Bayes Sınıflandırıcı İle Türkiye'nin Tamamını İçeren Bölgelerdeki Linyit Kömürünün Kalite Tespiti** 403-413
Quality Determination Of Lignite Coal In The Regions Including The Whole Of Turkey Using Wavelet Transform Based Naive Bayes Classifier
Sevcan AYTAÇ
- Arı Kovanlarının Çevresel Ve Akustik Verilere Dayalı Durum Analizi: Normal Ve Özel Koşulların Karşılaştırılması** 414-429
Environmental And Acoustic Data-Based Status Analysis Of The Honeybee Colonies: A Comparison Of Normal And Special Conditions
Yeliz DURGUN, Mahmut DURGUN
- Kum Zeminde Kazık Taşıma Kapasitesinin Laboratuvar Model Kazık Yükleme Deneyleri İle Belirlenmesi** 430-440
Determination Of Pile Bearing Capacity In Sand Soil By Laboratory Model Pile Loading Tests
Murat GÜLEN, Havvanur KILIÇ
- Forecasting Energy Demand In Turkey Using Different Metaheuristic Methods: A Comparative Study** 441-459
Türkiye'de Enerji Talebinin Farklı Metasezgisel Yöntemler Kullanılarak Tahmini: Karşılaştırmalı Bir Çalışma
Taner SEVMİŞ, Rasim ÇEKİK
- Al7075-B₄C Kompozitlerinin Toz Metalürjisi ve Sıcak Preslemeyle Üretimi, Mekanik Özelliklerinin İncelenmesi** 460-471
Production Of Al7075-B₄c Composites By Powder Metallurgy And Hot Pressing, Investigation Of Their Mechanical Properties
Aleyna TAŞKIN, Elif IŞIK, Mahmut Can ŞENEL
- Barit Katkılı Betonlarda Radyasyon Geçirgenliğinin Regresyon Analizi İle Modellenmesi** 472-478
Modeling Of Radiation Permeability In Barite Additive Concretes Using Regression Analysis
Aytaç DİNÇER

A Graphical User Interface Design For Forecasting Nutrient Concentrations In WWTP 479-486
Atıksu Arıtım Tesisinde Organik Madde Öngörüsü İçin Grafikselsel Arayüz Geliştirilmesi
Eda GÖZ

ADnet: A CNN Model for Alzheimer's Disease Diagnosis on Oasis-1 Dataset 487-504
ADnet: Oasis-1 Veri Kümesi Üzerinde Alzheimer Hastalığı Teşhisi için Bir CNN Modeli
Ahmet Samed SARAÇOĞLU, Ayse Merve ACILAR, Özlem ERDAŞ ÇİÇEK

Farklı İşlem Koşullarında Ağartılan Kenevir Kumaşın Beyazlık Derecesinin Tahminlenmesi 505-512
Prediction Of The Whiteness Degree Of Hemp Fabric Bleached Under Different Conditions
Gamze Gülşen BAKICI

A Comparative Study Of Double-Step Deep Learning Framework For Burned Area Identification 513-523
And Severity Assessment In Wildfires
Yangınlarda Yanmış Alanların Belirlenmesi Ve Şiddet Değerlendirmesi İçin Çift Adımlı Derin
Öğrenme Çerçevesinin Karşılaştırmalı Bir Çalışması
Murat Mert YURDAKUL, Bülent BAYRAM, Tolga BAKIRMAN, Hamza Osman İLHAN

İot Destekli Hava Durumu Verileri İle Yapay Zekâ Tabanlı Hava Tahmin Sisteminin Geliştirilmesi 524-535
Development Of Artificial Intelligence-Based Weather Forecasting System With IOT-Supported
Weather Data
Nurullah DOĞAN, Fatih ÖZYURT

DERLEME MAKALESİ – REVIEW ARTICLE

Hidrojen: Sürdürülebilir Enerji İçin Çok Yönlü Çözüm 536-550
Hydrogen: A Versatile Solution For Sustainable Energy
Elif DAŞ, Emine TEKE ÖNER

A Literature Review Of Laser Engineered Net Shaping In Additive Manufacturing Using Artificial 551-582
Neural Networks
Yapay Sinir Ağları Kullanılarak Katmanlı Üretimde Lazerle Tasarlanmış Ağ Şekillendirme Üzerine
Bir Literatür İncelemesi
Filiz KARAÖMERLİOĞLU, Mustafa UCAR



Kahramanmaraş Sutcu Imam University

Journal of Engineering Sciences



Geliş Tarihi : 17.06.2024
Kabul Tarihi : 20.12.2024

Received Date : 17.02.2024
Accepted Date : 20.12.2024

EFFECT OF SEASONAL-TREND DECOMPOSITION ON MACHINE LEARNING-BASED SUSPENDED SEDIMENT LOAD PREDICTION PERFORMANCE

MEVSİMSSEL-TREND AYRIŞTIRMASININ MAKİNE ÖĞRENMESİ TABANLI ASKIDA SEDİMENT YÜKÜ TAHMİN PERFORMANSI ÜZERİNDEKİ ETKİSİ

Cihangir KÖYCEĞİZ^{1*} (ORCID: 0000-0002-0510-1164)
Meral BÜYÜKYILDIZ¹ (ORCID: 0000-0003-1426-3314)

¹ Konya Technical University, Faculty of Engineering and Natural Sciences, Department of Civil Engineering, 42250, Konya, Türkiye

*Sorumlu Yazar / Corresponding Author: Cihangir KÖYCEĞİZ, ckoycegiz@ktun.edu.tr

ABSTRACT

Forecasting of sediment is vital for water resources management. In this study, the machine learning-based prediction performance of suspended sediment load (SSL) at Bulakbaşı station of Kızılırmak River was investigated. Also, the effect of seasonal decomposition on the prediction performance was searched. Accordingly, Support Vector Machine (SVM), Adaptive Boosting (AdaBoost), and Generalized Regression Neural Network (GRNN) methods were used for SSL prediction. Grid Search (GS) algorithm was preferred for hyperparameter optimization. The seasonal component was obtained by Seasonal-Trend decomposition using the LOESS (STL) method. Six input combinations were generated using flow (Q_t), flow lag (Q_{t-1}), and the seasonal component of SSL ($S-SSL_t$). According to the findings, AdaBoost ($M6-NSE_{Train}=0.914$, $M4-NSE_{Test}=0.765$), SVM ($M6-NSE_{Train}=0.912$, $M6-NSE_{Test}=0.863$), and GRNN ($M6-NSE_{Train}=0.912$, $M4-NSE_{Test}=0.834$) models produced quite consistent results. In the test phase, SVM-M6 ($R^2=0.893$, $NSE=0.863$) is the most successful model according to various evaluation metrics. It was also observed that the last three input combinations, where the seasonal component of SSL was added, generally improved the performance. For SVM in the test phase, which is the most successful model, $R^2=0.873$, $NSE=0.820$ values were obtained in the combination without the seasonal component (M3), and $R^2=0.893$, $NSE=0.863$ values were obtained in the combination with the seasonal component (M6).

Keywords: Adaptive boosting, Kızılırmak, seasonal decomposition, support vector machine, suspended sediment load

ÖZET

Sedimentin tahmin edilmesi, su kaynakları yönetimi için hayati önem taşımaktadır. Bu çalışmada, Kızılırmak Nehri'nin Bulakbaşı istasyonundaki askıda sediment yükünün (SSL) makine öğrenmesi tabanlı tahmin performansı araştırılmıştır. Ayrıca mevsimsel ayrıştırmanın tahmin performansı üzerindeki etkisi incelenmiştir. Bu doğrultuda, Destek Vektör Makinesi (SVM), Adaptif Boosting (AdaBoost) ve Genelleştirilmiş Regresyon Sinir Ağı (GRNN) algoritmaları SSL tahmini için kullanılmıştır. Hiperparametre optimizasyonu için Grid Search (GS) algoritması tercih edilmiştir. Mevsimsel bileşen, Mevsimsel-Trend ayrıştırması LOESS (STL) yöntemi kullanılarak elde edilmiştir. Akış (Q_t), akış gecikmesi (Q_{t-1}) ve SSL'nin mevsimsel bileşeni ($S-SSL_t$) kullanılarak altı girdi kombinasyonu oluşturulmuştur. Bulgulara göre AdaBoost ($M6-NSE_{Eğitim}=0,914$, $M4-NSE_{Test}=0,765$), SVM ($M6-NSE_{Eğitim}=0,912$, $M6-NSE_{Test}=0,863$) ve GRNN ($M6-NSE_{Eğitim}=0,912$, $M4-NSE_{Test}=0,834$) modelleri oldukça tutarlı sonuçlar üretmiştir. Test aşamasında, SVM-M6 ($R^2=0,893$, $NSE=0,863$) çeşitli değerlendirme ölçütlerine göre en başarılı modeldir. SSL'nin mevsimsel bileşeninin eklendiği son üç girdi kombinasyonunun genel olarak performansı artırdığı da gözlemlenmiştir. En başarılı model olan test aşamasındaki SVM için mevsimsel bileşenin olmadığı

ToCite: KÖYCEĞİZ, C., & BÜYÜKYILDIZ, M., (2025). EFFECT OF SEASONAL-TREND DECOMPOSITION ON MACHINE LEARNING BASED SUSPENDED SEDIMENT LOAD PREDICTION PERFORMANCE. *Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences*, 28(1), 1-18.

kombinasyonda (M3) $R^2=0,873$, $NSE=0,820$ ve mevsimsel bileşenin olduğu kombinasyonda (M6) $R^2=0,893$, $NSE=0,863$ değerleri elde edilmiştir.

Anahtar Kelimeler: Adaptif boosting, Kızılırmak, mevsimsel ayrıştırma, destek vektör makinesi, askıda sediment yükü

INTRODUCTION

Measurement of suspended sediment load (SSL) and a better understanding of the physical processes affecting SSL are vital for water resources. Sediment transport has a negative impact on the management of the usability of water structures built along the river (Adnan et al., 2019). It can also lead to inefficiency as a result of its accumulation in hydraulic structures. Rivers whose cross-sections narrow due to sediment accumulation can cause danger during floods. Another negative effect of sediment on the environment is the pollutants and heavy metals it contains (Xie et al., 2022). Measurement at specific sections along the river provides the opportunity to take precautions against possible dysfunctions in the early stages. In addition, simulation studies on sediment transport are also useful for predicting sediment movement in the future (Onüçyıldız et al., 2014; Mohammadi et al., 2021; Saphioğlu and Acar, 2020).

Although measurements made at sediment observation stations provide the most accurate results in determining the amount of sediment, they are quite costly and time-consuming (Koycegiz et al., 2021). For this reason, various methods are adopted by researchers for sediment estimation. These can be generally categorized as sediment rating curves (SRC), empirical equations, physics-based models (PBM), and machine learning (ML) models. There are various studies in the literature using these methods in sediment estimation (Piraei et al., 2023; Koycegiz et al., 2021; Nourani et al., 2019). SSL, which is very difficult to measure, is affected by various processes, especially climatological, geological, and morphological (Koycegiz et al., 2021). It is not also an easy task to estimate the amount of sediment with empirical equations. Because the use of these methods also requires basin characteristics that are difficult to determine. On the other hand, the use of PBMs in sediment estimation, as in other hydrological processes, requires simulation of all hydrological processes in the basin and calibration of many parameters. PBMs require many accurate hydrological input data about the basin. Furthermore, the implementation of PBMs requires high computational time and expert knowledge (Koycegiz et al., 2021; Noori and Kalin, 2016). The use of PBMs in sediment estimation is not very common due to its impracticality. For these reasons, the use of ML methods in SSL estimation, as in other hydrological processes, is quite popular (Acar and Saphioğlu, 2022; Gupta et al., 2021).

ML methods such as artificial neural networks (ANN), support vector machines (SVM), and Adaptive Network Based Fuzzy Inference Systems (ANFIS) are among the ML methods that are frequently used in both sediment estimation and the estimation of many other hydrometeorological data. Kisi and Yaseen (2019) compared the performance of evolutionary fuzzy (EF) and ANFIS models for SSC estimation in the Eel River located in northwestern California. Subtractive clustering (SC), grid partition (GP), and fuzzy c-means (FCM) approaches were used in the generation of rules in ANFIS models. The results showed that the EF model was more successful than the ANFIS models. Buyukyildiz and Kumcu (2017), who performed ML-based SSL estimation on the Çoruh River in Türkiye, found that SVM was the most successful model. They stated that SSL estimation for this river, which has a high energy production potential, is very important for the water structures planned to be built. Kisi et al. (2009) investigated the performance of neuro-fuzzy computing methods in SSL prediction in the Kızılırmak Basin, a cross-section of which was selected as the study area. Accordingly, it was found that ML models made more successful predictions compared to empirical models. In the study by Asadi et al. (2021), where traditional ML algorithms are used in SSL prediction, it is stated that all models produce satisfactory results when geomorphological parameters are included.

In the literature, improving the prediction success of hydrological parameters such as precipitation, runoff, evaporation, and sediment has also been the focus of researchers. For this purpose, both various data preprocessing/decomposition techniques and ML models hybridized with metaheuristic methods come to the fore. Metaheuristic algorithms such as Genetic Algorithm (GA), Ant Colony Optimization (ACO), Artificial Bee Colony Optimization (ABCO), Particle Swarm Optimization (PSO), and Gray Wolf Optimization (GWO) are used alone or as a hybrid with other artificial intelligence methods, and their effects on model performance are evaluated (Aghelpour et al., 2023; Katipoğlu et al., 2024; Sales et al., 2021; Mohammadi et al., 2021; Kilinc and Yurtsever,

2022). Wavelet transform (WT), variational mode decomposition (VMD), empirical mode decomposition (EMD), Singular Spectrum Analysis (SSA), and Fourier transform (FT) are examples of the most widely used data decomposition/data preprocessing techniques (Zhou et al., 2017). A new method proposed to improve the prediction success of models is the Band Similarity (BS) method developed by Yılmaz (2022). There are a limited number of studies in the literature using this method. These studies include water consumption (Yılmaz, 2022; Yılmaz and Alpars, 2023), pan evaporation (Yılmaz, 2023), and streamflow (Yılmaz et al., 2024a, 2024b). In all these studies, findings were obtained that the BS method improved the prediction performance.

Samantaray et al. (2024) performed SSL prediction by hybridizing the traditional SVM with various metaheuristic optimization algorithms. Among the metaheuristic algorithms they applied, they found that the new sparrow search algorithm produced the most successful hybrid model with SVM. Besides hybrid models, ensemble ML algorithms are also known to produce consistent results. Piraei et al. (2023) tested various traditional and ensemble model algorithms on the SSL prediction. They state that eXtreme Gradient Boosting (XGBoost), an ensemble model, has the best prediction performance. Zhang et al. (2021) investigated the performance of the Least Absolute Shrinkage and Selection Operator (LASSO) model in predicting suspended sediment concentration (SSC) in the subaqueous Yellow River Delta in China. In addition, the prediction success of LASSO was compared with classification and regression tree (CART), support vector regression (SVR), multilayer perceptron (MLP), and stepwise regression (SR) models. As a result of the analysis, it was determined that the LASSO method performed better than other models in SSC prediction. In another study, AIDahoul et al. (2021) used Long Short-Term Memory (LSTM), Extreme Gradient Boosting (XGB), MLP, and ElasticNet Linear Regression (LR) methods in the estimation of suspended sediment load (SSL) in the Johor River basin in Peninsular Malaysia. In the study where SSL estimation was examined in 4 different scenarios (daily, weekly, 10-day, and monthly), the analyses were carried out for the period 1988-1998. The LSTM method showed higher estimation performance than the other 3 models in all scenarios.

There are studies investigating the effect of decomposition and transformation methods on the success of ML algorithms in SSL prediction. Özger and Kabataş (2015) investigated the effect of wavelet transform (WT) on the success of fuzzy logic models in SSL estimation. It was found that WT significantly increased the success compared to the stand-alone model at 4 SSL measurement points located in the Black Sea region of Türkiye. Ghasempour et al. (2021) investigated the effect of WT and Ensemble Empirical Mode Decomposition (EEMD) on the success of ML models. According to the findings, it was found that the forecasting performance of hybrid models increased significantly. Seasonal and trend decomposition using LOESS (locally weighted regression and scatterplot smoothing) (STL) (Cleveland et al., 1990) method is also an alternative data decomposition method. In addition to being used in the temporal analysis of hydrometeorological parameters, the STL method is also used as a data preprocessing/data decomposition method in forecasting studies (Yuan et al., 2023; Yılmaz et al., 2024a; Yin et al., 2024; Shaqiri, 2024).

In line with the information obtained from the literature, studies on improving the performance of ML models in SSL forecasting have an important place. However, there is no study investigating the effect of Seasonal-Trend decomposition using LOESS (STL), one of the decomposition techniques, on the performance of ML models in SSL prediction. All processes affecting the physical mechanism of SSL are under the influence of various periodicities. With this motivation, the aim of this study;

- to estimate the SSL parameter using three different machine learning methods, namely SVM, Adaptive Boosting (AdaBoost), and Generalized Regression Neural Network (GRNN) algorithms,
- to examine the effect of using the seasonality component obtained using the STL technique as input on model estimation performance.

In this respect, Bulakbaşı station on the Kızılırmak River was chosen as the study area. The novelty of this study is that, to the best of our knowledge, there is no study in the literature where STL is used in sediment estimation. In this context, it is thought that the success to be achieved by using the STL technique in estimating sediment, which has a chaotic and nonlinear structure, will make a significant contribution to the solution of sediment-focused problems and therefore to both water resources management and sustainability clean environment applications.

MATERIALS AND METHODS

To make the methodology applied in this study easy and clear to follow, the workflow diagram given in Figure 1 was created. In addition, ArcGIS Pro (version 3.1.1) was used to create the location map shown in Figure 2, and Matlab (version 2022b) was used for statistical calculations. Python (version 3.10.9) and Spyder (version 5.4.1) scientific python development environments were preferred for the creation and decomposition of machine learning models. The NumPy (NumPy, 2008), pandas (Pandas, 2024), and sklearn (Pedregosa et al., 2011) libraries in Python were used.

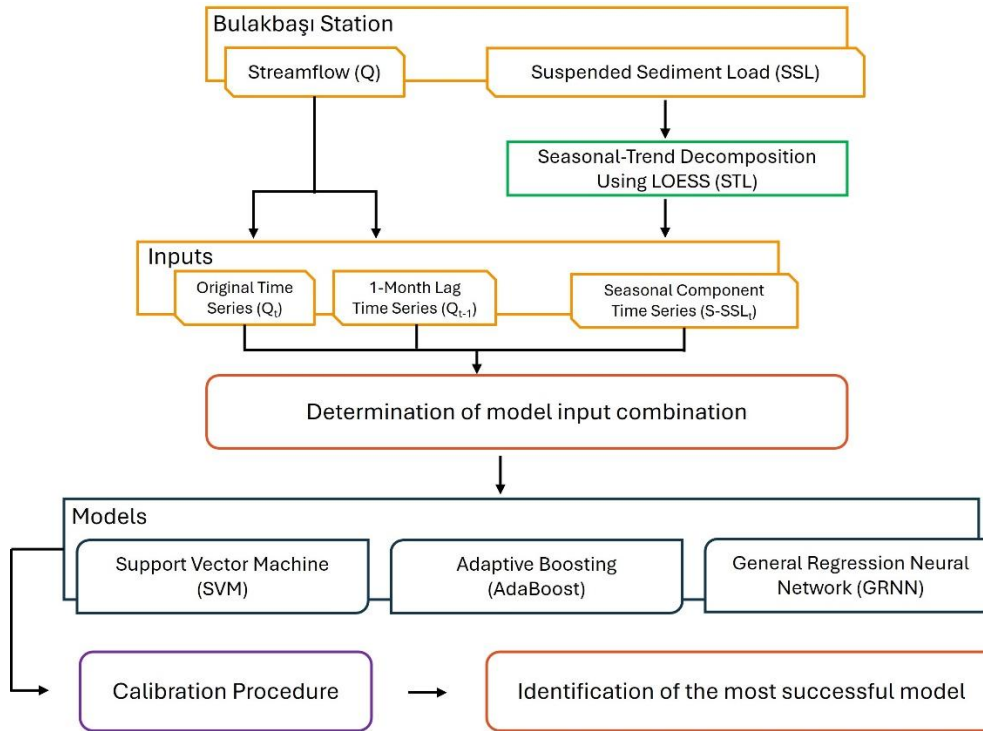


Figure 1. Workflow Diagram for This Study

Study Area and Data

Located in the central-northern part of Türkiye, the Kızılırmak Basin has a surface area of approximately 78000 km². The elevation of the basin reaches up to 3000 m. Continental climate prevails throughout the basin. However, it is observed that the average precipitation increases from south to north. While the average annual total precipitation is around 250 mm in the south of the basin, it increases to 900 mm towards the north. There are agricultural areas and perennial forests in the basin. In addition, the geological characteristics and morphology of the basin contain a tendency to cause erosion (Acar, 2019). Existing water resources and fertile lands cause intensive agricultural activities in the basin. The Kızılırmak River is important not only for agriculture but also for the socioeconomic, energy, and drinking water supply of the region. The headwaters of the Kızılırmak Basin and the drainage area of Bulakbaşı gauge (No: 1539) are located in the east of the basin. The location map of the Kızılırmak Basin and Bulakbaşı gauge is given in Figure 2. The altitude of the station is 1298 m. The drainage area is 1642 km². It has coordinates 39.87°N, 37.56°E. Bulakbaşı station is located in Canova village, Zara district of Sivas province. Although there are several surface water bodies near the measurement station, Lake Tödürge is the largest surface water body in the vicinity.

The main statistical characteristics of the streamflow and SSL data obtained from Bulakbaşı gauge are given in Table 1. In the study, measurements of SSL and the corresponding runoff, which were not made in equal temporal steps in the period 1973-2015, were used. The data used in the study were obtained from the General Directorate of State Hydraulic Works.

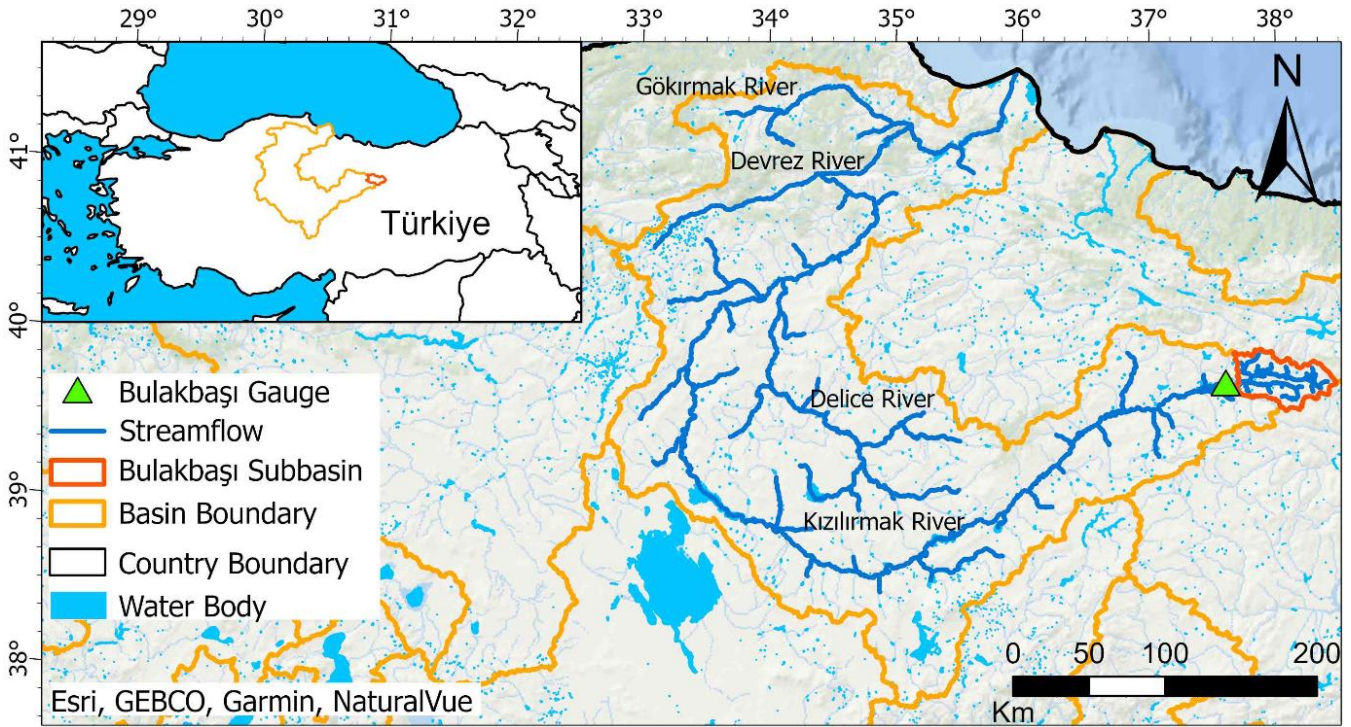


Figure 2. Location Map of Bulakbaşı Gauge and The Kızılırmak Basin

Table 1. Descriptive Statistics of The Data Used in The Study

	Min	Mean	Max	Standard Deviation (SD)	Skewness (C _s)	Kurtosis (C _k)
Q (m ³ /s)	0.36	15.93	119.60	24.61	2.72	10.78
SSL (ton/day)	0.51	1536.01	30138.23	4173.68	4.02	18.32

Support Vector Machine (SVM)

SVM, which is widely used in classification and regression problems, was introduced by Vapnik (1995). The application of SVM to classification and regression problems has some differences. Figure 3 shows an illustration of how SVM is applied to classification and regression problems.




Figure 2. Conceptual Illustration of SVM for Classification and Regression Problems

In this study, the regression adaptation of SVM is used. It can produce successful results in solving linear and nonlinear problems. Its working principles are based on structural risk minimization and statistical learning theory

(Koycegiz and Buyukyildiz, 2019). There are two versions of SVM used in regression problems, Nu (ν -SVR) and Epsilon (ϵ -SVR). ϵ -SVR was used in this study. ϵ -SVR has three parameters that have a significant impact on model success. These are the kernel function parameters (γ) which vary depending on the kernel function selected, the insensitive error term (ϵ), and the regularization factor (C). The Radial Basis Function (RBF) was chosen as the kernel function. The following objective function is used to apply SVM to nonlinear problems.

$$f(x) = \sum_{i=1}^N (\alpha_i - \alpha_i^*) K(x, z) + b_i \quad (1)$$

where $K(x, z)$ is the kernel function, $(\alpha_i - \alpha_i^*)$ is the Lagrange multipliers and b_i is the bias. The RBF kernel function chosen in this study is given below.

$$K(x, z) = \exp\left(\gamma \|x_i - x_j\|^2\right) \quad (2)$$

where γ is the kernel function parameter for RBF. For more detailed information on the theoretical background, please see references (Hamida et al., 2020; Miao et al., 2024; Misra et al., 2009).

Adaptive Boosting (AdaBoost)

The AdaBoost machine learning model is characterized as an ensemble model in which weak learners collaborate to produce a stronger learning framework. The AdaBoost algorithm proposed by Freund and Schapire (1995, 1996, 1997) is designed to be successfully applied to a variety of problems, in some cases weaker but from a fairly general perspective. AdaBoost achieves excellent outcomes in hydrological problem solving by effectively utilizing decision trees. It may be less susceptible to overfitting in certain of the problems it addresses. It's also a popular model among boosting algorithms (Zounemat-Kermani et al., 2021). Three parameters of the AdaBoost model significantly affect the model's success. Therefore, optimizing these parameters is vital for building a consistent model. These parameters are the number of estimators ($n_{\text{estimators}}$) learning rate (lr) and loss function type (Freund and Schapire, 1997). In this study, we tested 3 different loss function types: linear (ln), square (sq), and exponential (ex).

AdaBoost basically aims to create a strong prediction architecture with the help of error functions by weighting the predictions of weak learners. Accordingly, the following equation summarizes the general working principle of the AdaBoost algorithm.

$$f(x) = \sum_{i=1}^N \alpha_i \cdot h_i(x) \quad i = 1, 2, 3, \dots, N \quad (3)$$

$$\alpha_i = \frac{1}{2} \log\left(\frac{1-e_i}{e_i}\right) \quad (4)$$

$$\text{Linear Loss Function } L(y_o, y_M) = |y_o - y_M| \quad (5)$$

$$\text{Square Loss Function } L(y_o, y_M) = (y_o - y_M)^2 \quad (6)$$

$$\text{Exponential Loss Function } L(y_o, y_M) = e^{-y_o \cdot y_M} \quad (7)$$

where α_i , the weight of the weak learner, e_i , error rate of the weak learner and $h_i(x)$ represents the prediction of the weak learner. AdaBoost aims to minimize the objective function. In this equation, weights are determined according to loss functions. The objective function is updated so that the weight of the learner with more loss is less and the weight of the learner with less loss is more. Thus, a progressively stronger prediction model is obtained from weaker learners (Hastie et al., 2009).

Generalized Regression Neural Network (GRNN)

GRNN can be defined as a network architecture based on the artificial neural network model, which was introduced to produce more successful solutions to regression problems. In addition to regression, it is also used in prediction and classification problems. Due to its fast convergence, it can be used to analyze online dynamic systems. It is a variation of the Radial Basis Neural Network (RBNN) (Naghizadeh et al., 2024). It was first proposed by Specht

(1991). It requires little data to train. It can cope with noise in the inputs. It is optimized with few parameters, making it very useful. In GRNN, the spread parameter (n) is defined as a variable upon optimization. The outputs of the GRNN model are calculated with the help of the following equations. GRNN includes two additional layers: pattern and summation layers. The pattern layer realizes the nonlinear behavior of the model. Improvement is done by adding spread parameter (n) to this layer. The summation layer of GRNN contains two types of neurons. These are summation neurons (S) and single-division neurons (D). Thus, GRNN is a highly effective model that can converge quickly by establishing a strong relationship between input and output.

$$E_i^2 = (X - X_i)^T (X - X_i) \quad (8)$$

$$S = \sum_{i=1}^k y_i \exp\left(-\frac{E_i^2}{2n^2}\right) \quad (9)$$

$$D = \sum_{i=1}^k \exp\left(-\frac{E_i^2}{2n^2}\right) \quad (10)$$

$$Y(x) = \frac{S}{D} \quad (11)$$

where E is the Euclidean distance from X , k is the number of neurons, T is the matrix transpose operation, X is the input and Y is the output. For detailed information on the theoretical background of GRNN, see references (Cai et al., 2021; Cigizoglu, 2005; Naghizadeh et al., 2024).

Seasonal-Trend Decomposition Using LOESS (STL)

The method is a decomposition method commonly used in various sectors, particularly economics, meteorology, health, and marketing, to identify seasonal, trend, and residual components in time series. The foundations of the method were laid by Cleveland (1979). Afterward, it was gradually developed and reached the current version applied in this study (Cleveland et al., 1990; Cleveland and Devlin, 1988). STL's decomposition technique relies on local regression. The trend component is derived from the slopes of a region. It is particularly successful at detecting trends and seasonal regularity in nonlinear issues (Lafare, et al., 2016). In this study, only the seasonal component (S_t), which reflects the periodicity of the time series, was used to investigate its effect on the success of machine learning methods.

There are two different implementations of the STL method, additive and multiplicative. In this study, the additive method is used. The additive method is recommended as a highly effective method if no significant variations of the standard deviation are observed during the period under study (Yang and Li, 2023). The equation for the additive method is given below.

$$Y_t = S_t + T_t + R_t \quad (12)$$

where Y_t is the original time series of SSL, S_t is the seasonal component of SSL time series, T_t is the trend component of the original time series, and R_t is the residual component of the original time series.

Evaluation Metrics

Nash-Sutcliffe Efficiency (NSE) coefficient was used as the objective function to determine the optimum parameter set of the models. However, various performance metrics were applied to observe the model performance from different perspectives. The equations and references for these performance metrics can be found in Table 2. Here we denote the simulated SSL y_M , the observed SSL y_o , and the total number of data N . \bar{y}_m and \bar{y}_o represent the means of the simulated and observed SSL time series. Statistical metrics (minimum, mean, maximum, standard deviation, skewness, and kurtosis) were also used to evaluate model performance.

Table 2. Equations and References of The Performance Metrics Used in The Study

Performance Metric	Equation	Reference
Coefficient of Determination (R^2)	$\frac{[\sum_{i=1}^N (y_o - \bar{y}_o)(y_M - \bar{y}_M)]^2}{\sum_{i=1}^N (y_o - \bar{y}_o)^2 \sum_{i=1}^N (y_M - \bar{y}_M)^2}$	(Wright, 1921)
Nash–Sutcliffe Efficiency (NSE)	$1 - \frac{\sum_{i=1}^N (y_o - y_M)^2}{\sum_{i=1}^N (y_o - \bar{y}_o)^2}$	(Nash and Sutcliffe, 1970)
Root Mean Square Error (RMSE)	$\sqrt{\frac{\sum_{i=1}^N (y_o - y_M)^2}{N}}$	(Hodson, 2022)
Mean Absolute Error (MAE)	$\frac{\sum_{i=1}^N y_o - y_M }{N}$	(Hodson, 2022)

RESULTS

Model Structure and Calibration

In this study, different combinations of inputs are constructed using runoff (Q_t), runoff lag (Q_{t-1}), and the seasonal component of SSL ($S\text{-SSL}_t$). As a result, 6 models are obtained. The input-output combinations of the 6 models used in the study are presented in Table 3. The first three models include only the runoff time series, while the last three models include the seasonal component of the SSL. 70% of the time series were used for training and 30% for testing. Based on the general assumption that SSL data are log-normally distributed (Holtschlag, 2001), a logarithmic transformation was applied to the data.

Table 3. Input-output Structure of Models

Models	Input Parameters	Output
M1	Q_t	
M2	Q_{t-1}	
M3	Q_t, Q_{t-1}	
M4	$Q_t, S\text{-SSL}_t$	SSL_t
M5	$Q_{t-1}, S\text{-SSL}_t$	
M6	$Q_t, Q_{t-1}, S\text{-SSL}_t$	

The search space and the optimum parameter sets of the machine learning model parameters that significantly affect the model performance are given in Table 4. In this study, the Grid Search (GS) algorithm was used to determine the optimum parameter set in the search space of machine learning models. GS, which is widely used in model optimization, is effective in machine learning and produces solutions with low computational costs depending on the data set (James et al., 2021).

Performance of Models in Simulating Suspended Sediment Load

Training and testing performance metric statistics for 6 input combinations of AdaBoost, SVM, and GRNN models are given in Table 5. RMSE and MAE values given in Table 5 are for normalized data. High values in R^2 and NSE and low values in RMSE and MAE mean better prediction accuracy. Accordingly, the metric values of the most successful scenarios for each method are indicated in bold in Table 5.

Table 4. Optimal Parameters of Machine Learning Models

Models	Parameters	Search Space	Increment	M1	M2	M3	M4	M5	M6
AdaBoost	n_estimators	10-50	1	39	10	13	28	14	24
	Loss function	ln, sq, ex	-	ex	ex	ln	ex	ex	ln
	lr	0.01-0.5	0.01	0.08	0.29	0.39	0.24	0.02	0.37
SVM	C	1-100	1	99	1	40	93	1	69
	ϵ	0.01-5	0.01	0.04	0.01	0.02	0.03	0.04	0.03
	γ	0.1-8	0.1	0.20	0.10	7.70	0.50	8.0	0.70
GRNN	n	0.01-1	0.01	0.18	0.17	0.1	0.16	0.1	0.13

Table 5. Performance Metrics for 6 Input Combinations of AdaBoost, SVM, and GRNN Models

Method	Scenario	Train				Test				Performance Rating
		R ²	NSE	RMSE	MAE	R ²	NSE	RMSE	MAE	
AdaBoost	M1	0.895	0.895	0.865	0.675	0.854	0.747	1.153	0.953	Good
	M2	0.369	0.367	2.126	1.666	0.227	0.173	2.084	1.692	Unsatisfactory
	M3	0.901	0.900	0.846	0.658	0.842	0.746	1.154	0.946	Good
	M4	0.910	0.909	0.805	0.630	0.852	0.765	1.110	0.935	Very good
	M5	0.639	0.634	1.617	1.169	0.498	0.498	1.623	1.140	Unsatisfactory
	M6	0.915	0.914	0.783	0.625	0.846	0.765	1.112	0.936	Very good
SVM	M1	0.881	0.881	0.922	0.709	0.864	0.790	1.050	0.859	Very good
	M2	0.293	0.259	2.300	1.688	0.285	0.283	1.940	1.435	Unsatisfactory
	M3	0.900	0.900	0.845	0.629	0.873	0.820	0.973	0.766	Very good
	M4	0.897	0.896	0.859	0.634	0.875	0.831	0.942	0.762	Very good
	M5	0.618	0.612	1.665	1.050	0.569	0.558	1.523	0.996	Satisfactory
	M6	0.912	0.912	0.793	0.588	0.893	0.863	0.848	0.687	Very good
GRNN	M1	0.867	0.835	1.087	0.846	0.843	0.798	1.031	0.828	Very good
	M2	0.288	0.279	2.269	1.790	0.287	0.269	1.959	1.572	Unsatisfactory
	M3	0.883	0.880	0.927	0.711	0.836	0.793	1.043	0.837	Very good
	M4	0.886	0.873	0.954	0.729	0.850	0.834	0.934	0.741	Very good
	M5	0.673	0.667	1.542	1.066	0.556	0.552	1.534	1.079	Satisfactory
	M6	0.917	0.912	0.791	0.599	0.843	0.830	0.945	0.737	Very good

Accordingly, while the M6 combination produces the best results among the three models in the training period, this situation varies in the test period. In the training period, the R² and NSE metrics for the most successful combinations generally have values between 0.912 and 0.917. In SSL estimation, the error metrics (RMSE and MAE) in the most successful scenarios obtained in all three methods ranged between 0.588-0.793 for the training period. In general, it was decided which method is more successful in SSL prediction according to the NSE value with the highest value in the test period. In the test period, the best successful combinations are M4 for AdaBoost, M6 for SVM, and M4 for GRNN. However, it is seen from Table 5 that metric values very close to the M4 scenario are also obtained in the M6 scenario in AdaBoost and GRNN. While the R² and NSE values in the scenarios with the most successful estimation success for all three methods in the test period varied between 0.765 and 0.893, the error metrics varied

between 0.687 and 1.11. According to these findings, we can say that results with high prediction accuracy were obtained for all three models. However, when compared to the other models, the SVM-M6 model has the best simulation performance with $R^2=0.893$, $NSE=0.863$, $RMSE=0.848$, and $MAE=0.687$ values according to the test period. On the other hand, when the performance metrics are analyzed, it is observed that the first three models (M1, M2, and M3) without the seasonal component generally have lower performance compared to the last three models (M4, M5, and M6).

In AdaBoost models, in the M1 scenario where Q_t is used as input, the R^2 (NSE) values were obtained as 0.895 (0.895) and 0.854 (0.747) for the training and testing periods, respectively. On the other hand, in the M4 scenario where Q_t and the seasonal component of SSL (S-SSL_t) are used as input, these metrics were obtained as 0.910 (0.909) for the training period and 0.852 (0.765) for the testing period. Similarly, when comparing the M2 (Q_{t-1} and S-SSL_t) scenarios, it is observed that the inclusion of the seasonality component obtained with the SLT decomposition technique increases the forecast success according to the R^2 and NSE metrics for both the training and testing periods. According to Table 3, unlike M3, in the M6 scenario, Q_t is used as an input in S-SSL_t together with Q_{t-1} inputs, and increases in R^2 and NSE metrics are obtained in the M6 scenario compared to M3, where seasonality is not included. The fact that SSL prediction accuracy increases in the scenarios where S-SSL_t is included as input, i.e. in M4 compared to M1, in M5 compared to M2 and in M6 compared to M3, is also supported by the lower values obtained in RMSE and MAE metrics for AdaBoost models (Table 5). If a similar evaluation made for AdaBoost is made in the other two models, when the scenarios (M1-M4, M2-M5, and M3-M6) in which the seasonality effect is included and not included as input are compared with each other in both SVM and GRNN models, it is seen that the inclusion of S-SSL_t increases R^2 and NSE, while decreasing RMSE and MAE. This shows that the SLT data decomposition technique improves SSL prediction accuracy in all models used.

According to Moriasi et al. (2007), the performance ratings in the prediction models are "unsatisfactory" for $NSE \leq 0.5$, "satisfactory" for $0.5 < NSE \leq 0.65$, "good" for $0.65 < NSE \leq 0.75$, and "very good" for $0.75 < NSE \leq 1$, respectively. According to these criteria, the performance rates obtained in each scenario and each model for the test period are given in Table 5. The performance ratios given in Table 5 show that the degree of success increases in scenarios where the seasonal effect is used for some methods. In addition, the performance rates given for the test period show that all three methods used, namely AdaBoost, SVM, and GRNN, generally produced SSL predictions with high accuracy. The scenario where the lowest estimate was obtained in all three methods is the M2 scenario where Q_{t-1} with the "unsatisfactory" performance rating is used as input. The fact that M2 has the lowest performance among scenarios where S-SSL_t is not used as input and M5 has the lowest performance among scenarios where S-SSL_t is used as input shows that the input parameter Q_{t-1} used in both scenarios is the input with the lowest effect. It is observed that the observation and model statistics for the train and test periods given in Table 6 confirm the results obtained from the evaluation metrics in Table 5. In addition, according to the statistical features given in Table 6, it is seen that the model that gives the closest results to the observation data in the training and test periods is SVM-M6.

Table 6. Statistical Performance of The Most Successful Input Combination of Each Model

	Train				Test			
	Observation	AdaBoost-M4	SVM-M6	GRNN-M4	Observation	AdaBoost-M4	SVM-M6	GRNN-M4
Min	1.00	1.86	1.03	3.78	2.33	3.76	3.51	7.46
Mean	1520.30	1002.36	1323.93	696.58	1570.77	1080.97	1131.57	647.02
Max	30138.23	7630.59	35981.64	8653.96	23700.36	7510.14	14928.22	5009.62
SD	3914.69	1872.96	3590.83	1352.15	4695.79	2036.60	2662.98	1174.45
C_s	4.35	2.06	5.54	2.90	3.58	2.08	3.19	2.05
C_k	23.52	3.33	42.07	10.37	11.99	3.09	10.40	3.19

Comparison of the Most Successful Simulations

After examining the performance metrics, AdaBoost-M4, SVM-M6, and GRNN-M4 were found to be the most successful models. The time series and scatter diagrams of these models for the training and test phases are given in Figure 4 and Figure 5, respectively. Accordingly, it can be said that all models produce results consistent with the observations. However, there are minor differences. Compared to the observation data, GRNN-M4 is less successful

in capturing the peaks. Peak and dip timing of all models are quite consistent. SVM and AdaBoost were more successful in catching the peaks. For low SSL values, it was determined that SVM performed the most successful simulation, while GRNN showed overestimated performance. The models showed similar behavior in the training and testing phases. The models successfully simulated high SSL during periods of high flow and low SSL during periods of low flow.

To compare the observation and simulation time series, a Scatter diagram in Figure 5 shows the distributional comparison of the three most successful models. Accordingly, AdaBoost and SVM show similar behavior in the training phase. GRNN has a deviation in low data and a scatter in high data. However, in general, it can be said that consistent results are produced in all three models. In the test phase, no significant outliers were observed in all three models. This can be considered as another sign that all three models produce satisfactory results.




Figure 4. Time Series of The Most Successful Input Combination of The Three Models, SSL and Runoff (Q) Time Series

DISCUSSION

In this study, the prediction performance of machine learning-based algorithms for SSL obtained from the Bulakbaşı gauge in the Kızılırmak Basin is analyzed. In addition to algorithms such as SVM and GRNN, which produce consistent results in many different problems, AdaBoost, an ensemble model, was also used in the study. In addition, the STL method, in which the seasonal component is obtained in addition to the runoff lags, was also applied to determine the input combination. According to the findings, AdaBoost-M4, SVM-M6, and GRNN-M4 models produced quite consistent results. To the test statistics, the SVM-M6 model produced more successful results among these three models. However, the prediction performance of all three models is quite satisfactory. The use of the seasonality component ($S-SSL_t$) obtained with the STL technique increased the NSE performance between 2.4% and 5.2% in the M4 and M6 scenarios compared to the M1 and M3 scenarios where $S-SSL_t$ was not used, in general for the test period in all three models. According to Table 5, the prediction accuracy is at the level of “good” and “very good” according to the performance ratings given by Moriasi et al (2007) in the M1 and M3 scenarios with AdaBoost, SVM and GRNN models. Therefore, the STL technique provided lower improvement performance in scenarios where success was already high, such as in the M1 and M3 scenarios. However, in the M5 scenarios obtained by

adding the $S\text{-SSL}_t$ component to the M2 scenario where performance was low, model performances increased by 188% (2.9 times) for AdaBoost, 97% (2 times) for SVM and 105% (2 times) for GRNN compared to NSE in the test period. And overall, it increased the success from “unsatisfactory” to “satisfactory” level in all three models. These results show that the STL technique is especially effective in improving the performance of low-performing ML models.

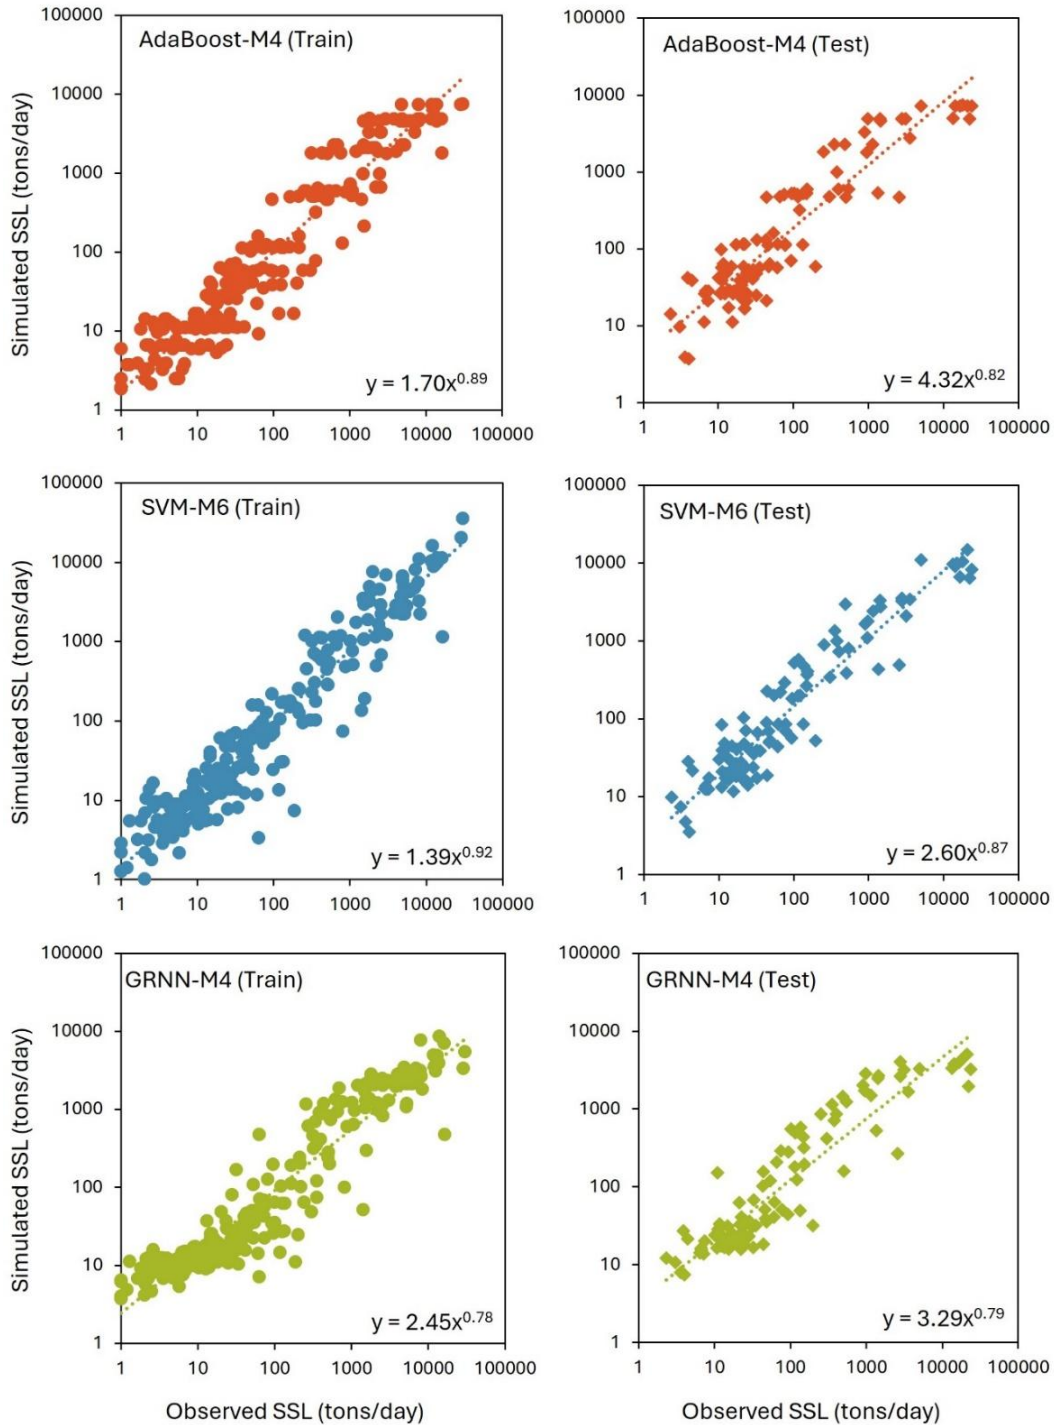


Figure 5. Scatter Plots of The Most Successful Input Combination of The Three Models

In the literature, studies are using various techniques on the prediction performance of SSL. Piraei et al. (2023) examined the prediction performance of sediment measurements of 93 rivers obtained from the United States Geological Survey (USGS) with various machine learning algorithms. According to the results obtained, the XGBoost model, which is an ensemble model among many algorithms including eXtreme Gradient Boosting

(XGBoost), Artificial Neural Networks (ANN), Gradient Boost Regressor (GBR) algorithms, showed the most successful prediction performance. Sharafati et al. (2020) simulated sediment transport in the Mississippi River with machine learning models. As a result, AdaBoost, GBR and random forest regression (RFR) models performed above 0.9 in R^2 and NSE statistics. There are also examples where different stand-alone and hybrid versions of SVM are used in sediment modeling studies (Samantaray and Sahoo, 2022; Samantaray et al., 2020). The test statistics obtained within the scope of the study also show consistency in terms of model performance.

Nourani et al. (2019) compared the performance of ANN, Wavelet-ANN (W-ANN), M5 Model Tree (M5), and Wavelet-M5 (W-M5) models in estimating daily and monthly SSL of Lighvanchai River in northwestern Iran and Upper Rio Grande river in western USA. The results showed that the performance of hybrid models (W-ANN and W-M5) was higher than the single models (ANN and M5) for both training and validation periods in predicting the SSL phenomenon. Applying the wavelet transform improved the performance of the ANN model for the Lighvanchai River by 13% and 62% on daily and monthly time scales, respectively, while it improved the performance of the M5 model by 10% and 30% (according to the NSE metric in validation period). For the SSL of the Upper Rio Grand River, WT-ANN models increased the prediction success by 58% and 2.56 times on daily and monthly scales, respectively, while WT-M5 models increased it by 19% on a daily scale and 23% on a monthly scale. For all models, the prediction successes were higher in Lighvanchai River than in the Upper Rio Grand River. In addition, the prediction successes obtained on a daily scale were also better than the monthly scale successes. In terms of overall performance, both single and hybrid M5 models showed higher success in SSL prediction in both rivers. Himanshu et al. (2017) used data obtained from measurement stations and satellite images for the estimation of daily SSL for the period 1998-2013 in two basins (Marol and Muneru) in South India. They applied single SVM and hybridized SVM with wavelet analysis (WASVM) methods in SSL estimation. The findings showed that the accuracy of WASVM in SSL prediction was higher than single SVM.

Sediment studies in the Kızılırmak River have focused on the measurement and monitoring of pollutants and heavy metals. However, some studies simulate sediment transport. Kisi et al. (2009) used adaptive neuro-fuzzy computational techniques for modeling at gauging stations on the Kızılırmak River. Neuro-fuzzy, artificial neural networks, and sediment rating curve models produced successful results, respectively. The consistent performance statistics obtained by Kisi et al. (2009) are in parallel with this study. Acar (2019) examined the prediction performances of ANN and wavelet transformed-ANN (WT-ANN) models at various stations in the Kızılırmak River. It was found that model prediction performance increased with wavelet transformation. The fact that the seasonal decomposition method increased the prediction performance in this study shows that various decomposition methods improve SSL model prediction performance. In addition, findings similar to the performance statistics obtained by Acar (2019) at Bulakbaşı station were obtained within the scope of this study. Acar (2019), who investigated the effect of WT on the prediction performance of the ML model for SSL prediction in various sections of the Kızılırmak Basin, found that the success increased significantly. Accordingly, a performance increase of 10-30% was observed at the examined stations.

Researchers have focused on some factors, basic difficulties, and limitations affecting the performance of models used in SSL estimation. Nourani et al. (2019) reported that both temporal scale and basin behavior are effective in the estimation performance of the models. It has been suggested that SSL, which is a complex hydrological phenomenon by nature, is affected not only by flow but also by several hydraulic, hydrographic, meteorological and basin structure-related complex factors such as evaporation, temperature, precipitation, precipitation intensity, basin topography, land use, soil properties (Himanshu et al., 2017; Pandey et al., 2016; Merritt et al., 2003). In addition to these factors affecting SSL, the processes of the models to be used (such as input variables, data availability, model efficiency, model capability, required hardware, and expert knowledge) also affect prediction success (Pandey et al., 2016). Due to the complex nonlinear structure of SSL, the necessity of a complete data screening procedure for reliable estimation has limitations attributed to the simplification of boundary conditions and important parameters in the model processes to be used in rivers or basins with dominant hydrological behavior (Shiri et al., 2022; Nourani et al., 2019).

Another limitation is that in the studies in the literature, researchers generally conducted their studies with a limited number of stations/rivers/basins in the ML applications they used in SSL estimation. This means that a generalization cannot be made regarding the use of ML successes obtained in the studies conducted in every basin, river, or station (Fang et al., 2022). The behavior of SSL depends on many natural factors mentioned above which vary spatially, as well as anthropogenic effects. Therefore, an ML method suitable for one region may not be suitable for another

region. In addition, the inadequacy of meteorological and hydrological data affecting SSL also limits the use of data-based ML methods, especially in ungauged basins.

One of the main limitations of our study is that SSL measurements are not available at equal time intervals and for long periods. In this case, machine learning-based algorithms have difficulty in discovering seasonal patterns. In addition, due to the long computation time, the search space was run in parameter spaces commonly used in the literature. Parameter optimization in a wider search space on computers with high computational power may affect the model prediction performance. In addition, conducting prediction studies at all stations along the Kızılırmak River may provide important information on SSL dynamics. In this case, the importance of data acquisition comes to the forefront again. Within the scope of this study, care has been taken to use the most reliable data period that is available.

CONCLUSION

In this study, many machine learning models were used to assess suspended sediment load. The data for this instance came from the Bulakbaşı station on the Kızılırmak River. The seasonal component of sediment, as well as runoff lags, were taken into account while determining input combinations. Sediment forecasting performance is evaluated using six different input combinations and three machine learning models, as well as several performance measures. Significant findings are included below.

- Among the various model and input combinations, SVM achieved the best prediction performance with input combinations including runoff series, 1-time step lag of runoff, and a seasonal component of sediment, while AdaBoost and GRNN achieved the best prediction performance with input combinations including runoff series and a seasonal component of sediment.
- All three models performed quite consistently in prediction. SVM was the most successful model among them.
- The seasonal component of sediment significantly improved the forecast performance in all models.
- Suspended sediment load is directly connected to flow. The suspended sediment load is considerable in measurements with high flow, whereas it is modest elsewhere.
- It was found that flow lag had a much lower impact on model performances than the flow and seasonal sediment components.

The main limitation of the study is that the sediment phenomenon is influenced by a wide variety of factors and model successes may change their behavior under different conditions. The station used in the study (Bulakbaşı) is quite important in terms of the basin in which it is located. However, spatial distribution should be investigated to deeply understand the sediment transport process of the basin. This is one of the limitations of the study. The limited frequency of measurements taken within the time period considered in the study limits the investigation of temporal variability. Increasing the frequency of measurements may allow the analysis of sediment transport before and after flood catastrophes.

It is hoped that this study, which is thought to be the first application of the STL data decomposition technique in sediment estimation, will contribute to the relevant literature, guide private and legal practitioners, and help the use of accurate and appropriate techniques for SSL estimation, which is a challenging hydrological phenomenon. Additionally, we hope that such studies will be useful in river basins where there is little or no adequate information about the hydrological processes occurring.

In future studies, it is planned to test the performance of the STL data decomposition technique by hybridizing it with different learning models (metaheuristic, ensemble, etc.) and comparing it with hybridized models with different data decomposition tools, to examine it in basins with different characteristics and at different time scales, to investigate its effectiveness in study areas where human impacts and climate change effects are intense, and to test its usability in estimating various hydro-meteorological parameters in addition to sediment, and it is recommended to researchers.

Acknowledgments

The authors would like to thank the General Directorate of State Hydraulic Works for the data used in this study.

REFERENCES

- Acar, A. A. (2019). Kızılırmak havzasında yapay zekâ metotları kullanarak sediment taşınımının tahmini. Yüksek Lisans Tezi. Konya Teknik Üniversitesi Lisansüstü Eğitim Enstitüsü İnşaat Mühendisliği Anabilim Dalı, Konya 89s.
- Acar, R., & Saplıoğlu, K. (2022). Etkili girdi parametrelerinin çoklu regresyon ile belirlendiği su sertliğinin anfis yöntemi ile tahmin edilmesi. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 22(6), 1413-1424. <https://doi.org/10.35414/akufemubid.1147492>
- Adnan, R. M., Liang, Z., El-Shafie, A., Zounemat-Kermani, M., & Kisi, O. (2019). Prediction of Suspended Sediment Load Using Data-Driven Models. *Water*, 11(10), 2060. <https://doi.org/10.3390/w11102060>
- Aghelpour, P., Graf, R., & Tomaszewski, E. (2023). Coupling ANFIS with ant colony optimization (ACO) algorithm for 1-, 2-, and 3-days ahead forecasting of daily streamflow, a case study in Poland. *Environmental Science and Pollution Research*, 30(19), 56440-56463. <https://doi.org/10.1007/s11356-023-26239-3>
- AlDahoul, N., Essam, Y., Kumar, P., Ahmed, A. N., Sherif, M., Sefelnasr, A., & Elshafie, A. (2021). Suspended sediment load prediction using long short-term memory neural network. *Scientific Reports*, 11(1), 7826. <https://doi.org/10.1038/s41598-021-87415-4>
- Asadi, M., Fathzadeh, A., Kerry, R., Ebrahimi-Khusfi, Z., & Taghizadeh-Mehrjardi, R. (2021). Prediction of river suspended sediment load using machine learning models and geo-morphometric parameters. *Arabian Journal of Geosciences*, 14(18), 1–14. <https://doi.org/10.1007/s12517-021-07922-6>
- Buyukyildiz, M., & Kumcu, S. Y. (2017). An Estimation of the Suspended Sediment Load Using Adaptive Network Based Fuzzy Inference System, Support Vector Machine and Artificial Neural Network Models. *Water Resources Management*, 31(4), 1343–1359. <https://doi.org/10.1007/s11269-017-1581-1>
- Cai, Q. C., Hsu, T. H., & Lin, J. Y. (2021). Using the General Regression Neural Network Method to Calibrate the Parameters of a Sub-Catchment. *Water*, 13(8), 1089. <https://doi.org/10.3390/w13081089>
- Cigizoglu, H. K. (2005). Application of Generalized Regression Neural Networks to Intermittent Flow Forecasting and Estimation. *Journal of Hydrologic Engineering*, 10(4), 336–341. [https://doi.org/10.1061/\(ASCE\)1084-0699\(2005\)10:4\(336](https://doi.org/10.1061/(ASCE)1084-0699(2005)10:4(336)
- Cleveland, R., Cleveland, W., McRae, J., & Terpenning, I. (1990). STL: A seasonal-trend decomposition procedure based on Loess. *Journal of Official Statistics*, 6(1), 3–73.
- Cleveland, W. S. (1979). Robust locally weighted regression and smoothing scatterplots. *Journal of the American Statistical Association*, 74(368), 829–836. <https://doi.org/10.1080/01621459.1979.10481038>
- Cleveland, W. S., & Devlin, S. J. (1988). Locally weighted regression: An approach to regression analysis by local fitting. *Journal of the American Statistical Association*, 83(403), 596–610. <https://doi.org/10.1080/01621459.1988.10478639>
- Fang, K., Kifer, D., Lawson, K., Feng, D., & Shen, C. (2022). The data synergy effects of time-series deep learning models in hydrology. *Water Resources Research*, 58(4), e2021WR029583. <https://doi.org/10.1029/2021WR029583>
- Freund, Y., & Schapire, R. E. (1995). A decision-theoretic generalization of on-line learning and an application to boosting. In *European Conference on Computational Learning Theory* (Vol. 904, pp. 23–37). Springer, Berlin, Heidelberg.
- Freund, Y., & Schapire, R. E. (1996). Experiments with a New Boosting Algorithm. In *icml*. 96, 148-156.
- Freund, Y., & Schapire, R. E. (1997). A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting. *Journal of Computer and System Sciences*, 55(1), 119–139. <https://doi.org/10.1006/jcss.1997.1504>
- Ghasempour, R., Roushangar, K., & Sihag, P. (2021). Suspended sediment load prediction in consecutive stations of river based on ensemble pre-post-processing kernel based approaches. *Water Supply*, 21(7), 3370–3386. <https://doi.org/10.2166/ws.2021.094>
- Gupta, D., Hazarika, B. B., Berlin, M., Sharma, U. M., & Mishra, K. (2021). Artificial intelligence for suspended sediment load prediction: a review. *Environmental Earth Sciences*, 80(9), 1–39. <https://doi.org/10.1007/s12665-021-09625-3>

- Hamida, S., Gannour, O. E., Cherradi, B., Ouajji, H., & Raihani, A. (2020). Optimization of Machine Learning Algorithms Hyper-Parameters for Improving the Prediction of Patients Infected with COVID-19. *IEEE 2nd International Conference on Electronics, Control, Optimization and Computer Science (ICECOCS)*, Kenitra, Morocco, 1-6.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, Second Edition. Springer New York, NY.
- Himanshu, S. K., Pandey, A., & Yadav, B. (2017). Assessing the applicability of TMPA-3B42V7 precipitation dataset in wavelet-support vector machine approach for suspended sediment load prediction. *Journal of Hydrology*, 550, 103-117. <https://doi.org/10.1016/j.jhydrol.2017.04.051>
- Hodson, T. O. (2022). Root-mean-square error (RMSE) or mean absolute error (MAE): when to use them or not. *Geoscientific Model Development*, 15(14), 5481–5487. <https://doi.org/10.5194/gmd-15-5481-2022>
- Holtschlag, D. J. (2001). Optimal estimation of suspended-sediment concentrations in streams. *Hydrological processes*, 15(7), 1133-1155. <https://doi.org/10.1002/hyp.207>
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2021). *An Introduction to Statistical Learning*. Springer.
- Katipoğlu, O. M., Kartal, V., & Pande, C. B. (2024). Sediment load forecasting from a biomimetic optimization perspective: Firefly and Artificial Bee Colony algorithms empowered neural network modeling in Çoruh River. *Stochastic Environmental Research and Risk Assessment*, 38, 3907–3927. <https://doi.org/10.1007/s00477-024-02785-1>
- Kilinc, H. C., & Yurtsever, A. (2022). Short-term streamflow forecasting using hybrid deep learning model based on grey wolf algorithm for hydrological time series. *Sustainability*, 14(6), 3352. <https://doi.org/10.3390/su14063352>
- Kisi, O., Haktanir, T., Ardiclioglu, M., Ozturk, O., Yalcin, E., & Uludag, S. (2009). Adaptive neuro-fuzzy computing technique for suspended sediment estimation. *Advances in Engineering Software*, 40(6), 438–444. <https://doi.org/10.1016/j.advengsoft.2008.06.004>
- Kisi, O., & Yaseen, Z. M. (2019). The potential of hybrid evolutionary fuzzy intelligence model for suspended sediment concentration prediction. *Catena*, 174, 11-23. <https://doi.org/10.1016/j.catena.2018.10.047>
- Koycegiz, C., & Buyukyildiz, M. (2019). Calibration of SWAT and two data-driven models for a data-scarce mountainous headwater in Semi-Arid Konya Closed Basin. *Water*, 11(1), 147. <https://doi.org/10.3390/w11010147>
- Koycegiz, C., Buyukyildiz, M., & Kumcu, S. Y. (2021). Spatio-temporal analysis of sediment yield with a physically based model for a data-scarce headwater in Konya Closed Basin, Turkey. *Water Supply*, 21 (4): 1752–1763. <https://doi.org/10.2166/ws.2021.016>
- Lafare, A. E. A., Peach, D. W., & Hughes, A. G. (2016). Use of seasonal trend decomposition to understand groundwater behaviour in the Permo-Triassic Sandstone aquifer, Eden Valley, UK. *Hydrogeology Journal*, 24(1), 141–158. <https://doi.org/10.1007/s10040-015-1309-3>
- Merritt, W. S., Letcher, R. A., & Jakeman, A. J. (2003). A review of erosion and sediment transport models. *Environmental modelling & software*, 18(8-9), 761-799. [https://doi.org/10.1016/S1364-8152\(03\)00078-1](https://doi.org/10.1016/S1364-8152(03)00078-1)
- Miao, J., Zhang, X., Zhang, G., Wei, T., Zhao, Y., Ma, W., Chen, Y., Li, Y., & Wang, Y. (2024). Applications and interpretations of different machine learning models in runoff and sediment discharge simulations. *Catena*, 238, 107848. <https://doi.org/10.1016/j.catena.2024.107848>
- Misra, D., Oommen, T., Agarwal, A., Mishra, S. K., & Thompson, A. M. (2009). Application and analysis of support vector machine based simulation for runoff and sediment yield. *Biosystems Engineering*, 103(4), 527–535. <https://doi.org/10.1016/j.biosystemseng.2009.04.017>
- Mohammadi, B., Guan, Y., Moazenzadeh, R., & Safari, M. J. S. (2021). Implementation of hybrid particle swarm optimization-differential evolution algorithms coupled with multi-layer perceptron for suspended sediment load estimation. *Catena*, 198, 105024. <https://doi.org/10.1016/j.catena.2020.105024>
- Moriasi D. N., Arnold J. G., Van Liew M. W., Bingner R. L., Harmel R. D. & Veith T. L. (2007). Model evaluation guidelines for systematic quantification of accuracy in watershed simulations, *Transactions of the ASABE*, 50 (3), 885–900. <https://doi.org/10.13031/2013.23153>

- Naghizadeh, A., Amiri-Ramsheh, B., Atashrouz, S., Abuswer, M. A., Abedi, A., Mohaddespour, A., & Hemmati-Sarapardeh, A. (2024). Modeling thermal conductivity of hydrogen-based binary gaseous mixtures using generalized regression neural network. *International Journal of Hydrogen Energy*, 59, 242-250. <https://doi.org/10.1016/j.ijhydene.2024.01.216>
- Nash, J. E., & Sutcliffe, J. V. (1970). River flow forecasting through conceptual models part I — A discussion of principles. *Journal of Hydrology*, 10(3), 282–290. [https://doi.org/10.1016/0022-1694\(70\)90255-6](https://doi.org/10.1016/0022-1694(70)90255-6)
- Noori, N., Kalin, L., 2016. Coupling SWAT and ANN models for enhanced daily streamflow prediction. *Journal of Hydrology*, 533, 141-151. <https://doi.org/10.1016/j.jhydrol.2015.11.050>
- Nourani, V., Molajou, A., Tajbakhsh, A. D., & Najafi, H. (2019). A wavelet based data mining technique for suspended sediment load modeling. *Water Resources Management*, 33, 1769-1784. <https://doi.org/10.1007/s11269-019-02216-9>
- NumPy. (2008). <https://numpy.org/doc/2.1/> Accessed 15.04.2024.
- Onüçyıldız, M., Bostancı, İ., & Yazar, A. (2014). Konya Altınapa Baraj Gölündeki Sedimentasyon Kaynaklı Kapasite Kaybının Coğrafi Bilgi Sistemleri Kullanılarak Hesaplanması. *Selçuk Üniversitesi Sosyal ve Teknik Araştırmalar Dergisi*, (7), 12-26.
- Özger, M., & Kabataş, M. B. (2015). Sediment load prediction by combined fuzzy logic-wavelet method. *Journal of Hydroinformatics*, 17(6), 930–942. <https://doi.org/10.2166/hydro.2015.148>
- Pandas. (2024). <https://pandas.pydata.org/docs/> Accessed 21.04.2024.
- Pandey, A., Himanshu, S. K., Mishra, S. K., & Singh, V. P. (2016). Physically based soil erosion and sediment yield models revisited. *Catena*, 147, 595-620. <https://doi.org/10.1016/j.catena.2016.08.002>
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M. & Duchesnay, E. (2011). Scikit-learn: Machine Learning in Python. *Journal of Machine Learning Research*, 12, 2825-2830.
- Piraei, R., Afzali, S. H., & Niazkar, M. (2023). Assessment of XGBoost to Estimate Total Sediment Loads in Rivers. *Water Resources Management*, 37(13), 5289–5306. <https://doi.org/10.1007/s11269-023-03606-w>
- Samantaray, S., & Sahoo, A. (2022). Prediction of suspended sediment concentration using hybrid SVM-WOA approaches. *Geocarto International*, 37(19), 5609–5635. <https://doi.org/10.1080/10106049.2021.1920638>
- Samantaray, S., Sahoo, A., & Ghose, D. K. (2020). Assessment of Sediment Load Concentration Using SVM, SVM-FFA and PSR-SVM-FFA in Arid Watershed, India: A Case Study. *KSCE Journal of Civil Engineering*, 24(6), 1944–1957. <https://doi.org/10.1007/s12205-020-1889-x>
- Samantaray, S., Sahoo, A., Satapathy, D. P., Oudah, A. Y., & Yaseen, Z. M. (2024). Suspended sediment load prediction using sparrow search algorithm-based support vector machine model. *Scientific Reports*, 14 (1), 12889. <https://doi.org/10.1038/s41598-024-63490-1>
- Sales, A. K., Gul, E., Safari, M. J. S., Ghodrat Gharehbagh, H., & Vaheddoost, B. (2021). Urmia lake water depth modeling using extreme learning machine-improved grey wolf optimizer hybrid algorithm. *Theoretical and Applied Climatology*, 146(1), 833-849. <https://doi.org/10.1007/s00704-021-03771-1>
- Saplıoğlu, K., & Acar, R. (2020). K-means kümeleme algoritması kullanılarak oluşturulan yapay zeka modelleri ile sediment taşımının tespiti. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(1), 306-322. <https://doi.org/10.17798/bitlisfen.558113>
- Shaqiri, F. (2024). Applications of Time Series Forecasting Models, Decomposition Methods, Non-parametric Regression Methods, and Artificial Neural Networks. Fraunhofer Verlag.
- Sharafati, A., Haji Seyed Asadollah, S. B., Motta, D., & Yaseen, Z. M. (2020). Application of newly developed ensemble machine learning models for daily suspended sediment load prediction and related uncertainty analysis. *Hydrological Sciences Journal*, 65, 2022–2042. <https://doi.org/10.1080/02626667.2020.1786571>
- Shiri, N., Shiri, J., Nourani, V., & Karimi, S. (2022). Coupling wavelet transform with multivariate adaptive regression spline for simulating suspended sediment load: independent testing approach. *ISH Journal of Hydraulic Engineering*, 28(sup1), 356-365. <https://doi.org/10.1080/09715010.2020.1801528>

- Specht, D. F. (1991). A General Regression Neural Network. *IEEE Transactions on Neural Networks*, 2(6), 568–576.
- Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*. Springer New York.
- Wright, S. (1921). Correlation and causation. *Journal of Agricultural Research*, 20(7), 557–585.
- Xie, B., Bao, R., Yin, D., Zhu, L., Hu, R., Cai, W., Liu, T., Lin., C., & Lu, P. (2022). The spatio-temporal distribution and transport of suspended sediment in Laizhou Bay: Insights from hydrological and sedimentological investigations. *Frontiers in Earth Science*, 10, 994258. <https://doi.org/10.3389/feart.2022.994258>
- Yang, H., & Li, W. (2023). Data decomposition, seasonal adjustment method and machine learning combined for runoff prediction: A case study. *Water Resources Management*, 37(1), 557-581. <https://doi.org/10.1007/s11269-022-03389-6>
- Yılmaz, V. (2022). The use of band similarity in urban water demand forecasting as a new method. *Water Supply*, 22(1), 1004-1019. <https://doi.org/10.2166/ws.2021.221>
- Yılmaz, V. (2023). Farklı performans metriklerinin buharlaşma modellenmesi üzerindeki etkisinin incelenmesi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(2), 472-486. <https://doi.org/10.28948/ngumuh.1206278>
- Yılmaz, V., & Alpars, M. (2023). An Investigation of the Temporal Interaction of Urban Water Consumption in the Framework of Settlement Characteristics. *Water Resources Management*, 37(4), 1619-1639. <https://doi.org/10.1007/s11269-023-03447-7>
- Yılmaz, V., Koycegiz, C., & Buyukyildiz, M. (2024a). Performance of data-driven models based on seasonal-trend decomposition for streamflow forecasting in different climate regions of Türkiye. *Physics and Chemistry of the Earth, Parts A/B/C*, 136, 103696. <https://doi.org/10.1016/j.pce.2024.103696>
- Yılmaz, V., Koycegiz, C., & Buyukyildiz, M. (2024b). An approach on the estimation and temporal interaction of runoff: the band similarity method. *Journal of Water and Climate Change*, 15 (9): 4775–4789. <https://doi.org/10.2166/wcc.2024.420>
- Yin, Y., Xia, R., Liu, X., Chen, Y., Song, J., & Dou, J. (2024). Spatial response of water level and quality shows more significant heterogeneity during dry seasons in large river-connected lakes. *Scientific Reports*, 14(1), 8373. <https://doi.org/10.1038/s41598-024-59129-w>
- Yuan, Z., Gao, S., Wang, Y., Li, J., Hou, C., & Guo, L. (2023). Prediction of PM2.5 time series by seasonal trend decomposition-based dendritic neuron model. *Neural Computing and Applications*, 35(21), 15397-15413. <https://doi.org/10.1007/s00521-023-08513-0>
- Zhang, S., Wu, J., Jia, Y., Wang, Y. G., Zhang, Y., & Duan, Q. (2021). A temporal LASSO regression model for the emergency forecasting of the suspended sediment concentrations in coastal oceans: Accuracy and interpretability. *Engineering Applications of Artificial Intelligence*, 100, 104206. <https://doi.org/10.1016/j.engappai.2021.104206>
- Zhou, T., Wang, F., Yang, Z., 2017. Comparative Analysis of ANN and SVM Models Combined with Wavelet Preprocess for Groundwater Depth Prediction. *Water*, 9 (10), 781. <https://doi.org/10.3390/w9100781>
- Zounemat-Kermani, M., Batelaan, O., Fadaee, M., & Hinkelmann, R. (2021). Ensemble machine learning paradigms in hydrology: A review. *Journal of Hydrology*, 598, 126266. <https://doi.org/10.1016/j.jhydrol.2021.126266>



Kahramanmaraş Sutcu Imam University

Journal of Engineering Sciences



Geliş Tarihi : 27.06.2024
Kabul Tarihi : 29.01.2025

Received Date : 27.06.2024
Accepted Date : 29.01.2025

DETERMINATION OF PHYSICAL, MECHANICAL, THERMAL PROPERTIES OF READY THERMAL INSULATION PLASTERS

HAZIR ISI YALITIM SIVALARININ FİZİKSEL, MEKANİK, ISI ÖZELLİKLERİNİN BELİRLENMESİ

*Şemsettin KILINÇARSLAN*¹ (ORCID: 0000-0001-8253-9357)

*Metin DAVRAZ*² (ORCID: 0000-0002-6069-7802)

Yasemin ŞİMŞEK TÜRKER^{1*} (ORCID: 0000-0002-3080-0215)

*Mehmet Ali AKBULUT*¹ (0009-0007-0635-4618)

¹Suleyman Demirel University, Faculty of Engineering and Natural Sciences, Department of Civil Engineering, Isparta, Türkiye

² Isparta University of Applied Sciences, Technology Faculty, Civil Engineering Department, Isparta, Turkey

*Sorumlu Yazar / Corresponding Author: Yasemin ŞİMŞEK TÜRKER, yaseminturker@sdu.edu.tr

ABSTRACT

Thermal insulation in buildings is of fundamental importance in reducing energy consumption and ensuring environmental sustainability. This practice, which increases energy efficiency by minimizing heat transfer, both limits fossil fuel consumption and reduces greenhouse gas emissions. In addition, it improves thermal comfort conditions in interior spaces, increasing the quality of life and providing long-term economic savings. In this study, the compliance of some properties of thermal insulation mortars produced in our country, especially thermal conductivity coefficient and compressive strength, with the criteria were evaluated. Mortar samples were produced with five different plasters from different manufacturers. Fresh and hardened samples were tested, and their values were obtained. When the compressive strength values are examined, the highest compressive strength value belongs to product E. The lowest compressive strength value belongs to the insulating plaster samples of product C. When the heat resistance values that class T plasters should have are taken into consideration, it has been determined that the D, A, and F insulating plasters meet the CS I criterion, while the E and B insulating plasters meet the CS II criterion. When the thermal conductivity coefficient values are examined, the highest value belongs to the insulating plaster samples of product B. The lowest heat insulation value belongs to the insulating plaster samples of product C. When the thermal conductivity coefficient values that class T plasters should have been taken into consideration, it has been determined that the A, C, and D insulating plasters meet this criterion. As a result, it was seen that a significant part of the insulation plasters did not meet the values declared by the manufacturers.

Keywords: Thermal insulation plaster, thermal properties, mechanical properties

ÖZET

Yapılarda ısı yalıtımı, enerji tüketiminin azaltılması ve çevresel sürdürülebilirliğin sağlanması açısından temel bir öneme sahiptir. Isı transferini minimize ederek enerji verimliliğini artıran bu uygulama, hem fosil yakıt tüketimini sınırlamakta hem de sera gazı emisyonlarını azaltmaktadır. Bunun yanı sıra, iç mekânlarda termal konfor koşullarını iyileştirerek yaşam kalitesini artırmakta ve uzun vadeli ekonomik tasarruf sağlamaktadır. Bu çalışmada, ülkemizde üretilen ısı yalıtım harçlarının, ısı iletkenlik katsayısı ve basınç dayanımı başta olmak üzere bazı özelliklerinin kriterlere uygunluğu değerlendirilmiştir. Harç numuneleri farklı üreticilere ait 5 farklı sıva ile üretilmiştir. Numunelerin taze ve sertleşmiş haldeki deneyleri yapılmış ve değerleri elde edilmiştir. Basınç dayanımı değerleri incelendiğinde en yüksek basınç dayanımı değeri E firmasının yalıtım sıvası numunelerine aittir. En düşük basınç dayanımı değeri ise C firmasının yalıtım sıvası numunelerine aittir. T sınıfı sıvaların sahip olması gereken ısı

ToCite: KILINÇARSLAN, Ş., DAVRAZ, M., ŞİMŞEK TÜRKER, Y., & AKBULUT, M.A. (2025). DETERMINATION OF PHYSICAL, MECHANICAL, THERMAL PROPERTIES OF READY THERMAL INSULATION PLASTERS. Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences, 28(1), 19-29.

dayanımı değerleri dikkate alındığında, D, A ve F yalıtım sıvalarının CS I kriterini, E ve B yalıtım sıvalarının ise CS II kriterini sağladığı tespit edilmiştir. Isıl iletkenlik katsayısı değerleri incelendiğinde en yüksek değer B firmasının yalıtım sıvası numunelerine aittir. En düşük ısı yalıtım değeri ise C firmasının yalıtım sıvası numunelerine aittir. T sınıfı sıvaların sahip olması gereken ısıl iletkenlik katsayısı değerleri dikkate alındığında, A, C ve D yalıtım sıvalarının bu kriteri sağladığı tespit edilmiştir. Sonuç olarak, yalıtım sıvalarının önemli bir kısmının firmanın beyan ettiği değerleri karşılamadığı görülmüştür.

Anahtar Kelimeler: Isı yalıtım sıvası, ısıl özellikler, mekanik özellikler

INTRODUCTION

The ability of the outer shell of the building to prevent moisture and water from the atmosphere, that is, its ability to release water, is extremely important for the safety and long-term usability of the building. One of the oldest known solutions in this regard is the plastering of building walls (Nascimento et al., 2020; Faria et al., 2016; Balovic et al., 2016). Plaster is a mortar-based continuous coating applied at a certain thickness to the interior and exterior wall surfaces and ceilings of the building. The use of unsuitable materials, such as plaster in buildings causes the expected efficiency to decrease, the building weight and heat losses to increase, and therefore the expected savings in energy costs cannot be achieved (Santos et al., 2019; Xu et al., 2022; Yi et al., 2023). The most important factor in fully meeting these features expected from plaster is the complexity value of the plaster mortar (Molnar & Manea, 2016; Mutouskova et al., 2021). Certainly, a plaster mortar with a high complexity will also provide strength and durability properties. In addition, if the plaster is used for various purposes such as adherence, easy workability, strength and impermeability, and obtaining decorative surfaces depending on the place where it will be applied in the structure, it is envisaged that the binder within the plaster will be selected to provide these properties (Çolakoğlu, 2004). Studies to increase awareness of water and heat insulation It is gaining momentum due to factors such as the adaptation of regulations and standards to current conditions and the implementation of finalized regulations within the sector (İzoder, 2002; Altuncı and Ocal, 2021; Yetkin et al., 2024). Çolakoğlu (2004) investigated the feasibility of making a plaster with thermal insulation properties using pumice and limestone. It was stated that the plaster sample complies with the TS 6433 standard. Davraz & Kılınçarslan (2014) aimed to develop a perlite aggregate plaster material that provides high-performance thermal insulation, has sufficient pressure and flexural strength, has low water absorption rate and capillarity, and is resistant to environmental effects such as freezing and thawing effects. They stated that since heat loss in buildings will be greatly reduced by perlite-added plaster produced by the standards, energy savings will be achieved by using our resources, and the economy of our country, which imports most of its energy, will be positively affected. Dilmaç & Kesen (2003) stated the importance of the heat permeability coefficient U-value of building elements (such as walls, windows, roofs) and especially transparent surfaces in the annual energy consumption of buildings. Dylewski et al. (2014) investigated whether it is beneficial to use thermally insulated pumice granules or EPS plaster instead of cement plaster on the exterior walls of a building. They determined that there was an improvement in the thermal insulation properties of pumice granule and EPS plastered walls, and as a result, savings in energy consumption were achieved. It has been claimed that this effect occurs in 2-5 years for pumice and EPS plaster, depending on the heat source, while this period exceeds 30 years for cement plaster. Barbero et al. (2014) made a general analysis of thermal insulation plasters in the European market, comparing existing products according to technical and economic features. The main aim of the research is to direct research in the field of thermal insulation plaster towards innovative applications and to create new plasters that can meet the demands of the real market and end users. It is explained that the three main factors defined according to European standards are the dry bulk mass of the mixture, the dry unit volume mass of the hardened plaster, and the thermal conductivity. Zach et al. (2013) explained the research results on the development of silica-based ultra-light thermal insulation plasters. It has been stated that the developed materials have a significant potential for use in the field of thermal insulation in buildings due to their high open porosity and low unit volume weight. In practice, the basic requirements of these materials are explained as dry conductivity λ_{10} , dry ≤ 0.08 W/mK, and minimum compressive strength $f_c \geq 0.5$ N/mm². Davraz et al. (2011) conducted a study on lightweight aggregate foam plaster. In the study, three different pumice and expanded perlite were used as lightweight aggregates. In foam plaster samples, dry unit volume mass varies between 338-487 kg/m³, compressive strength 0.64-2.34 MPa, flexural strength 0.070-0.11 MPa, capillary water absorption coefficient 0.62-1.82 kg/m².min and thermal conductivity coefficient 0.068-0.088 W/mK.

To reduce heat loss and prevent condensation, it is possible to completely insulate all kinds of elements such as columns, beams, and beams, which are located on the exterior of the building and act as thermal bridges, by applying

thermal insulation from the outside, based on the principle of continuity of insulation (Dylewski & Adamczyk, 2011; Papadopoulos & Giama, 2007; Manohar, 2012). However, since the structure is enclosed in a sheath, it is protected against external climatic conditions, preventing strong temperature changes and unwanted internal stresses, cracks, and structural damage in the main material that forms the wall. The external thermal insulation system helps keep the indoor temperature balanced in summer and winter by providing the structure with the ability to store sufficient heat. Additionally, the risk of condensation that may occur on the building envelope is minimized (Pasztory, 2021; Çomaklı & Yüksel, 2004; Tychanicz-Kwiecien et al., 2019).

When choosing the materials used for thermal insulation, attention is paid to whether they fulfill certain properties depending on where they are used (Papadopoulos, 2005; Bektaş et al., 2017; Davraz et al., 2020). While it is important that insulation materials are light and do not crumble against external impacts, it is also desirable that they be resistant to moisture and have a low coefficient of vapor permeability when working in humid environments (Al-Homoud, 2005; Davraz et al., 2011; Davraz et al., 2015). According to different usage areas, the specific volume of thermal insulation materials, low drying shrinkage, workability, ease of workmanship, deformation resistance against compression and tensile stress, chemical neutrality, resistance to decay and crumbling, thermal insulation function at continuous, periodic, or short-term temperatures. The selection is made by taking into account the relevant factors such as not changing the material, being suitable for the element to be applied, having high fire resistance and low thermal conductivity coefficient (Villasmil et al., 2019; Abu-Jdayil et al., 2019; Zach et al., 2013).

Plaster has functional functions other than aesthetics in the building. The most important function of the plaster is to maintain the relative humidity at the comfort level in the interior and reduce heat loss or to reduce the heat loss/gain ratio. Plaster is also a major factor in sound insulation and fire prevention. However, plaster is divided into types according to its usage area in the building, its structure, the type of binding material in its composition, the way its surface is used, and its construction. The goal of this study was to determine whether thermal insulation mortars made in our nation by TS EN 998-1 standard meet the other requirements listed in this standard, particularly those related to pressure resistance and thermal conductivity coefficient, and to compare the results with the declared values.

MATERIAL AND METHODS

Material

Samples from five different companies, including A, B, C, D, and E the most preferred T1 class ready-made thermal insulation plasters in the market, were obtained. The amount of mixture recommended by the companies was prepared by weighing the insulation plaster and water and mixed with a mixer. The amount of mixing water recommended by each company is different, and therefore the mixing amounts are not given so that the companies cannot be identified. Mixing was carried out until a homogeneous mortar was obtained (approximately 3-5 minutes). A total of 5 series of plaster mortars were produced and placed in sample molds. After being in the mold for twenty-four hours, the samples were taken out of it. Figure 1 displays the samples of plaster mortar that were manufactured.



Figure 1. Produced Plaster Mortar Samples

Experimental Test

In this study, five series of plaster mortars were produced. The produced plaster mortars were tested in fresh and hardened states. The consistency of the wet mortar mixtures to be prepared from each plaster sample was determined

according to TS EN 1015-3 standard. Before the experiment, the inner and outer surfaces and edges of the circular plate and truncated cone-shaped mold were cleaned with a clean and damp cloth. The mortar was then filled into the mold and compacted. After the compression process was completed, the mold was pulled, and the mortar was spread by hitting it 10 times at fixed intervals. The pressure method in accordance with TS EN 1015-7 standard was used to determine air content. Spreading diameter measurement and air content determination experiments are shown in Figure 2.




Figure 2. A: Spreading Diameter, B: Air Content Determination Experiment

For the fresh unit volume mass test, mortar was added until it overflowed the edge of the measuring cup. Excess mortar was scraped off so that the mortar surface was smooth and at the same level as the upper surface of the measuring cup. Mortar residues on the surface of the measuring cup were cleaned by wiping with a damp cloth. The total mass of the measuring cup filled with mortar was weighed. In dry unit volume mass tests, the drying method was applied until a constant mass was reached according to TS EN 1015-10. For this, the sample was dried in an oven set at $70^{\circ}\text{C} \pm 5^{\circ}\text{C}$ until it reached a constant mass. If the sample masses determined by successive weighings at intervals of two hours during the drying process do not differ from each other by more than 0.2% of the dry sample mass, this indicates that the sample has reached a constant mass. After the sample reached a constant mass, the dry sample mass was immediately measured with an electronic balance with an accuracy of 0.01 g. Prisms with dimensions of $160 \times 40 \times 40$ mm were produced for the capillary water absorption (capillarity) experiment (Figure 3A). The prisms produced were placed on the tray as shown in TS EN 1015-18. The masses of the samples placed in water were measured at the end of the 10th and 90th minutes. Flexural strength determination was subjected to a three-point loading test according to TS EN 1015-11 (2000) standard (Figure 3B). For this, each sample is placed on two cylinders with 100 mm between them, and the sample is loaded with the same size cylinder in the middle of the upper surface of the sample until it breaks. The flexural strength can be calculated from the breaking load found. For this experiment, a flexural strength test device with adjustable loading speed was used. To determine the flexural strength, 3 $40 \times 40 \times 160$ mm prism samples were produced from each mixture.



Figure 3. Performing The Experiments A: Capillary Water Absorption, B: Flexural Strength, C: Compressive Strength

The uniaxial compressive strength test, one of the destructive test methods, was performed (Figure 3C). A uniaxial compressive strength tester was used for this experiment. After the flexural strength test, compressive strength tests were performed on two pieces obtained from a prism sample. The compressive strength test of 28-day hardened

plaster samples was carried out according to TS EN 1015-11. Lasercomp Fox 50 thermal conductivity device, which works with the heat flux measurement method, was used for the thermal conductivity coefficient determination experiment. It is designed for thermal conductivity coefficient measurements of materials with a thermal conductivity coefficient of less than 10 W/mK. Using this device, the thermal conductivity coefficient (λ) of samples up to 63 mm in diameter and 1-30 mm in thickness can be measured (Figure 4). Two samples were produced for each plaster series and thermal conductivity tests were carried out on a total of 10 samples.



Figure 4. Thermal Conductivity Coefficient (λ) Measurement

RESULTS AND DISCUSSION

Experimental Test Results

In this study, the test results of plaster mortars produced with plasters supplied by five different companies were compared with the standards given in TS EN 198-1. It has been compared with the standards given in TS EN 198-1. The properties that the plaster mortars of class T should have are given in Table 1.

Table 1. Properties that Plaster Mortars Belonging to T Class

Properties	Classes
Compressive strength	CS I: 0.4-2.5 MPa CS II: 1.5-5 MPa
Capillary water absorption	W 1
Thermal conductivity (W/mK)	T 1 : ≤ 0.10 T 2 : ≤ 0.20

Unit volume mass and air content values of fresh mortar for the plaster mixtures prepared within the scope of the study are given in Figure 5.




Figure 5. Properties of Fresh Mortar, A: Unit Volume Mass, B: Air Content

When the unit volume mass values shown in Figure 5 are examined, it is seen that the highest value belongs to the insulation plaster mortar of product E and the lowest value belongs to the insulation plaster mortar of product A. When the air content values are examined, it is seen that the highest value belongs to the insulation plaster mortar of products D, and the lowest value belongs to the insulation plaster mortar of companies E and C. Additionally, it improves the workability of fresh mortar. In this study, the consistency of 5 different plaster mortars was determined and their spreading diameters were determined. Spreading diameter values of insulation plasters are given in Figure 6.




Figure 6. Spreading Diameter Values of Thermal Insulation Plasters

When the spreading diameter values are examined, it is seen that the highest value belongs to the insulation plaster mortar of product D and the lowest value belongs to the insulation plaster mortar of product A. The spreading diameter feature affects the processability. The w/c ratio of the mortar, air content, adherence additive content, and binder content affects the spreading diameter. While the spreading diameter makes a positive contribution up to a certain value, it is not desired as it will cause flow in plaster application afterward.

The dry unit volume mass values for the hardened plaster samples produced in the experimental study were determined according to the TS EN 1015-10 standard. For each series, 3 prismatic samples that completed the 28-day curing period were tested. The samples were dried in an air circulation oven until a constant mass was reached and weighed, and the arithmetic average of the weighing results was taken. Dry unit volume mass of hardened plaster samples is given in Figure 7.

In insulating plasters, dry unit volume mass is the most important parameter affecting the mechanical properties and thermal conductivity values of the plaster. When the dry unit volume mass values shown in Figure 7 were examined, it was determined that the highest value belonged to the insulation plaster samples of product B and the lowest value belonged to the insulation plaster samples of product A. The coefficients (c) obtained from capillary water absorption tests of prisms produced in dimensions of 160×40×40 mm according to TS EN 1015-112 are given in Figure 8.

c values are closely related to the sustainability of the thermal insulation properties of thermal insulation plasters. The thermal insulation performance of insulation materials with high C values also decreases. When the c values shown in Figure 8 are examined, it is seen that the highest value belongs to the insulation plaster samples of product E and the lowest value belongs to the insulation plaster samples of product B. Considering the c values that class T plasters must have, it has been determined that only B-code insulation plaster meets this criterion.




Figure 7. Dry Unit Volume Mass Values of Hardened Samples




Figure 8. Capillary Water Absorption Coefficient Values of Insulation Plasters

In each series, 3 prismatic samples were subjected to flexural strength tests perpendicular to the casting direction, and the arithmetic average of the 3 test results was accepted as the flexural strength value. After the flexural strength test, compressive strength tests were carried out on two pieces obtained from a prism sample, and the arithmetic average of the test results obtained from 6 pieces was accepted as the compressive strength. Figure 9 shows the average flexural and compressive strength values of the plaster samples.

When the f_c values shown in Figure 9 are examined, it is seen that the highest value belongs to the insulation plaster samples of products E and the lowest value belongs to the insulation plaster samples of products C. The compressive strength-flexural strength relationship of insulation plasters is given in Figure 10.

When the graph in Figure 10 is examined, it is seen that the R^2 value is determined as 0.98. f_{cf} -28-day, 28-day flexural strength, MPa; f_c -28-day, 28-day compressive strength is MPa.




Figure 9. Strengths of Insulation Plasters, A: Flexural Strength, B: Compressive Strength




Figure 10. Compressive Strength-Flexural Strength Relationship of Insulation Plasters

For each series, 3 cylindrical samples with a diameter of 63 mm and a thickness of 25 mm were tested for determining thermal conductivity coefficients. Thermal conductivity coefficients (λ) of 28-day hardened plaster samples are given in Figure 11.

When the thermal conductivity coefficient values shown in Figure 11 are examined, it is seen that the highest value belongs to the insulation plaster samples of product B and the lowest value belongs to the insulation plaster samples of product C. When the values given in Table 1 are examined, it is seen that plasters with a heat transfer coefficient of 0.10 and below are in the T1 class, and plasters with a heat transfer coefficient of 0.20 and below are in the T2 class. When the results are examined, plasters A, C, and D are in the T1 class, and plasters B and E are in the T2 class.

CONCLUSIONS

This study analyzed the physical, mechanical, and thermal properties of insulation plaster mortars from various companies, identifying significant variations in performance and discrepancies between experimental results and manufacturer claims. The findings highlight the critical role of properties like unit volume mass, air content, spreading diameter, capillary water absorption, compressive strength, and thermal conductivity coefficient in determining insulation materials' overall effectiveness and functionality. The unit volume mass values ranged widely among the samples, with product E products showing the highest values, indicating greater density, while product A had the lowest. Air content, a key factor influencing thermal insulation, capillary water absorption, and workability, was highest in product D samples and lowest in products E and C. However, excessive air content negatively impacted compressive and flexural strength values, underscoring the need for balance to optimize performance. Spreading diameter significantly affects the processability of fresh mortar. While a larger diameter improves workability, excessive spreading can cause flow issues during plaster application. This metric, influenced by water-

to-cement (w/c) ratio, air content, and binder additives, requires careful optimization to balance application efficiency with structural integrity.




Figure 11. Thermal Conductivity Coefficients of Insulation Plasters

The study revealed discrepancies in capillary water absorption and compressive strength values. Product B had the lowest water absorption and highest adherence to standard requirements, while product E exhibited the highest absorption. Compressive strength values varied similarly, with product E mortars achieving the highest performance and product C the lowest. Only certain products met the required class T plaster standards for compressive strength and capillary water absorption, indicating a need for quality improvement across many samples.

Thermal conductivity, crucial for energy efficiency, was highest in product B and lowest in product C. Several products, including those from Companies A, C, and D, met the required standards, but discrepancies between manufacturer claims and experimental results were common. For instance, product A declared thermal conductivity and capillary water absorption values were unmet, while compressive strength was consistent. A strong correlation was observed between unit volume mass and flexural strength, compressive strength, and thermal conductivity, suggesting that denser materials generally perform better. However, the study highlighted that many insulation plasters did not meet the stated manufacturer specifications, emphasizing the need for stricter regulatory oversight and regular quality control inspections.

The growing demand for energy-efficient, environmentally friendly building materials offers significant opportunities for innovation. With abundant perlite reserves, the focus in Turkey should shift toward developing eco-friendly insulation materials that serve as alternatives to expanded polystyrene (EPS). Enhancing R&D efforts to create sustainable, energy-saving, and high-performance products is critical for advancing the industry. In conclusion, aligning the actual performance of insulation plasters with declared standards is vital for fostering consumer trust and promoting energy conservation. By intensifying inspections and supporting innovative R&D initiatives, the construction industry can deliver next-generation insulation solutions that combine environmental benefits with superior quality and durability. This approach will contribute to more sustainable building practices, reducing energy consumption and environmental impact.

References

- Abu-Jdayil, B., Mourad, A. H., Hittini, W., Hassan, M., & Hameedi, S. (2019). Traditional, state-of-the-art and renewable thermal building insulation materials: An overview. *Construction and Building Materials*, 214, 709-735. <https://doi.org/10.1016/j.conbuildmat.2019.04.102>
- Al-Homoud, M. S. (2005). Performance characteristics and practical applications of common building thermal insulation materials. *Building and Environment*, 40(3), 353-366.
- Altuncı, Y. T., & Ocal, C. (2021). Investigation of the Usability of Cotton Bagasse as Aggregate in Plaster Mortar. *Journal of Süleyman Demirel University Institute of Science and Technology*, 25(3), 558-563.

<https://doi.org/10.22312/sdufbed.1000007>

Baloević, G., Radnić, J., Grgić, N., & Matešan, D. (2016). The application of a reinforced plaster mortar for seismic strengthening of masonry structures. *Composites Part B: Engineering*, 93, 190-202. <https://doi.org/10.1016/j.compositesb.2016.03.007>

Barbero S., Marco Dutto M., Ferrua C., & Pereno A. (2014). Analysis on existent thermal insulating plasters towards innovative applications: Evaluation methodology for a real cost-performance comparison, *Energy and Buildings*, 77, 40–47. <https://doi.org/10.1016/j.enbuild.2014.03.037>

Bektaş, V., Çerçevik, A. E., & Kandemir, S. Y. (2017). The Importance of Thermal Insulation in Buildings and the Effect of Thermal Insulation Material Thickness on Insulation. *Bilecik Şeyh Edebali University Journal of Science*, 4(1), 36-42. <https://doi.org/10.18185/bseufbd.32048>

Çolakoğlu, A. (2004). Investigation of the Feasibility of Thermal Insulating External Plaster in Buildings, Master's Thesis, Süleyman Demirel University, Isparta.

Çomaklı, K., & Yüksel, B. (2004). Environmental impact of thermal insulation thickness in buildings. *Applied Thermal Engineering*, 24(5-6), 933-940. <https://doi.org/10.1016/j.applthermaleng.2003.10.020>

Davraz, M., Gündüz, L., & Başpınar, E. (2011). Lightweight aggregated foam plaster for thermal insulation in buildings. *Journal of Engineering Sciences and Design*, 1(3), 150-155. <https://doi.org/10.16990/jesd.32048>

Davraz, M., & Kılınçarslan, Ş., 2014. The Effect of Perlite Aggregate Plasters on Energy Saving in Buildings, II. International Davraz Symposium, 29-31 May 2014, Isparta.

Davraz, M., Koru, M., & Akdağ, A. E. (2015). The effect of physical properties on thermal conductivity of lightweight aggregate. *Procedia Earth and Planetary Science*, 15, 85-92. <https://doi.org/10.1016/j.proeps.2015.08.022>

Davraz, M., Koru, M., Akdağ, A. E., Kılınçarslan, Ş., Delikanlı, Y. E., & Çabuk, M. (2020). Investigating the use of raw perlite to produce monolithic thermal insulation material. *Construction and Building Materials*, 263, 120674. <https://doi.org/10.1016/j.conbuildmat.2020.120674>

Dilmaç, Ş., & Kesen, N., 2003. A Comparison of New Turkish Thermal Insulation Standard (TS-825). ISO 9164, EN 832 and German Regulation, *Energy and Buildings*, 35: 161- 174.

Dylewski R., & Adamczyk J. (2014). The comparison of thermal insulation types of plaster with cement plaster, *Journal of Cleaner Production*, 83, 256-262.

Dylewski, R., & Adamczyk, J. (2011). Economic and environmental benefits of thermal insulation of building external walls. *Building and Environment*, 46(12), 2615-2623.

Faria, P., Santos, T., & Aubert, J. E. (2016). Experimental characterization of an earth eco-efficient plastering mortar. *Journal of Materials in Civil Engineering*, 28(1), 04015085. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0001363](https://doi.org/10.1061/(ASCE)MT.1943-5533.0001363)
İzoder, 2002. Turkish Construction Sector and Insulation Market Evaluation Report. Istanbul.

Manohar, K. (2012). Experimental investigation of building thermal insulation from agricultural by-products. *British Journal of Applied Science & Technology*, 2(3), 227-239.

Matoušková, E., Pavelka, K., & Ibrahim, S. (2021). Creating a Material Spectral Library for Plaster and Mortar Material Determination. *Materials*, 14(22), 7030. <https://doi.org/10.3390/ma14227030>

Molnar, L. M., & Manea, D. L. (2016). New types of plastering mortars based on marble powder slime. *Procedia technology*, 22, 251-258. <https://doi.org/10.1016/j.protcy.2016.01.076>

Nascimento, A. S., dos Santos, C. P., de Melo, F. M. C., Oliveira, V. G. A., Oliveira, R. M. P. B., Macedo, Z. S., &

- de Oliveira, H. A. (2020). Production of plaster mortar with incorporation of granite cutting wastes. *Journal of Cleaner Production*, 265, 121808. <https://doi.org/10.1016/j.jclepro.2020.121808>
- Papadopoulos, A. M. (2005). State of the art in thermal insulation materials and aims for future developments. *Energy and buildings*, 37(1), 77-86.
- Papadopoulos, A. M., & Giama, E. (2007). Environmental performance evaluation of thermal insulation materials and its impact on the building. *Building and environment*, 42(5), 2178-2187.
- Pásztor, Z. (2021). An overview of factors influencing thermal conductivity of building insulation materials. *Journal of Building Engineering*, 44, 102604. <https://doi.org/10.1016/j.jobbe.2021.102604>
- Santos, T., Faria, P., & Silva, V. (2019). Can an earth plaster be efficient when applied on different masonries?. *Journal of Building Engineering*, 23, 314-323. <https://doi.org/10.1016/j.jobbe.2019.02.011>
- TS EN 1015-10, 2001. Determination of Dry Unit Volume Mass of Hardened Mortar with Voids, Ankara.
- TS EN 1015-11, 2000. Determination of Compressive and Flexural Strength of Hardened Mortar, Ankara.
- TS EN 1015-18, 2004. Determination of Water Absorption Coefficient of Hardened Mortar During Capillary Effects, Ankara.
- TS EN 1015-3, 2000. Determination of Fresh Mortar Consistency. Necatibey Caddesi No:112 Ministries, Ankara.
- TS EN 1015-6, 2000. Determination of Void Unit Volume Mass of Fresh Mortar, Ankara.
- TS EN 1015-7, 2000. Determination of Air Content of Fresh Mortar, Necatibey Caddesi No:112 Ministries, Ankara.
- Tychanicz-Kwiecień, M., Wilk, J., & Gil, P. (2019). Review of high-temperature thermal insulation materials. *Journal of Thermophysics and heat transfer*, 33(1), 271-284. <https://doi.org/10.2514/1.T5420>
- Villasmil, W., Fischer, L. J., & Worlitschek, J. (2019). A review and evaluation of thermal insulation materials and methods for thermal energy storage systems. *Renewable and Sustainable Energy Reviews*, 103, 71-84. <https://doi.org/10.1016/j.rser.2018.12.040>
- Xu, Z., Zhu, Z., Zhao, Y., Guo, Z., Chen, G., Liu, C., Chen, X. (2022). Production of sustainable plastering mortar containing waste clay brick aggregates. *Case Studies in Construction Materials*, 16, e01120. <https://doi.org/10.1016/j.cscm.2022.e01120>
- Yetkin, M., Calayır, Y., & Alyamaç, K. E. (2024). The effect of mortar and bond type on mechanical parameters of masonry walls. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 39(1), 621-634. <https://doi.org/10.17341/gazimmfd.1080258>
- Yi, W., Xiling, Z., Jinglin, Y., Wenxuan, W., & Tian, T. (2023). A comprehensive performance evaluation of the cement-based expanded perlite plastering mortar. *Science of The Total Environment*, 858, 159705. <https://doi.org/10.1016/j.scitotenv.2022.159705>
- Zach J., Hela R., Sedlmajer M., Hroudova J., (2013). Development of Thermal Insulation Plasters for Insulating and Sanitation of Building Constructions, *IACSIT International Journal of Engineering and Technology*, Vol. 5, No. 3, June 2013, <https://doi.org/10.7763/IJET.2013.V5.582>
- Zach, J., Hroudová, J., Brožovský, J., Krejza, Z., & Gailius, A. (2013). Development of thermal insulating materials on natural base for thermal insulation systems. *Procedia Engineering*, 57, 1288-1294. <https://doi.org/10.1016/j.proeng.2013.04.162>



Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences



Geliş Tarihi : 02.07.2024
Kabul Tarihi : 03.10.2024

Received Date : 02.07.2024
Accepted Date : 03.10.2024

VITAMIN C ENRICHMENT APPLICATION TO REDUCE THE RISK OF CARCINOGENIC NITROSAMINE FORMATION IN SMOKED FISH

TÜTSÜLENMİŞ BALIKLARDA KANSEROJEN NİTROSAMİN OLUŞUM RİSKİNİ AZALTMAK İÇİN C VİTAMİNİ ZENGİNLEŞTİRME UYGULAMASI

Aydin KILIC (ORCID: 0000-0002-8952-9909)

Recep Tayyip Erdoğan University, Gastronomy and Culinary Arts Department, Rize, Turkey

*Sorumlu Yazar / Corresponding Author: Aydin KILIC, aydin.kilic@erdogan.edu.tr

ABSTRACT

Vitamin C, with its antioxidant and prooxidant properties, can prevent carcinogenic nitrosamine by chelating residual nitrite. It decreases the formation of nitrosamine. The objective of the study was to determine the protective effect of vitamin C in fish in reducing the formation of biogenic amines and the formation of nitrosamines. In this context, smoked samples were treated with vitamin C and analyzed by preparing in portions with different experiments and stored at $\pm 4^{\circ}\text{C}$ for different storage conditions. In this regard, putrescine(PUT), cadaverine(CAD), tyramine(TYR), and histamine(HIS) changed during storage. On the other hand, analyzes were also made for nitrosodimethylamine (NDMA), nitrosopiperidine(NPIP), nitrosopyrrolidine(NPYR), nitrosodibutylamine(NDBA). The lowest biogenic amine values are detected in group N2. It was determined that groups had 2.41, 3.66, 0.13, and 1.17($\mu\text{g/g}$) biogenic amine values after 30 days, respectively. The obtained results showed that vitamin C had lower histamine and putrescine values than other groups separately. In addition, NDMA, NPYR, and NPYR were detected in nitrite containing groups after 30 days. Finally, Vitamin C containing groups were found to be better in terms of biogenic amines and nitrosamines content. All these results show that vitamin C can be used as a preservative in foods to protect against carcinogens.

Keywords: Food, smoked fish, vitamin C, nitrosamine, carcinogen.

ÖZET

Antioksidan ve prooksidan olarak bilinen C vitamini, gıdalarda oluşabilecek kalıntı nitriti şelatlama özelliğine sahiptir. Bu özelliği ile kalıntı nitritten kaynaklanabilecek kanserojen nitrozamin radikallerinin oluşum riskini azaltma özelliğine sahiptir. Bu çalışmanın temel hedefi, füme balıklarda C vitamininin, biyojenik amin ve tüm bunlara bağlı olarak kanserojen nitrozaminlerin oluşumunu azaltmadaki koruyucu etkisini belirlemektir. Bu bağlamda, füme balık örnekleri C vitamini muamele edilmiş ve edilmemiş deney grupları halinde hazırlanarak incelenmiş ve farklı depolama sürelerinde $\pm 4^{\circ}\text{C}$ 'de depolanmıştır. Bu bağlamda, putresin (PUT), kadaverin (CAD), tiramin (TYR) ve histamin (HIS) değerleri depolama sırasında değişmiştir. Öte yandan nitrosamin olarak, örneklerdeki nitrosodimetilamin (NDMA), nitrosopiperidin (NPIP), nitrosopirrolidin (NPYR), nitrosodibutylamin (NDBA) değerleri belirlenmiştir. Deneysel verilere göre en düşük biyojenik amin değerleri N2 grubunda bulunmuştur. Deney gruplarının 30 günlük depolamadan sonra sırasıyla 2.41, 3.66, 0.13 ve 1.17 ($\mu\text{g/g}$) biyojenik amin değerlerine sahip olduğu belirlenmiştir. Elde edilen sonuçlar, C vitamini eklenen grupların diğer gruplara göre daha düşük histamin ve putresin değerlerine sahip olduğunu göstermiştir. Ayrıca nitrit içeren gruplarda 30 günlük depolamadan sonra NDMA, NPYR, NPYR tespit edilmiştir. Son olarak askorbik asit içeren grupların biyojenik amin ve nitrozamin içeriği açısından daha iyi olduğu tespit edilmiştir. Tüm bu deneysel sonuçlar, C vitamininin gıdalarda kanserojen nitrozamin radikallerinin oluşumunu önlemek amacıyla koruyucu olarak kullanılabileceğini göstermektedir.

Anahtar Kelimeler: Gıda, füme balık, C vitamini, nitrozamin, kanserojen.

ToCite: KILIC, A., (2025). VITAMIN C ENRICHMENT APPLICATION TO REDUCE THE RISK OF CARCINOGENIC NITROSAMINE FORMATION IN SMOKED FISH. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 30-37.

INTRODUCTION

One of the many technologies used to increase sensory quality and safety in foods is smoking. The smoking process is a complex processing technology that uses many unit operations and some preservatives. In addition to unit operations such as heat treatment and drying, smoking also includes chemical preservative applications such as curing, salting, smoke, antioxidant, and antimicrobial treatment. It is known that some safety risks arise in smoked products, which are highly sought after by consumers as a traditional taste. The many risks that arise are usually because the product is smoked, nitrite used, semi-dried, or cold-processed product. Some of the many risks that may arise from direct consumption or storage are the risk of the formation of biogenic amines and nitrosamines. By reducing these and similar risks, it may be possible to further increase the demand for the product and consumer health. The main purpose of food smoke in contemporary societies is to improve the sensory qualities of the product, increase the shelf life, and increase the added value of the product (Kilic and Oztan, 2013, 2015).

In the processing and storage process, many unwanted changes and chemical metabolites are formed in the product due to quality losses. Biogenic amines, are formed as a result of the decarboxylation of amino acids and have the potential to form carcinogenic compounds as a result of their direct effects such as deterioration and poisoning, as well as their interaction with nitrite (Kilic and Oztan, 2013; Masoud et al., 2007). Biogenic amines and nitrosamines are risky, undesirable chemical metabolites for consumer health formed in the product. Biogen amines, which have extremely high risks in terms of food safety, are known as heterocyclics as toxic aliphatics and organic metabolites with biological activity (Vural and Oztan, 1996). Biogenic amines, one of the main indicators of quality loss, are compounds formed by decarboxylation of amino acids or transamination of aldehydes and ketones. Although hot smoking decreases amine production, this risk does not disappear in cold smoking (Kilic and Oztan, 2013; Flick et al., 2001). The use of vitamin C is one of the many protective effects used in foods (Wasson et al., 1991; Tömen et al., 1991, Kim et al., 2000, Hamre et al., 2003). Vitamin C, also known as ascorbic acid, can be used as a preservative, especially in products that use nitrite or to prevent nitrite use due to high nitrite accumulation (Kilic, Oztan, 213; Kilic, Oztan, 215).

Free biogenic amines in nitrite media react to form nitrosamines. This condition can occur in the gastrointestinal tract. Experimental studies have revealed that nitrosamines such as Ndma, Npip, Npyr, and Ndba are high-risk molecules that have a direct effect on cancer formation. Nitrous amines are toxic compounds with carcinogenic, mutagenic, and even teratogenic effects, that are formed by the combination of nitrite or nitrite salts with an amino group. Even if the products do not add nitrite, they can occur spontaneously in the body (Madhavi et al., 1996; Kilic, 2013, 2015).

While vitamin C acts as an antioxidant in high-density aqueous environments, it acts as a low-intensity pro-oxidant (Frankel, 1996; Yen et al., 2002). With this feature, it is necessary to increase the concentration of vitamin C to prevent oxidation in products. Vitamin C reacts with the free oxygen present in the product, protecting the molecular bonds in the surrounding bonds, and also exerts a synergistic effect against specific antioxidants such as tocopherols present in the product. On the other hand, it can chelate free nitrite left over from nitrite or nitrate naturally found in products or added for preservative purposes (Madhavi et al., 1996). Ascorbic acid, which has antioxidant, prooxidant, metal diluent, and reducing agent or oxygen collector properties, reduces the risk of nitrosamines in products where nitrite is used or in products where nitrite accumulation is high for various reasons. Although ascorbic acid is known to reduce autoxidation in fish, this effect may not be seen in cooked fish. The combination of these effects may dominate in most food applications. It acts as a high antioxidant concentration in aqueous environments. On the contrary, it functions as a prooxidant at low concentrations (Frankel, 1996). Deoxidizers such as ascorbic acid, ascorbyl palmitate, sulfites, and erythorbaceous react with free oxygen, keeping them bound to the environment. They show synergistic reactions to ascorbic acid and specific antioxidants such as ascorbyl palmitate and tocopherols. The use of ascorbate and erythorbate now reduces the amount of nitrite or residual nitrite (Madhavi et al., 1996; Kilic, 2013, 2015). Vitamin C shows not only its direct effect but also an indirect mechanism of action by showing a synergistic effect for vitamin E, which is known as a chelating agent. Vitamin C and E can decrease nitrosation together (Kilic and Öztan, 2013; Mirvish, 1995; Mirvish, et al., 1972; Mirvish et al., 1986; Ahn et al., 2004). Vitamin C not only inhibits nitrosation directly but also acts synergistically by showing a protective effect on vitamin E, which is also known as an anti-carcinogen and has a chelating feature for free nitrite. It has been proven by experiments that vitamins C and E show anti-carcinogenic properties by reducing nitrosation together (Kilic and Öztan, 2013; Mirvish et al., 1986).

The main purpose of this study is to determine whether ascorbic acid, which has various functional properties and protective effects, has protective advantages in terms of biogenic amine and nitrosamine formation. Experimental results obtained in the study revealed that ascorbic acid may have some protective functional properties in terms of biogenic amine and nitrosamine formation. In addition to all these protective properties, although the protective effects of vitamin C on the formation of biogenic amines and nitrosamines are estimated, a study in this scope has not yet been found in the literature. The study is important in terms of revealing the effects of ascorbic acid on the formation of biogenic amines and nitrosamines and completing the important deficiencies in the literature and food industry.

MATERIAL AND METHOD

The raw materials anchovy (*Engraulis encrasicolus*) was purchased by a private company (Subatan Alabalık Production Ltd. Şti., Kayseri). Before determining the chemical characteristics of the raw material, the condition factor was also determined for approximately 6 fish selected by random sampling. The same raw material was chosen to determine the chemical properties of the experimental product.

In the experimental studies, each analysis was repeated twice and 50 fish of approximately 250 g each were consumed in each trial. During the experimental studies, experimental sampling was done from four groups: 1. raw material, 2. processed product (day 0), 3. stored product at +4°C (day 15), and 4. stored product at +4°C (day 30). Figure 1 shows the procedures, experimental groups, additives, and parameters applied during the experiment.




Figure 1. The Standard Chromatogram of Nitrosamines ($1000 \mu\text{g L}^{-1}$ Solvent Standard).

The parameters of each process applied in the experimental groups are shown in Figure 1. 2% of salted fish were subjected to cold smoking after drying. The drying process was continued until a maximum of 5% drying was achieved. After the surface dried, the cold fumigation process was carried out.

Biogenic Amine and Nitrosamine Analysis

Ozogul et al., (2002) modified the method suggested by the UV/VIS detector and C18 Waters Spherisorp ODS-2 (125x 4.60 mm, 5 μm particle diameter) column equipped HPLC system. For this purpose, 5 g of sample was homogenized with 20 ml of trichloroacetic acid (6%), centrifuged at 12000 rpm for 10 minutes (4°C), and subjected to filtration with a Whatman (no:1) strainer. The obtained sample was made up to 50 ml using distilled water of HPLC purity. The obtained extract was analyzed in HPLC system equipped with UV/VIS detector and C18 Waters Spherisorp ODS-2 (125x 4.60 mm, 5 μm particle diameter) column. Obtained chromatograms were compared with standard biogenic amine chromatograms and biogenic amine ratios were determined. As Carrier A; Acetonitrile was increased to 80% within 8 minutes by increasing the flow rate from 5%. HPLC distilled water was used as carrier B. The chromatograms obtained were compared with the biogenic amine standard and the biogenic amine ratios were

determined. Statistical evaluations were determined with the SPSS 11.5 for Windows package program and Duncan test was applied to the variables found to be important (Sümbüloğlu and Sümbüloğlu, 2002).

Nitrosamine analysis was determined by modifying the method applied by Andrade et al., (2005). In this context, after 2.5 g of homogeneous fish sample was cooked at 177°C for 3 minutes, the extracts were placed in a blender with dry ice and placed in GC vials with 24 mL Teflon septa. The figure presents the standard chromatogram of nitrosamines (1000 µg L⁻¹ solvent Standard). Figure 2 presents the standard chromatogram of nitrosamines (1000 µg L⁻¹ solvent Standard).

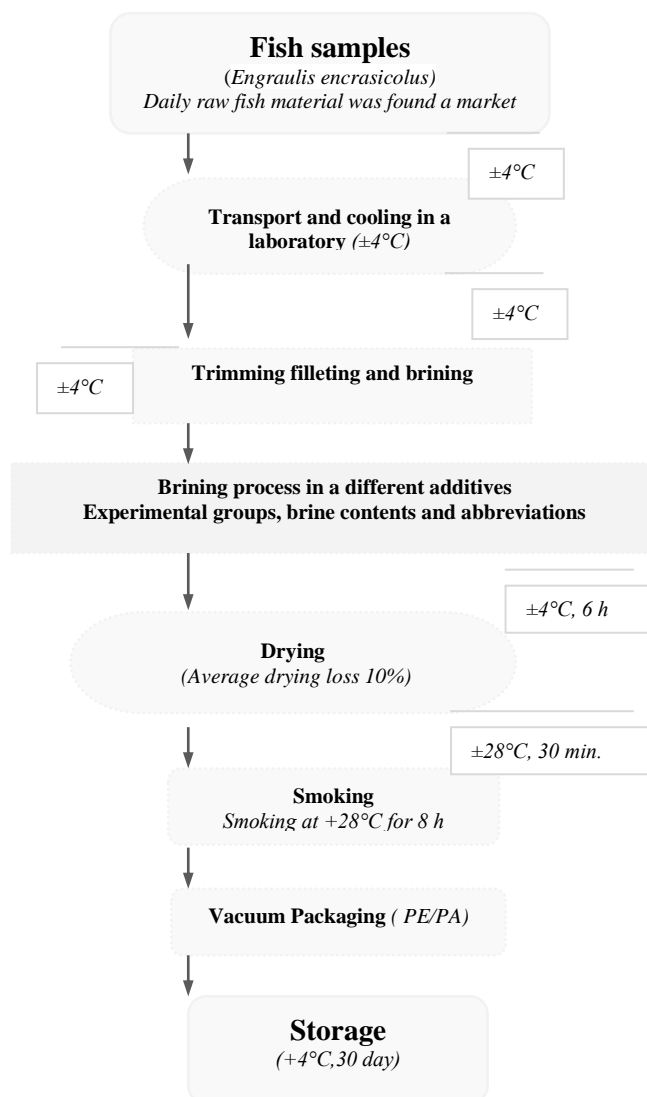


Figure 2. Experimental Groups And Production Flow Chart (Modified from Kılıc and Oztan, 2013, 2015)

Chromatographic separations were determined by GC/MS according to a standard stock solution chromatogram with a column of Carbowax amine, 60 m x 0.53 ID, 1 µm film thickness.

RESULTS AND DISCUSSIONS

Biogenic amines, which have an important role in the biological functions of humans and animals, can show toxic effects when taken in large amounts with food. The most common poisoning caused by biogenic amines is histamine and tyramine poisoning. Tyramine mainly acts indirectly on the sympathetic nervous system by increasing blood pressure by peripheral vasoconstriction. Diamines such as putresin and cadaverine are considered mutagenic precursors due to their tendency to react with nitrites and the formation of potential carcinogen nitrosamines. These amines are converted by heat to pyrrolidine and piperidine, forming nitrozopyrrolidine and nitrozopiperidine. In the

study, nitrosamine amounts formed in experimental groups were determined. In the study, biogenic amine values such as *putrescine (Put)*, *histamine (His)*, *cadaverine (Cad)*, and *tyramine (Tyr)*, which are very important for fish quality, were determined. According to the results obtained, it was determined that there was a significant increase in biogenic amine values due to deterioration. The results obtained in the statistical analyzes will be determined and used in the preparation of the study for publication. If the values are to be examined, it is determined in the product. If the values are examined, it will be seen that there is a significant correlation between the quality parameters determined in the product and the biogenic amine values. Table 1 presents the variation in total biogenic amine values ($\mu\text{g/g}$) during shelf life.

Table 1. The Variation in Total Biogenic Amine Values during Shelf Life ($\mu\text{g/g}$)

Time (Day)	Biogenic amin ($\mu\text{g/g}$)											
	tyramine (Tyr)			histamine (His)			putrescine (Put)			cadaverine (Cad)		
	0	15	30	0	15	30	0	15	30	0	15	30
Experimental groups	Ty	Ty		Hi	Hi		Pu	Pu		Ka	Ka	
<i>Fresh (R)</i>	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00
<i>Brined (B)</i>	0.00	0.00	0.00	0.00	0.00	0.76	0.00	1.87	1.32	0.00	1.04	0.99
<i>Control (C)</i>	0.00	0.00	0.13 ^a	0.00	0.52 ^{ab}	1.56 ^b	0.00	3.53 ^c	3.72 ^d	0.00	1.05 ^a	3.22 ^a
<i>LTHV4</i>	0.00	0.00	0.86 ^b	0.00	0.54 ^{ab}	1.63 ^{bc}	0.00	3.21 ^{bc}	3.54 ^{bc}	0.00	1.33 ^a	3.28 ^a
<i>LTHV10</i>	0.00	0.00	0.85 ^{ab}	0.00	0.57 ^b	1.33 ^b	0.00	3.36 ^{bc}	3.66 ^{cd}	0.00	2.56 ^b	3.85 ^c
<i>LTHV15</i>	0.00	0.00	0.93 ^b	0.00	0.57 ^{ab}	1.47 ^b	0.00	3.54 ^c	3.74 ^d	0.00	2.44 ^b	3.46 ^{ab}
<i>LTHV20</i>	0.00	0.00	0.95 ^{bc}	0.00	0.51 ^{ab}	1.73 ^c	0.00	3.88 ^d	3.85 ^d	0.00	2.76 ^d	3.74 ^{bc}
<i>N4</i>	0.00	0.00	0.19 ^a	0.00	0.30 ^a	1.28 ^{ab}	0.00	2.35 ^a	2.69 ^c	0.00	2.23 ^{ab}	3.72 ^b
<i>N2</i>	0.00	0.00	0.13 ^a	0.00	0.22 ^a	1.17 ^a	0.00	2.46 ^a	2.41 ^{ab}	0.00	2.31 ^{ab}	3.66 ^{ab}
<i>A</i>	0.00	0.00	0.51 ^{ab}	0.00	0.52 ^{ab}	1.98 ^c	0.00	3.74 ^{cd}	2.76 ^c	0.00	2.74 ^{cd}	4.56 ^{ab}
<i>N4A</i>	0.00	0.00	0.24 ^a	0.00	0.28 ^a	1.16 ^a	0.00	2.71 ^{ab}	2.44 ^{ab}	0.00	2.54 ^{bc}	3.81 ^{cd}
<i>N2A</i>	0.00	0.00	0.15 ^a	0.00	0.29 ^a	1.39 ^{ab}	0.00	2.55 ^a	2.37 ^a	0.00	2.62 ^c	3.89 ^d

*n= 2; a-d Mean values within a column with different letters are significantly different ($p < 0.05$).

Experimental data show that although the biogenic amine load could not be determined at the beginning of the storage or low values were determined, increases occurred after 15 days of storage, and even higher values were determined in 30 days. Especially Hi, Pu and Ka values were determined higher than Ty values in groups using preservatives and cold drying (N4, N2, A, N4A, N2A).

When these values were compared, it was determined that Pu and Ka values were lower when compared to control and raw materials. At the same rate, no differences were observed between drying and preservative added groups (LTHV4, LTHV10, LTHV15, LTHV20, N4, N2, A, N4A, N2A). Although the change in the quality values revealed significant differences between the groups, the same differences could not be determined in the biogenic amine values. In the presence of free biogenic amine formed in the fish's content, if residual nitrite is detected in its content, it means that nitrosation will occur under these conditions (Kilic and Öztan, 2013; Bruce Topkin, 2005). However, it was revealed that vitamin C would inhibit nitrosation. Vitamin C shows not only its direct effect but also an indirect mechanism of action by showing a synergistic effect for vitamin E, which is known as a chelating agent. Vitamin C and E can decrease nitrosation together (Kilic and Öztan, 2013; Mirvish, 1995; Mirvish et al., 1972; Mirvish, 1986; Ahn et al., 2004).

Nitrosamine Values

The retention times of *nitrosodimethylamine (Ndma)*, *nitrosopiperidine (Npip)*, *nitrosopyrrolidine (Npyr)*, *nitrosodibutylamine (Ndba)* for NDMA was 6,9 mn, NPIP 12,50 mn, NPYR 11.7 mn, and NDBA 13,2 (30 $\mu\text{g mL}^{-1}$).

According to the obtained results, the samples treated with ascorbic acid have decreased especially histamine and putrescine values in comparison with other groups ($p < 0.05$). In Addition, *NDMA*, *NPYR*, and *NPYR* were detected in all nitrite included experimental groups after 30 days storage. Consequently, the ascorbic acid including groups had better results for biogenic amines and nitrosamine content. It is suggested that ascorbic acid utilization be applied to preserve the fish quality.

The experimental determination of nitrite and ascorbic acid addition on nitrosamine formation is very important for the food industry and consumer health. Existing tests were carried out regarding the formation of nitrosamines in different groups in the products produced, and positive or negative results were obtained as shown in the table below. In the analyses made; for the *Ndma*, *Npip*, *Npyr*, and *Ndba* yes or no tests were performed. In particular, the results obtained in the study reveal the effect of additives as well as the effect of storage on nitrosamine formation. According to the results obtained from the study, nitrosamine formation of especially nitrite-containing groups was positive. Table 2 presents the detected nitrosamines in experimental groups depending on storage time ($\mu\text{g}/\text{kg}$).

Table 2. The Detected Nitrosamines in Experimental Groups Depended on Storage Time ($\mu\text{g}/\text{kg}$).

Nitrosamine	Storage time (day)											
	0	15	30	0	15	30	0	15	30	0	15	30
	<i>NDMA</i>			<i>NPIP</i>			<i>NPYR</i>			<i>NDBA</i>		
Raw (R)	-	-	-	-	-	-	-	-	-	-	-	-
Brined (B)	-	-	-	-	-	-	-	-	-	-	-	-
Control (C)	-	-	-	-	-	-	-	-	-	-	-	-
LTHV4	-	-	-	-	-	-	-	-	-	-	-	-
LTHV10	-	-	-	-	-	-	-	-	-	-	-	-
LTHV15	-	-	-	-	-	-	-	-	-	-	-	-
LTHV20	-	-	-	-	-	-	-	-	-	-	-	-
N4	-	-	+	-	+	+	-	-	+	-	-	-
N2	-	-	+	-	-	+	-	-	+	-	-	-
A	-	-	-	-	-	-	-	-	+	-	-	-
N4A	-	-	+	-	+	+	-	-	+	-	-	+
N2A	-	-	+	-	+	+	-	-	+	-	-	+

*n= 2; (-): Not detected.

The values of the retention times for *Ndma* were 6,9 mn, *Npip* 12,50 mn, *Npyr* 11.7 mn, *Ndba* 13,2 ($30 \mu\text{g mL}^{-1}$). According to the results obtained, the samples treated with ascorbic acid have decreased especially histamine and putrescine values in comparison with other groups. In Addition, *Ndma*, *Npip*, *Npyr*, and *Ndba* were detected in all nitrite included experimental groups after 30 days of storage. Consequently, the ascorbic acid including groups had better results for biogenic amines and nitrosamine content. It is suggested that ascorbic acid utilization be applied to preserve the fish quality. Table 2 presents the detected nitrosamines in experimental groups depending on storage time ($\mu\text{g}/\text{kg}$). The results give good agreement with Kılıç and Öztan (2013, 2016). The results obtained showed a good correlation between the residual nitrite ratios determined by Kılıç and Öztan (2013, 16) and the effect of ascorbic acid on the residual nitrite values. In their study, the researchers showed that the residual nitrite values in the experimental groups to which nitrite was added using ascorbic acid completely disappeared depending on time. Residual nitrite, which occurs spontaneously in the product or is formed due to nitrite added, is a possible expected result, in which nitrosation is eliminated and nitrosamine formation is prevented due to its elimination with ascorbic

acid. Experimental studies have shown that different nitrosamines can lead to the formation of different cancers. From this point of view, the data obtained show that nitrosamine compounds formed due to nitrite and free amine compounds that cause the risk of different cancer types such as different liver, lung, oesophagus, bladder, and pancreas (Li et al., 2013; Bogovski and Bogovski, 1981; Magee and Barnes, 1956).

CONCLUSIONS

Experimental studies reveal that although PUT, CAD, TYR, and HIS values are correlated with the quality loss due to preservative use as expected, this relationship is evident in raw material and control groups and the groups using drying and preservatives, but in the groups treated with preservative and drying. No significant or significant differences could be identified among them. On the other hand, it can be said that the histamine and putrescine values in the samples, especially in which ascorbic acid was applied, were lower than the other groups ($p < 0.05$).

On the other hand, NDMA, NPYR, and NPYR were detected in all experimental groups containing nitrite after 30 days of storage in the NDMA, NPIP, NPYR, and NDBA analyzes. Briefly, enrichment of vitamin C, known as ascorbic acid, has better results for groups containing ascorbic acid, biogenic amines, and nitrosamine content and reduces the risk of nitrosamine formation. As a result, the following benefits are obtained with the addition of vitamin C in the Anchovy as a fish;

1. Long storage life,
2. Decrease in residual nitrite rate,
3. Decrease in biogenic amine ratio,
4. Decrease in nitrosamine formation,
5. Synergetic contribution to vitamin E,
6. Inhibiting nitrosamine formation,
7. Preservation of color and texture,
8. Nutrient enrichment.

It has been revealed that Vitamin C is recommended to be used in production technologies with its important advantages.


ACKNOWLEDGEMENTS

This study was supported by Hacettepe University, Recep Tayyip Erdogan University, Omer Halisdemir University, and Bagci Fishery Co. The authors would kindly like to thank them for their contributions and corporations.

CONFLICT OF INTEREST STATEMENT

All authors declare no conflict of interest.

ORCID

Aydin Kılıç  <https://orcid.org/0000-0002-8952-9909>

REFERENCES

- Ahn, H. J., Kim, J. H., Jo, C., Lee, J. W., Yook, H. S., & Byun, M. W. (2004). Effect of gamma irradiation on residual nitrite, residual ascorbate, color and N- nitros amines of cooked sausage during storage. *Food Control*, 15, 197- 2003. [https://doi.org/10.1016/S0956-7135\(03\)00047-1](https://doi.org/10.1016/S0956-7135(03)00047-1)
- Andrade, R., Reyes F. G.R. , Rath, S. (2005). A method for the determination of volatile N-nitrosamines in food by Hs-Spme-Gc-Tea. *Food Chemistry*, 91 (1)173-179. <https://doi.org/10.1016/j.foodchem.2004.08.015>
- Bogovski P, Bogovski S. (1981). Animal species in which N-nitroso compounds induce cancer. *Int. J. Cancer*. 27: 471-474. <https://doi.org/10.1002/ijc.2910270408>
- Bruce Tompkin,R. (2005). Nitrite, in *Antimicrobials in Food*, Third Edition, Edited by P. Michael Davidson, John, N. Sofos, A. L. Branen, c. 6, 171-216. <https://doi.org/10.1201/9781420028737>

- Flick, G. J., Oria, M. P., Douglas, L. (2001). Potential hazards in cold-smoked fish: Biogenic amines. *Journal of Food Science- Supplement to Vol. 66*, 7. <https://doi.org/10.1111/j.1365-2621.2001.tb15528.x>
- Frankel, E. N. (1996). Antioxidants in lipid foods and their impact on food quality. *Food Chemistry*, 57(1) 51-55. [https://doi.org/10.1016/0308-8146\(96\)00067-2](https://doi.org/10.1016/0308-8146(96)00067-2)
- Hamre, K., Lie, Ø., Sandnes, K. (2003). Development of lipid oxidation and flesh colour in frozen stored fillets of Norwegian spring spawning herring (*Lupea herangus* L.) effect of treatment with ascorbic acid. *Food Chem.*, 82, 447-453. [https://doi.org/10.1016/S0308-8146\(03\)00070-0](https://doi.org/10.1016/S0308-8146(03)00070-0)
- Kilic, A. & Oztan, A. (2013). Effect of ascorbic acid utilization on cold-smoked fish quality (*Oncorhynchus mykiss*) during process and storage. *Food Science Technology Research*, 19, 823-831. <https://doi.org/10.3136/fstr.19.823>
- Kilic, A. & Oztan, A. (2015). Preservative characteristics of ascorbic acid on color, texture and fatty acid of cold-smoked fish, *International Journal of Food Engineering*. 12(1) 49–61. <https://doi.org/10.1515/ijfe-2014-0095>
- Li, L., Shao, J., Zhu, X., Zhou, G. & Xu, X. (2013) Effect of plant polyphenols and ascorbic acid on lipid oxidation, residual nitrite and N-nitrosamines formation in dry-cured sausage. *International Journal of Food Science and Technology*, 48, 1157–1164. doi.org/10.1111/ijfs.12069
- Magee P. N., Barnes J. M. (1956). The production of malignant primary hepatic tumours in the rat by feeding dimethylnitrosamine. *Br. J. Cancer*. 10: 114-122. <https://doi.org/10.1038/bjc.1956.15>
- Rezaei, M., Montazeri, N., Langrudi, H. E., Mokhayer, B., Parviz, M., Nazarini, A. (2007). The biogenic amines and bacterial changes of farmed rainbow trout (*Oncorhynchus mykiss*) stored in ice. *Food Chemistry* 103, 150–154. <https://doi.org/10.1016/j.foodchem.2006.05.066>
- Mirvish, S. S. (1995). Role of N-nitroso compounds (NOC) and N-nitrosation in etiology of gastric, esophageal and bladder cancer and contribution to cancer of known exposure to NOC. *Cancer Letter*, 93, 17-48. [https://doi.org/10.1016/0304-3835\(95\)03786-V](https://doi.org/10.1016/0304-3835(95)03786-V)
- Mirvish, S. S., Wallcave, L., Eagen, M., & Shubik, P. (1972). Ascorbate-nitrite reaction: Possible means of blocking the formation of carcinogenic N-nitroso compounds. *Science*, 177, 65-68. <https://doi.org/10.1126/science.177.4043.65>
- Mirvish, S. S. (1986). Effects of vitamins C and E on N-nitroso compound formation, carcinogenesis, and cancer. *Cancer*. 1842-50. [https://doi.org/10.1002/1097-0142\(19861015\)58:8](https://doi.org/10.1002/1097-0142(19861015)58:8)
- Ozogul, F., Taylor, K. D. A., Quantick, P., Özogul, Y. (2002). Biogenic amines formation in Atlantic herring (*Clupea harengus*) stored under modified atmosphere packaging using a rapid HPLC method, *International Journal of Food Science & Technology*, 37 (5), 515-522. <https://doi.org/10.1046/j.1365-2621.2002.00608.x>
- Sümbüloğlu, K., Sümbüloğlu, V. (2002). *Biyoistatistik*. Hatipoğlu Yayın Evi, Mareşal Çakmak C., 64-A, 10. baskı, Beşevler-ANKARA, 250-270.
- Vural, H., Oztan, A. (1996). Et Ürünleri Kalite Kontrol Laboratuvarı Ugulama Kılavuzu. Hacettepe Üniversitesi Mühendislik Fakültesi Yayınları Yayın No: 36., ANKARA, 35-118.
- Wasson, D. H., Reppond, K. D., Kandianis, T., M. (1991). Antioxidants to Preserve rockfish color. *Journal of Food Science*, 56(6)1564-1566. <https://doi.org/10.1111/j.1365-2621.1991.tb08641.x>
- Yen, G. C., Duh., P. D., Tsai., H. L. (2002). Antioxidant and pro-antioxidant properties of ascorbic acid and gallic acid. *Food Chemistry*, 79, 3. [https://doi.org/10.1016/S0308-8146\(02\)00145-0](https://doi.org/10.1016/S0308-8146(02)00145-0)



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 08.08.2024
Kabul Tarihi : 07.11.2024

Received Date : 08.08.2024
Accepted Date : 07.11.2024

RADYOMİK ÖZELLİKLER VE MAKİNE ÖĞRENMESİ TEKNİKLERİYLE MEME TÜMÖRLERİNİN SINIFLANDIRILMASI

CLASSIFICATION OF BREAST TUMORS USING RADIOMIC FEATURES AND MACHINE LEARNING TECHNIQUES

*Asuman KAPLAN*¹ (ORCID: 0009-0004-9357-1773)
*Esra KAVADAR*² (ORCID: 0009-0005-9548-7548)
Mehmet Ali ALTUNCU^{3*} (ORCID: 0000-0002-2948-3937)

^{1,2,3} Kocaeli Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye

*Sorumlu Yazar / Corresponding Author: Mehmet Ali ALTUNCU, mehmetali.altuncu@kocaeli.edu.tr

ÖZET

Meme kanseri, dünya genelinde kadınlar arasında en sık görülen kanser türüdür ve erken teşhis, tedavi başarısını önemli ölçüde artırmaktadır. Bu çalışmada, meme ultrason görüntülerinden iyi huylu ve kötü huylu tümörleri sınıflandırmak amacıyla radyomik özellikler ve makine öğrenmesi teknikleri kullanılmıştır. Çalışmada, halka açık BUSI veri seti kullanılmıştır. Sadece iyi huylu ve kötü huylu olarak etiketlenmiş görüntüler sınıflandırmada kullanılmış olup, normal etiketli görüntüler çalışmaya dahil edilmemiştir. Bu yaklaşım, modelin iki sınıf arasındaki ayrımı en yüksek doğrulukla yapmasına odaklanmıştır. Veri setindeki dengesizlik, kötü huylu tümörlerin görüntülerinin y ekseninde aynalanarak artırılmasıyla giderilmiştir. PyRadiomics kütüphanesi ile çıkarılan 123 radyomik özellik arasından, özellik önem skoru ve korelasyon matrisi kullanılarak en önemli 40 özellik seçilmiştir. Sınıflandırma aşamasında XGBoost, Gradient Boosting, AdaBoost, SVM, Random Forest ve Decision Tree algoritmaları uygulanmış, en yüksek doğruluk oranı (%98,13) Gradient Boosting algoritması ile elde edilmiştir.

Anahtar Kelimeler: Makine öğrenmesi, meme kanseri, radyomik özellikler, tümör sınıflandırma.

ABSTRACT

Breast cancer is the most common type of cancer among women worldwide, and early diagnosis significantly increases the success of treatment. In this study, radiomic features and machine learning techniques were used to classify benign and malignant tumors from breast ultrasound images. The publicly available BUSI dataset was used in the study. Only images labeled as benign and malignant were used in the classification, and normal labeled images were not included in the study. This approach focused on the model distinguishing between the two classes with the highest accuracy. The imbalance in the dataset was eliminated by mirroring and augmenting the images of malignant tumors in the y-axis. Among the 123 radiomic features extracted with the PyRadiomics library, the most important 40 features were selected using feature importance scores and correlation matrix. XGBoost, Gradient Boosting, AdaBoost, SVM, Random Forest and Decision Tree algorithms were applied in the classification phase, and the highest accuracy rate (98.13%) was obtained with the Gradient Boosting algorithm.

Keywords: Machine learning, breast cancer, radiomics, tumor classification.

GİRİŞ

Meme kanseri, genellikle meme dokusunda başlar ve zamanla vücudun diğer bölgelerine yayılabilir. Kadınlarda en yaygın görülen kanser türlerinden biri meme kanseridir. Dünya genelinde ise akciğer tümörlerinden sonra, en sık teşhis edilen ikinci tümör türü olarak kabul edilmektedir (Jabeen vd., 2022). 2022 yılında, dünya genelinde yaklaşık

ToCite: KAPLAN, A., KAVADAR, E., & ALTUNCU, M. A. (2025). RADYOMİK ÖZELLİKLER VE MAKİNE ÖĞRENMESİ TEKNİKLERİYLE MEME TÜMÖRLERİNİN SINIFLANDIRILMASI.

Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi, 28(1), 38-50.

2.3 milyon kadına meme kanseri tespiti koyulmuş ve 670 bin kişinin ölümüne neden olmuştur (WHO, 2024). Bu rakamlar, meme kanserinin ne kadar yaygın bir sağlık sorunu olduğunu ve erken teşhisin önemini vurgulamaktadır.

Meme kanseri tümörleri, iyi ve kötü huylu olmak üzere iki ana kategoriye ayrılır. İyi huylu tümörler genellikle sağlığa ciddi bir tehdit oluşturmaz ve nadiren insanlarda ölüme yol açar. Bu tür tümörler sınırlı bir büyüme kapasitesine sahiptir ve sadece vücudun belirli bir bölgesinde gelişir. Genellikle yavaş büyürler ve çevre dokulara yayılmazlar, bu da onları tedavi edilmesi daha kolay ve genellikle daha az tehlikeli kılar. Öte yandan, kötü huylu tümörler çok daha tehlikelidir ve uygun tedavi edilmezse bir kişinin hayatını tehdit edebilir. Bu tür tümörlerdeki hücreler, kontrolsüz ve anormal bir şekilde hızla çoğalır. Kötü huylu tümörler, çevre dokulara yayılabilir ve metastaz yaparak vücudun diğer bölgelerine sıçrayabilir, bu da hastalığın tedavisini daha zor ve karmaşık hale getirir. Bu nedenle, kötü huylu tümörlerin erken teşhis ve tedavisi, hastanın hayatta kalma şansını önemli ölçüde artırır (Assiri vd., 2020).

Meme kanserinin taranmasında genellikle mamografi, ultrasonografi ve manyetik rezonans görüntüleme (MRI) yöntemleri tercih edilmektedir. Mamografi, düşük dozda X-ışını kullanarak meme dokusunun görüntülenmesini sağlar ve erken evre kanserlerin tespitinde oldukça etkili bir tarama yöntemidir. Ancak, genç kadınlarda sıkça görülen yoğun meme dokusu, mamografinin duyarlılığını azaltabilir ve bu durum tanıların atlanmasına yol açabilir. Bu durumda, ultrasonografi, ses dalgaları kullanarak meme dokusunu detaylı bir şekilde görüntüleyerek, mamografide belirsiz kalan kitleleri netleştirebilir ve tümör tespitinde daha yüksek bir duyarlılık sağlar. MRI ise, yüksek çözünürlükte ve ayrıntılı görüntüler sunarak, özellikle yoğun meme dokusu ve yüksek riskli hastalarda etkili bir tarama seçeneği sunar. Ancak, MRI'nın yüksek maliyeti ve zaman alıcı olması, genellikle birincil tarama aracı olarak tercih edilmemesine yol açmaktadır (Sun vd., 2018, Aristokli vd., 2022).

Radyomik, tıbbi görüntülerden özelliklerin otomatik olarak çıkarılması ve analiz edilmesi yöntemidir. Bu özellikler, hastalıkların tanısında, prognozda ve tedavi yanıtının tahmininde önemli bir rol oynamaktadır. Görüntülerde gözle fark edilemeyen ayrıntıları ve örüntüleri ortaya çıkaran radyomik, kişiselleştirilmiş tıp ve tedavi planlamasında değerli bir araç olarak kabul edilmektedir. Özellikle onkoloji alanında, makine öğrenimi ve yapay zeka gibi ileri analiz yöntemleriyle birleştirildiğinde, radyomik çok daha kapsamlı ve faydalı bilgiler sağlayabilir (Kumar vd., 2012).

Radyomik özellik çıkarımı, LIFEx (LIFEx, n.d.), MITK (Medical Imaging Interaction Toolkit, n.d.), CERR (CERR, n.d.) ve PyRadiomics (Van Griethuysen vd., 2017) gibi açık kaynaklı yazılım araçları kullanılarak gerçekleştirilir. Bu yazılımlar, görüntülerden sayısal özelliklerin otomatik olarak çıkarılmasını sağlar. Kullanılan yazılım aracılığıyla, segment edilmiş tümör bölgesinden şekil, yoğunluk, doku ve türetilmiş özellikler gibi veriler elde edilir. Çıkarılan özellikler, çeşitli algoritmalar tarafından analiz edilerek görüntülerdeki yeni örüntüler ve ilişkiler ortaya konur. Bu süreç, tanı ve prognoz için önemli olabilecek yeni bilgilerin elde edilmesini sağlar (Zhang vd., 2023).

Geleneksel meme kanseri değerlendirme yöntemleri genellikle niteliksel olup subjektif değerlendirmelere dayanır, bu da bazı durumlarda tümörlerin doğru şekilde tespit edilmesini zorlaştırabilir. Radyomik analizler ise, görüntülerden detaylı özellikler çıkararak tümörlerin mikroskobik özelliklerini daha hassas bir şekilde değerlendirme imkanı sunar. Bu sayısal veriler, makine öğrenmesi veya derin öğrenme algoritmalarıyla birleştirilerek, iyi ve kötü huylu tümörlerin sınıflandırılmasında kullanılabilir (Pesapane vd., 2023).

Literatürdeki çalışmaların büyük çoğunluğu, meme tümörlerinin varlığının belirlenmesi ve sonrasında iyi veya kötü huylu olarak sınıflandırılmasını bir arada ele almaktadır. Bu çalışmada ise yalnızca mevcut tümörlerin iyi veya kötü huylu olarak doğru bir şekilde sınıflandırılmasına odaklanılmıştır. Bu yaklaşım ile tanı sürecinin daha hassas bir şekilde gerçekleştirilmesi sağlanarak, tedavi planlamalarında daha net ve kesin sonuçlar elde edilmesi hedeflenmektedir. Ayrıca, veri setindeki sınıf dengesizliği veri artırma teknikleri ile giderilmiş ve dengelenmiş veri seti kullanılarak model performansının optimize edilmesi amaçlanmıştır. Bu doğrultuda, radyomik özelliklerin meme tümörleri sınıflandırmasında daha verimli kullanımı sağlanmıştır. Elde edilen sonuçların, etkili tedavi stratejilerinin geliştirilmesinde kritik bir rol oynayacağı öngörülmektedir.

Makalenin geri kalanı şu şekilde yapılandırılmıştır: İlk bölümde, meme kanseri tespiti için son dönemde yapılan çalışmalar hakkında bilgi verilmiştir. İkinci bölümde, kullanılan veri seti ve önerilen yöntemler açıklanmıştır. Üçüncü bölümde, deneysel çalışma sonuçları detaylandırılmıştır. Sonuçlar ve tartışma bölümünde ise, elde edilen bulgular değerlendirilmiş ve gelecekteki araştırmalar için potansiyel yönler üzerinde durulmuştur.

İLGİLİ ÇALIŞMALAR

Literatürdeki çalışmalar incelendiğinde, meme kanserinin tespiti için klasik makine öğrenmesi, derin öğrenme ve bu iki yöntemin birlikte kullanıldığı hibrit yöntemlerin önerildiği görülmektedir.

Mishra vd. (2021), meme kanserlerinin malignitesini tahmin etmek amacıyla ultrason görüntülerini kullanarak etkili bir makine öğrenmesi (ML) ve radyomik tabanlı sınıflandırma yöntemi önermişlerdir. BUSI veri setindeki veri dengesizliği sorununu ele almak için SMOTE tekniği uygulanmıştır. Görüntülerden çeşitli bölgesel özellikler çıkarılarak radyomik özellikler elde edilmiştir ve sınıflandırma sürecinde en yüksek doğruluk oranı %97,4 ile AdaBoost algoritması kullanılarak sağlanmıştır. Çapkan vd. (2022), meme kanseri tespiti için K-Nearest Neighbors (KNN), Decision Tree (DT), Support Vector Machine (SVM) ve hibrit yöntemlerden oluşan bir mimari kullanmışlardır. Çalışmada, iyi huylu ve kötü huylu sınıflarına ait toplam 647 ultrason görüntüsü ve 133 normal ultrason görüntüsünden oluşan bir veri seti kullanmışlardır. Fisher Score algoritması ile özellik seçimi yapılmış ve toplam 25 özellik elde edilmiştir. Deneysel sonuçlar, önerilen yöntemin %99.24 doğruluk oranı ile sınıflandırma işlemini gerçekleştirdiğini göstermektedir. Ghabrim vd. (2023), meme ultrason görüntülerini segmentlere ayırarak iyi huylu veya kötü huylu olarak sınıflandırmayı hedeflemiştir. Görüntü ön işleme aşamasında, görüntülerin kalitesini artırmak için parlaklık ve kontrast ayarları, gürültü azaltma ve kenar keskinleştirme yöntemleri kullanılmıştır. Ayrıca, Canny, Laplacian ve Sobel gibi kenar belirleme filtreleri de uygulanmıştır. Veriler bu ön işlem aşamalarından geçirildikten sonra, U-Net modeli yardımıyla meme kanseri ultrason görüntüleri segmentlere ayrılmıştır. Meme lezyonlarını iyi ve kötü huylu olarak sınıflandırmak için ise KNN, Random Forest (RF), DT ve SVM gibi geleneksel yöntemler kullanılmıştır. Bu yöntemler arasında en yüksek doğruluk oranı %86 ile KNN yöntemi kullanılarak elde edilmiştir. Şenol & Kaya (2024), meme kanseri sınıflandırmasında gürültülü verilerdeki aykırı değerleri tespit etmek için kümeleme tabanlı iki aşamalı bir yöntem önermişlerdir. İlk aşamada, veri ön işleme sürecinde beş farklı kümeleme algoritması karşılaştırılmış ve bu algoritmalarından en yüksek performans, sınıflama aşamasında kullanılan KNN algoritması ile %98.34 doğruluk değeri elde edilmiştir. Ara vd. (2021), iyi ve kötü huylu tümörlerin tespitinde beş farklı klasik makine öğrenmesi yönteminin etkinliğini değerlendirmiştir. Çalışmada, halka açık Wisconsin Meme Kanseri veri seti kullanılmıştır. Elde edilen bulgular, RF ve SVM yöntemlerinin, %96.5 doğruluk oranı ile diğer yöntemlerden daha üstün performans sergilediğini göstermiştir.

Badawy vd. (2021), meme ultrason görüntülerinden meme kanseri tespiti için on adet tanınmış önceden eğitilmiş CNN (Convolutional Neural Network) sınıflandırma modelleri arasında karşılaştırmalı bir çalışma gerçekleştirmişlerdir. Çalışma sonucunda, giriş görüntülerinin net ve kontrastı yüksek olduğunda ResNet101 modelinin %96.27 ile en iyi doğruluk oranına sahip olduğu belirtilmiştir. Bota vd. (2024), meme ultrason görüntülerinden meme kitlelerini sınıflandırmak için transfer öğrenme yöntemlerini kullanarak çok örnekli sınıflandırma gerçekleştirmeyi amaçlamıştır. Çalışmada özellik çıkarımı için InceptionResNetV2, MobileNetV2, InceptionV3 ve ResNet50 gibi çeşitli CNN mimarileri kullanılmıştır. Verilerdeki dengesizlikleri gidermek için alt örnekleme yöntemleri uygulanmış ve önceden eğitilmiş mimarilerle ince ayar yapılmıştır. Araştırma sonuçlarına göre, MobileNetV2 ile çıkarılan özellikler ile %84 doğruluk oranına ulaşıldığı belirtilmiştir. Liu vd. (2022), meme kanseri teşhisi amacıyla 600 kadın hastanın görüntülerini içeren açık kaynak bir veri seti üzerinde çalışmışlardır. Veri setinde özellik çıkarımı için ızgara (grid) tabanlı derin özellik oluşturucu kullanılmıştır. Özellik çıkarma işleminin karmaşıklığını azaltmak için ultrasonik görüntüler satır ve sütunlara bölünmüştür ve bunun sonucunda özellik çıkarılması için 10 adet ızgara elde edilmiştir. Özellik seçimi aşamasında ise 16 önceden eğitilmiş CNN mimarileri kullanılarak 9000 özellik çıkarılmış, Neighborhood Component Analysis (NCA) kullanılarak bu özelliklerden en iyileri seçilmiştir. Model seçimi aşamasında, SVM ile hesaplanan hata değerleri kullanılarak en uygun modeller seçilmiştir. Bu modellerle oluşturulan özellik vektörleri, derin sinir ağı (DNN) kullanılarak sınıflandırılmıştır. Deneysel sonuçlara göre, ResNet101, MobileNetV2 ve EfficientNetb0 modellerinden elde edilen özelliklerin, %97.18 doğruluk oranıyla diğer modellere kıyasla daha yüksek doğruluk sağladığı belirtilmiştir.


Eroğlu vd. (2021), meme kanseri kitlelerinin iyi huylu, kötü huylu ve normal olarak sınıflandırılması için hibrit tabanlı bir CNN sistemi geliştirmiştir. Bu çalışmada, özneliklerin birleştirilmesi için AlexNet, ResNet50 ve MobileNetV2 olmak üzere üç farklı CNN modeli kullanılmıştır. Sınıflandırma aşamasında, en yüksek doğruluk oranı %95.6 ile SVM yöntemi kullanılarak elde edilmiştir. Paurasad vd. (2021), ultrason görüntülerinden meme tümörlerini tespit etmek için geleneksel makine öğrenmesi ve özgün bir CNN mimarisinden oluşan altı farklı yöntemi karşılaştırmışlardır. Ayrıca, önerilen CNN modeli, eğitim ve deneysel setlerde %99.7 doğruluk oranı sağlamıştır. Deneysel sonuçlar, meme tümörlerinin teşhisinde yüksek potansiyele sahip bir CNN algoritmasının kullanılabilirliğini ortaya koymuştur. Khanna vd. (2021), derin öğrenme, optimizasyon ve makine öğrenmesi

tekniklerini birleştiren bir hibrit yaklaşım önermişlerdir. Çalışmada tümörlerin iyi huylu, kötü huylu ve normal olarak sınıflandırılması amaçlanmıştır. Özellik çıkarımı adımı için bir CNN modeli olan ResNet-50, özellik seçimi adımı için BGWO (Binary Gray Wolf Optimization) algoritması, sınıflandırma için ise SVM yöntemi kullanılmıştır. Özellik seçimi algoritmasının kullanımı ile önerilen modelde %84.9 sınıflama doğruluğu sağlanmış ve işlem süresinde yaklaşık dört kat iyileşme elde edilmiştir. Lanjewar vd. (2024), transfer öğrenme ve derin öğrenme modellerinin meme kanseri teşhisindeki etkinliğini değerlendirmeyi amaçlamışlardır. Çalışmada önerilen model, MobileNetV2, ResNet50 ve VGG16 gibi transfer öğrenme yöntemleri ile Long Short-Term Memory (LSTM) yöntemini birleştiren hibrit bir yaklaşıma dayanmaktadır. Çalışmada ayrıca, sentetik azınlık aşırı örnekleme (SMOTE) ve Tomek yöntemi (SMOTETomek) kullanılarak az sayıdaki veri noktasına sahip olan özelliklerin oranları artırılmıştır. Sonuçlar incelendiğinde, VGG16 yöntemi ile %96 F1 skoru elde edildiği gözlemlenmiştir. Rashid vd. (2022), meme tümörü sınıflandırmasında radyomik özellikler ve derin öğrenme yöntemlerinin karşılaştırılması için iki farklı yaklaşım önermişlerdir. İlk yöntemde, 111 tümör lezyonundan türetilen 74 radyomik özellik, SVM algoritmasının çeşitli kernel'leri kullanılarak sınıflandırılmış ve maksimum %97.06 doğruluk elde edilmiştir. İkinci yöntemde ise, CNN ve SVM yöntemlerinin birleşiminden oluşan hibrit bir yaklaşım uygulanmış ve %95.28 doğruluk sağlanmıştır.

Literatürdeki birçok çalışma, tümör tespiti ve sınıflandırmasını bir arada ele alırken, bu çalışmada yalnızca tümör olduğu bilinen örneklerin iyi huylu veya kötü huylu olarak doğru şekilde ayrılması hedeflenmiştir. Bu yaklaşım, teşhis sürecine odaklanarak tedavi planlamalarında daha net ve kesin sonuçlar elde edilmesini amaçlamaktadır.

ÖNERİLEN YÖNTEM

Çalışma kapsamında önerilen meme tümörü sınıflandırılması modelinin genel mimarisi Şekil 1'de gösterilmektedir. Önerilen model dört temel aşamadan oluşmaktadır. İlk aşamada, veri setindeki sınıflar arasındaki dengesizliğin üstesinden gelebilmek için maskelenmiş görüntüler üzerinde aynalama tekniği uygulanmıştır. İkinci aşamada, maskelenmiş görüntülerden, açık kaynaklı bir Python kütüphanesi olan PyRadiomics aracılığıyla 123 adet radyomik özellik çıkarılmıştır. Üçüncü aşamada, elde edilen 123 özelliğinden en önemlilerinin belirlenmesi için önemlilik skoru ve korelasyon analizi yöntemleri uygulanarak sınıflandırma işlemi öncesi 40 özellik belirlenmiştir. Son aşamada ise tümörün iyi veya kötü huylu olarak sınıflandırılması için 6 makine öğrenmesi yönteminin (XGBoost, Gradient Boosting, AdaBoost, SVM, RF ve DT) performansları karşılaştırılmıştır.




Şekil 1. Genel Sistem Mimarisi

Veri Seti

Çalışma kapsamında Kaggle'da bulunan, meme kanseri teşhisi ve tümör sınıflandırması için kullanılan ultrason görüntüleri içeren BUSI veri seti (Al-Dhabyani vd., 2020) kullanılmıştır. 2018 yılında Baheya hastanesinde 25-75 yaş arası 600 kadından toplanan ve 780 meme ultrason görüntüsünden oluşan veri seti, normal, iyi huylu ve kötü huylu olarak üç sınıfa ayrılmıştır. Bu çalışmanın amacı, meme ultrason görüntülerinden iyi huylu ve kötü huylu tümörleri sınıflandırmak olduğundan, veri setindeki normal etiketli görüntüler eğitim ve test aşamalarında

kullanılmamıştır. Başlangıçta DICOM formatında olan görüntüler, DICOM dönüştürücü kullanılarak PNG formatına çevrilmiş ve ortalama 500×500 piksel boyutundadır. BUSI veri setinin en önemli özelliği, her görüntüye ait maskelerin de dahil edilmesidir. Bu maskeler, kötü huylu vakalarda tümör bölgelerini hassas bir şekilde belirler. Maskelerin varlığı, bilgisayarlı destekli tarama sistemlerinin eğitilmesi için oldukça değerlidir. Bu sayede sistemler, ultrason görüntülerindeki belirli bölgelere odaklanabilir ve bu sayede kanser teşhis doğruluğu potansiyel olarak artırılabilir. Veri setinde iyi huylu tümör sınıfında 437 adet ve kötü huylu tümör sınıfında 210 adet görüntü bulunduğundan, görüntüler üzerinden veri dengesizliği sorununu çözmek için Şekil 2.a ve Şekil 2.b'deki gibi, kötü huylu tümör sınıfına y-ekseninde aynalama tekniği uygulanmıştır. Y-ekseni boyunca aynalama yöntemi, tıbbi görüntülerin özel niteliklerini korumak açısından kritik bir öneme sahiptir. Bu yöntem, tıbbi görüntülerde dikey yansıma değişmezliğini sağlayarak modelin performansını artırır. Ayrıca, doğal görüntülerde genellikle tercih edilen yatay aynalamanın ötesinde, gerçekçi kitle görüntüleri elde edilmesine yardımcı olur (Hussain vd., 2018). Aynalama işlemi sonrasında veri setindeki toplam görüntü sayısı 857'ye ulaşmıştır.



Şekil 2. a. Orijinal Görüntüye Aynalama Tekniği Uygulanması b. Maskelenmiş Görüntüye Aynalama Tekniği Uygulanması

Özellik Çıkarma

Radyomik özellikler, MR ve bilgisayarlı tomografi gibi tıbbi görüntülerden otomatik olarak çıkarılan ve tümörlerin biyolojik yapısını nicel olarak tanımlayan verilerdir. Bu özellikler, tümörlerin şekil, doku yapısı ve yoğunluk dağılımı gibi mikroskobik düzeydeki detaylarını ortaya çıkararak, hastalıkların teşhisi, tedavi yanıtının tahmini ve prognoz belirlemesi gibi klinik karar verme süreçlerinde önemli bir katkı sağlar (Zhang vd., 2022). Radyomik özellikler, şekil, yoğunluk ve doku özellikleri gibi ana kategorilere ayrılmakta olup, bu kategorilerin altında ikinci ve daha yüksek dereceden özellikler de yer almaktadır.

Şekil özellikleri, tümörün geometrik yapısını (boyut, hacim, şekil) tanımlar ve maksimum çap, yüzey-hacim oranı gibi çeşitli parametreleri içerir. Yoğunluk özellikleri, piksel veya voxel değerlerinin istatistiksel dağılımını ölçer ve histogram analizi kullanılarak ortalama, maksimum, minimum, standart sapma gibi parametreler hesaplanır. Doku özellikleri ise piksellerin veya voxel'lerin düzenlenme biçimlerini ve bu düzenlemelerin istatistiksel özelliklerini içerir (Rizzo vd., 2018). İkinci ve daha yüksek dereceden özellikler, voxeller arasındaki mekansal ilişkileri değerlendirir ve enerji, entropi, homojenlik gibi dokusal parametreleri hesaplayarak doku paternlerinin karmaşıklığını belirler. Bu özellikler, özellikle tümörlerin heterojenliğini değerlendirmede önemli bir rol oynar (Zhang vd., 2022).

Bu çalışmada, meme ultrason görüntülerinden radyomik özelliklerin çıkarılması için açık kaynaklı bir Python kütüphanesi olan PyRadiomics kullanılmıştır. PyRadiomics, kullanıcıların özelleştirilebilir parametrelerle birçok farklı radyomik özelliği çıkarmasına olanak tanır (Van Griethuysen vd., 2017). Hem açık kaynaklı olması hem de istatistiksel güvenilirlik sağlaması nedeniyle tercih edilmiştir (Fornacon-Wood vd., 2020). Çalışmamızda, görüntülerle birlikte her bir görüntüye ait maske dosyaları kullanılarak toplamda 123 radyomik özellik çıkarılmıştır. Bu özellikler, tümörlerin doku yapısını, şekil bozukluklarını ve yoğunluk farklılıklarını daha hassas bir şekilde tanımlayarak, meme kanseri sınıflandırmasında kullanılan makine öğrenmesi algoritmalarına zengin veri sağlamıştır.

Çıkarılan bu özellikler, daha sonra analiz ve modelleme süreçlerinde kullanılmak üzere bir .csv dosyasına kaydedilmiştir.

Özellik Seçimi

Bu çalışmada, özellik seçimi için iki aşamalı bir yaklaşım benimsenmiştir: önemlilik skoru ve korelasyon matrisi. İlk aşamada, Scikit-learn kütüphanesi kullanılarak farklı sınıflandırıcılar için feature_importances_ veya coef_ öznelikleri aracılığıyla özelliklerin önem düzeyleri hesaplanmıştır. Bu sınıflandırıcılardan elde edilen önem skorları birleştirilerek her bir özellik için ortalama bir önemlilik skoru oluşturulmuştur. İkinci aşamada ise, Pandas kütüphanesi kullanılarak her bir özelliğin diğer özelliklerle olan ortalama korelasyonu hesaplanmış, bu da özellikler arasındaki bağımsızlık derecesini yansıtmıştır. Üçüncü aşamada, ilk iki aşamada elde edilen ortalama önemlilik skoru ve ortalama korelasyon değerleri matematiksel olarak birleştirilerek her bir özellik için bileşik bir puan hesaplanmıştır. Özelliklerin önemlilik skorları incelendiğinde, 0.02 değerinin üzerindeki ve altındaki özellikler arasında diğerlerine göre belirgin bir fark olduğu gözlemlenmiş ve bu nedenle eşik değer olarak 0.02 belirlenmiştir. Bu eşik değere göre özellikler sıralanmış ve bileşik puanı 0.02'nin üzerinde olan 40 özellik, 123 radyomik özellik arasından sınıflandırma işleminde kullanılmak üzere seçilmiştir. Böylece, daha az ancak etkili özelliklerle model eğitimi yapılarak hem hesaplama maliyeti hem de eğitim süresi önemli ölçüde azaltılmış ve daha verimli bir model elde edilmiştir. Tablo 1'de seçilen özelliklerin bir kısmı ve bu özelliklere karşılık gelen bileşik puan değerleri verilmiştir.

Tablo 1. Özellik Seçimi Aşamasından Sonra Seçilen Radyomik Özellikler ve Birleşik Puan Değerleri

Sıra	Radyomik Özellik Adı	Birleşik Puan Değeri	Sıra	Radyomik Özellik Adı	Birleşik Puan Değeri
1	original_shape2D_PixelSurface	0,109	6	original_glrIm_GrayLevelNon Uniformity	0,052
2	original_gldm_DependenceEntropy	0,082	.		
3	original_glrIm_ShortRunHighGrayLevel Emphasis	0,069	.		
4	original_glrIm_RunEntropy	0,065	39	original_firstorder_MeanAbsolute Deviation	0,0207
5	original_glcM_Idn	0,053	40	original_glszm_LargeAreaLowGray LevelEmphasis	0,0205
			41	original_glszm_SmallAreaEmphasis	0,0188

Makine Öğrenmesi

Bu çalışmada, veri setindeki radyomik özellikler kullanılarak iyi ve kötü huylu tümörlerin sınıflandırılmasında XGBoost, Gradient Boosting, AdaBoost, SVM, DT ve RF algoritmalarından yararlanılmıştır. Scikit-learn kütüphanesi kullanılarak veriler, %80 eğitim ve %20 test olacak şekilde ayrılmıştır. Modellerin performansını optimize etmek amacıyla, hiperparametreler GridSearch yöntemi ile belirlenmiştir. GridSearch, belirtilen hiperparametrelerin çeşitli kombinasyonlarını deneyerek çapraz doğrulama yöntemi ile en iyi parametre kombinasyonunu seçer. Bu yöntem, aşırı öğrenme (overfitting) ve eksik öğrenme (underfitting) risklerini azaltır ve modelin genelleme yeteneğini artırarak daha doğru tahminler yapmasını sağlar (Adnan vd., 2022).

XGBoost Algoritması

Tianqi Chen tarafından geliştirilen XGBoost (Extreme Gradient Boosting), gradient boosting framework'üne dayanan yüksek performanslı bir açık kaynak makine öğrenimi algoritmasıdır (Chen & Guestrin, 2016). XGBoost'un temel amacı, mevcut modelin hatalarını minimize edecek yeni modeller oluşturmaktır. İlk aşamada basit bir modelle tahmin yapılır ve bu modelin hataları (rezidüel) hesaplanır. Daha sonra, bu hataları azaltmaya yönelik olarak yeni karar ağaçları eklenir. Her eklenen karar ağacı, önceki modelin hatalarını öğrenir ve bu hataları gidermeye çalışır. Bu işlem, hatalar belirli bir seviyeye düşene veya belirli sayıda karar ağacı eklenene kadar devam eder. XGBoost, L1 ve L2 düzenleme teknikleriyle aşırı öğrenmeyi engeller ve paralel işleme, bellek optimizasyonları ile donanım hızlandırmaları sayesinde hızlı ve verimli çalışır. Algoritma, regresyon, sınıflandırma ve sıralama gibi çeşitli görevlerde üstün performans gösterir ve eksik veri noktalarını etkili bir şekilde işleyebilir. Özellikle yapılandırılmış veri setlerinde yüksek doğruluk sağlanmasıyla öne çıkar (Nielsen, 2016).

Gradient Boosting (GB) Algoritması

Tıpkı XGBoost'ta olduğu gibi, GB algoritması da gözetimli öğrenme kapsamında tahmin doğruluğunu artırmak için ardışık olarak zayıf öğrenicileri birleştirir (Friedman, 2001). Bu yöntem, başlangıçta basit bir modelle tahmin yapar, ardından modelin hataları hesaplanır ve bu hataları düzeltmek için yeni bir model eğitilerek eklenir. Her yeni model, önceki modelin hatalarını öğrenir ve gidermeye çalışır. Süreç boyunca kayıp fonksiyonunun gradyanı kullanılarak hatalar minimize edilir. Gradient Boosting, öğrenme oranı ve düzenleme (regularization) parametreleri ile aşırı öğrenmeyi önler. Bu algoritma, özellikle karmaşık sınıflandırma ve regresyon problemlerinde yüksek doğruluk ve esneklik sağlar (Natekin & Knoll, 2013).

SVM Algoritması

SVM, hem sınıflandırma hem de regresyon problemlerinde kullanılan güçlü bir denetimli öğrenme algoritmasıdır. SVM'nin temel prensibi, iki sınıfı en iyi şekilde ayıran bir hiper düzlem bulmaktır. Bu hiper düzlem, sınıflar arasındaki mesafeyi (margin) maksimize ederek, modelin genelleme yeteneğini artırır ve farklı veri kümelerinde daha iyi performans göstermesine olanak tanır. Hiper düzleme en yakın veri noktaları, destek vektörleri olarak adlandırılır ve modelin oluşturulmasında kritik bir rol oynarlar. Karmaşık veri kümeleri için SVM, çekirdek (kernel) fonksiyonlarını kullanarak veriyi daha yüksek boyutlu uzaylara projeler. Yaygın olarak kullanılan çekirdek fonksiyonları arasında lineer, polinomial, RBF (Radial Basis Function) ve sigmoid fonksiyonları bulunur. Bu fonksiyonlar, SVM'nin karmaşık yapıları tanımasına ve sınıflar arasındaki ayrımı daha esnek bir şekilde gerçekleştirmesine olanak sağlar (Pisner & Schnyer, 2020).

AdaBoost Algoritması

AdaBoost (Adaptive Boosting), sınıflandırma problemleri için geliştirilmiş bir topluluk öğrenme (ensemble learning) algoritmasıdır ve temel amacı, bir dizi zayıf öğreniciyi birleştirerek güçlü bir sınıflandırıcı oluşturmaktır (Schapire, 2013). AdaBoost, iteratif bir süreçle zayıf öğrenicileri eğitir ve her iterasyonda, önceki modellerin yanlış sınıflandırdığı örnekler daha fazla ağırlık verir. Böylece her yeni model, önceki modellerin hatalarını öğrenerek bunları minimize etmeye çalışır. Bu yaklaşım, zayıf öğrenicilerin bir araya getirilmesiyle güçlü bir sınıflandırıcı elde edilmesini sağlar. AdaBoost, genellikle az sayıda hiperparametre gerektirmesi ve aşırı öğrenmeye karşı dirençli olmasıyla öne çıkar. Ancak, dengesiz veri kümelerinde performansında düşüş gözlemlenebilir (Luo vd., 2024).

DT Algoritması

Karar Ağacı (DT), gözetimli öğrenme problemlerinde sınıflandırma ve regresyon görevleri için yaygın olarak kullanılan bir makine öğrenimi algoritmasıdır. GB, XGBoost, RF gibi ağaç tabanlı algoritmaların temelini oluşturur. Karar ağacı, veri kümesindeki özelliklerin değerlerine göre bir dizi karar düğümü ve yaprak düğümü aracılığıyla verileri bölerek tahminler yapar. Bu algoritma, veri kümesinin yapısını basit ve sezgisel bir şekilde temsil ederken, aynı zamanda yüksek derecede yorumlanabilir sonuçlar sağlar. Karar ağacı oluşturulurken, her bir özellik değeriyle ilişkilendirilen bir karar düğümü oluşturulur. Veri kümesindeki her bir özellik, karar ağacının bir düğümünü oluşturacak şekilde sırayla değerlendirilir. Bu değerlendirme, veri kümesini en iyi şekilde bölmek amacıyla bir bölme kriteri kullanılarak yapılır (Myles vd., 2004). Genellikle, bölme kriteri olarak bilgi kazancı (information gain) veya gini index (gini impurity) gibi ölçütler tercih edilir. Karar ağacı oluşturma süreci, veri kümesi tamamen bölünene kadar veya belirli bir ağaç derinliğine ulaşılan kadar devam eder. Bu süreç sonucunda, ağaç yapısı ortaya çıkar ve her yaprak düğümü bir sınıf etiketi veya regresyon değeri tahmin eder (Quinlan, 1996). Modelin eğitimi tamamlandığında, karar ağacı tahmin yapmak için kullanılabilir.

RF Algoritması

RF, gözetimli öğrenme alanında sıkça kullanılan bir topluluk (ensemble) öğrenme tekniğidir. Bu yöntem, birden fazla karar ağacının birleşiminden oluşan bir model kullanarak tahminler yapar. Her bir karar ağacı, veri kümesinin rastgele örneklemeleri ve rastgele seçilmiş özellik alt kümeleri üzerinde eğitilir. Bu rastgelelik, her ağacın farklı bir alt küme üzerinde eğitilmesini sağlar ve genellikle aşırı öğrenmeyi (overfitting) önler. Karar ağaçları genellikle tamamen büyütülmez; yani her bir ağaç, tüm veriyi değil, sadece bir alt küme veriyi ve bir alt küme özellikleri kullanarak eğitilir. Tahmin yaparken, her bir karar ağacının tahminleri birleştirilir. Bu genellikle sınıflar arasında oylama veya regresyon problemlerinde ortalama alma yoluyla gerçekleştirilir. Böylece, her bir ağacın hataları telafi edilerek topluluk olarak daha güçlü ve istikrarlı bir tahmin elde edilir (Ali vd., 2012, Oshiro vd., 2012).

DENEYSEL SONUÇLAR VE BULGULAR

Önerilen sınıflandırma algoritmalarının performansları, Doğruluk, Duyarlılık, Özgüllük, Kesinlik, F1-Score ve Matthews Correlation Coefficient (MCC) olmak üzere altı farklı metrikle değerlendirilmektedir. Bu metrikler, Eşitlik (1-6)'da verilen formüllerle hesaplanmaktadır. Bu metriklerin hesaplanmasında TP, TN, FP ve FN parametreleri kullanılır. TP, modelin gerçekten iyi huylu olarak sınıflandırdığı tümörlerin sayısını ifade eder. TN, modelin gerçekten kötü huylu olarak sınıflandırdığı tümörlerin sayısını belirtir. FP, modelin gerçekten iyi huylu olan ancak yanlış olarak kötü huylu olarak sınıflandırdığı tümörlerin sayısını gösterir. FN ise, modelin gerçekten kötü huylu olan ancak yanlış olarak iyi huylu olarak sınıflandırdığı tümörlerin sayısını belirtir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (3)$$

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (4)$$

$$\text{F1 - Score} = \frac{2 \times \text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (5)$$

$$\text{MCC} = \frac{(TP \times TN) - (FP \times FN)}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (6)$$

Eşitlik 6'daki MCC değeri denge ve doğruluğu tek bir sayı ile özetleyip, +1 mükemmel sınıflandırmayı, 0 rastgele tahminlemeyi ve -1 tamamen hatalı sınıflandırmayı göstermektedir.


Tablo 2'de, XGBoost, GB, SVM, Adaboost, DT ve RF algoritmalarının sınıflandırma performansları karşılaştırılmaktadır. En yüksek doğruluk %98.13 ile GB algoritması tarafından elde edilirken, XGBoost ve RF algoritmaları %98.02, SVM %97.90, DT %96.27 ve Adaboost %95.68 doğruluk değerlerine ulaşmıştır. GB algoritması, %98.61 duyarlılık ve 0.9627 MCC (Matthew's Correlation Coefficient) değeri ile sınıflar arasında güçlü bir denge kurarak yüksek performans sergilemiştir. Özgüllük değeri ve kesinlik açısından GB, XGBoost ve SVM benzer sonuçlar verirken, Adaboost'un özgüllük değerinde düşük performans sergilediği dikkat çekmektedir. F1-Score ve MCC gibi metriklerde elde edilen yüksek değerler, GB algoritmasının genel performansa önemli katkı sağladığını göstermektedir.

Tablo 2. Sınıflandırma Sonuçları


Model	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	Kesinlik (%)	F1-Score (%)	MCC
XGBoost	98,02	98,39	97,64	97,71	98,05	0,9603
GB	98,13	98,61	97,64	97,71	98,16	0,9627
SVM	97,90	98,38	97,41	97,48	97,93	0,9580
Adaboost	95,68	98,08	93,42	93,36	95,66	0,9148
DT	96,27	95,71	96,86	97,03	96,36	0,9254
RF	98,02	98,08	96,97	97,03	98,03	0,9605

Şekil 3'te yer alan karmaşıklık matrisi, en yüksek doğruluğa sahip GB algoritmasının sınıflandırma performansını detaylandırmaktadır. Yanlış pozitif ve yanlış negatif oranlarının oldukça düşük olduğu matriste, modelin tümör tiplerini ayırt etmede başarılı olduğu görülmektedir. Özellikle düşük yanlış negatif oranı, kötü huylu tümörlerin doğru şekilde tespit edildiğini ve modelin güvenilirliğini göstermektedir. Bu sonuç, GB algoritmasının duyarlılık ve özgüllük metriklerindeki yüksek performansı ile uyumludur.

GB algoritmasına ait ROC eğrisi Şekil 4'te verilmiştir. AUC değerinin 0.99 olması, modelin doğru pozitif ve doğru negatif tespitlerde başarılı olduğunu göstermektedir. Ayrıca, bu yüksek AUC değeri, GB algoritmasının sınıflandırma işlemlerinde doğru ve tutarlı sonuçlar sağladığını da ortaya koymaktadır.



Şekil 3. GB Algoritmasına Ait Karmaşıklık Matrisi



Şekil 4. GB Algoritmasına Ait ROC Eğrisi Grafiği

Tablo 3, önerilen yöntemin literatürde aynı veri setini kullanan çalışmalarla karşılaştırmasını sunmaktadır. Tabloya göre, önerilen çalışma, Mishra vd. (2021) ve Zhang vd. (2021) BUSI veri setinde iki sınıf (iyi huylu tümör ve kötü huylu tümör) üzerinden sınıflandırma gerçekleştirmektedir. Diğer yandan, Liu vd. (2022), Badawy vd. (2021) ve Eroğlu vd. (2021) çalışmalarında normal sınıfı da içeren üç sınıf üzerinden sınıflandırma yapılmıştır. İki sınıflı çalışmalarda, Mishra vd. (2021) %97.4 ve Zhang vd. (2021) %94.12 doğruluk oranı elde etmiştir. Üç sınıflı çalışmalarda ise Liu vd. (2022) %97.18, Badawy vd. (2021) %96.27 ve Eroğlu vd. (2021) %95.6 doğruluk oranlarına ulaşmıştır. Önerilen yöntem, iki sınıf (iyi huylu tümör ve kötü huylu tümör) kullanarak %98.13 doğruluk oranı elde etmiştir. Bu sonuç, önerilen yönteminin hem iki sınıflı hem de üç sınıflı çalışmalara kıyasla daha yüksek doğruluk değerine ulaştığını ve böylece klinik uygulamalar için geçerliliğini artırdığını göstermektedir. AUC değerleri incelendiğinde, önerilen yöntemin Eroğlu vd. (2021) çalışmasıyla aynı AUC değerine (0.99) ulaştığı görülmektedir. Diğer çalışmalara kıyasla elde edilen yüksek AUC değeri, önerilen yöntemin sınıf sayısının ikiye indirilmesi ve tümör tiplerine odaklanması sayesinde sağlanmıştır; böylece sınıflandırmada yanlış pozitif oranı azaltılmıştır. Bu durum, doğru teşhis ve tedavi planlaması açısından önemli bir avantaj sunmaktadır.

SONUÇLAR VE TARTIŞMA

Meme kanseri, dünya genelinde kadınlar arasında en sık rastlanan kanser türlerinden biri olup, erken teşhis yaşam süresi ve yaşam kalitesini önemli ölçüde artırmaktadır. Ancak, meme kanserinin erken evrelerde tespiti, belirtilerin genellikle belirgin olmaması ve yanlış pozitif ya da yanlış negatif sonuçların yaygınlığı nedeniyle zorlu bir süreçtir.

Bu çalışmada, literatürdeki birçok çalışmadan farklı olarak, yalnızca meme ultrason görüntülerinde yer alan iyi huylu ve kötü huylu tümörlerin sınıflandırılmasına odaklanılmıştır. Bu sayede tanı sürecinin hassasiyeti artırılarak, tedavi planlamalarında daha net ve kesin sonuçlar elde edilmesi amaçlanmaktadır. Çalışmada kullanılan BUSI veri setindeki sınıf dengesizliğini gidermek için aynalama tekniği uygulanmıştır. Her bir görüntüden 123 radyomik özellik çıkarılmış ve bu özelliklerin sınıflama üzerindeki etkilerini değerlendirmek için önem skoru ve korelasyon analizi gibi yöntemler kullanılmıştır. Analiz sonucunda, 123 özellik arasından en anlamlı 40 özellik seçilmiştir. Sınıflandırma aşamasında, 6 farklı makine öğrenmesi algoritması değerlendirilmiş ve GB algoritması en yüksek doğruluk oranı olan %98.13'ü sağlamıştır. Bu bulgular, radyomik özelliklerin ve makine öğrenimi tekniklerinin meme kanseri teşhis ve sınıflandırma süreçlerinde önemli bir potansiyele sahip olduğunu ortaya koymaktadır.

Tablo 3. Önerilen Yöntemin Literatürdeki Bazı Çalışmalarla Karşılaştırılması

Çalışma	Veri Seti	Sınıf Sayısı	Önerilen Yöntem	Doğruluk (%)	AUC
Mishra vd. (2021)	BUSI	2 (iyi huylu tümör, kötü huylu tümör)	Radyomik Özellik Seçimi + Adaboost	97,4	0,962
Liu vd. (2022)	BUSI	3 (iyi huylu tümör, kötü huylu tümör, normal)	İteratif komşuluk bileşeni analizi (INCA) + CNN	97,18	-
Badawy vd. (2021)	BUSI	3 (iyi huylu tümör, kötü huylu tümör, normal)	Resnet101	96,27	-
Eroğlu vd. (2021)	BUSI	3 (iyi huylu tümör, kötü huylu tümör, normal)	CNN + SVM	95,6	0,99
Zhang vd. (2021)	BUSI	2 (iyi huylu tümör, kötü huylu tümör)	Yumuşak ve sert dikkat çoklu görev öğrenme modeli	94,12	0,9628
Bu çalışma	BUSI	2 (iyi huylu tümör, kötü huylu tümör)	Radyomik Özellik Seçimi + GB	98,13	0,99

Gelecekteki araştırmalarda, daha büyük ve çeşitli veri setlerinin kullanımı, modelin farklı tümör tiplerini daha etkili bir şekilde sınıflandırmasını ve genel performansını artırmasını sağlayabilir. Ayrıca, gelişmiş özellik seçimi ve boyut indirgeme yöntemlerinin uygulanması, modelin doğruluğunu ve hesaplama verimliliğini iyileştirebilir. Diğer makine öğrenmesi yöntemlerinin ve hibrit yaklaşımların değerlendirilmesi de mevcut sonuçların daha da geliştirilmesine katkıda bulunabilir. Y-ekseni boyunca aynalama tekniği, veri dengesizliğini gidermede etkili bir yöntem olmasına rağmen, yalnızca mevcut görüntülerin simetrik versiyonlarını ürettiği için veri çeşitliliğini artırma kapasitesi kısıtlıdır. Bu sınırlamaları aşmak ve modelin genelleme yeteneğini artırmak amacıyla, dengesiz veri setlerinde daha etkili çözümler sunabilen gelişmiş veri artırma teknikleri, örneğin Generative Adversarial Networks (GAN), kullanılabilir.

KAYNAKLAR

- Adnan, M., Alarood, A. a. S., Uddin, M. I., & Rehman, I. U. (2022). Utilizing grid search cross-validation with adaptive boosting for augmenting performance of machine learning models. *PeerJ. Computer Science*, 8, e803. <https://doi.org/10.7717/peerj-cs.803>
- Al-Dhabyani, W., Gomaa, M., Khaled, H., & Fahmy, A. (2020). Dataset of breast ultrasound images. *Data in Brief*, 28, 104863. <https://doi.org/10.1016/j.dib.2019.104863>
- Ali, J., Khan, R., Ahmad, N., & Maqsood, I. (2012). Random forests and decision trees. *International Journal of Computer Science Issues*, 9(5), 272–278. <http://ijcsi.org/papers/IJCSI-9-5-3-272-278.pdf>
- Ara, S., Das, A., & Dey, A. (2021, April). Malignant and benign breast cancer classification using machine learning algorithms. In 2021 International Conference on Artificial Intelligence (ICAI) (pp. 97-101). IEEE.
- Ardakani, A. A., Bureau, N. J., Ciaccio, E. J., & Acharya, U. R. (2022). Interpretation of radiomics features—A pictorial review. *Computer Methods and Programs in Biomedicine*, 215, 106609. <https://doi.org/10.1016/j.cmpb.2021.106609>
- Aristokli, N., Polycarpou, I., Themistocleous, S. C., Sophocleous, D., & Mamais, I. (2022). Comparison of the diagnostic performance of Magnetic Resonance Imaging (MRI), ultrasound and mammography for detection of

- breast cancer based on tumor type, breast density and patient's history: A review. *Radiography*, 28(3), 848–856. <https://doi.org/10.1016/j.radi.2022.01.006>
- Assiri, A. S., Nazir, S., & Velastin, S. A. (2020). Breast tumor classification using an ensemble machine learning method. *Journal of Imaging*, 6(6), 39. <https://doi.org/10.3390/jimaging6060039>
- Badawy, S. M., Mohamed, A. E. N. A., Hefnawy, A. A., Zidan, H. E., GadAllah, M. T., & El-Banby, G. M. (2021, July). Classification of Breast Ultrasound Images Based on Convolutional Neural Networks-A Comparative Study. In 2021 International Telecommunications Conference (ITC-Egypt) (pp. 1-8). IEEE.
- Bota, M. A., Gota, D. I., Bota, P., Stan, O. P., Pop, A., Fanca, A., ... & Miclea, L. (2024, February). Utilizing Transfer Learning-Based Algorithms for Breast Ultrasound Data in Multi-Instance Classification. In 2024 International Conference on Artificial Intelligence, Computer, Data Sciences and Applications (ACDSA) (pp. 1-6). IEEE.
- CERR. (n.d.). CERR: Computational Environment for Radiotherapy Research. Retrieved September 4, 2024, from <https://cerr.github.io/CERR/>
- Chen, T., & Guestrin, C. (2016, August). Xgboost: A scalable tree boosting system. In Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining (pp. 785-794).
- Çapkan, H., Dönmez, B., Kalkan, G. M., Kaya, M. Z., Gürel, S., Akdağlı, E., ... & Uçar, M. K. (2022). Diagnosis of Breast Cancer with Hybrid Artificial Intelligence Method. *Avrupa Bilim ve Teknoloji Dergisi*, (42), 14-19.
- Eroğlu, Y., Yildirim, M., & Çınar, A. (2021). Convolutional Neural Networks based classification of breast ultrasonography images by hybrid method with respect to benign, malignant, and normal using mRMR. *Computers in Biology and Medicine*, 133, 104407. <https://doi.org/10.1016/j.combiomed.2021.104407>
- Fornacon-Wood, I., Mistry, H., Ackermann, C. J., Blackhall, F., McPartlin, A., Faivre-Finn, C., ... & O'Connor, J. P. (2020). Reliability and prognostic value of radiomic features are highly dependent on choice of feature extraction platform. *European Radiology*, 30(12), 6241-6250. <https://doi.org/10.1007/s00330-020-06957-9>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5). <https://doi.org/10.1214/aos/1013203451>
- Ghabrim, H., Essid, C., & Sakli, H. (2023, February). A diagnostic system for classifying and segmenting breast cancer based on ultrasound images. In 2023 20th International Multi-Conference on Systems, Signals & Devices (SSD) (pp. 919-924). IEEE.
- Gupta, S., Panwar, A., Yadav, R., Aeri, M., & Manwal, M. (2022, February). Employing Deep Learning Feature Extraction Models with Learning Classifiers to Diagnose Breast Cancer in Medical Images. In 2022 IEEE Delhi Section Conference (DELCON) (pp. 1-6). IEEE.
- Hussain, Z., Gimenez, F., Yi, D., & Rubin, D. (2017). Differential data augmentation techniques for medical imaging classification tasks. *AMIA annual symposium proceedings*, 2017, 979-984.
- Jabeen, K., Khan, M. A., Alhaisoni, M., Tariq, U., Zhang, Y. D., Hamza, A., Khalid, A., Kumar, S., Awais, M., Ali, M., & Damaševičius, R. (2022). Breast cancer classification from ultrasound images using probability-based optimal deep learning feature fusion. *Sensors*, 22(3), 807. <https://doi.org/10.3390/s22030807>
- Khanna, P., Sahu, M., & Singh, B. K. (2021, December). Improving the classification performance of breast ultrasound image using deep learning and optimization algorithm. In 2021 IEEE International Conference on Technology, Research, and Innovation for Betterment of Society (TRIBES) (pp. 1-6). IEEE.
- Kumar, V., Gu, Y., Basu, S., Berglund, A., Eschrich, S. A., Schabath, M. B., Patil, D. C., Little, R. B., Tsien, C. I., & Gillies, R. J. (2012). Radiomics: The process and the challenges. *Magnetic Resonance Imaging*, 30(9), 1234-1248. <https://doi.org/10.1016/j.mri.2012.06.010>
- Lanjewar, M. G., Panchbhai, K. G., & Patle, L. B. (2024). Fusion of transfer learning models with LSTM for detection of breast cancer using ultrasound images. *Computers in Biology and Medicine*, 169, 107914. <https://doi.org/10.1016/j.combiomed.2023.107914>
- LIFEx. (n.d.). LIFEx: Lesion imaging feature extraction. Retrieved September 4, 2024, from <https://www.lifexsoft.org/>

- Liu, H., Cui, G., Luo, Y., Guo, Y., Zhao, L., Wang, Y., . . . Tuncer, T. (2022). Artificial Intelligence-Based breast cancer diagnosis using ultrasound images and Grid-Based Deep Feature Generator. *International Journal of General Medicine, Volume 15*, 2271–2282. <https://doi.org/10.2147/ijgm.s347491>
- Luo, J., Quan, Y., & Xu, S. (2024). Robust-GBDT: GBDT with nonconvex loss for tabular classification in the presence of label noise and class imbalance. arXiv. <https://arxiv.org/abs/2310.05067>
- Medical Imaging Interaction Toolkit. (n.d.). The Medical Imaging Interaction Toolkit (MITK). Retrieved September 4, 2024, from [https://www.mitk.org/wiki/The_Medical_Imaging_Interaction_Toolkit_\(MITK\)](https://www.mitk.org/wiki/The_Medical_Imaging_Interaction_Toolkit_(MITK))
- Mishra, A. K., Roy, P., Bandyopadhyay, S., & Das, S. K. (2021). Breast ultrasound tumour classification: A Machine Learning—Radiomics based approach. *Expert Systems, 38*(7). <https://doi.org/10.1111/exsy.12713>
- Myles, A. J., Feudale, R. N., Liu, Y., Woody, N. A., & Brown, S. D. (2004). An introduction to decision tree modeling. *Journal of Chemometrics, 18*(6), 275–285. <https://doi.org/10.1002/cem.873>
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in neurorobotics, 7*, 21. <https://doi.org/10.3389/fnbot.2013.00021>
- Nielsen, D. (2016). Tree Boosting With XGBoost. Master's thesis. Norwegian University of Science and Technology, Trondheim 98s.
- Oshiro, T. M., Perez, P. S., & Baranauskas, J. A. (2012). How many trees in a random forest?. In Machine Learning and Data Mining in Pattern Recognition: 8th International Conference, MLDM 2012, Berlin, Germany, July 13-20, 2012. Proceedings 8 (pp. 154-168). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-642-31537-4_13
- Pesapane, F., De Marco, P., Rapino, A., Lombardo, E., Nicosia, L., Tantrige, P., Sardanelli, F., Manfredi, R., Bertelli, E., Castello, R., & Cassano, E. (2023). How radiomics can improve breast cancer diagnosis and treatment. *Journal of Clinical Medicine, 12*(4), 1372. <https://doi.org/10.3390/jcm12041372>
- Pisner, D. A., & Schnyer, D. M. (2020). Support vector machine. In *Machine learning* (pp. 101-121). Academic Press. <https://doi.org/10.1016/B978-0-12-815739-8.00006-7>
- Podda, A. S., Balia, R., Barra, S., Carta, S., Fenu, G., & Piano, L. (2022). Fully-automated deep learning pipeline for segmentation and classification of breast ultrasound images. *Journal of Computational Science, 63*, 101816. <https://doi.org/10.1016/j.jocs.2022.101816>
- Pourasad, Y., Zarouri, E., Parizi, M. S., & Mohammed, A. S. (2021). Presentation of novel architecture for diagnosis and identifying breast cancer location based on ultrasound images using Machine learning. *Diagnostics, 11*(10), 1870. <https://doi.org/10.3390/diagnostics11101870>
- Quinlan, J. R. (1996). Learning decision tree classifiers. *ACM Computing Surveys (CSUR), 28*(1), 71-72.
- Rashid, H. U., Ibrikci, T., Paydaş, S., Binokay, F., & Çevik, U. (2022). Analysis of breast cancer classification robustness with radiomics feature extraction and deep learning techniques. *Expert Systems, 39*(8), e13018. <https://doi.org/10.1111/exsy.13018>
- Rizzo, S., Botta, F., Raimondi, S., Origgi, D., Fanciullo, C., Morganti, A. G., & Bellomi, M. (2018). Radiomics: the facts and the challenges of image analysis. *European Radiology Experimental, 2*(1). <https://doi.org/10.1186/s41747-018-0068-z>
- Şenol, A., & Kaya, M. (2024). An investigation on the use of clustering algorithms for data preprocessing in breast cancer diagnosis. *Türk Doğa ve Fen Dergisi, 13*(1), 70-77. <https://doi.org/10.46810/tdfd.1364397>
- Schapire, R. E. (2013). Explaining AdaBoost. In Springer eBooks (pp. 37–52). https://doi.org/10.1007/978-3-642-41136-6_5
- Sun, H., Li, H., Si, S., Qi, S., Zhang, W., Ma, H., Chen, X., Liu, Y., Yang, J., Zhang, X., & Qian, W. (2018). Performance evaluation of breast cancer diagnosis with mammography, ultrasonography, and magnetic resonance imaging. *Journal of X-ray Science and Technology, 26*(5), 805-813. doi: <https://doi.org/10.3233/xst-18388>
- Van Griethuysen, J. J., Fedorov, A., Parmar, C., Hosny, A., Aucoin, N., Narayan, V., . . . Aerts, H. J. (2017). Computational Radiomics system to decode the radiographic phenotype. *Cancer Research, 77*(21), e104–e107. <https://doi.org/10.1158/0008-5472.can-17-0339>

World Health Organization (WHO). (2024, Eylül 4). Breast cancer. <https://www.who.int/news-room/fact-sheets/detail/breast-cancer>

Zhang, G., Zhao, K., Hong, Y., Qiu, X., Zhang, K., & Wei, B. (2021). SHA-MTL: Soft and hard attention multi-task learning for automated breast cancer ultrasound image segmentation and classification. *International Journal of Computer Assisted Radiology and Surgery*, 16(12), 1719-1725. <https://doi.org/10.1007/s11548-021-02445-7>

Zhang, W., Guo, Y., & Jin, Q. (2023). Radiomics and its feature selection: A review. *Symmetry*, 15(10), 1834. <https://doi.org/10.3390/sym15101834>

Zhang, X., Zhang, Y., Zhang, G., Qiu, X., Tan, W., Yin, X., & Liao, L. (2022). Deep learning with radiomics for disease diagnosis and treatment: Challenges and potential. *Frontiers in Oncology*, 12, 773840. <https://doi.org/10.3389/fonc.2022.773840>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 12.07.2024
Kabul Tarihi : 04.10.2024

Received Date : 12.07.2024
Accepted Date : 04.10.2024

KAFATASI KIRIKLARININ TEŞHİSİNDE YAPAY ZEKÂ: GÜNCEL DERİN ÖĞRENME MİMARİ PERFORMANSLARI

ARTIFICIAL INTELLIGENCE IN SKULL FRACTURE DIAGNOSIS: CURRENT DEEP LEARNING ARCHITECTURE PERFORMANCES

Fidan KAYA GÜLAĞIZ^{1*} (ORCID: 0000-0003-3519-9278)

Tuğrul Hakan GENÇTÜRK¹ (ORCID: 0000-0002-2736-271X)

İsmail KAYA² (ORCID: 0000-0002-4128-5845)

¹ Kocaeli Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye

² Niğde Ömer Halis Demir Üniversitesi, Tıp Fakültesi, Beyin Cerrahisi Bölümü, Niğde, Türkiye

*Sorumlu Yazar / Corresponding Author: Fidan KAYA GÜLAĞIZ, fidan.kaya@kocaeli.edu.tr

ÖZET

Kafa travmaları, ciddi sonuçlara yol açabilen ve etkileri uzun yıllar sürebilecek sağlık sorunlarından biridir. Teşhis, ilk aşamada nörolojik muayene ile başlar ve gerektiğinde bilgisayarlı tomografi (BT) kullanılır. Kafatası kırıkları, diğer kafa travmalarına göre daha ciddi hasarlara eşlik ederler ve sıkça görülür. Özellikle ilk müdahalenin pratisyen hekimler ve acil uzmanları tarafından yapılması, BT görüntülerinin yorumlanmasında uzmanlık ve destek gerektirir. Bu noktada, özellikle ilk teşhis ve tanı aşamasında hekimlere destek olacak yapay zeka tekniklerinin varlığı büyük bir önem taşımaktadır. Bu çalışmada kafatası kırığının tespiti için kullanılabilecek dört farklı mimarinin alt modelleriyle birlikte kapsamlı bir karşılaştırması yapılmıştır. Bu amaçla Verimli Sinir Ağı (EfficientNet), Artık Ağlar (ResNet), Residual Networks with Aggregated Residual Transformations (ResNeXt) ve Maximum Vision Transformer (MaxVit) mimarileri çalışmaya dahil edilmiştir. Modellerin kafatası kırığını sınıflandırma açısından başarısı çalışmaya özgü olarak toplanan kapsamlı ve güncel bir veri kümesi üzerinden gösterilmiştir. Deneysel sonuçlar ile hem hangi yöntemin kafatası kırığı açısından daha uygun ve doğru sonuçlar verdiği ortaya konulmuş hem de güncel derin öğrenme mimarilerinin bu alandaki durumu özetlenmiştir.

Anahtar Kelimeler: BT, derin öğrenme, kafatası kırığı, sınıflandırma.

ABSTRACT

Cranial injuries are one of the health issues that can lead to serious consequences and have effects that may last for many years. Diagnosis begins with a neurological examination in the initial stage and employs computed tomography (CT) when necessary. Skull fractures are more frequently accompanied by severe injuries compared to other types of head trauma and are commonly observed. The initial intervention is often performed by general practitioners and emergency specialists, necessitating expertise and support in interpreting CT images. At this point, the presence of artificial intelligence techniques to assist physicians, particularly during the initial diagnosis and evaluation stages, is of significant importance. In this study, a comprehensive comparison of four different architectures that can be used for skull fracture detection has been made together with their sub-models. For this purpose, Efficient Neural Network (EfficientNet), Residual Network (ResNet), Residual Networks with Aggregated Residual Transformations (ResNeXt) and Maximum Vision Transformer (MaxVit) architectures are included in the study. The success of the models in terms of skull fracture classification is demonstrated on a comprehensive and up-to-date dataset collected specifically for the study. With the experimental results, both which method is more appropriate and accurate for skull fracture classification and the state of the art of current deep learning architectures in this field are summarized.

Keywords: CT, deep learning, skull fracture, classification.

GİRİŞ

Günümüzde artan nüfus ve yaşantımızın kompleksleşmesi ile birlikte kafa travmaları önemli bir sağlık sorunu haline gelmiştir (Brain Trauma Foundation, 2024). Kafa travmaları, genel vücut travmalarının yaklaşık %11'ini oluşturur (Maconochie & Ross, 2007). Bu travmaların uzun vadeli etkileri, bireylerin yaşam kalitesini düşürmekte ve sağlık sistemine ciddi bir yük getirmektedir (Türkiye Cumhuriyeti Sağlık Bakanlığı, 2024). Kafa travmaları içinde kafatası kırıkları %74.6 oranında görülür (Sehlikoğlu vd., 2024). Kafa kemiklerinin kırıkları, korudukları nöral yapılar nedeniyle ciddi sonuçlar doğurabilecek travmalardır (Sehlikoğlu vd., 2024). Günümüz tıp pratiğinde, kafa kemiklerinin cerrahi müdahale gerektirmeyen kırıkları bile en azından hastane yatışı ve takibi gerektirir (Greenberg, 2010). Atlanmaları halinde kanamalar, beyin hasarları, epilepsi ve kistlere neden olabilirler (Greenberg, 2010). Bu nedenle, kırıkların tespit edilmesi büyük önem taşır.

Günümüzde kafatası kırıklarının görüntülenmesi için kullanılan bilgisayarlı tomografi (BT) cihazlarının sayısı artsa da, bu yöntemlerin yorumlanması uzmanlık gerektiren bir süreçtir (Türkiye Ministry of Health Expert Board in Medicine, 2024). Mevcut durumda, radyolog sayısının yetersizliği nedeniyle iş yükü yeterince karşılanamamaktadır (Türkiye Ministry of Health Expert Board in Medicine, 2024). Bu durum özellikle yoğun iş yükünde hızlı karar verme gerektiren teşhis ile tedavide gecikmelere, dolayısıyla mortalite ve morbidite oranlarının artmasına neden olmaktadır (Wallis & McCoubrie, 2011). Bu sebeple, otomatik raporlama sistemlerinin geliştirilmesi büyük önem taşımaktadır (Kaya vd., 2023).

İnternet kullanımının her geçen gün daha da yaygınlaşması ve teknolojideki hızlı gelişim beraberinde hem veri kaynaklarının, dolayısıyla veri türlerinin çeşitlenmesini hem de veri miktarlarının artmasını getirmiştir. Bu denli büyük miktarlara ulaşan verinin içerisinde elde edilebilecek faydalı bilgilerin varlığı insanların dikkatini çekmiştir. Bu nedenle bu alanda yıllardır hem kullanılabilir yeni modeller / mimariler hem de altyapı araştırmaları devam etmektedir. İstatistiksel teknikler kullanılarak verinin anlamlandırılması ile başlayan süreç el yapımı özelliklerin işlendiği makine öğrenmesi teknikleri ile devam etmiş ve günümüzde de özellik çıkarma sürecini otomatize eden derin öğrenme teknikleri ile gelişmesini sürdürmektedir. Özellikle derin öğrenme teknikleri sayesinde yalnızca yapılandırılmış formda bulunan veriler değil yapılandırılmamış ya da yarı yapılandırılmış formdaki veriler de işlenebilir ve anlamlandırılabilir hale gelmiştir. Bu alanda işlenebilir olarak karşımıza çıkan verilerden en dikkat çekenleri görüntü, video ve ses verileridir. Özellikle görüntü formundaki verilerin işlenebilir hale gelmesi tıp alanında pek çok farklı probleme özgü olarak geliştirilen modellerin de çıkış kaynağı olmuştur.

Tıp alanında teşhis aşamasında en yaygın kullanılan görüntüleme türleri BT ve MR'dır. MR, BT'ye göre çok daha detaylı görüntüleme sunsa da maliyet, manyetik özelliklerde implant bulduran hastalarda çekilememesi, kemik patolojilerde yetersiz olması ve uzun çekim süresince hareketsizlik gerektirmesi gibi sebeplerle travmalarda kullanımı uygun değildir (Greenberg, 2010). Bu nedenle ilk teşhis aşamasında BT görüntülerinin anlamlandırılması çok önemlidir. Derin öğrenme modelleri arasında görüntüleri girdi olarak alıp işleyebilen konvolüsyonel ağlar BT görüntülerini işleyebilmekte ve teşhis aşamasında pek çok farklı tıp alanında başarılı sonuçlar vermektedir.

Kafatası kırıklarının tespiti konusunda da BT, uzmanlar tarafından kullanılan en hızlı ve en etkili yöntemdir (Lin vd., 2022; Choi vd., 2022). Ancak kafatası kırıklarının çoğunluğunun piksel bazında değerlendirildiğinde küçük boyutlu olması ve kırık şekillerinin çeşitliliği, kafatası kırıklarının tespitini zorlaştırmaktadır (Lin vd., 2022). Bu nedenle uzmanlar bu alanda yapay zeka destekli teşhis ve tanı sistemlerine ihtiyaç duymaktadırlar. Literatürde bu alanda yapılan erken zamanlı çalışmalar (Zaki vd., 2008; Wan Zaki vd., 2009; Abubacker vd., 2013; Yamada vd., 2016; Yamada vd., 2018; Shao & Zhao, 2003) incelendiğinde yöntemlerin daha çok görüntü işleme teknikleri ile elde edilen ve el yapımı olarak adlandırılan özellikler ile tespit yapmaya çalıştıkları gözlemlenmiştir. Ancak bu modeller özellikle kafatasının karmaşık yapısı ve kırıkların irili ufaklı çok farklı yapılarda karşımıza çıkabilmesi gibi gerekçelerle yetersiz kalmaktadır (Lin vd., 2022). Derin ağlar bu sorunları ortadan kaldırarak özellik tespiti sürecini otomatize etmekte ve kırık bölgesini daha detaylı analiz edebilmemizi sağlayan çok daha fazla sayıda özelliği otomatik olarak çıkarmaktadır. Son yıllarda kafatası kırığı tespiti amacıyla BT görüntüleri üzerinden derin ağlar kullanılarak yapılan çalışmalar incelendiğinde kısıtlı sayıda çalışma olduğu tespit edilmiştir. Bu durumun en temel sebeplerinden bir tanesi bu alanda yeterli sayıda kullanıma açık etiketli veri kümesinin olmamasıdır.

Beyin hasarlarının tespiti konusunda bilinen en yaygın açık veri kümesi CQ500 ve Qure25k veri kümeleridir (Chilamkurthy vd., 2018). Bu veri kümeleri 5 farklı merkezden toplanmış sırasıyla 491 ve 21095 tarama içermektedir. Veri kümeleri içerisinde kırık içeren tarama sayısı Qure25k için 992 iken CQ500 için toplam 34 olarak listelenmiştir.

Aynı zamanda bu kırıklar sadece kafatası kırıkları türündedir. Veri kümelerinin elde edildiği bu çalışmada (Chilamkurthy vd., 2018) kafatası kırıklarının tespiti için DeepLab ve Random Forest teknikleri kullanılmıştır. Qure25k veri kümesinde 0.9244 eğrinin altında kalan alan (AUC) değeri elde edilirken, CQ500 veri kümesinde 0.9624 AUC değeri elde edilmiştir. Lin ve arkadaşları (Lin vd., 2022) tarafından kafatası kırıklarının el yapımı özellikler kullanılarak tespitinde karşılaşılan sorunların etkisini azaltmaya yönelik iki aşamalı bir bölgesel evrimsel sinir ağı (R-CNN) temelli yöntem tasarlanmıştır. Önerilen yöntem çalışmaya özgü olarak toplanan 110 hastaya ait BT görüntüleri üzerinden test edilmiştir ve Intersection over Union (IOU) değeri 0.5 alındığında ortalama kesinlik (AP) değeri 0.5388 olarak elde edilmiştir. Shan ve arkadaşları (Shan vd., 2021) tarafından gerçekleştirilen başka bir çalışmada YOLOv3 ve Modified attention U-net mimarileri kullanılarak kafa kırığı tespiti yapılmaya çalışılmıştır. Kafatası kırığı tanısı alan 4.782 hastanın BT taramaları kullanılarak gerçekleştirilen çalışmada YOLOv3 algoritması ile % 85.96 doğruluk, Modified attention U-net ile ise % 88.26 doğruluk değeri elde edilmiştir.

Kranial patolojilerin tespiti için gerçekleştirilen başka bir derin ağ temelli çalışmada (Guo vd., 2022) her bozukluk türünü sınıflandırmak için omurgası Artık Ağlar-18 (ResNet-18) olan ayrı bir konvolüsyonel sinir ağı ve sınırlandırıcı için ise iki katmanlı, tam bağlantılı bir ağ tasarlanmıştır. Tasarlanan bu mimari 4 farklı veri kümesi (retrospektif, prospektif, merkezler arası ve açık bir veri seti (CQ500)) üzerinde test edilmiştir. Veri kümeleri üzerinden kırık tespiti için elde edilen AUC değerleri sırasıyla 0.982, 0.978, 0.958, 0.971 olarak belirlenmiştir. Hem kafatası hem de yüz kemik kırıklarının tespiti için gerçekleştirilen farklı bir çalışmada (Wang vd., 2023) kırık tespiti için YOLOv4 ve kafatası ile yüz kemiklerinin segmentasyonu için ResUNet++ mimarisi kullanılmıştır. Eğitim ve test verileri iki farklı üçüncü seviye travma hastanesinden toplanmıştır. Kafatası kırıklarının tespitinde doğruluk değeri 0.8958 ve 0.8864 F1 skoru elde edilmiştir. Mangrulkar ve arkadaşlarının çalışmasında (Mangrulkar vd., 2021) giriş kafa görüntüsünden otomatik hasar tespiti için birleşik bir derin öğrenme modeli önerilmiştir. Çalışmada evrimsel sinir ağı (CNN) kullanılarak çıkarılan özellikler uzun kısa süreli bellek (LSTM) modeli ile sınıflandırılmıştır. Önerilen derin öğrenme modeli manuel olarak çıkarılan özellikler kullanılarak destek vektör makinesi (SVM), yapay sinir ağı (ANN) ve Naive Bayes sınıflandırıcıları ile sınıflandırılmıştır. Son olarak derin öğrenme modelinin sonuçları makine öğrenmesi modelleriyle karşılaştırılmıştır. Önerilen CNN-LSTM modeli 98.33 doğruluk oranıyla en yüksek başarıya sahip olmuştur. Çalışma kapsamında kullanılan veri kümesi ise 125 tanesi normal 355 tanesi hasarlı toplam 480 adet 3 boyutlu kafatası modelinden oluşmaktadır. Son olarak 2022 yılında akut travmatik beyin hasarlarının tespiti konusunda gerçekleştirilen bir derleme çalışmasında (Lin & Yuh, 2022) kafatası kırığı tespitinin diğer beyin hasarlarına nispeten daha zor olduğu bu nedenle bu alanda kısıtlı sayıda çalışma bulunduğu bahsedilmiştir. Bunlara ek olarak bu konuda gerçekleştirilen çalışmaların henüz ön çalışma aşamasında olduğu ve nispeten küçük veri kümeleri ile yapıldığı vurgulanmıştır.

Mevcut çalışmalar genel olarak değerlendirildiğinde hem yetersiz veri kümeleri hem de kafatası kırık tespiti probleminin diğer kafatası problemlerine göre zorlu olması sebebiyle sınırlı sayıda çalışma mevcuttur. Mevcut çalışmalar ise daha çok hibrit yöntemler üzerinden ilerlemektedir ancak son zamanlarda popüler olan CNN temelli model/mimarileri kapsamlı şekilde karşılaştıran ve modellerin bu alandaki güncel başarısını gösteren bir çalışmaya rastlanmamıştır. Bu nedenle çalışma kapsamında kafatası kırığının tespiti amacıyla kapsamlı bir veri kümesi oluşturulmuştur ve bu veri kümesi üzerinde Verimli Sinir Ağı (EfficientNet), ResNet, Residual Networks with Aggregated Residual Transformations (ResNeXt) ve Maximum Vision Transformer (MaxVit) mimarileri farklı alt modelleriyle kapsamlı şekilde karşılaştırılmıştır.


Çalışmanın geri kalanı şu şekilde organize edilmiştir. Çalışmanın gereç ve yöntemler bölümünde kullanılan mimari / modeller, veri kümesi ve değerlendirme metrikleri detaylı şekilde açıklanmıştır. Sonraki bölümde deneysel çalışmaya yer verilmiştir. Deneysel sonuçların yorumlandığı ve ileriye yönelik çalışmalardan bahsedildiği tartışma ve sonuçlar bölümüyle makale sonlandırılmıştır.

GEREÇ VE YÖNTEMLER

Makalenin bu bölümünde ilk olarak kafatası kırıklarının tespiti amacıyla oluşturulan kapsamlı veri kümesi açıklanmıştır. İkinci alt bölümde sırasıyla EfficientNet, ResNet, ResNeXt ve MaxVit mimarileri ve bu mimarilerin alt modellerinin farkları verilmiştir. Üçüncü alt bölümde de yöntemlerin değerlendirilmesinde kullanılan metrikler formülleriyle detaylı olarak açıklanmıştır.

Veri Kümesi

Niğde Ömer Halisdemir Üniversitesi'nden alınan 2023/77 Protokol numaralı girişimsel olmayan klinik araştırmalar etik kurul kararı ardından 1.12.2023 ile 31.5.2024 arasında rastgele travma nedenleriyle hastaneye başvuran 550 hastanın kranial BT görüntüleri anonim hale getirilerek toplandı. Hastaların demografik verilerinin kranial BT'de kemik değerlendirme açısından önemi olmadığından incelenmemiştir. Toplanan hasta verilerinden 1476 adet tarama görüntüsü kafatası kırığı içermektedir. Bu nedenle 1476 kafatası kırığı içeren görüntünün yanına 2079 adet kafatası kırığı içermeyen görüntü rastgele seçilerek eklenmiştir. Veri kümesinden örnek görüntüler Şekil 1'de gösterilmiştir. Sonuç olarak çalışmada kullanılan veri kümesi 3555 BT taraması içermektedir. Veri kümesinin etiketlenmesi için Computer Vision Annotation Tool (CVAT) kullanılmıştır. Etiketleme işlemi, görüntü etiketleme yöntemiyle gerçekleştirilmiştir. Bu süreçte, kafatası kırığı içeren her bir BT görüntüsüne bir beyin cerrahisi uzmanı tarafından "kırık" etiketi eklenmiştir. Kırık veriler içerisinde eğitim ve test verilerinin ayrılması sürecinde eğitim veri kümesindeki hasta taramalarının test kümesine karışmaması sağlanmıştır. Yani bölümlenme işlemi hasta bazlı olacak şekilde yüzde seksen eğitim yüzde yirmi test olarak gerçekleştirilmiştir.



Şekil 1. a. Sınıf 0 (Sağlam Kafatası)'a Ait Örnek Görüntüler b. Sınıf 1 (Kırık Kafatası)'e Ait Örnek Görüntüler

Tablo 1. Kafatası Kırığı İçeren Veri Kümeleri

Veri Kümesi	Kırıklı Görüntü Sayısı	Kullanılan Cihaz Özellikleri
CQ500 (Batch B1)	6	GE BrightSpeed, GE Discovery CT750 HD, GE LightSpeed, GE
CQ500 (Batch B2)	12	Optima CT660, Philips MX 16slice, Philips Access-32 CT
Qure25k	992	GE BrightSpeed, GE Brivo CT315, GE Brivo CT385, GE HiSpeed, GE LightSpeed, GE ProSpeed, GE Revolution ACTs, Philips Brilliance, Siemens Definition, Siemens Emotion, Siemens Sensation, Siemens SOMATOM, Siemens Spirit
Toplanan Veri kümesi	1476	Magnetom Aera; Siemens, Erlanger; Germany, Aquilion cx edition 128 slice ct-scanner; Toshiba, Japan

Tablo 1'de kafatası kırığı BT tarama görüntülerini içeren ve açık olarak erişilebilir olan veri kümeleri listelenmiş. Bunlardan CQ500 veri kümesi yeterli sayıda görüntü içermemesi sebebiyle çalışmaya dahil edilmemiştir. CQ500 veri kümesinin kapsamlı hali olan Qure25k veri kümesinde yeterli sayıda görüntü mevcuttur ancak bu veri

kümesi de görüntülerin çoğunun elde edildiği cihazların düşük sayıda sensörlü eski model cihazlar olması ile görüntü çözünürlükleri daha kötüdür. Bu nedenle patoloji tespit yetenekleri daha düşüktür.

Yöntemler

Çalışmamız, geniş kapsamlı bir veri kümesi üzerinde modern CNN mimarilerinin performansını karşılaştırmayı amaçlamaktadır. Model seçiminde Torch kütüphanesinde mevcut en güncel yöntemler hesaplama kaynakları da göz önünde bulundurularak seçilmiştir. MaxViT özellikle CNN ve Transformer mimarilerini birleştiren hibrit yapısı nedeniyle tercih edilmiştir. Bu hibrit yapı sayesinde hem CNN'lerin yerel özellikleri yakalama kabiliyeti, hem de Transformer'ların küresel bağlamı anlama yeteneği bir arada değerlendirilmiştir.

Bu bölümde kafatası kırıklarının otomatik tespiti için karşılaştırılan EfficientNet, ResNet, ResNeXt ve MaxViT mimarilerinin yapısı ve bu çalışma kapsamında kullanılan modelleri detaylandırılacaktır. Son olarak, modellerin performansını değerlendirmek için kullanılan metrikler ve değerlendirme yöntemleri ele alınacaktır.

EfficientNet

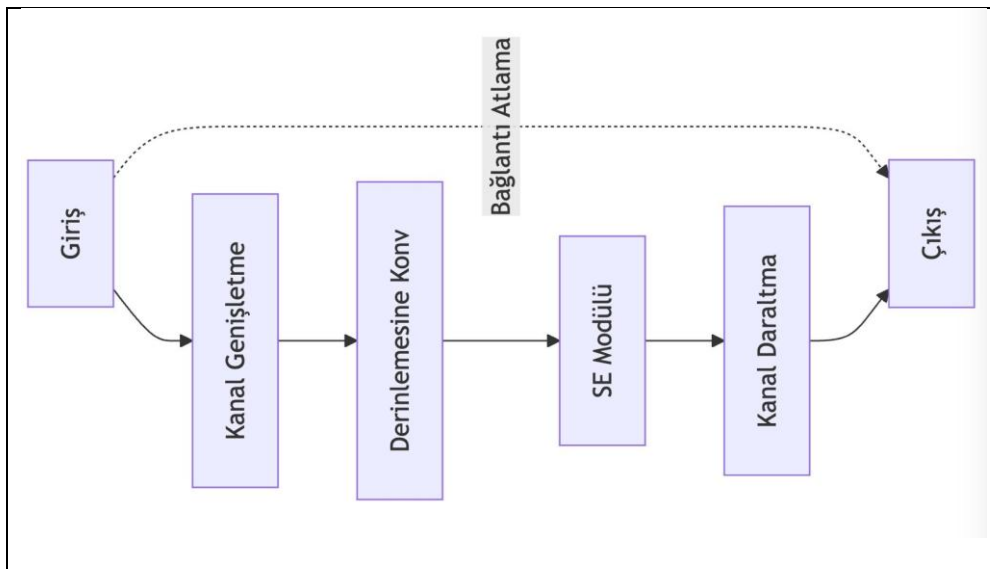
EfficientNet, (Tan & Le, 2019) 2019 yılında önerilen ve ağ mimarisinin ölçeklendirilmesi konusunda yeni bir yaklaşım getiren bir CNN mimarisidir. Bu mimari, ağın derinliği, genişliği ve giriş çözünürlüğü arasında optimum bir denge kurarak, daha az parametre ve hesaplama maliyeti ile yüksek doğruluk elde etmeyi amaçlar. EfficientNet'in temel prensibi, ağı tüm boyutlarını (derinlik, genişlik, çözünürlük) birlikte ve dengeli bir şekilde ölçeklendirmektir. Bu yaklaşım, "bileşik ölçeklendirme" olarak adlandırılır ve aşağıdaki Eşitlik (1), (2) ve (3) ile ifade edilir:

$$\text{Derinlik } (d) = \alpha^\varphi \quad (1)$$

$$\text{Genişlik } (w) = \beta^\varphi \quad (2)$$

$$\text{Çözünürlük } (r) = \gamma^\varphi \quad (3)$$

Burada α , β , ve γ sabit katsayılar, φ ise ölçeklendirme faktörüdür. Bu ölçeklendirme yöntemi, EfficientNet'in farklı boyutlarda (B0'dan B7'ye kadar) modeller oluşturmasına olanak tanır.



Şekil 2. Örnek Bir EfficientNet Bloğu.

EfficientNet'in yapı taşı, Mobil Inverted Bottleneck Convolutional (MBConv) bloklarıdır. Örnek bir blok Şekil 2'de gösterilmiştir. MBConv bloğu, yüksek performans ve verimlilik sağlayan beş ana adımdan oluşur. İlk olarak, 1×1 konvolüsyon ile kanal genişletme işlemi yapılarak özellik uzayı genişletilir. Ardından, derinlemesine ayrılabilir konvolüsyon uygulanarak uzamsal özellikler yakalanır ve hesaplama verimliliği artırılır. Üçüncü adımda, Squeeze-and-Excitation (SE) modülü ile kanal bazında özellik yeniden kalibrasyonu gerçekleştirilir. Dördüncü adımda, 1×1 konvolüsyon ile kanal daraltma işlemi yapılarak model boyutu küçültülür. Son olarak, giriş ve çıkış boyutları aynıysa bağlantı atlama uygulanarak gradyan akışı iyileştirilir. Bu yapı, geleneksel CNN bloklarından farklı olarak daha az parametre ile daha etkili özellik çıkarımı ve hesaplama verimliliği sağlar.


EfficientNet'in bu özellikleri, kafatası kırığı tespiti gibi karmaşık tıbbi görüntü analizi görevleri için onu ideal bir seçenek haline getirir. Modelin ölçeklenebilir yapısı, farklı boyut ve karmaşıklıkta kırıkları tespit etmede esneklik sağlar. Çalışmamızda, EfficientNet'in B0'dan B7'ye kadar olan tüm modelleri kullanılmış ve performansları karşılaştırılmıştır.

ResNet

ResNet (He vd., 2016), 2015 yılında tanıtılan bir derin öğrenme mimarisidir. Derin ağlardaki gradyan kaybı problemini ele alarak, eğitim sürecini etkinleştirir. ResNet'in en önemli yeniliği, "atlama bağlantıları" veya "kısayol bağlantıları" olarak adlandırılan yapıdır. Bu yapı, ağın öğrenme şeklini değiştirerek her katmanın sadece "ek bilgi" veya "değişiklik" olduğunda öğrenmesini sağlar. Matematiksel olarak Eşitlik (4)'te gösterildiği gibi ifade edilir.

$$H(x) = F(x) + x \quad (4)$$

Burada $H(x)$ katmanın çıktısını, $F(x)$ öğrenilen değişikliği, x ise orijinal girişi temsil eder. Bu yaklaşım, derin ağlarda bilginin kolayca ilerlemesini sağlayarak gradyan kaybını azaltır. ResNet'in temel yapı taşı, artık bloğudur. Şekil 3. a bu bloğun yapısını göstermektedir:



Şekil 3. a. Temel ResNet Bloğu, b. ResNet Darboğaz (Bottleneck) Bloğu

Bu blok, iki evrişim katmanından oluşur ve her biri batch normalizasyonu ve ReLU aktivasyonu ile takip edilir. Atlama bağlantısı, giriş verisini doğrudan ikinci batch normalizasyonunun çıkışına ekler. ResNet, ResNet-18'den ResNet-152'ye kadar çeşitli derinliklerde modellere sahiptir. Daha derin ağlar için (ResNet-50 ve üzeri), ResNet artık bloklarında bir "darboğaz" tasarımı kullanır. Bu tasarım Şekil 3. b'de gösterilmiştir: Darboğaz tasarımı, boyutları azaltmak ve sonra artırmak için 1×1 evrişimler kullanır ve bunların arasına 3×3 evrişim yerleştirir. Bu yaklaşım, performansı korurken hesaplama karmaşıklığını azaltır. Çalışmamızda, kafatası kırığı tespitinde performanslarını karşılaştırmak için ResNet mimarisine ait ResNet-50, ResNet-101 ve ResNet-152 modelleri kullanılmıştır.

ResNeXt

ResNeXt (Xie vd., 2017), ResNet mimarisinin geliştirilmiş bir versiyonudur. En önemli yeniliği, "kardinality" kavramını eklemesidir. Kardinality, bir bloktaki paralel yolların sayısını ifade eder. Geleneksel ResNet bloklarında tek bir yol varken, ResNeXt bloklarında birden fazla paralel yol bulunur. Bu yaklaşım, modelin öğrenme kapasitesini artırırken hesaplama karmaşıklığını kontrol altında tutar. ResNeXt'in temel yapı taşı olan blok, şu adımlardan oluşur:

1. 1×1 konvolüsyon ile boyut azaltma
2. 3×3 konvolüsyon ile özellik çıkarımı (kardinality sayısı kadar paralel yol)
3. 1×1 konvolüsyon ile boyut artırma
4. Atlama bağlantısı ile giriş ekleme

Bu yapı, matematiksel olarak Eşitlik (5)'te verildiği gibi ifade edilebilir:


$$Y = X + \Sigma(T_i(X)) \quad (5)$$

Burada X giriş tensörünü, T_i i. paralel yolu, Y ise çıkış tensörünü temsil eder. ResNeXt'in bu yapısı, modelin daha zengin ve çeşitli özellikler öğrenmesine olanak tanır. Kardinality, ağırlık genişliğini ve derinliğini artırmaktan daha etkili bir şekilde model performansını artırabilir. Çalışmamızda, kafatası kırığı tespitinde ResNeXt mimarisinin ResNeXt-50 ve ResNeXt-101 modelleri kullanılmış ve performanslarını diğer mimarilerle karşılaştırılmıştır.

MaxVit

MaxVit (Tu vd., 2022), görüntü sınıflandırma ve nesne tespiti gibi görevler için tasarlanmış yeni nesil bir derin öğrenme mimarisidir. Bu mimari, CNN ve Vision Transformers (ViT) modellerinin güçlü yönlerini birleştirerek daha etkili bir öğrenme sağlar. MaxVit'in temel yapı taşları şunlardır:

1. Mobil Ters Darboğaz Evrişim (MBCConv) Blokları: EfficientNet'te de kullanılan bu bloklar, yerel özellikleri verimli bir şekilde yakalar.
2. Blok Bazlı Öz-Dikkat: Görüntüyü bloklara bölerek her blok içinde öz-dikkat uygular. Bu, genel bağlamı yakalamaya yardımcı olur.
3. Izgara Bazlı Öz-Dikkat: Görüntüyü ızgara şeklinde bölerek, bloklar arası ilişkileri yakalar.
4. Çok Katmanlı Algılayıcı (ÇKA): Öğrenilen özellikleri işler ve son çıktıyı üretir.



Şekil 4. MaxVit Mimarisi Temel Bileşenleri

Şekil 4, MaxVit mimarisinin temel bileşenlerini ve veri akışını göstermektedir. Giriş verisi sırasıyla MBCConv bloklarından, blok-bazlı self-attention katmanından, ızgara-bazlı self-attention katmanından ve son olarak MLP katmanından geçer. MaxVit, bu yapı taşlarını kullanarak hem yerel hem de global özellikleri etkili bir şekilde öğrenir. Çalışmamızda, MaxVit mimarisinin MaxVit-Tiny, MaxVit-Small, MaxVit-Base ve MaxVit-Large modelleri kullanılmıştır.

Değerlendirme Ölçütleri

Çalışmamız kapsamında karşılaştırılan modellerin performanslarını değerlendirmek amacıyla doğruluk, kesinlik, hassasiyet, F1 skor, AUC ve Gradyan ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) metrikleri kullanılmıştır. Metriklerin hesaplanması Eşitlik (6) - (11)'de gösterilmiştir (Han vd., 2012). Eşitliklerde yer alan TP değeri kafatası kırığı içerir olarak yapılan sınıflandırmalardan doğru olanların sayısını, TN değeri kafatası kırığı içermez olarak yapılan sınıflandırmalardan doğru olanların sayısını, FP değeri kafatası kırıklı olarak tahmin edilen ancak gerçekte kafatası kırığı içermeyen görüntülerin sayısını ve FN değeri ise kafatası kırığı içermez olarak tahmin edilen ancak gerçekte kafatası kırığı içeren görüntülerin sayısını temsil etmektedir. Son olarak P değeri TP+FN toplamını ve N değeri TN+FP değerini temsil etmektedir.

Yukarıda verilen kısaltmalar doğrultusunda doğruluk, model tarafından doğru yapılan sınıflandırmaların oranını ifade eder (Han vd., 2012) hesaplanması Eşitlik (1)'de (Han vd., 2012) gösterilmiştir, kesinlik, doğru tahmin ettiğimiz

kafatası kırığı içeren görüntülerin, tüm kırık tahminlerimize oranını, hassasiyet, doğru tahmin ettiğimiz kafatası kırığı içeren görüntülerin tüm kafatası kırığı içeren görüntülere oranını ve F1 skor, kesinlik ve hassasiyet metriklerinin harmonik ortalamasını ifade eder (Gençtürk vd., 2023; Gençtürk vd., 2024). Metriklere ait formüller sırasıyla Eşitlik (6), (7), (8) ve (9)'te verilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{P + N} \quad (6)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (7)$$

$$\text{Hassasiyet} = \frac{TP}{P} \quad (8)$$

$$\text{F1 Skoru} = 2 * \frac{\text{Kesinlik} * \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}} \quad (9)$$

AUC değeri ROC eğrisi üzerinden hesaplanır ve ikili sınıflandırma problemlerinde yaygın olarak kullanılmaktadır (Muschelli III, 2020). ROC eğrisi modelin False Positive Rate (FPR) olarak ifade edilen tahminleri ile True Positive Rate (TPR) olarak ifade edilen tahminleri arasındaki grafiksel ilişkiyi göstermektedir (Han vd., 2012). Çalışma kapsamındaki problemde FPR değeri kafatası kırığı içerir olarak yaptığımız sınıflandırmalardan yanlış olanların, toplam kafatası kırığı içermeyen görüntülere oranını ifade ederken, TPR değeri kafatası kırığı içerir olarak yaptığımız sınıflandırmalardan doğru olanların, toplam kafatası kırığı içeren görüntülere oranını ifade etmektedir. FPR değeri ROC grafiğindeki x eksenini, TPR ise y eksenine karşılık gelmektedir. TPR ve FPR değerlerinin hesaplanması Eşitlik 10 ve 11' de gösterilmiştir (Han vd., 2012). Bu değerler arasındaki ilişki bize ROC olarak ifade edilen olasılık eğrisini verir. Modelin olasılık eğrisinin altında kalan alanın yani AUC değerinin yüksek olması, TPR değerinin yüksek olmasına karşılık gelir ve bu istenen durumdur.

$$\text{TPR} = \frac{TP}{P} \quad (10)$$

$$\text{FPR} = \frac{FP}{N} \quad (11)$$

Bu metriklere ek olarak en başarılı modelin sınıflandırma sürecinde hangi noktalara odaklandığını gözlemleyebilmek için Grad-CAM (Selvaraju vd., 2017) görselleştirmesi kullanılmıştır. Grad-CAM, CNN tabanlı modellerde kullanılır ve modelin çalışma mantığının açıklanabilir olmasını sağlar (Bakchy vd., 2023).

DENEYSEL ÇALIŞMA

Çalışmanın bu bölümünde EfficientNet, ResNet, ResNeXt ve MaxVit mimarileri ilk olarak alt modelleriyle kendi içlerinde karşılaştırılmıştır. Elde edilen sonuçlar sırasıyla Tablo 2, Tablo 3, Tablo 4 ve Tablo 5'te verilmiştir.

Tablo 2. EfficientNet Modelleri Sonuçları

	Doğruluk	Kesinlik	Hassasiyet	F1 Skoru
EfficientNet-B0	0,868458	0,868517	0,868458	0,866914
EfficientNet-B1	0,862801	0,862536	0,862801	0,86132
EfficientNet-B2	0,893918	0,89358	0,893918	0,893657
EfficientNet-B3	0,889675	0,889797	0,889675	0,888636
EfficientNet-B4	0,898161	0,897826	0,898161	0,897873
EfficientNet-B5	0,865629	0,867229	0,865629	0,863233
EfficientNet-B6	0,889675	0,894626	0,889675	0,887147
EfficientNet-B7	0,882603	0,882116	0,882603	0,882044

EfficientNet mimarisinde B0'dan B7'ye kadar 8 alt model için sonuçlar elde edilmiştir. Modeller kendi içerisinde karşılaştırıldığında kırık tespiti için B4 modeli, tüm metriklerde en yüksek değerlere sahip olup, en iyi performansı sergileyen modeldir. B1 ve B5 modelleri, diğer modellere göre daha düşük performans göstermektedir.

Tablo 3. ResNet Modelleri Sonuçları

	Doğruluk	Kesinlik	Hassasiyet	F1 Skoru
ResNet-50	0,803395	0,825986	0,803395	0,789594
ResNet-101	0,820368	0,821699	0,820368	0,815931
ResNet-151	0,861386	0,860753	0,861386	0,860889

ResNet mimarisinde 50, 101 ve 151 alt modelleri için sonuçlar elde edilmiştir. ResNet-50 mimarisi için kesinlik metriği diğer metriklerle göre biraz daha yüksektir, ancak genel olarak en düşük performansa sahip modeldir. ResNet-151 modeli, tüm metriklerde en yüksek değerlere sahip olup, en iyi performansı sergileyen modeldir. ResNet-50 modeli, diğer modellere göre daha düşük performans göstermektedir ve daha az karmaşık görevler için uygun olabilir. ResNet-101 modeli, ResNet-50'ye kıyasla daha yüksek performans göstermektedir ve belirli senaryolar için başarılı sonuçlar verebileceği söylenebilir.

Tablo 4. ResNeXt Modelleri Sonuçları

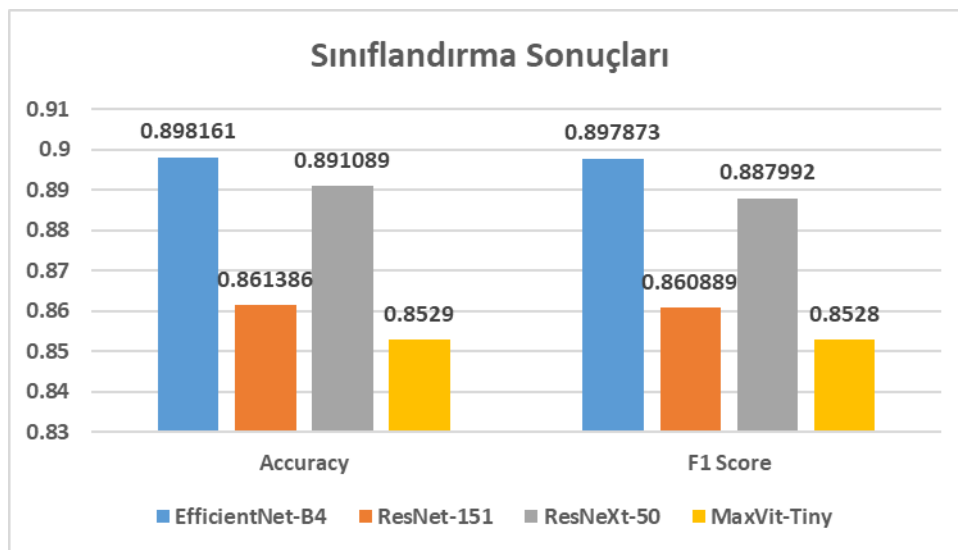
	Doğruluk	Kesinlik	Hassasiyet	F1 Skoru
ResNeXt-50	0.891089	0.89913	0.891089	0.887992
ResNeXt-101	0.845827	0.850372	0.845827	0.841443

ResNeXt mimarisinde 50 ve 101 alt modellerinin kafatası kırığı tespiti için performansları elde edilmiştir. Sonuçlara göre ResNeXt-50 modeli, tüm metriklerde en yüksek değerlere sahiptir aynı zamanda bu model, özellikle kesinlik ve hassasiyet metriklerinde de doğruluk ile paralel yüksek sonuçlar elde etmiştir. ResNeXt-101 modeli, ResNeXt-50'ye göre daha düşük bir performans göstermiştir ve ResNet-50 modelinde de olduğu gibi karmaşıklığı daha düşük kırık görüntüleri üzerinde daha başarılı olacağı söylenebilir.

Tablo 5. MaxVit Modelleri Sonuçları

	Doğruluk	Kesinlik	Hassasiyet	F1 Skoru
MaxVit- Tiny	0,8529	0,852714	0,8529	0,8528
MaxVit- Small	0,850071	0,849694	0,850071	0,848239
MaxVit- Base	0,821782	0,820681	0,821782	0,819431
MaxVit- Large	0,851485	0,851587	0,851485	0,851535


MaxVit mimarisi için Tiny, Small, Base ve Large alt modelleri değerlendirilmiştir. Tiny modeli, tüm metriklerde en yüksek değerlere sahip olup, en iyi performansı sergileyen modeldir. Base modeli, diğer modellere göre daha düşük performans göstermektedir. Large ve Small modellerinin de Tiny modeline yakın sonuçlar verdiği görülmektedir.

**Şekil 5.** Farklı Güncel Derin Öğrenme Mimarileri İle Elde Edilen Sınıflandırma Sonuçları

Şekil 5'te karşılaştırma için seçilen dört mimarinin en başarılı olan alt modelleri karşılaştırılmıştır. Grafiğe göre EfficientNet-B4 modeli, hem doğruluk hem de F1 skoru açısından en yüksek değerlere sahip olup, genel olarak en iyi performansı sergileyen modeldir. MaxVit-Tiny modeli, hem doğruluk hem de F1 skoru açısından diğer modellere

göre daha düşük performans göstermiştir. ResNeXt-50 modeli ise EfficientNet-B4 modeline yakın bir doğruluk göstermiştir. Bu nedenle EfficientNet-B4 ve ResNeXt-50 modellerinin kafatası kırığı tespiti açısından daha uygun olduğu söylenebilir.


Şekil 6’da, dört farklı modelin (EfficientNet-B4, ResNet-151, ResNeXt-50 ve MaxVit-Tiny) karmaşıklık matrisleri gösterilmiştir. Her bir karmaşıklık matrisi, modelin sınıflandırma performansını gerçek pozitif (TP), gerçek negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) örnekler açısından daha iyi değerlendirmemizi sağlamaktadır. Matrisler incelendiğinde özellikle doğruluk açısından en başarılı olarak sınıflandırılan EfficientNet-B4 ve ResNeXt-50 modellerinin farkı daha net anlaşılmaktadır. Sınıflandırma probleminin amacı kafatası kırıklarının tespitidir. Dolayısıyla özellikle TP değerinin yüksek olması istenmektedir. TP değeri açısından değerlendirildiğinde EfficientNet-B4 modelinin ResNeXt-50 modeline göre üstünlüğü daha net anlaşılmaktadır. ResNeXt-50 modelinin doğruluk değerinin yüksek olması FP yani kırık içermeyen görüntüleri diğer modellere göre daha iyi tespit etmesinden kaynaklanmaktadır.



Şekil 6. a. EfficientNet-B4 Modeli Karmaşıklık Matrisi b. ResNet-151 Modeli Karmaşıklık Matrisi c. ResNeXt-50 Modeli Karmaşıklık Matrisi d. MaxVit-Tiny Modeli Karmaşıklık Matrisi

Doğruluk ve karmaşıklık matrisi üzerinden yapılan değerlendirmelere ek olarak en başarılı olarak tespit edilen EfficientNet-B4 modelinin sınıflandırma sürecinde hangi bölgelere odaklandığını gösteren Grad-CAM görselleri Şekil 7’de gösterilmiştir. Görseller modelin sınıflandırma aşamasında hem tek bir kırık bölgesi içeren hem de birden fazla kırığa sahip görüntülerde doğru bölgelere odaklandığını açık şekilde göstermektedir.

Tablo 6’da her mimarinin en başarılı modeli üzerinde uygulanan 10 katlı çapraz doğrulama işleminin sonucu da gösterilmiştir. Sonuçlar incelendiğinde ortalama doğruluğun yüzde yirmi test, yüzde seksen eğitim bölümlenmesi ile elde edilen doğruluk değerinden daha düşük olduğu ancak en başarılı modelin değişmediği ve EfficientNet-B4 olduğu tespit edilmiştir. Doğruluğun azalmasındaki sebep veri bölümlenmesinin on katlı çapraz doğrulamada yüzde doksan eğitim, yüzde on test olacak şekilde farklı oranlarda yapılmasıdır.



Şekil 7. EfficientNet-B4 Modelinin Grad-CAM Görselleştirmeleri

Tablo 6. Literatürde Yer Alan Çalışmalar Ve Çalışma Kapsamında Değerlendirilen Modellerin Sonuçları

	EfficientNet-B4	ResNet-152	ResNeXt-50	MaxVit- Tiny
1. Kat	0,7602	0,8115	0,6947	0,7766
2. Kat	0,9016	0,7828	0,7992	0,8197
3. Kat	0,7975	0,7934	0,8058	0,7851
4. Kat	0,9211	0,8465	0,8838	0,9087
5. Kat	0,9231	0,9231	0,9231	0,8932
6. Kat	0,8725	0,8017	0,8414	0,8612
7. Kat	0,7488	0,7093	0,7186	0,7279
8. Kat	0,7671	0,7032	0,7831	0,7055
9. Kat	0,8767	0,7854	0,8562	0,8196
10. Kat	0,8814	0,8770	0,8747	0,8837
Ortalama	0,8450	0,8034	0,8181	0,8181

Tablo 7’de çalışma kapsamında karşılaştırılan modeller ve literatürde kafatası kırığı tespiti yapan çalışmaların kapsamlı bir karşılaştırılması verilmiştir. Çalışmaların hepsinde doğruluk değeri bulunmaması ve aynı veri kümeleri üzerinden gerçekleştirilmiş olmamaları sebebiyle kesin bir karşılaştırma yapılması mümkün değildir. Ancak sonuçlar genel olarak değerlendirildiğinde kırıkların çok farklı çeşitliliğe sahip olması sebebiyle bu alanda derin öğrenme tabanlı yaklaşımlara ihtiyaç olduğu açık olarak görülmektedir

TARTIŞMA VE SONUÇLAR

Hayati öneme sahip kafatası kırıklarının tespiti için, modern yaşamın oluşturduğu iş yükü altında sağlık çalışanlarına destek sağlamak amacıyla otomatize raporlama sistemlerinin geliştirilmesi, en önemli yapay zekâ problemlerinden biridir. Çalışma kapsamında bu probleme çözüm sunmak amacıyla güncel olarak toplanan kafatası kırığı ve farklı beyin hasarlarını içeren geniş bir veri kümesi üzerinde güncel derin öğrenme yöntemlerinin kafatası kırığı tespiti

açısından başarısı değerlendirilmiştir. Problemin çözümü için EfficientNet, ResNet, ResNeXt ve MaxVit mimarileri alt modelleriyle birlikte değerlendirilmiştir. Alt modellerin de işleme alınması problem çözümünde karmaşık modellere ihtiyaç var mıdır sorusunun da cevabını vermiştir. Elde edilen sonuçlara göre Efficient mimarisi, B4 modeliyle %89.81, ResNet mimarisi 151 alt modeliyle %86.13, ResNeXt mimarisi, 50 alt modeliyle %89.10 ve MaxVit mimarisi Tiny alt modeliyle %85.29 doğruluk değeri elde edilmiştir.

Tablo 7. Literatürde Yer Alan Çalışmalar Ve Çalışma Kapsamında Değerlendirilen Modellerin Sonuçları

Model	Veri Kümesi	Doğruluk	F1 Skoru	AUC	AP
DeepLab ve Random Forest (Chilamkurthy vd., 2018)	Qure25k	-	-	0,9244	
DeepLab ve Random Forest (Chilamkurthy vd., 2018)	CQ500	-	-	0,9624	
Önerilen İki Aşamalı R-CNN (Lin vd., 2022)	Çalışmaya özgü veri kümeleri	-	-	-	0,5388
YOLOv3 Modified attention U-net (Shan vd., 2021)	Çalışmaya özgü veri kümesi	85,96 88,26			
ResNet 18 + iki katmanlı FCN Guo vd., 2022	Çalışmaya özgü 3 farklı veri kümesi			0,982 0,978 0,958	
ResNet 18 + iki katmanlı FCN Guo vd., 2022	CQ500			0,971	
YOLOv4 (Wang vd., 2023)	Çalışmaya özgü veri kümesi	0,8958	0,8864		
CNN + LSTM (Mangrulkar vd., 2021)	Çalışmaya özgü veri kümesi	98,33	98,76		
EfficientNet-B4	Çalışmaya özgü	0,898161	0,897873		
ResNet-152	veri kümesi	0,861386	0,860889		
ResNeXt-50		0,891089	0,887992		
MaxVit- Tiny		0,852900	0,852800		

EfficientNet-B4 modeli en yüksek başarıya sahiptir ancak ResNeXt-50 modelinin de doğruluk açısından EfficientNet-B4 modeline yakın olduğu görülmüştür. Karmaşıklık matrisi üzerinden yapılan değerlendirme de EfficientNet-B4 modelinin TP yani kırıkları daha doğru tespit ettiği ResNeXt-50 modelininse FP durumları yani kırık içermeyen taramaları daha doğru tespit ettiği bu nedenle yakın sonuç elde edildiği tespit edilmiştir. Aynı zamanda kırık tespiti açısından çok yüksek karmaşıklığa sahip modellerin daha düşük başarı gösterdiği de elde edilen sonuçlar arasındadır.

Çalışma kapsamında yalnızca kafatası kırığının varlığının tespitine odaklanılmıştır. İlerleyen çalışmalarda mevcut veri kümesi üzerinde bölütlemeye uygun işaretlemelerin beyin cerrahisi uzmanları tarafından yapılması ve bölütleme açısından derin öğrenme mimarilerinin başarısının ortaya konulması hedeflenmektedir. Özellikle veri kümesi eksikliği ve kırık türlerinin çeşitliliği, aynı örüntüye sahip olmaması sebepleriyle sınırlı sayıda çalışma içeren bu alanda mevcut derin öğrenme yöntemlerinin doğruluğunu arttıracak teknikler veya yeni modeller geliştirilmesi de büyük bir ihtiyaç olarak tespit edilmiştir.

KAYNAKLAR

Abubacker, N. F., Azman, A., Azrifah, M., & Doraisamy, S. (2013, December). An approach for an automatic fracture detection of skull dicom images based on neighboring pixels. In 2013 13th International Conference on Intelligent Systems Design and Applications (pp. 177-181). IEEE. <https://doi.org/10.1109/ISDA.2013.6920731>

Bakchy, S. C., Peyal, H. I., Islam, M. I., Yeamin, G. K., Miraz, S., & Abdal, M. N. (2023, September). A lightweight-CNN model for efficient lung cancer detection and Grad-CAM visualization. In 2023 International Conference on Information and Communication Technology for Sustainable Development (ICICT4SD) (pp. 254-258). IEEE. <https://doi.org/10.1109/ICICT4SD59951.2023.10303569>

Brain Trauma Foundation. Traumatic brain injury statistics. (2024). <https://www.braintrauma.org/> Son Erişim: 01.07.2024

Chilamkurthy, S., Ghosh, R., Tanamala, S., Biviji, M., Campeau, N. G., Venugopal, V. K., ... & Warier, P. (2018). Deep learning algorithms for detection of critical findings in head CT scans: a retrospective study. *The Lancet*, 392(10162), 2388-2396. [https://doi.org/10.1016/S0140-6736\(18\)31645-3](https://doi.org/10.1016/S0140-6736(18)31645-3)

Choi, J. W., Cho, Y. J., Ha, J. Y., Lee, Y. Y., Koh, S. Y., Seo, J. Y., Choi, Y. H., Cheon, J., Phi, J. H., Kim, I., Yang, J. & Kim, W. S. (2022). Deep learning-assisted diagnosis of pediatric skull fractures on plain radiographs. *Korean Journal of Radiology*, 23(3), 343-354. <https://doi.org/10.3348/kjr.2021.0449>.

Gençtürk, T. H., Gülağız, F. K., & Kaya, İ. (2023). Derin öğrenme yöntemleri kullanılarak BT taramalarında beyin kanaması teşhisinin karşılaştırmalı bir analizi. *Journal of Intelligent Systems: Theory and Applications*, 6(1), 75-84. <https://doi.org/10.38016/jista.1215025>

Gençtürk, T. H., Gülağız, F. K., & Kaya, İ. (2024). Detection and segmentation of subdural hemorrhage on head CT images. *IEEE Access*, 12, 82235-82246. <https://doi.org/10.1109/ACCESS.2024.3411932>
Greenberg, M. S. (2010). *Handbook of neurosurgery*. (7th ed.) Thieme. ISBN: 978-1-60406-326-4.

Guo, Y., He, Y., Lyu, J., Zhou, Z., Yang, D., Ma, L., ... & Dai, Q. (2022). Deep learning with weak annotation from diagnosis reports for detection of multiple head disorders: a prospective, multicentre study. *The Lancet Digital Health*, 4(8), e584-e593. [https://doi.org/10.1016/S2589-7500\(22\)00090-5](https://doi.org/10.1016/S2589-7500(22)00090-5)

Han, J., Kamber, M., & Pei, J. (2012). *Data mining concepts and techniques*. (3rd ed.). Waltham: Morgan Kaufmann Publishers.

He, K., Zhang, X., Ren, S., & Sun, J. (2016, June). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition* (pp. 770-778). IEEE. <https://doi.org/10.1109/CVPR.2016.90>

Kaya, İ., Gençtürk, T. H. & Kaya Gülağız, F. (2023). A revolutionary acute subdural hematoma detection based on two-tiered artificial intelligence model. *Ulusal Travma Acil Cerrahi Dergisi*, 29(8), 858–871. PMID: 37563894; PMCID: PMC10560802. <https://doi.org/10.14744/tjtes.2023.76756>

Lin, X., Yan, Z., Kuang, Z., Zhang, H., Deng, X. & Yu L. (2022). Fracture R-CNN: An anchor-efficient anti-interference framework for skull fracture detection in CT images. *Medical Physics*, 49(11), 7179-7192. <https://doi.org/10.1002/mp.15809>

Lin, E., & Yuh, E. L. (2022). Computational approaches for acute traumatic brain injury image recognition. *Frontiers in Neurology*, 13, 791816, 1-25. <https://doi.org/10.3389/fneur.2022.791816>

Maconochie, I. & Ross, M. (2007). Head injury (moderate to severe). *BMJ Clin Evid*, 2007(1210), 1-13, 2007. PMID: 19450357; PMCID: PMC2943769.

Mangrulkar, A., Rane, S. B., & Sunnapwar, V. (2021). Automated skull damage detection from assembled skull model using computer vision and machine learning. *International Journal of Information Technology*, 13, 1785-1790. <https://doi.org/10.1007/s41870-021-00752-5>

Muschelli III, J. (2020). ROC and AUC with a binary predictor: a potentially misleading metric. *Journal of Classification*, 37(3), 696-708. <https://doi.org/10.1007/s00357-019-09345-1>

Sehlikoğlu, K., Türkoğlu, A., Bork, T., & Batbaş, M. (2024). Investigation of fatal traumatic head injuries. *Ulus Travma Acil Cerrahi Derg*, 30(3), 160-166. PMID: 38506383; PMCID: PMC10977496. <https://doi.org/10.14744/tjtes.2024.32463>

Selvaraju, R. R., Cogswell, M., Das, A., Vedantam, R., Parikh, D., & Batra, D. (2017). Grad-cam: Visual explanations from deep networks via gradient-based localization. In Proceedings Of The IEEE International Conference On Computer Vision (pp. 618-626). IEEE. <https://doi.org/10.1109/ICCV.2017.74>

Shan, W., Guo, J., Mao, X., Zhang, Y., Huang, Y., Wang, S., ... & Wang, Y. (2021). Automated identification of skull fractures with deep learning: a comparison between object detection and segmentation approach. *Frontiers in Neurology*, 12, 687931, 1-10. <https://doi.org/10.3389/fneur.2021.687931>

Shao, H., & Zhao, H. (2003, September). Automatic analysis of a skull fracture based on image content. In Third International Symposium on Multispectral Image Processing and Pattern Recognition (pp. 741-746). SPIE. <https://doi.org/10.1117/12.538780>

Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In International Conference On Machine Learning (pp. 6105-6114). PMLR. <https://doi.org/10.48550/arXiv.1905.11946>

Tu, Z., Talebi, H., Zhang, H., Yang, F., Milanfar, P., Bovik, A., & Li, Y. (2022, October). MaxVit: Multi-axis vision transformer. In European Conference on Computer Vision (pp. 459-479). Cham: Springer Nature Switzerland. <https://doi.org/10.48550/arXiv.2204.01697>

Türkiye Cumhuriyeti Sağlık Bakanlığı. Health statistics Türkiye, Health statistics yearbook for Türkiye . (2019). <https://www.saglik.gov.tr/TR,84966/saglik-istatistikleri-yilligi-2019-yayinlanmistir.html> Son Erişim: 23.06.2024.

Türkiye Ministry of Health Expert Board in Medicine. Türkiye emergency medicine specialty training curriculum. (2022). <https://tuk.saglik.gov.tr/aciltipmufredatv24doc>. Son Erişim: 23.06.2024.

Wallis, A. & McCoubrie, P. (2011). The radiology report--are we getting the message across?. *Clin Radiol*, 66(11), 1015-1022. <https://doi.org/10.1016/j.crad.2011.05.013>

Wan Zaki, W. M. D., Ahmad Fauzi, M. F., & Besar, R. (2009, November). A new approach of skull fracture detection in CT brain images. In Visual Informatics: Bridging Research and Practice: First International Visual Informatics Conference (pp. 156-167). Springer Berlin Heidelberg.

Wang, H. C., Wang, S. C., Yan, J. L., & Ko, L. W. (2023). Artificial Intelligence model trained with sparse data to detect facial and cranial bone fractures from head CT. *Journal of Digital Imaging*, 36(4), 1408-1418. <https://doi.org/10.1007/s10278-023-00829-6>

Xie, S., Girshick, R., Dollár, P., Tu, Z., & He, K. (2017, July). Aggregated residual transformations for deep neural networks. In Proceedings of the IEEE Conference On Computer Vision And Pattern Recognition (pp. 1492-1500). IEEE. <https://doi.org/10.1109/CVPR.2017.634>

Yamada, A., Teramoto, A., Otsuka, T., Kudo, K., Anno, H., & Fujita, H. (2016, August). Preliminary study on the automated skull fracture detection in CT images using black-hat transform. In 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC) (pp. 6437-6440). IEEE. <https://doi.org/10.1109/EMBC.2016.7592202>

Yamada, A., Teramoto, A., Kudo, K., Otsuka, T., Anno, H., & Fujita, H. (2018). Basic study on the automated detection method of skull fracture in head ct images using surface selective black-hat transform. *Journal of Medical Imaging and Health Informatics*, 8(5), 1069-1076. <https://doi.org/10.1166/jmihi.2018.2410>

Zaki, W. M. D. W. , Fauzi, M. F. A. & R. Besar. (2008, November) .Automated method of fracture detection in CT brain images. In 2008 3rd International Conference on Intelligent System and Knowledge Engineering (pp. 1156-1160). IEEE. <https://doi.org/10.1109/ISKE.2008.4731105>



Kahramanmaraş Sutcu Imam University

Journal of Engineering Sciences



Geliş Tarihi : 16.07.2024
Kabul Tarihi : 30.10.2024

Received Date : 16.07.2024
Accepted Date : 30.10.2024

MAKİNE ÖĞRENMESİ İLE ÜRETİM PERFORMANSI TAHMİNLEMESİ

PREDICT OF PRODUCTION PERFORMANCE WITH MACHINE LEARNING

Semih GÖKSU^{1*} (ORCID: 0009-0007-8158-6654)
*Prof.Dr.Bülent SEZEN*² (ORCID: 0000-0001-7485-3194)
*Dr.Yavuz Selim BALCIOĞLU*³ (ORCID: 0000-0001-7138-2972)

^{1,2,3} Gebze Teknik Üniversitesi, İşletme Fakültesi, İşletme Bölümü, Kocaeli, Türkiye

*Sorumlu Yazar / Corresponding Author: Semih GÖKSU, s.goksu2022@gtu.edu.tr

ÖZET

Bu çalışmanın amacı, makine öğrenmesi algoritmaları kullanarak üretim performansının tahmin edilmesidir. Üretim sistemleri, çeşitli makineler, parametreler ve set değerler üzerinden çalışmakta olup, her bir üretim koşulu değişkenlik gösterebilmektedir. Gelişen teknolojiler sayesinde, bu değişkenliklerin kontrol altına alınması, üretim koşullarının optimize edilmesi ve birbirini etkileyen süreçlerden çıkarım yapılması mümkün hale gelmiştir. Bu bağlamda, makine öğrenmesi, istatistiksel metotlarla veri setleri üzerinden üretim performansının tahmin edilmesine olanak tanıyan önemli bir araçtır. Çalışmada, aynı ürün grubuna ait 2 yıllık veri kullanılarak üretim performansını tahmin etmek amacıyla Karar Ağacı, Lineer Regresyon, Lasso Regresyon, XGBoost, Destek Vektör Regresyonu ve LSTM algoritmaları uygulanmıştır. Bu algoritmalar, üç farklı senaryo üzerinden değerlendirilmiş ve üretim performansını en doğru şekilde tahmin edebilecek modelin belirlenmesi hedeflenmiştir. Elde edilen sonuçlar, basit ve karmaşık modellerin performanslarını karşılaştırarak üretim süreçlerinin iyileştirilmesine yönelik pratik öneriler sunmaktadır.

Anahtar Kelimeler: makine öğrenmesi, performans, regresyon, tahminleme, üretim parametreleri

ABSTRACT

The aim of this study is to predict production performance using machine learning algorithms. Production systems operate based on various machines, parameters, and set values, with each production condition potentially exhibiting variability. Advances in technology have made it possible to control these variabilities, optimize production conditions, and derive insights from interconnected processes. In this context, machine learning serves as a valuable tool that enables the prediction of production performance through statistical methods applied to datasets. In this study, two years of data from the same product group were used to predict production performance through the application of Decision Tree, Linear Regression, Lasso Regression, XGBoost, Support Vector Regression, and LSTM algorithms. These algorithms were evaluated across three different scenarios, with the goal of identifying the model that can most accurately predict production performance. The results provide practical insights into improving production processes by comparing the performance of simple and complex models.

Keywords: machine learning, performance, regression, prediction, production parameters

GİRİŞ

Üretim sistemleri birbirini etkileyen birçok parametreden oluşmaktadır. Üretim parametreleri; üretimin hızını, kalitesini, maliyetini, fiyatını, işlem sürelerini, kapasitelerini doğrudan ya da dolaylı olarak etkilemektedir. Üretim sistemlerinin ana amacı tek seferde doğru miktarda, doğru kalitede ve doğru zamanda üretimi yapabilmektir. Üretim sistemlerini etkileyen birden fazla girdi mevcuttur. Girdiler hammadde, teknoloji, makine, ekipman, personel,

ToCite: GÖKSU, S., & SEZEN, B., & BALCIOĞLU, Y.S., (2025) MAKİNE ÖĞRENMESİ İLE ÜRETİM PERFORMANSI TAHMİNLEMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 65-79.

ergonomi, teknik gereksinimler, üretim parametreleri şeklinde sıralanabilir (Rahul vd., 2021). Operasyon yöneticileri, üretim sürecinin girdilerden etkilenme düzeyini minimum seviyeye indirmeyi amaçlarlar. Bu amaca ulaşmak her zaman mümkün olmayabilir. Bir girdide oluşan değişkenlik, diğer girdileri pozitif veya negatif anlamda etkileyebilir ve süreç bu girdiden etkilenebilir. Kontrol altında tutulabilen girdiler, üretim sürecinin performansını iyileştirmek için ele alındığında kritik öneme sahiptir. Kontrol altında tutulabilen girdiler için süreç; deney tasarımı, istatistiksel araçlar gibi endüstriyi etkileyen modeller ile çeşitli denemeler aracıyla kurgulanabilir ve sonuçları değerlendirilebilir. Üretim parametreleri, kontrol altında tutulabilen girdilere bir örnek olarak verilebilir (Sittón-Candanedo vd., 2018). Üretim sistemlerinin içerisinde yer alan üretim parametrelerinin üretimi tek seferde kaliteli şekilde üretecek net bir değer ya da belli bir aralığı ifade eden; değer alt limit ve üst limitinden oluşan aralık değerlerine ihtiyacı vardır. Parametrelerin alabildikleri değerlerde oluşan her sapma, üretimin kalitesini, işlem süresini ya da maliyetini etkileyecektir (Rimpault vd., 2018).

Geçmişten günümüze üretim sistemleri içerisinde yer alan, üretimi etkileyen parametreler incelendiğinde ustalık ve deneyimlerin kazandırmış olduğu beceri ile yapılan işlemlerin yerini günümüzde hızla otomasyon sistemlerinin aldığını gözlemlenmektedir (Angelopoulos vd., 2019). Otomasyonlar entegre edildikleri sistemlerdeki insan faktörünü azaltmaya yönelik kurgulanmış yapılardır. Otomasyonlar, daha az bağlı insan gücü ile birlikte daha verimli ve daha kaliteli üretim çıktısı için kullanılır (Cinar vd., 2020). Otomasyonlar içerisinde yer alan en temel düzeydeki sinyallerden, anlık ölçüm yapabilen cihazlara kadar çeşitlilik gösteren materyaller üretimin çıktısına etki etmektedir. Üretim çıktısı hem üretilen ürün adedi ilgili olabileceği gibi, kullanılan ekipmanlarla, ayarlanabilen parametrelerle, kullanıcı tutumlarıyla, ustalıkla, malzemeye ve makinelerle ilgili olabilir. Üretim sistemi içerisinde yer alan otomasyonlar, özellikle ayarlanabilen parametreler açısından üretim yöneticilerine operasyonunun durumu görmek için fırsat sağlamaktadır. Otomasyon sistemleri üretim ekipmanlarının, makinelerinin içerisinde gömülü ya da harici olarak yer alıp, ölçümlerle veri kaynağını oluşturur (Rahul vd., 2021). Elde edilen verilerin doğruluğu; sistemin kurgulanması ile ilgili bir konudur ve genel olarak algoritmalar üzerine kurulu bir yapıdadır. Algoritmaların oluşturduğu yapının içerisindeki veriler, belirli koşullara bağlı olarak veri ataması yapabilmektedir. Sürekliliği sağlanan veri yapısı aracılığıyla veriler elde edilir. Elde edilen verilerin anlamlı yorumlanması ve analiz edilmesi, üretim sisteminin geliştirilmesi için önemlidir (Angelopoulos vd., 2019). Verilerden sağlanan analizler, sistem ile ilgili çıkarımlar yapılmasını sağlar. Çıkarımlar tahminleme, optimizasyon, etki analizi, nedensellik analizi, kalite analizi, maliyet analizi şeklinde sınıflanabilmektedir (Rahul vd., 2021).

Endüstri 4.0 ve beraberinde getirdiği dijitalleşme süreçleri ile verilerin doğruluğu kritik önem kazanmıştır. Rekabet avantajı elde etmek isteyen firmalar üretim sistemlerine yapacakları iyileştirmeleri mümkün oldukça kapsamlı araştırmaktadırlar ve süreçlerinde uygulamak istemektedirler (Sittón-Candanedo vd., 2018). Verilerin yorumlanması, analiz edilmesi ve modellenmesi; üretim sistemlerinin iyileştirme noktalarının tespiti açısından önemlidir (Cinar vd., 2020). Tecrübeye ve geçmiş bilgi birikimine dayalı üretimin yapısını belirleyen parametre değerlerinin; üretim sistemi üzerinden alınan verilerle belli bir değer aralığına oturtulması üretim sistemi içerisinde kişi farklılıklarının getirdiği değişkenliği ve üretilen ürün birim başına oluşan kullanılmayan makine performans kaybını azaltacaktır (Angelopoulos vd., 2019).

Makine öğrenmesi endüstride görüntü olarak ve statü olarak kalite problemlerini tespit etme, talep ve pazar tahminleri, ürün gruplandırma/sınıflandırma gibi alanlarda kullanılmaktadır (Angelopoulos vd., 2019). Makine öğrenmesinin endüstrilere entegrasyonu ile insan işgücüne bağlı ve hataya açık operasyonlardaki kaliteli çıktısı ve yüksek verimlilik beklentisi oluşmuştur (Rahul vd., 2021). Makine öğrenmesi modelleri çeşitli algoritmalar kullanarak ileri istatistik ile beraber süreçleri modelleme ve modele uygun şekilde optimizasyon fırsatı sunmaktadır (Cinar vd., 2020).

Çalışmamızda iki yıllık veri üzerinden, üretim performansı üç farklı senaryoya dayalı olarak tahmin edilmiştir. Bu, mevcut literatürde kullanılan tek veri seti veya belirli parametreler üzerine odaklanan çalışmalardan önemli bir farklılık sunmaktadır. Örneğin, literatürde yaygın olan Cinar vd. (2020) çalışmasında makine öğrenmesi ve tahmin edilebilir bakım üzerine odaklanılırken, bizim çalışmamızda daha geniş kapsamlı üretim parametreleri üzerine odaklanılmıştır. Bununla birlikte, Karar Ağacı, Lineer Regresyon, Lasso Regresyon, XGBoost, Destek Vektör Regresyonu ve LSTM gibi çeşitli makine öğrenmesi algoritmalarını kullanarak geniş bir tahminleme analizi yapılmıştır. Literatürdeki çalışmalarda genellikle birkaç algoritmanın karşılaştırılmasıyla sınırlı kalan analizler varken (Rahul vd., 2021), bu çalışma kapsamlı bir model performansı değerlendirmesi sunmaktadır. Son olarak, üç farklı senaryo kullanılarak performans ölçümü yapılması, bu çalışmayı literatürdeki benzer çalışmalarla kıyaslandığında daha özgün ve uygulamaya yönelik kılmaktadır. Mevcut çalışmalar genellikle tek bir model veya

senaryo üzerinden ilerlerken, bu çalışmada parametrelerin farklı senaryolarda nasıl değiştiği derinlemesine incelenmiştir (Sittón-Candanedo vd., 2018). Sonraki bölümlerde, çalışmada kullanılan makine öğrenmesi üzerine üretim süreçlerinde yapılan çalışmalar literatür incelemesi olarak, materyal ve metot bölümünde kullanılan algoritmaların açıklamaları ve kullanım alanları, analiz bölümünde yapılan çalışmanın detaylarını içeren analizler, bulgular bölümünde çalışmaya ait bulgulara ve sonuçlar kısmında da çalışmanın sonuçları detaylı olarak aktarılmıştır.

LİTERATÜR İNCELEMESİ

Makine öğrenmesi (ML) ve ilgili yöntemlerin üretim süreçlerindeki kullanımı, son yıllarda üretim performansını optimize etmek ve süreç verimliliğini artırmak amacıyla önemli bir alan haline gelmiştir. Chen vd. (2020), iş birliğine dayalı üretim planlamasında ML ve Model Öngörücü Kontrol (MPC) yöntemlerini birleştirerek, üretim parametrelerindeki belirsizliklerin giderilmesine ve üretim verimliliğinin artırılmasına katkı sağlamışlardır. Benzer şekilde, küçük ölçekli sanayilere yönelik geliştirilen ML tabanlı modeller, hava durumu ve satış geçmişi gibi dış parametreleri kullanarak üretim planlamasında belirsizlikleri azaltmayı hedeflemektedir (Batra vd., 2023).

Denetimsiz öğrenme algoritmalarıyla üretim hatlarının performansının tahmin edilmesi ise arıza oranlarını azaltarak üretim süreçlerinde karar almayı optimize etmektedir (Adesiyan, 2021). Mokrova vd. (2018), k-En Yakın Komşu ve Rastgele Ormanlar algoritmalarını kullanarak üretimle ilgili olası tehlikeleri önceden tespit etmenin iş güvenliği ve üretim maliyetlerini düşürmedeki önemini vurgulamışlardır.

Petrol endüstrisinde ML kullanımı ise üretim tahminlerinde doğruluğu artırarak maliyetlerin düşürülmesine katkıda bulunmaktadır (Noshi vd., 2019). Ayrıca, genetik algoritmalarla üretim parametrelerinin optimize edilmesi, yüksek hacimli üretim süreçlerinde maliyetleri düşürerek verimliliği artırmaktadır (Al-Aomar & Al-Okaily, 2006).

Katmanlı üretim ve Bernoulli hatları gibi farklı üretim sistemlerinde makine öğrenimi algoritmalarının kullanımı da literatürde dikkat çekmektedir. Meng vd. (2020), ML'in katmanlı üretim süreçlerinde parametre optimizasyonu ve anomali tespitinde nasıl kullanıldığını incelemişlerdir. Sun ve Zhang (2020) ise Bernoulli hatlarında ML tabanlı parametrik tahmin yöntemleri geliştirerek üretim süreçlerinin doğruluğunu artırmayı hedeflemişlerdir.

Sinir ağları (CNN ve yapay sinir ağları) ise üretim süreçlerinde verimliliği artırmak ve ürün deformasyonlarını tahmin etmek amacıyla yaygın olarak kullanılmaktadır (Khdoudi vd., 2019; Mezentsev & Yasnitsky, 2022). Bu yöntemler, endüstriyel süreçlerde kaliteyi artırmak ve maliyetleri azaltmak için önemli araçlar haline gelmiştir. Bu çalışmalar, makine öğrenimi ve ilgili algoritmaların üretim süreçlerinde maliyetleri azaltma, verimliliği artırma ve kaliteyi iyileştirme konusundaki potansiyelini ortaya koymaktadır. Literatürdeki çeşitli yöntemler ve uygulamalar, ML'in üretim süreçlerine entegrasyonunun önemli faydalar sağladığını göstermektedir.

MATERYAL ve METOT

Materyal

Çalışmamızda, üretim performansının tahmin edilmesi amacıyla Karar Ağacı, Lineer Regresyon, Lasso Regresyon, XGBoost, Destek Vektör Regresyonu (DVR) ve LSTM algoritmaları kullanılmıştır. Her bir algoritmanın uygulanış şekli ve katkıları aşağıda açıklanmıştır:

1. Karar Ağacı (Decision Tree): Karar Ağacı Regresyon Modeli, bir hedef değişkeni tahmin etmek için kullanılan bir makine öğrenmesi yöntemidir. Veriyi dallara ayırarak kararlar oluşturan bir yapıdır. Karar Ağacı algoritmasının temel çalışma prensibi, bağımsız değişkenlerin değerlerine göre veri setini belirli kurallara dayanarak dallara ayırmaktır. Ağaç yapısı şeklinde organize edilir ve veri seti içindeki örnekleri bölerek çalışmaktadır. Temel çalışma mekanizması sırasıyla düğümler ve bölünmeler, karar kuralları, yaprak düğümler ve tahmin şeklindedir (Klusowski & Tian, 2021). Karar ağacı regresyon modelleri, mühendislik, finans, sağlık, pazarlama gibi birçok alanda kullanılmaktadır. Özellikle karmaşık veri yapılarında, açıklanabilirliğin önemli olduğu durumlarda tercih edilir. Bununla birlikte, genellikle diğer modelleme teknikleriyle (örneğin, rastgele ormanlar, gradyan artırılmalı ağaçlar) birlikte kullanılarak performans artırılabilir ve dezavantajları minimize edilebilir (Sevvanthi vd., 2023). Çalışmada kullanımı üretim parametreleri arasındaki ilişkileri hiyerarşik bir şekilde inceleyerek, her adımda en uygun kararı belirlemektedir. Bu algoritma, özellikle kararların görsel olarak anlaşılmasını kolaylaştırarak, üretim

süreçlerinde hangi parametrelerin daha etkili olduğunu belirlemeye katkı sağlar. Çalışmamızda, üretim performansını etkileyen en önemli parametreleri belirlemek amacıyla kullanılmıştır.

2. **Lineer Regresyon (Linear Regression):** Lineer regresyon modeli, bağımlı bir değişkeni (hedef değişken) bir veya daha fazla bağımsız değişkene (girdi değişkenleri) dayalı olarak tahmin etmek için kullanılan istatistiksel bir tekniktir. Lineer regresyon, bağımsız ve bağımlı değişkenler arasında doğrusal bir ilişki olduğunu varsayar. Bu varsayım her zaman geçerli olmayabilir ve doğrusal olmayan ilişkileri modellemek için yetersiz kalabilir (Ramachandran & Tsokos, 2021). Lineer regresyon, ekonomiden mühendisliğe, sosyal bilimlerden biyolojiye kadar pek çok alanda kullanılmaktadır (James vd., 2021). Çalışmada üretim performansını etkileyen parametreler arasındaki doğrusal ilişkiyi bulmak ve bu ilişkiyi kullanarak gelecekteki üretim performansını tahmin etmek amacıyla uygulanmıştır. Model, basit ve etkili tahminler sunarak üretim süreçlerinin optimizasyonuna katkıda bulunmuştur.
3. **Lasso Regresyon (Lasso Regression):** Lasso regresyon modeli, lineer regresyonun bir türüdür ve değişken seçimi ve düzenleme amacıyla kullanılır. Temel amacı, modelin karmaşıklığını azaltarak aşırı uyumu önlemektir. Lasso regresyon, klasik lineer regresyon modeline benzer, yani $y = b_0 + b_1x_1 + b_2x_2 + \dots + b_nx_n$ formülüne sahiptir. Ancak, lasso regresyon, katsayıları belirlerken bir ek kısıtlayıcı terim ekler (Lutay & Khusainov, 2021). Lasso regresyonu gereksiz veya anlamsız değişkenleri otomatik olarak sıfıra indirerek, modelin sadeliğini ve yorumlanabilirliğini artırmaktadır. Bu, yüksek boyutlu veri setlerinde özellikle faydalıdır. Lasso regresyonun düzenleme terimi, modelin aşırı öğrenmesini engeller ve genelleme yeteneğini artırır. Bu, modelin yeni veriler üzerinde daha iyi performans göstermesini sağlar (Ben-Moshe, 2020). Lasso regresyon, standart doğrusal regresyon tekniklerine benzer şekilde uygulanabilir ve mevcut istatistiksel yazılım paketlerinde kolayca kullanılabilir. Lasso regresyon, yüksek korelasyonlu bağımsız değişkenlerin bir kısmını sıfıra indirerek modelin stabilitesini artırabilir.
4. **XGBoost (Extreme Gradient Boosting):** XGBoost, denetimli öğrenme problemleri için kullanılan güçlü ve esnek bir makine öğrenmesi algoritmasıdır. Ayrıca XGBoost, karar ağaçları topluluğu oluşturarak hataları minimize eden bir gradyan artırma algoritmasıdır. Genellikle sınıflandırma ve regresyon görevlerinde kullanılır. XGBoost, bir dizi zayıf öğreniciyi, genellikle karar ağaçları olmak üzere ardışık olarak eğiterek güçlü bir öğrenici oluşturmaktadır. Her yeni ağaç, önceki ağaçların hatalarını düzeltmeye çalışır. Bu işlem, hataları minimize edecek şekilde ağırlıklandırılarak yapılır (Zhang vd., 2022). XGBoost'un avantajları arasında yüksek tahmin doğruluğu, hızlı hesaplama, esneklik ve düzenleme özellikleri sayılabilir. Özellikle yüksek doğruluk sunan ve hesaplama açısından verimli olan bu algoritma, büyük veri setleriyle iyi performans gösterir. Dezavantajları ise, hiperparametre ayarlarının karmaşıklığı ve büyük veri setlerinde hafıza tüketiminin yüksek olabilmesidir (Chen & Fan, 2021). Çalışmada, çok sayıda parametre içeren üretim süreçlerinin performans tahmin edilmesinde etkili olmuştur.
5. **Destek Vektör Regresyonu (Support Vector Regression - SVR):** Destek Vektör Regresyonu (DVR), makine öğrenmesinde kullanılan ve doğrusal ya da doğrusal olmayan bir modelle veri noktaları arasındaki ilişkileri tahmin etmeye çalışan bir yöntemdir. DVR'nin amacı, belirli bir hata toleransı içinde en geniş karar sınırını oluşturup yalnızca bu sınırın dışında kalan veri noktalarına odaklanarak tahminlerin doğruluğunu artırmaktır. DVR'de model, tahmin edilen değer ile gerçek değer arasındaki fark belirlenmiş bir hata toleransı (ϵ) sınırında kaldığında bu hatayı göz ardı eder ve yalnızca daha büyük sapmalara dikkat eder; böylece aşırı öğrenmenin önüne geçilerek genelleme kapasitesi artırılır (Vapnik, 1995). Bu yaklaşım, doğrusal bir fonksiyon ile verilerin arasındaki ilişkiyi tahmin etmek yerine, destek vektörleri olarak adlandırılan belirli veri noktalarına dayanarak karar sınırı belirler ve modelin daha hızlı işlem yapmasını sağlar (Cortes & Vapnik, 1995). Doğrusal verilerde DVR basit bir doğrusal fonksiyon kullanırken, doğrusal olmayan verilerde kernel (çekirdek) yöntemleri ile karmaşık ilişkiler öğrenilebilir. Kernel fonksiyonları, DVR'nin doğrusal olmayan problemlerdeki başarısını artıran en önemli bileşenlerden biridir ve bu sayede polinom, RBF (Radial Basis Function) ve sigmoid fonksiyonları gibi yaygın kernel fonksiyonları kullanılabilir (Bishop, 2006). Cortes ve Vapnik'in çalışmalarında doğrusal olmayan veri yapılarına da başarıyla uygulanabilen kernel yöntemleri, DVR'nin geniş bir uygulama alanında kullanılmasını sağlamıştır (Cortes & Vapnik, 1995). DVR, özellikle yüksek boyutlu veri setlerinde etkili bir şekilde çalışır ve finansal zaman serisi tahminleri gibi doğruluğun kritik olduğu alanlarda tercih edilir. Ancak, veri setinin boyutu ve seçilen kernel fonksiyonuna göre hesaplama maliyeti artabileceğinden, DVR büyük veri setlerinde uzun eğitim sürelerine ihtiyaç duyabilir (Vapnik, 1995).

6. LSTM (Long Short-Term Memory): LSTM, zaman serisi verileri ve geçmiş bilgilere dayalı olarak gelecekteki değerleri tahmin eden bir yapay sinir ağı modelidir. Üretim performansını etkileyen parametrelerin zamana dayalı değişimlerini öğrenerek gelecekteki performansı tahmin etmek amacıyla kullanılmıştır. Bu model, üretim süreçlerindeki değişiklikleri geçmiş verilere dayalı olarak daha doğru bir şekilde tahmin etme yeteneğiyle çalışmamıza katkı sağlamıştır. LSTM, tekrarlayan sinir ağlarının bir türüdür ve özellikle zaman serisi verileri veya metin, ses gibi dizilim verileriyle çalışmak için tasarlanmıştır. LSTM'ler, uzun vadeli bağımlılıkları yakalayabilme yeteneği ile bilinir. LSTM'ler, zaman serisi verileri, dil modelleme, konuşma tanıma gibi sıralı veri problemlerinde çok etkilidir.

Metot

Üretim sistemleri birbirini etkileyen birçok parametreden oluşmaktadır. Haddeleme işlemi metalurji sektöründe sıklıkla kullanılan bir işlem türüdür. Genellikle kalınlık inceltme ve yüzey düzgünlüğü sağlamak amacıyla haddeleme operasyonları yapılmaktadır. Haddeleme operasyonlarını etkileyen çeşitli parametreler bulunmaktadır. Hadde hızı, makinelerin uyguladığı yük, gergi kuvvetleri parametrelere örnek olarak verilebilir. Bu çalışma 2021-2023 yılları arasında makineden alınan sinyallerle oluşturulan ham veri seti üzerinde yapılmıştır. Veriler aynı ürün grubuna ait verilerdir. Veri seti içerisindeki girdi statüsündeki veriler aracılığıyla üretim performansını tahminlemek amaçlanmıştır. Veri setinde yer alan girdiler parametre olarak adlandırılabilir. Parametrelere ait veriler üretim hatlarında yer alan sinyaller ile toplanan verilerdir. Her bir veri, sinyaller üzerinden zaman ve tarih sınırlamaları ile üretim kayıtları ile eşleştirilmiştir. Üretim veri kayıtları SAP üzerinden geri bildirim esaslı olarak tutulmaktadır. 2 yıllık üretim verisinde yer alan her satır bir üretilen ürünü ifade etmektedir. Her bir kolon ise üretim sonucunda o üretimin oluşmasını sağlayan parametrelerdir. SAP verisi içerisinde yer alan tarih ve saat bazlı zaman bildirimleri ile anlık alınan üretim parametrelerine ait sinyal verileri zaman bazında eşleştirilerek toplamda 30000*39 yapısında bir matris elde edilmiştir. Sütunlar içerisinde yer alan veriler numerik verilerdir. Bu sebeple metinsel ifadelerin numerik ifadelere dönüştürülmesine gerek kalmamıştır. Veriler kamuya açık değildir ve şirket içi verilerdir. Bu sebeple parametreler detaylıca açıklanamamıştır. Korelasyon analizi yapılarak ihtiyaç duyulan veri ön işleme işlemi yapılmıştır. Veri ön işleme aşamasında birbirleri ile yüksek korelasyon derecesine sahip verilerin modele girmemesi, eksik ya da uç verilerin modelden çıkartılması, birbirlerinden hesaplanan verilerin ayrıştırılması amaçlanmıştır. Veri ön işleme öncesindeki veri setinin boyutu 30000*39 iken, veri ön işleme sonrası 30000*22 matris yapısına sahip veri, ana veriyi oluşturmaktadır. Ana veride yer alan kategorik veri yer almamaktadır. Makine performansının bağlı olduğu iki ana kriter vardır. Kriterler birbirlerini etkiledikleri için ayrıştırılarak da tahminleme performansları ölçülmüştür. 3 farklı senaryo için makine öğrenmesi uygulanmıştır. Tahminleme uygulamalarında tolerans değeri %10 olarak belirlenmiştir. Destek Vektör Uygulaması tahminleme uygulamasında kernel ve lineer olarak ele alınmıştır. Veriler 3 farklı şekilde incelenmiştir. İncelenen koşullar senaryolar şeklinde ifade edilmiştir. Performans sütunu, akım oranına bağlı olarak formülize edildiği için ilk senaryoda akım sütunu model dışında tutulmuştur. İkinci ve üçüncü senaryolarda ise performans kolonu model dışında tutularak korelasyon etkisi indirmek amaçlanmıştır. İlk senaryo olarak üretim verilerinin herhangi bir kısıtlayıcıya bağlı olmadan değerlendirilmesi koşuludur. Bu koşul üzerinden yapılan hesaplamalar için toplam veri boyutu 30000*22 olarak kalmıştır. Performans sütunu hedef sütun olarak seçildiğinde 30000*21 boyutlu matris sırasıyla 0,8 eğitim ve 0,2 test olmak üzere ayrıştırılmıştır. İlk senaryo için oluşan matris boyutu eğitim ve test veri setleri için sırasıyla; 24000*21 ve 6000*21 olarak oluşmuştur. İkinci senaryo için akım performansı kısıtlayıcı olarak kabul edilmiştir. Akım makinenin ne ölçüde güç kullandığının ölçütüdür. Bu kapsamda belirlenen akım kullanım kapasitesi %80'dir. İkinci senaryo ve üçüncü senaryo akım oranı %80 oranına bağlı olarak oluşmuştur. İkinci senaryo akım oranının %80 altında olduğu üretim koşullarını içerir. Üçüncü senaryo ise akım oranının %80 üzerinde olduğu üretim koşullarını içerir. Bu kapsamda ikinci ve üçüncü senaryo için veri boyutları 30000*20 olarak oluşturulmuştur. İkinci senaryo için %80 oranından yüksek üretim koşulları için toplam veri seti boyutu 20500*20 ve %80 oranından düşük üretim koşulları için toplam veri seti boyutu 9500*20 olarak oluşmuştur. Numerik verilerden oluşan veri setinde MinMaxScaler uygulanarak veriler 0-1 arasında ölçeklendirilmiştir. Her bir satırın bir ürünün üretimini temsil ettiği veri setinde yer alan sütunlar üretilen ürünün üretim koşullarını niteler. Satırlarda yer alan ürün ve üretim parametreleri göz önüne alarak hangi parametrelerin üretimin performansına etki ettiğini saptamak amaçlanmıştır. Bu çalışma gelecek dönemlerde yapılacak olan parametre aralıklarının belirlenmesi çalışmalarına verimsiz üretimlerin oluştuğu koşulları kategorize ederek katkıda bulunacaktır. Verilerin tamamı güncel üretim verisi olduğu için sürekli kontrole tabi tutulmaktadır. Bu sebeple verilerde herhangi bir boş hücre yer almamaktadır.

Çalışmada kullanılan modellerin değerlendirilmesi için birden fazla ölçüt kullanılmıştır. Kullanılan ölçütler sırasıyla maddeler halinde açıklanmıştır.

1. MAE (Mean Absolute Error): MAE, tahmin edilen değerler ile gerçek değerler arasındaki farkların mutlak değerlerinin ortalamasıdır. Modelin tahminlerinin ne kadar sapma gösterdiğini ölçer ve hataların büyüklüğünü anlamak için kullanılmaktadır. Küçük MAE değerleri, modelin daha doğru tahminler yaptığını göstermektedir.
2. MSE (Mean Squared Error): MSE, tahmin edilen değerler ile gerçek değerler arasındaki farkların karesinin ortalamasıdır. MSE, hataları karelediği için büyük sapmaların etkisini daha fazla vurgular. Küçük MSE değerleri, modelin daha iyi performans gösterdiğini göstermektedir.
3. RMSE (Root Mean Squared Error): RMSE, MSE'nin kareköküdür ve tahmin hatalarının ortalama büyüklüğünü ifade eder. RMSE, MSE'den farklı olarak hataları gerçek birimlerle ifade eder ve hataların büyüklüğünü daha kolay yorumlamayı sağlar. Küçük RMSE değerleri daha iyi bir model performansına işaret etmektedir.
4. R^2 (R-Squared): R^2 , modelin veri üzerindeki açıklayıcılık oranını gösterir. 0 ile 1 arasında bir değer alır ve 1'e yakın bir değer modelin tahminlerinin mükemmel olduğunu gösterirken, 0'a yakın bir değer modelin veriyi iyi açıklayamadığını göstermektedir.
5. MAPE (Mean Absolute Percentage Error): MAPE, tahmin edilen değerlerin gerçek değerlere göre yüzdesel hata oranını ölçmektedir. Hataların yüzde olarak ifadesi, tahmin edilen değer ne kadar doğru olduğunu anlamak için kullanılır. Küçük MAPE değerleri, modelin daha iyi bir performans gösterdiğini belirtmektedir. Bununla birlikte, MAPE değerinin teorik olarak alt sınırı 0'dır. Bu, tahmin edilen değerlerin tam olarak gerçek değerlerle örtüştüğünü göstermektedir; yani hata yoktur. MAPE'nin üst sınırı ise belirli bir değerle sınırlı değildir ve 100'ün üzerine çıkabilir. Yüksek MAPE değerleri, tahminlerin gerçek değerlere kıyasla çok büyük hatalar içerdiğini gösterir. MAPE metriği büyük hatalar durumunda çok büyük değerlere ulaşabilir, bu yüzden uç değerler göz önünde bulundurulmalıdır. Ancak genellikle pratikte çok yüksek MAPE değerleri (örneğin 100'den büyük) kötü performans anlamına gelmektedir.

Çalışmada üretimi etkileyen parametreler bilgi gizliliği kapsamında paylaşılmamaktadır. Çalışmada kullanılan algoritmalar sırasıyla; Karar Ağacı, Lineer Regresyon, Lasso Regresyon, XGBoost, Destek Vektör Regresyonu ve LSTM'dir. Algoritmalar oluşturulurken kullanılan hiperparametre değerleri maddeler halinde verilmiştir.

1. Karar Ağacı (Decision Tree):
 - DecisionTreeRegressor, max_depth:2, min_samples_split: 2, min_samples_leaf:1, criterion: "mse"
2. Lineer Regresyon (Linear Regression):
 - Fit_intercept: True, normalize: False
3. Lasso Regresyon (Lasso Regression):
 - Alpha:2, max_iter: 1000, tol:0.0001
4. XGBoost (Extreme Gradient Boosting):
 - XGBRegressor, Booster="gblinear", learning_rate:0.1, n_estimators: 100, max_depth: 3, subsample: 0.8, colsample_bytree: 0.8
5. Destek Vektör Regresyonu (Support Vector Regression - SVR):
 - SVR1: SVR, kernel: "RBF", C: 1.0, epsilon: 0.1, gamma: "scale" (RBF kernel için)
 - SVR2: SVR, kernel:"linear", C: 1.0, epsilon: 0.1
6. LSTM (Long Short-Term Memory):
 - Sequential, nöron=50, return_sequences=True, optimizer="adam", loss="mean_squared_error", Dense=1

Tüm analiz senaryoları için eğitim aşamasında veriler; 0,8 ve 0,2 oranında eğitim ve test verisi olarak ikiye ayrılmıştır. Ardından veriler MinMaxScaler metodu ile normalleştirilmiştir. Veri normalleştirilmesinin ardından veri seti üzerinde makine öğrenmesi algoritmaları Karar Ağacı, Lineer Regresyon, Lasso Regresyon, XGBoost, Destek Vektör Makinesi ve LSTM sıralı olarak uygulanmıştır. Senaryo açıklamaları sırasıyla maddeler halinde açıklanmıştır. Ayrıca, DVR1 ve DVR2, Destek Vektör Makinesi algoritmasının farklı çekirdek fonksiyonları (kernel) ile uygulanan varyantlarını temsil etmektedir. Bu doğrultuda, DVR1, RBF (Radial Basis Function) çekirdeğini, DVR2 ise lineer çekirdek fonksiyonunu kullanmaktadır. Bu iki varyant arasındaki farklar, çekirdek fonksiyonlarının veri üzerinde gösterdiği performansa dayanmaktadır.

- Senaryo 1:
 - Makine hız performansı ve akım performansı yüzde oranının büyük olanının kabul edildiği ortak performans tahminlemesi
- Senaryo 2:
 - Akım performansının performans kısıtı olarak kabul edildiği %80'nin altındaki senaryoya ait tahminleme
- Senaryo 3:
 - Akım performansının performans kısıtı olarak kabul edildiği %80'nin üzerindeki senaryoya ait tahminleme

ANALİZLER

Senaryo 1 Analizleri:

Veri setinde yer alan Ortak Performans değişkeni hedef değişken olarak belirlenmiştir.

Tablo 1. Senaryo 1 Model Doğruluk Ölçütleri

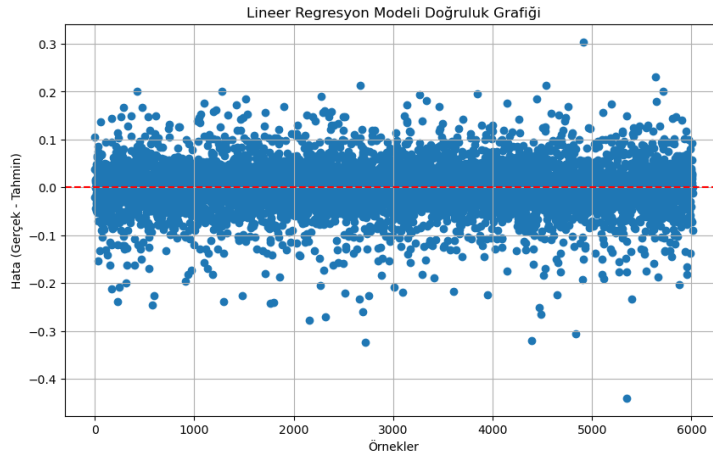
Algoritma	MAE	MSE	RMSE	R2	MAPE
Karar Ağacı	0,035	0,003	0,059	0,515	4,135
Lineer Regresyon	0,038	0,003	0,053	0,598	4,338
Lasso Regresyon	0,056	0,007	0,084	0,000	6,735
XGBoost	0,055	0,005	0,072	0,263	6,225
DVR1	0,070	0,006	0,079	0,109	7,324
DVR2	0,045	0,003	0,058	0,517	4,964
LSTM	0,860	0,747	0,865	-104,825	90,141

Model performanslarına ait veriler Tablo-1'de gösterilmiştir. Karar Ağacı düşük hata değerlerine ve makul bir R^2 değerine sahiptir. Bu da modelin veriyi iyi açıklayabildiğini göstermektedir. Lineer Regresyon, Karar Ağacı modelinden biraz daha yüksek MAE ve MAPE değerlerine sahip olsa da, en yüksek R^2 değerini elde ederek veriyi en iyi şekilde açıklayan model olarak öne çıkmaktadır. Lasso Regresyon, yüksek hata değerleri ile R^2 değerinin sıfır olması nedeniyle diğer modellerden çok daha kötü performans göstermektedir. XGBoost ise Lasso Regresyon'a benzer şekilde yüksek hata değerlerine sahiptir ve R^2 değeri daha düşüktür. Bu değer modelin yeterince iyi performans sağlamadığını göstermektedir. DVR1, yüksek hata değerleri ve düşük R^2 değeri ile diğer modellerden daha kötü performans göstermektedir. DVR2 ise SVM1'den daha iyi performans göstermektedir ve Karar Ağacı ile benzer sonuçlar elde etmektedir. LSTM modeli diğer modellerden çok daha kötü performans göstermektedir. Özellikle negatif R^2 değeri analiz sonuçlarında elde edilmiştir. Modelin tahminlerinin, ortalama tahminlerden daha kötü olduğunu göstermektedir. Özetle, Lineer Regresyon, en yüksek R^2 değeri ve makul hata metrikleriyle en iyi performans gösteren model olduğu tespit edilmiştir. Karar Ağacı ve DVR2, iyi performans gösteren diğer modellerdir. Lasso Regresyon, XGBoost, ve DVR1 daha düşük performans sergilerken, LSTM modeli belirgin şekilde en kötü performans sergilmektedir. Sonuç olarak, basit modeller (Lineer Regresyon ve Karar Ağacı) bu veri setinde daha karmaşık modellerden (LSTM, DVR1, XGBoost) daha iyi performans göstermiştir.

Tablo 2. Senaryo 1 Doğru Tahmin Yüzdesi

Algoritma	Doğru Tahmin Yüzdesi
Karar Ağacı	%93
Lineer Regresyon	%94
Lasso Regresyon	%90
XGBoost	%88
DVR1	%77
DVR2	%92
LSTM	%0

Model doğru tahmin yüzdesine ait veriler Tablo-2’de gösterilmiştir. Tablo-2’den yapılan çıkarım ile; Lineer Regresyon, en yüksek doğruluk oranı ile en iyi performansı göstermektedir. Karar Ağacı ve DVR2 de yüksek doğruluk oranları ile iyi performans göstermektedir. Lasso Regresyon ve XGBoost, diğer modellerden biraz daha düşük ancak kabul edilebilir performans sergilemektedir. DVR1 düşük doğruluk oranıyla diğer modellerden daha kötü performans göstermektedir. LSTM modelinin doğruluk oranı sıfır tespit edilmiştir, bu da modelin analizlerde en başarısız model olduğunu göstermektedir.

**Şekil 1.** Senaryo 1 Lineer Regresyon Doğruluk Grafiği

Şekil 1’de modelin tahmin performans değerlendirmesine ait grafik görülmektedir. Y ekseninde yer alan rakamlar, modelin tahmin ettiği değerler ile gerçek değerler arasındaki farkı göstermektedir. X ekseninde ise veri noktalarını temsil etmektedir. Her bir mavi nokta bir örneği temsil etmektedir. Bu noktalar modelin tahmin hatalarını göstermektedir. Mavi noktaların sıfır (0) değerine yakın olması modelin doğruluk oranının yüksek olmasını gösterir. Grafikte yer alan kırmızı çizgi, tahmin ile gerçek durumun örtüştüğü durumu niteler. Grafik genel olarak tahmin hatalarının dağılımını göstermektedir.

Şekil 1 incelendiğinde, %94 oranında doğruluk gösteren modelin hatalarının 0 değerinin altında ve üstünde dağılım gösterdiğini söylemek mümkündür. Hatalar sıfır çevresine yoğunlaştığı görülmektedir ve bu durum model açısından olumlu bir durumdur.

Model performanslarına ait veriler Tablo-3’te gösterilmiştir. Bu tabloda farklı makine öğrenimi modellerinin performans ölçümleri olumsuz sonuçlar göstermektedir. Genel olarak, tüm modeller negatif R^2 değerlerine sahip, bu da modellerin veriye iyi uyum sağlayamadığını ve tahminlerde başarısız olduğunu göstermektedir. Özellikle, LSTM modelinin R^2 değeri (-3186,204) ile en düşük performansı sergilediği, aynı zamanda en yüksek MAE (0,990) ve MAPE (100,001) değerlerine sahip olduğu gözlemlenmektedir. Bu, LSTM'nin bu verisetinde çok kötü bir sonuç verdiğini ortaya koymaktadır. Lasso Regresyon, en düşük MAE (0,318) ve MAPE (32,121) değerlerine sahip olmasına rağmen, R^2 değeri (-329,207) hala oldukça kötü, bu da modelin tahmin doğruluğunun düşük olduğunu

göstermektedir. Karar Ağacı ve DVR1 modelleri de benzer MAE ve MAPE değerleri sunuyor, ancak onların da R^2 değerleri oldukça negatif (-436,04 ve -459,651) olduğundan, başarı oranları düşük kalmaktadır. XGBoost ise en yüksek MSE (0,330) ve RMSE (0,574) değerleriyle birlikte, en kötü R^2 değerlerinden biri olan (-1072,142) ile tahminlerde oldukça başarısız bir performans sergilemektedir. Lineer Regresyon ve DVR2 modelleri de yüksek hata oranlarına sahip ve negatif R^2 değerleri (-764,418 ve -716,682) ile başarısızlıklarını göstermektedir. Genel olarak, bu modellerin hiçbirinin bu verisetinde iyi performans göstermediği ve veriyi yeterince iyi tahmin edemedikleri söylenebilir. Özellikle, negatif R^2 değerleri modellerin düşük uyum yeteneğini ve zayıf genelleme yapabildiğini işaret etmektedir.

Senaryo 2 Analizleri:

Veri setinde yer alan Kriter-1 kolonu hedef olarak belirlenmiştir. (Akım performansı < %80)

Tablo 3. Senaryo 2 Model Doğruluk Ölçütleri

Algoritma	MAE	MSE	RMSE	R2	MAPE
Karar Ağacı	0,337	0,134	0,366	-436,04	34,048
Lineer Regresyon	0,461	0,235	0,485	-764,418	46,491
Lasso Regresyon	0,318	0,101	0,318	-329,207	32,121
XGBoost	0,550	0,330	0,574	-1072,142	55,459
DVR1	0,334	0,141	0,376	-459,651	33,598
DVR2	0,446	0,220	0,470	-716,682	44,920
LSTM	0,990	0,981	0,990	-3186,204	100,001


Tablo 4. Senaryo 2 Doğru Tahmin Yüzdesi

Algoritma	Doğru Tahmin Yüzdesi
Karar Ağacı	%48,95
Lineer Regresyon	%32,94
Lasso Regresyon	%27,43
XGBoost	%16,9
DVR1	%85,34
DVR2	%39,32
LSTM	%44,93

Model doğru tahmin yüzdesine ait veriler Tablo-4'te gösterilmiştir. Tablo-4'ten yapılan çıkarım ile; DVR1, en yüksek doğruluk oranı ile en iyi performansı sergileyen modeldir. Bu, modelin veriyi çok iyi öğrendiğini ve güvenilir tahminler sağladığını gösterir. Karar Ağacı ve LSTM, orta düzeyde performans sergileyen modellerdir. Bu modellerin doğruluk oranları %40-50 arasında değişmektedir. DVR2, doğruluk oranı açısından DVR1'den çok daha düşük performans sergiliyor ve %40 civarında doğruluk sağlıyor. Lineer Regresyon ve Lasso Regresyon, düşük doğruluk oranları ile diğer modellerden daha kötü performans gösteriyor. XGBoost modeli, %16,9 doğruluk oranı ile başarısız olmuştur. Bu, modelin yapılandırmasında veya eğitiminde ciddi sorunlar olduğunu göstermektedir.

En yüksek doğru tahmin yüzdesine sahip olan DVR1 Modeli için doğruluk grafiği Şekil-2'de verilmiştir. Şekil-2'den yapılan çıkarımla, hatalar genelde -0,4 ile 0,4 arasında yoğunlaşmıştır. Bu, modelin genel olarak tahminlerinde büyük sapmalar yapmadığını, hataların çoğunlukla küçük olduğunu göstermektedir. Hataların çoğu sıfır etrafında yoğunlaşmıştır, bu da modelin tahminlerinin genel olarak doğruya yakın olduğunu işaret etmektedir. Grafikte, belirgin şekilde sıfırdan sapmış bazı aykırı değerler mevcuttur. Bunlar, modelin belirli örneklerde büyük hatalar

yaptığını göstermektedir. Ancak bu aykırı değerler genel dağılıma kıyasla az sayıda görünmektedir. X ekseninde boyunca hatalar geniş bir yelpazede dağılmıştır. Örnekler arasında belirgin bir desen ya da sistematik hata gözükmemektedir. Hatalar örnek sayısına göre rastgele dağılım göstermektedir. Bu tarz bir hata grafiği, modelin genellikle doğru tahminler yaptığını, ancak zaman zaman aykırı değerler gördüğünü ve hatalarının rastgele dağıldığını göstermektedir.



Şekil 2. Senaryo 2 DVR1 Doğruluk Grafiği

Senaryo 3 Analizleri:

Veri setinde yer alan Kriter-1 kolonu hedef olarak belirlenmiştir. (Akım performansı > %80)

Tablo 5. Senaryo 3 Model Doğruluk Ölçütleri

Algoritma	MAE	MSE	RMSE	R2	MAPE
Karar Ağacı	0,083	0,012	0,111	0,595	13,547
Lineer Regresyon	0,052	0,004	0,070	0,840	8,545
Lasso Regresyon	0,148	0,030	0,174	0,000	25,787
XGBoost	0,081	0,009	0,095	0,703	12,695
DVR1	0,064	0,006	0,083	0,772	9,108
DVR2	0,049	0,004	0,065	0,859	7,949
LSTM	0,646	0,449	0,670	-13,757	94,699

Model performanslarına ait veriler Tablo-5'te gösterilmiştir. Tablo, farklı makine öğrenimi algoritmalarının performansını karşılaştırmak için çeşitli hata metrikleriyle değerlendirilmiş sonuçları içermektedir. Modeller, MAE (Ortalama Mutlak Hata), MSE (Ortalama Kare Hatası), RMSE (Kök Ortalama Kare Hatası), R² (Doğruluk) ve MAPE (Ortalama Yüzde Hatası) gibi ölçütlerle analiz edilmiştir. Genel olarak, DVR2 ve Lineer Regresyon gibi bazı modeller iyi sonuçlar verirken, Lasso Regresyon ve LSTM gibi diğer modeller beklenenden çok daha düşük performans sergilemiştir. En iyi sonuçları veren model DVR2'dir. En düşük hata oranına (MAE: 0,049) ve en yüksek doğruluk oranına (R²: 0,859) sahiptir. Ayrıca MAPE değeri de en düşük olan modeldir (%7,949). DVR2, veri üzerinde oldukça iyi uyum sağlamış ve başarılı tahminler yapmıştır. Lineer Regresyon da DVR2'ye yakın bir performans sergilemiştir. Hata oranları düşük (MAE: 0,052) ve R² değeri oldukça yüksektir (0,840). Ayrıca MAPE değeri %8,545 ile oldukça başarılıdır. Bu iki model, düşük hata oranları ve yüksek doğrulukları ile veri üzerinde en iyi performansları sergilemişlerdir. DVR1 modeli de başarılı modeller arasında yer alır. MAE değeri 0,064, R² değeri ise 0,772'dir. Hata oranları biraz daha yüksek olmasına rağmen, doğruluk oranı tatmin edicidir. XGBoost ise orta seviye bir performans sergilemektedir. MAE değeri 0,081 ve R² değeri 0,703 ile veriye kabul edilebilir düzeyde uyum sağlamıştır. Ancak hata oranları diğer başarılı modellere göre biraz daha yüksektir. Karar Ağacı modeli ise yine orta düzeyde bir performans sergilemektedir. MAE değeri 0,083 ve R² değeri 0,595 ile DVR1 ve XGBoost'un gerisinde kalmış, ancak yine de makul sonuçlar üretmiştir. Diğer yandan, Lasso Regresyon modeli çok kötü bir performans sergilemiştir. MAE değeri 0,148 ile en yüksek değerlerden biridir ve R² değeri sıfırdır, yani model veriye hiç uyum

sağlayamamıştır. Yüzdesele hata oranı da oldukça yüksektir (MAPE: %25,787). LSTM ise en düşük performansı gösteren modeldir. Çok yüksek bir MAE değeri (0,646) ve negatif R² değeri (-13,757) ile veriye tamamen uyumsuz kalmıştır. Yüzdesele hata oranı da oldukça yüksektir (%94,699), bu da modelin veri üzerinde ciddi şekilde başarısız olduğunu göstermektedir. Sonuç olarak, DVR2, Lineer Regresyon ve DVR1 modelleri en iyi performansı sergileyen modellerdir. XGBoost ve Karar Ağacı ise orta seviye performans göstermektedir. Ancak Lasso Regresyon ve özellikle LSTM modeli oldukça kötü sonuçlar vermiştir.

Tablo 6. Senaryo 3 Doğru Tahmin Yüzdesi

Algoritma	Doğru Tahmin Yüzdesi
Karar Ağacı	%73,80
Lineer Regresyon	%86,97
Lasso Regresyon	%32,94
XGBoost	%67
DVR1	%77,61
DVR2	%88,80
LSTM	%0,00

Model doğru tahmin yüzdesine ait veriler Tablo-6'da gösterilmiştir. Tablo-6'dan yapılan çıkarım ile; DVR2 ve Lineer Regresyon en yüksek doğruluk oranları ile en iyi performansı sergileyen modellerdir. Bu, modellerin veriyi çok iyi öğrendiğini ve doğru tahminler sağladığını göstermektedir. DVR1, Karar Ağacı ve XGBoost modelleri de yüksek doğruluk oranları ile iyi performans sergilemektedir. Lasso Regresyon modeli düşük doğruluk oranı ile yetersiz performans sergilemektedir. LSTM modelleri ise neredeyse hiç doğru tahmin yapmamış ve tamamen başarısız olmuştur. Bu, modellerin yapılandırmasında veya eğitiminde ciddi sorunlar olduğunu göstermektedir.

Özellikle Lineer Regresyon ve Karar Ağacı modellerinin düşük hata metrikleri ile iyi performans sergilemesinin, üretim süreçlerinde önemli avantajlar sunmaktadır (Gültepe, 2019). Düşük hata oranları, üretim süreçlerinde daha doğru tahminlemelere olanak tanıyarak üretim hattındaki aksaklıkların ve hataların önüne geçilmesini sağlamaktadır (Aktaş & Aydın, 2018). Bu da hem maliyetleri düşürmekte hem de zaman kayıplarını en aza indirmektedir. Örneğin, doğru bir şekilde tahmin edilen üretim parametreleri sayesinde, fazla ya da yetersiz üretimden kaynaklanan stok maliyetleri minimize edilebilmektedir. Ayrıca, üretim hatlarındaki işlem sürelerinin optimize edilmesi, makinelerin duruş sürelerini azaltarak verimliliği arttırmaktadır. Bu durum, özellikle hızlı üretim süreçlerinin kritik olduğu sektörlerde, zamanında teslimat ve müşteri memnuniyeti açısından da büyük faydalar sağlamaktadır. Ayrıca, bulgularımızın literatürdeki benzer çalışmalarla karşılaştırılması da yapılmıştır. Moura vd. (2011) çalışmasında da benzer şekilde Lineer Regresyon'un iyi performans gösterdiği, ancak bizim çalışmamızda geniş veri seti ve farklı senaryoların kullanılmasıyla daha kapsamlı bir analiz yapıldığı vurgulanmıştır. Ayrıca, DVR2 modelinin diğer modellere göre daha yüksek doğruluk oranlarıyla öne çıktığı ve bu sonucun literatürdeki diğer çalışmalarda da benzer şekilde rapor edildiği belirtilmiştir (G. Angayarkanni & S. Hemalatha, 2023). Sonuç olarak, çalışmamızda elde edilen bulguların, üretim süreçlerini optimize etmek için makine öğrenmesi modellerinin nasıl kullanılabileceği konusunda önemli katkılar sunduğu vurgulanmıştır.

BULGULAR

Üretim performansı için kullanılan geliştirme yöntemlerinden biri olan veri analizi yoluyla makine öğrenmesi algoritmaları kullanılarak yapılan sonuçlara uygulama kısmında yer verilmiştir. Senaryo 1 için; Lineer Regresyon ve Karar Ağacı modelleri, düşük MAE ve RMSE değerleri ile iyi performans sergilemiştir. LSTM modeli ise çok yüksek hata metrikleri ve negatif R² değeri ile kötü performans göstermiştir. DVR1 ve DVR2 modelleri arasında DVR2, daha düşük hata metrikleri ile daha iyi performans sergilemiştir. Senaryo 2 için; R² değerinin negatif olması, modelin veriyi tahmin etmede başarısız olduğunu göstermektedir. Bu durum, modellerin çoğunun veri setindeki varyasyonu yakalayamadığını ve doğruluk oranlarının oldukça düşük olduğunu göstermektedir. Lasso Regresyon ve Karar Ağacı, görece en iyi sonuçları verse de, R² değerlerinin negatif olması ve hataların oldukça yüksek olması, modellerin genel performansını sınırlandırmaktadır. Özellikle LSTM'nin çok düşük performansı, bu modelin bu veri seti için uygun

bir seçenek olmadığını işaret etmektedir. Senaryo 3 için; DVR2 ve Lineer Regresyon modelleri en iyi sonuçları sunmakta olup, düşük hata oranları ve yüksek R^2 değerleri ile dikkat çekmektedir. Özellikle DVR2 modeli, hata oranlarının düşük olması ve yüksek doğruluğuyla veri setine çok iyi uyum sağlamaktadır. DVM1 modeli de tatmin edici bir performans sergilemektedir ve veriyi oldukça iyi açıklayabilmektedir. Bu üç model, düşük hata oranları ve yüksek R^2 değerleri ile güvenilir sonuçlar sağlamaktadır. Orta seviye performans gösteren XGBoost ve Karar Ağacı, farklı hiperparametre optimizasyonları ile daha başarılı sonuçlar verebilir. Lasso Regresyon ve LSTM, düşük uyum ve yüksek hata oranları nedeniyle veri seti için uygun modeller gibi görünmemektedir. Özellikle LSTM, bu veri setine uygun bir model olmadığını net bir şekilde göstermektedir.

Çalışmada Lineer Regresyon ve Karar Ağacı modellerinin düşük MAE ve RMSE değerleriyle iyi performans gösterdiği tespit edilmiştir. Bu sonuçlar, Moura vd. (2011) makinesel komponentlerin başarısızlık zamanlarını tahmin etmeye yönelik çalışmalarıyla uyum içindedir. Moura vd. SVM modelini kullandıkları çalışmada, DVR modeli de yüksek performans göstermiştir, ancak Lineer Regresyon'un bu bağlamda daha iyi sonuçlar verdiği bazı uygulamalarda rapor edilmiştir. Ayrıca, çalışmamızda LSTM yüksek hata metrikleri ve negatif R^2 değeri ile düşük performans gösterdiği gözlemlenmiştir. Bu sonuçlar, Hitam ve Ismail'in (2018) zaman serisi verisiyle kripto para birimi tahmini üzerine yaptıkları çalışmayla da paralellik göstermektedir. Bu çalışmada DVR'in, LSTM ve XGBoost modellerine göre daha doğru sonuçlar verdiği gözlemlenmiştir. Bununla birlikte, çalışmamızda DVR modelleri, özellikle DVR2'nin, diğer modellere kıyasla daha düşük hata metriklerine sahip olduğu ve yüksek performans sergilediği bulunmuştur. Bu sonuç, G. Angayarkanni ve S. Hemalatha'nın (2023) çeşitli hastalıkları tahmin etmek için farklı makine öğrenmesi algoritmalarını karşılaştırdıkları çalışmayla da örtüşmektedir. Onların çalışmasında da DVR'in yüksek doğruluk ve hassasiyet değerleri elde ettiği gözlemlenmiştir. Son olarak, çalışmamızda Karar Ağacı'nın da birçok durumda iyi performans gösterdiği vurgulanmıştır. Bu sonuç, Kathiresan vd. (2023) makine öğrenmesi algoritmalarının çeşitli veri setlerinde performanslarını karşılaştırdıkları çalışmalarla benzerlik taşımaktadır. Onların çalışmasında Karar Ağacı, diğer algoritmalar arasında ortalama bir performans sergilemiş, ancak belirli durumlarda daha etkili olmuştur. Bu çalışmada kullanılan üç senaryo üzerinde yapılan analizler sonucunda, Lineer Regresyon ve DVR2 modelleri genellikle en iyi performansı göstermiştir. Karar Ağacı ve DVR1 modelleri de çoğu durumda iyi performans sergilemiştir. Lasso Regresyon, XGBoost ve LSTM modelleri ise genel olarak düşük performans göstermiştir. Özellikle XGBoost ve LSTM, bazı veri setlerinde çok yüksek hata metrikleri ve negatif R^2 değerleri ile en kötü performansı sergilemiştir. Bu sonuçlar, model seçiminde dikkat edilmesi gereken önemli faktörleri ve her veri seti için en uygun modelin dikkatle belirlenmesi gerektiğini göstermektedir.

Model seçiminde dikkate alınması gereken çeşitli kriterler bulunmaktadır. İlk olarak, veri setinin yapısı, model seçiminde en önemli unsurlardan biridir. Veri setinin boyutu, özellik sayısı, verilerin dağılımı ve varsa sınırlamalar, hangi modelin daha iyi performans göstereceğini doğrudan etkilemektedir. Basit modeller, genellikle daha küçük ve daha düzenli veri setlerinde karmaşık modellere göre daha iyi performans göstermektedir. Bu çalışmada da görüldüğü üzere, Lineer Regresyon ve Karar Ağacı gibi daha basit modeller, karmaşık modellere (LSTM, XGBoost) kıyasla daha düşük hata oranları ve daha yüksek doğruluk oranları ile öne çıkmıştır. Bu durum, veri setinde fazla karmaşıklık olmaması halinde basit modellerin tercih edilmesinin performans açısından avantajlı olabileceğini göstermektedir. Karmaşık modeller, genellikle büyük ve karmaşık veri setlerinde daha etkili olsa da, bu çalışmada kullanılan veri seti, daha basit modellerle daha iyi sonuçlar vermiştir. Bunun temel nedeni, karmaşık modellerin yüksek miktarda veriye ve dikkatli hiperparametre ayarlamalarına ihtiyaç duymasındır. Ayrıca, karmaşık modellerin hesaplama maliyetleri daha yüksek olabilir ve fazla öğrenme (overfitting) riski taşıyabilmektedirler. Bu bağlamda, üretim süreçlerinde maliyetlerin düşürülmesi ve süreçlerin optimize edilmesi açısından, veri setine uygun basit modellerin tercih edilmesi hem pratik hem de maliyet açısından daha uygun olabilmektedir. Doğru model seçiminin, üretim süreçlerinde sadece tahmin doğruluğunu artırmakla kalmayıp, aynı zamanda süreç iyileştirmelerini daha etkin hale getirdiği tespit edilmiştir. Daha düşük hata oranları ile tahmin edilen üretim parametreleri, yanlış üretim kararlarının önüne geçilmesine, üretim maliyetlerinin düşürülmesine ve süreçlerin daha hızlı ve verimli bir şekilde optimize edilmesine olanak tanımaktadır. Bu nedenle, doğru model seçimi, yalnızca teknik bir karar değil, aynı zamanda operasyonel verimliliği artıran stratejik bir unsurdur.

SONUÇ

Bu çalışmada, iki yıllık veri seti kullanılarak üretim performansının tahmin edilmesi amacıyla farklı makine öğrenmesi algoritmaları (Karar Ağacı, Lineer Regresyon, Lasso Regresyon, XGBoost, Destek Vektör Makinesi ve LSTM) incelenmiştir. Üç farklı senaryo altında gerçekleştirilen analizler sonucunda, Lineer Regresyon ve Karar Ağacı modelleri genel olarak en düşük hata oranlarına ve en yüksek doğruluk seviyelerine ulaşarak veri setine uyum

sağlama konusunda güvenilir sonuçlar vermiştir. Özellikle Lineer Regresyon modeli, basit yapısı ile yüksek tahmin doğruluğu sağlamış, DVR2 modeli ise düşük hata oranlarıyla öne çıkmıştır. Bu çalışmada daha karmaşık modeller olan LSTM ve XGBoost, veri setinin yapısına uyum sağlamakta zorlanmış ve negatif R² değerleriyle düşük performans göstermiştir. LSTM modelinin özellikle üretim parametrelerini tahmin etmede başarısız olması, veri setinin karmaşık zaman serisi yapılarına uygun olmamasından kaynaklanabilir. Bununla birlikte, Lineer Regresyon ve Karar Ağacı gibi daha basit modeller, veri setinde düşük hata oranları ve yüksek doğruluk oranları sunarak özellikle küçük ve daha düzenli veri setleri için uygun modeller olduğunu ortaya koymuştur. Çalışmanın bulguları, literatürdeki benzer çalışmalarla karşılaştırıldığında, Lineer Regresyon ve Karar Ağacı modellerinin özellikle düşük hata oranları ve yüksek performansı ile öne çıktığı görülmektedir (Moura & arkadaşları, 2011; Hitam & Ismail, 2018).

Bu çalışma, belirli bir ürün grubuna ve iki yıllık bir zaman dilimine dayalı olarak yapılmış olup, sonuçların genellenebilirliği sınırlıdır. Farklı sektörlerde ve daha uzun zaman dilimlerinde yapılacak benzer çalışmalar, bulguların geçerliliğini ve genellenebilirliğini artırmaktadır. Ayrıca, çalışmamızda yalnızca statik veri kullanılmış olup, gelecekteki araştırmalarda gerçek zamanlı verilerin kullanımıyla daha dinamik analizler yapılabilir. Endüstri 4.0 ve dijitalleşme süreciyle birlikte, makine öğrenmesi algoritmalarının üretim süreçlerine entegrasyonu giderek daha önemli hale gelmektedir. Gelecekte, yapay zeka algoritmalarının daha geniş çapta kullanımını araştırmak ve bu algoritmaların çevresel ve sosyal etkilerini incelemek, sürdürülebilir üretim süreçlerine katkı sağlayabilecektir. Bu nedenle, gelecekteki araştırmalar, farklı veri setleri ve gelişmiş algoritmalar kullanılarak daha kapsamlı ve genellenebilir sonuçlar elde etmeye yönelik olmalıdır.

KAYNAKÇA

- Adesiyan, A. (2021). Performance Prediction Of Production Lines Using Machine Learning Algorithm. <https://doi.org/10.14293/s2199-1006.1.sor-.ppa7be8.v1>.
- Aktaş, B., & Aydın, C. (2018). Talaşlı imalat sektöründe zaman serileri kullanarak üretim etkinliğinin tahmini. *Bilişim Teknolojileri Dergisi*, 11(4), 407-416.
- Al-Aomar, R., & Al-Okaily, A. (2006). A GA-based parameter design for single machine turning process with high-volume production. *Comput. Ind. Eng.*, 50, 317-337. <https://doi.org/10.1016/j.cie.2006.02.003>.
- Angayarkanni, G., & Hemalatha, S. (2023). Evaluating the performance of supervised machine learning algorithms for predicting multiple diseases: A comparative study. 2023 9th International Conference on Advanced Computing and Communication Systems (ICACCS).
- Angelopoulos, A., Michailidis, E. T., Nomikos, N., Trakadas, P., Hatziefremidis, A., Voliotis, S., & Zahariadis, T. (2019). Tackling faults in the Industry 4.0 era—a survey of machine-learning solutions and key aspects. *Sensors* (Basel, Switzerland).
- Batra, R., Abbi, P., Sharma, R., Agarwal, H., & Bhulania, P. (2023). Production prediction using machine learning. 2023 10th International Conference on Signal Processing and Integrated Networks (SPIN), 399-404. <https://doi.org/10.1109/SPIN57001.2023.10116936>.
- Ben-Moshe, D. (2021). IDENTIFICATION OF LINEAR REGRESSIONS WITH ERRORS IN ALL VARIABLES. *Econometric Theory*, 37(4), 633–663. <https://doi.org/10.1017/S0266466620000250>
- Bishop, C. M. (2006). *Pattern Recognition and Machine Learning*. Springer. <https://doi.org/10.5555/1162264>
- Chandra Prabha, S., & Lakshmi, S. (2023). Data analysis and machine learning-based modeling for real-time production. *The Scientific Temper*. <https://doi.org/10.58414/scientifictemper.2023.14.2.22>.
- Chen, Y., Zhou, Y., & Zhang, Y. (2020). Collaborative Production Planning with Unknown Parameters using Model Predictive Control and Machine Learning. 2020 Chinese Automation Congress (CAC), 2185-2190. <https://doi.org/10.1109/CAC51589.2020.9326614>.
- Chen, Y., Zhou, Y., & Zhang, Y. (2021). Machine Learning-Based Model Predictive Control for Collaborative Production Planning Problem with Unknown Information. *Electronics*. <https://doi.org/10.3390/electronics10151818>.
- Chen, Z., & Fan, W. (2021). A freeway travel time prediction method based on an XGBoost model. *Sustainability*, 13(15), 8577. <https://doi.org/10.3390/su13158577>

- Cinar, Z., Abdussalam Nuhu, A., Zeeshan, Q., Korhan, O., Asmael, M. B. A., & Safaei, B. (2020). Machine learning in predictive maintenance towards sustainable smart manufacturing in Industry 4.0. *Sustainability*.
- Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, 20(3), 273-297. <https://doi.org/10.1007/BF00994018>
- Gültepe, Y. (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 8-15.
- Hitam, N. A., & Ismail, A. R. (2018). Comparative performance of machine learning algorithms for cryptocurrency forecasting. *Indonesian Journal of Electrical Engineering and Computer Science*.
- James, G., Witten, D., Hastie, T., Tibshirani, R., James, G., Witten, D., ... & Tibshirani, R. (2021). Linear model selection and regularization. An introduction to statistical learning: with applications in R, 225-288.
- Jun, Z. (2021). The development and application of support vector machine. In *Journal of Physics: Conference Series* (Vol. 1748, No. 5, p. 052006). IOP Publishing.
- Kathiresan, V., Dinesh, G., Sarveshwaran, V., Jayakanth, J. J., & Kiruthika, M. (2023). Comparative analysis of diverse classification algorithms of machine learning by using various quality metrics. 2023 IEEE 5th International Conference on Cybernetics, Cognition and Machine Learning Applications (ICCCMLA).
- Khdoudi, A., Masrour, T., & Mazgualdi, C. (2019). Using Machine Learning Algorithms for the Prediction of Industrial Process Parameters Based on Product Design. , 728-749. https://doi.org/10.1007/978-3-030-36671-1_67.
- Klusowski, J. M., & Tian, P. M. (2024). Large scale prediction with decision trees. *Journal of the American Statistical Association*, 119(545), 525-537.
- Leha, A., Pangercic, D., Rühr, T., & Beetz, M. (2009). Optimization of simulated production process performance using machine learning. 2009 IEEE Conference on Emerging Technologies & Factory Automation, 1-5. <https://doi.org/10.1109/ETFA.2009.5347229>.
- Lutay, V. N., & Khusainov, N. S. (2021, November). The selective regularization of a linear regression model. In *Journal of Physics: Conference Series* (Vol. 2099, No. 1, p. 012024). IOP Publishing
- Meng, L., McWilliams, B., Jarosinski, W., Park, H., Jung, Y., Lee, J., & Zhang, J. (2020). Machine Learning in Additive Manufacturing: A Review. *JOM*, 72, 2363 - 2377. <https://doi.org/10.1007/s11837-020-04155-y>.
- Mezentsev, A., & Yasnitsky, L. (2022). Neural network model for determining the regulations parameters in the technological process of ore raw materials processing. *Journal Of Applied Informatics*. <https://doi.org/10.37791/2687-0649-2022-17-6-56-67>.
- Mokrova, N., Mokrov, A., Safonova, A., & Vishnyakov, I. (2018). Machine Learning Methods for Production Cases Analysis. *IOP Conference Series: Materials Science and Engineering*, 317. <https://doi.org/10.1088/1757-899X/317/1/012044>.
- Moura, M., Zio, E., Lins, I. D., & Droguett, E. (2011). Failure and reliability prediction by support vector machines regression of time series data. *Reliability Engineering & System Safety*, 96(12), 1527–1534.
- Noshi, C., Eissa, M., & Abdalla, R. (2019). An Intelligent Data Driven Approach for Production Prediction. Day 4 Thu, May 09, 2019. <https://doi.org/10.4043/29243-MS>.
- Rahul, R., Tiwari, M., Ivanov, D., & Dolgui, A. (2021). Machine learning in manufacturing and Industry 4.0 applications. *International Journal of Production Research*, 59(18), 4773-4778.
- Ramachandran, K. M., & Tsokos, C. P. (2020). *Mathematical statistics with applications in R*. Academic Press.
- Rimpault, X., Balazinski, M., & Chatelain, J. (2018). Fractal analysis application outlook for improving process monitoring and machine maintenance in Manufacturing 4.0. *Journal of Manufacturing and Materials Processing*.
- Sevvanthi, K., Ganapathy, S., Penumadu, P., & Harichandrakumar, K. T. (2023). Comparing the predictive performance of a decision tree with logistic regression for oral cavity cancer mortality: A retrospective study. *Cancer Research, Statistics, and Treatment*, 6(1), 103-110.

Sittón-Candanedo, I., Hernández Nieves, E., Rodríguez, S., Santos-Martín, M., & González-Briones, A. (2018). Machine learning predictive model for Industry 4.0. In Proceedings of the 16th International Conference on Information Systems, Management, and Automation (pp. 501-510).

Strasser, S., Tripathi, S., & Kerschbaumer, R. (2018). An Approach for Adaptive Parameter Setting in Manufacturing Processes. , 24-32. <https://doi.org/10.5220/0006894600240032>.

Sun, Y., & Zhang, L. (2020). Parameter Identification for Multiple-Machine Bernoulli Lines using Statistical Learning Methods. 2020 IEEE 16th International Conference on Automation Science and Engineering (CASE), 810-815. <https://doi.org/10.1109/CASE48305.2020.9216960>.

Vapnik, V. (1995). The Nature of Statistical Learning Theory. Springer. <https://doi.org/10.1007/978-1-4757-2440-0>

Zhang, P., Jia, Y., & Shang, Y. (2022). Research and application of XGBoost in imbalanced data. International Journal of Distributed Sensor Networks, 18(6), 15501329221106935.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 18.07.2024
Kabul Tarihi : 21.08.2024

Received Date : 18.07.2024
Accepted Date : 21.08.2024

ÇORAP BOYAMA ATIKSULARININ FENTON VE ELEKTRO-FENTON PROSESLERİ İLE ARITIMI

TREATMENT OF SOCK DYEING WASTEWATER BY FENTON AND ELECTRO-FENTON PROCESSES

İbrahim YOKSULABAKAN¹ (ORCID: 0000-0002-5875-3350)

Özgecan MADENLİ¹ (ORCID: 0000-0002-8673-3963)

Ece Ümmü DEVECİ^{1*} (ORCID: 0000-0002-7551-188X)

¹ Niğde Ömer Halisdemir Üniversitesi, Çevre Mühendisliği Bölümü, Niğde, Türkiye

*Sorumlu Yazar / Corresponding Author: Ece Ümmü DEVECİ, ecedeveci@gmail.com

ÖZET

Tekstil endüstrisi hem dünya genelinde hem de Türkiye'de sürekli olarak gelişmekte olan bir sektördür ve üretim kapasitesi her geçen gün artmaktadır. Ancak bu büyüme artan atıksu problemini de beraberinde getirmektedir. Üretim süreci sonrasında ortaya çıkan atıksular, kullanılan kimyasallara ve boyalara bağlı olarak kirlilik derecesi değişkenlik göstermektedir. Bu atıksular genellikle renkli, yüksek organik içerikli ve biyolojik olarak parçalanması zor bileşenler içermektedir. Bu çalışma, bir tekstil fabrikasından alınan çorap boyama atıksularının klasik Fenton (KF) ve elektro-fenton (EF) prosesleri ile arıtılabilirliğini incelemektedir. Çalışmada KF ve EF proseslerinin arıtma verimliliği, renk ve KOİ (Kimyasal Oksijen İhtiyacı) giderimine etkisi değerlendirilmiştir. KF prosesinde zaman, Fe⁺² ve H₂O₂ konsantrasyonunu parametrelerin etkisi, EF prosesinde ise zaman, voltaj, H₂O₂ konsantrasyonu ve elektrotlar arası mesafe parametrelerin etkisi incelenmiştir. Elde edilen sonuçlara göre, KF prosesi için %96 KOİ ve %75 renk giderim, EF prosesi için %99 KOİ giderimi ve %85 renk giderimi sağlanmıştır. Bu bulgular, EF prosesinin daha etkili bir çözüm olduğunu göstermektedir. Sonuç olarak KF prosesi yüksek KOİ giderimi sağlasa da renk gideriminde yetersiz kalmaktadır. Buna karşılık EF prosesi daha etkili bir şekilde atıksuların arıtılmasını sağlamaktadır. Bu çalışma, çorap boyama atıksularının arıtımında EF prosesinin önemli bir potansiyele sahip olduğunu göstermektedir.

Anahtar Kelimeler: Çorap boyama atıksuları, fenton, elektro-fenton, kimyasal oksijen ihtiyacı, renk

ABSTRACT

The global textile industry, including Turkey, is continuously expanding, leading to an increase in production capacity and consequently, a rise in wastewater generation. The pollution levels in this wastewater depend on the chemicals and dyes used in the manufacturing process. Typically, textile wastewater is colored, has high organic content, and contains components that are challenging to degrade biologically. This study investigates the treatability of wastewater from a textile factory's sock dyeing process using conventional Fenton (CF) and electro-Fenton (EF) processes. The study focuses on the effectiveness of these processes in removing color and chemical oxygen demand (COD) from the wastewater. Key parameters such as time, Fe⁺² concentration, and H₂O₂ concentration were analyzed in the CF process, while the EF process examined the effects of time, voltage, H₂O₂ concentration, and electrode distance. The results showed that the CF process achieved 96% COD and 75% color removal, whereas the EF process achieved superior results with 99% COD and 85% color removal. These findings suggest that the EF process is a more effective method for treating textile wastewater, particularly in terms of color removal. This study highlights the significant potential of the EF process in improving wastewater treatment efficiency in the textile industry.

Keywords: Sock dyeing wastewater, fenton, electro-fenton, chemical oxygen demand, color

GİRİŞ

Tekstil endüstrisi, küresel ekonomide önemli bir rol oynamaktadır. Ancak, tekstil endüstrisi en büyük atıksu üreten endüstrilerden biridir. Günde 8000 kg ürün üreten bir tekstil üretim birimi yaklaşık 1,6 milyon litre su tüketmektedir (Alkaya & Demirer, 2014). Bu su tüketiminin yaklaşık %25'i baskı ve boyama işlemlerinden kaynaklanmaktadır (Raja vd., 2019). Ayrıca USEPA'ya göre, 1 kg kumaşı boyamak için 40 litre su gereklidir. Ancak bu miktar işlem türü ve tekstil malzemesinin değişimi gibi faktörlere bağlıdır (Ćurić vd., 2021). Öte yandan, tekstil üretiminde boyama işlemlerinden kaynaklanan tekstil atıksuyu çevre için ciddi bir tehdit oluşturmaktadır (Uddin, 2021). Boyama işlemlerinden kaynaklanan tekstil atıksuları genellikle çeşitli boyalar, yardımcı kimyasallar, yüzey aktif maddeler ve tuzlar içermektedir (Kishor vd., 2021). Bu bileşenleri içeren tekstil atıksuları, alıcı ortama girdiğinde çevrede kalarak biyotik ve abiyotik bileşenler için toksisitesine yol açmaktadır (Uddin, 2021).

Geleneksel tekstil atıksuyu arıtma süreçleri bu kirleticileri gidermek için genellikle yetersiz kalmaktadır ve bu da ileri arıtma teknolojilerine olan ihtiyacı arttırmaktadır (Azanaw vd., 2022). Son yıllarda, ileri oksidasyon süreçlerinin (AOP) tekstil atıksuyu arıtımında özellikle boyar madde içeren atıksuların arıtımı için umut verici ve kanıtlanmış bir yaklaşımdır (Paździor vd., 2019). AOP'lar arasında KF ve EF süreçleri, basit, hem de kısmi mineralizasyon sağlamaları, toksisiteyi azaltmaları ve atıksuyun biyolojik bozunabilirliğini artırmaları nedeniyle özel bir ilgi görmektedir (Pelalak vd., 2023). Fenton süreçlerinde, demir iyonlarının (Fe^{+2}) hidrojen peroksit (H_2O_2) ile reaksiyonu sonucu son derece reaktif hidroksil radikalleri (OH^\bullet) oluşmaktadır (Luo vd., 2022) Ayrıca, çeşitli organik bileşiklerin bozunması için büyük bir potansiyele sahiptir.

Literatür çalışmaları incelendiğinde, Kuleyin vd., (2021) tarafından yapılan çalışmalarda, grafit elektrotlarla biyolojik olarak arıtılmış tekstil atıksularının ileri arıtımında EF teknolojisinin etkinliği araştırılmıştır. Sonuçlarında, grafit anot ve katot ile EF sürecinin, optimal işletme koşulları altında %89 renk, %93 KOİ ve %58 TOC giderim verimliliği sağlayarak atıksu kalitesini iyileştiren ve suyun yeniden kullanımı için uygun hale getiren bir teknoloji olduğunu bildirmişlerdir. Sobczak vd., (2024), KF ve EF işlemlerinin tekstil atıksularının yeniden kullanımı için arıtımından sonra yan ürünlerin giderimi ve biyolojik bozunabilirliklerini araştırmışlardır. Başka bir çalışmada ise gerçek tekstil atıksuyunun EF ile bozunma performansı, atık biyokütleden modifiye edilmiş biyokömür elektrotlar kullanılarak araştırılmıştır (Temur Ergan vd., 2023). İncelenen literatür çalışmaları KF ve EF proseslerinin farklı elektrotlarla daha efektif ve yüksek verim elde edilmek için hala araştırmaların devam ettiğini göstermektedir.

Bu çalışmada, çorap boyama atıksularının arıtımında KF ve EF süreçlerinin etkinliği araştırılmış ve çorap boyama atıksularındaki organik boyalar ve diğer kirleticilerin giderim verimliliği değerlendirilmiştir. KF süreci için zaman, H_2O_2 ve Fe^{+2} konsantrasyonu etkisi araştırılırken EF süreci için ise H_2O_2 konsantrasyonu, elektrotlar arası mesafe, zaman ve voltaj parametrelerinin süreç verimliliği üzerindeki etkileri incelenmiştir. Ayrıca çorap boyama atıksularının arıtımı için KF ve EF prosesleri için optimum işletme koşulları belirlenmiştir.

MATERYAL ve METOT

Malzemeler

Çorap boyama atıksuyu, Kayseri Organize Sanayi Bölgesi'nde bulunan çorap üretim fabrikasından temin edilmiştir. Temin edilen atıksuyun fizikokimyasal özellikleri Tablo 1'de verilmiştir. Örnekler, analiz dönemine kadar $+4^\circ C$ sıcaklıkta ve karanlıkta saklanmıştır. Çalışmada, demir (II) sülfat heptahidrat ($FeSO_4 \cdot 7H_2O$, Merck), hidrojen peroksit (H_2O_2 %30, Merck), sülfürik asit (H_2SO_4 %95, Merck), pH metre (WTW Multi 9620 IDS), dijital manyetik karıştırıcı (IKA manyetik karıştırıcı), santrifüj (Thermo Scientific Sl 16) ve bir termoreaktör kullanılmıştır.

Tablo 1. Çorap Boyama Atıksuyunun Fizikokimyasal Özellikleri

Parametre	Değer
pH	6,39
KOİ (mg/L)	5330
İletkenlik (us/cm)	227
Bulanıklık (NTU)	105
Renk, absorbans (nm)	420

KF Prosesi

KF prosesi için pH, zaman, Fe⁺² ve H₂O₂ konsantrasyonu önemli parametrelerdir. Özellikle pH parametresi demir ve hidrojenin türleşmesi nedeniyle dikkate alınması gereken bir faktördür. İncelenen literatür çalışmalarına göre, KF süreç reaksiyonları için optimum pH aralığı 2,5-3'tür (Kaur vd., 2018; Ramirez-Pereda vd., 2020) Çorap boyama atıksuyunun KF ile arıtımı için belirlenen parametre aralıkları şunlardır: Karıştırma hızı = 200 rpm, zaman = 15, 30, 45, 60, 75, 90 ve 120 dakika, pH = 3, V = 500 mL, H₂O₂ konsantrasyonu = 25, 50, 100 ve 150 mL/L ve Fe⁺² = 0,50, 1, 2,5 ve 5 g/L.

EF Prosesi

Çorap boyama atıksuyunun EF prosesi için bir deneysel düzenek hazırlandı. Deneyler, 500 ml aktif hacme sahip bir cam beherde (10,5 cm (çap) × 14,5 cm (derinlik)) gerçekleştirildi. Kullanılan demir elektrotların tamamı 6,0 cm × 8,5 cm (genişlik × yükseklik) yüzey alanına sahip olup, her iki elektrot da aynı boyut ve 1 mm kalınlıktadır. EF prosesinin zaman, voltaj ve H₂O₂ konsantrasyonu açısından optimize edilmesi için deneyler yapıldı. EF reaktörünün işletme koşulları: hacim 500 mL, karıştırma hızı = 200 rpm, pH = 3, zaman = 15, 30, 45, 60 ve 120 dakika, elektrotlar arası mesafe = 1, 2 ve 3 cm, voltaj = 10, 20 ve 30 V ve H₂O₂ konsantrasyonu = 10, 20 30, 40 ve 50 mL/L. Atıksuyun pH'ını ayarlamak için 1 M H₂SO₄ çözeltisi kullanıldı. pH istenen işletme koşullarına ayarlandıktan sonra, elektrot çiftlerinin bağlandığı sisteme H₂O₂ dozajlanarak sistem başlatıldı. Reaksiyon süresi boyunca belirli aralıklarla numuneler alındı. Reaksiyonu durdurmak için toplanan numunelere sodyum tiyosülfat eklendi. Daha sonra numuneler, toplanan numunelerdeki demir partiküllerini çöktürmek için 9000 rpm'de 15 dakika santrifüj edildi. Arıtma verimliliği, santrifüjden sonra berrak fazdaki numunelerin KOİ ve renk analizi incelenerek test edildi.

Analitik Metotlar

Atıksu ve arıtılmış atıksu numunelerindeki KOİ konsantrasyonları, Standart Metotlara (APHA, 1995) göre analiz edilmiştir. Sürecin sonuçları, yüzde giderim fonksiyonu olarak, denklem (1) ile hesaplanmıştır:

$$\% \text{ KOİ Giderimi} = \frac{\text{KOİ}_{\text{giriş}} - \text{KOİ}_{\text{çıkış}}}{\text{KOİ}_{\text{giriş}}} * 100 \quad (1)$$

Atıksuyun ve arıtılmış atıksu numunelerin rengi, UV-VIS spektrofotometre kullanılarak absorpsiyon yöntemiyle belirlenmiştir. Spektrofotometrede 300–800 nm aralığında tarama yapılmış ve en uygun absorbans değeri 420 nm olarak ayarlanmıştır. KF ve EF reaksiyonu süresince 10 mL hacminde toplanan numuneler filtrelenmiştir. Daha sonra, 4 mL'lik spektrofotometre küvetlerine doldurulmuş ve 420 nm dalga boyunda absorbans değerleri okunmuştur. Renk giderim verimliliği, denklem (2) kullanılarak hesaplanmıştır:

$$\% \text{ Renk Giderimi} = 1 - \frac{A_t}{A_0} * 100 \quad (2)$$

A₀: atıksuyun absorpsiyon değerini, A_t ise arıtılmış suyun absorpsiyon değerini göstermektedir.


BULGULAR ve TARTIŞMA

KF Prosesi

H₂O₂ Konsantrasyonu Etkisi

KF sürecinde üretilen OH[•] radikallerinin en önemli kaynağı H₂O₂'dir. Reaksiyon çözeltisinde fazla H₂O₂ bulunması atıksuyun KOİ değerini artırmaktadır. Fakat H₂O₂ konsantrasyonunun çok yüksek olması işletme maliyetlerini de etkilemektedir (Ramos vd., 2021). Bu nedenle, KF prosesinde H₂O₂'nin optimizasyonu önemlidir. Farklı konsantrasyonlarda H₂O₂ eklenerek KF oksidasyon sürecinde optimizasyon için deneysel çalışmalar yapılmıştır. H₂O₂ konsantrasyonunu optimize etmek için reaktörün işletme koşulları: H₂O₂ konsantrasyonu 25, 50, 100, 150 mL/L, pH = 3, karıştırma hızı = 200 rpm, Fe⁺² konsantrasyonu = 2,5 g/L ve süre = 15-120 dakikadır. Şekil 1, H₂O₂ konsantrasyonunun KOİ ve renk giderimi üzerindeki etkilerini göstermektedir. H₂O₂ konsantrasyonu 150 mL/L'ye yükseldiğinde KOİ giderim verimliliği %80'in üzerine çıkarken, H₂O₂ konsantrasyonu 50 mL/L'nine altına düştüğünde KOİ giderim verimliliği azalmıştır. (Şekil 1a). H₂O₂ konsantrasyonu arttıkça, ortamda OH[•] radikallerinin artması nedeniyle KOİ giderim verimliliği yükselmiştir. Ortamdaki tüm OH[•] radikallerinin kullanılması ve arıtılmış suda OH[•] radikallerinin bulunmaması alıcı ortamda biyolojik bozunma için önemlidir. En yüksek KOİ giderim verimliliği (%92) 100 mL/L H₂O₂ konsantrasyonunda gözlemlenmiştir. Ayrıca, süreç 45. dakikada maksimum

giderim verimliliğine ulaşmıştır. Şekil 1b'de ise H₂O₂ konsantrasyonuna bağlı olarak renk giderim verimliliği verilmiştir. Renk giderimi 100 mL/L H₂O₂ konsantrasyonunda %75 olarak gözlemlenmiştir.



Şekil 1. H₂O₂ Konsantrasyonunun a) KOİ ve b) Renk Giderimi Üzerine Etkisi

Fe⁺² Konsantrasyonunun Etkisi

KF oksidasyonunda reaktifin dozu organik maddenin bozunmasında önemlidir. Genel olarak, organik maddenin parçalanma hızı, Fe⁺² dozajının artmasıyla artmaktadır. Fe⁺² yokluğunda, ortamda OH• radikalleri oluşturmak için temel bir faktör bulunmadığından, fenton reaksiyonuna dayalı etkili bir oksidasyon gerçekleşmez. Fe⁺² konsantrasyonu ne kadar yüksek olursa, teorik olarak o kadar fazla OH• radikali oluşmaktadır (GülPavas vd., 2017). Ancak, reaksiyonda fazla miktarda Fe⁺² iyonu, çözünmüş toplam demir konsantrasyonunu artırmakla kalmaz, aynı zamanda çamur oluşumuna da yol açmaktadır (Karthikeyan, vd., 2011). Bu durum, süreç maliyetleri üzerinde de olumsuz bir etkiye sahip olabilir. Bu nedenle, Fe⁺² konsantrasyonunu, radikallerle reaksiyona girecek şekilde ayarlamak ve optimize etmek önemlidir. Çorap boyama atıksuyunun KF oksidasyonunda Fe⁺² konsantrasyonunu optimize etmek için reaktörün işletme koşulları: Fe⁺² konsantrasyonu 0,5, 1, 2,5 ve 5 g/L, pH = 3, karıştırma hızı = 200 rpm, H₂O₂ konsantrasyonu = 100 mL/L ve zaman = 15-120 dakikadır. Şekil 2 Fe⁺² konsantrasyonunun zamana bağlı olarak KOİ ve renk giderimi üzerindeki etkisini göstermektedir. Sonuçlar, KOİ giderim verimliliğinin artan Fe⁺² konsantrasyonuyla arttığını göstermektedir. 45. dk'da Fe⁺² konsantrasyonu 5 g/L olduğunda %96 KOİ giderimi gözlemlenmiştir (Şekil 2a).


KF prosesinde Fe⁺² konsantrasyonunun renk giderimi üzerindeki etkisi Şekil 2b'de gösterilmiştir. 5 g/L Fe⁺² konsantrasyonunda %96 KOİ giderimi gözlemlenirken, 2,5 g/L Fe⁺² konsantrasyonunda renk giderimi %75 olarak gözlemlenmiştir. Fe⁺² konsantrasyonu ne kadar yüksek olursa, teorik olarak o kadar fazla OH• radikali oluşmaktadır. Bu durum KOİ giderimi üzerinde olumlu bir etkiye sahipken, renk giderimi sırasında Fe⁺² iyonlarının aşırı çözünmesi rengi dolayısıyla renk parametresi üzerinde olumsuz bir etkiye yaratmaktadır.

EF Prosesi


Voltajın Etkisi

EF prosesi ile çorap boyama atıksuyunun arıtımında zaman, elektrotlar arası mesafesi, voltaj ve H₂O₂ konsantrasyonu parametrelerinin etkileri araştırılmış ve optimize edilmiştir. EF prosesinin en önemli işletme parametrelerinden biri, elektrotlara uygulanan voltaj seviyesidir. Çorap boyama atıksuyunun KOİ değeri ve renk giderim verimliliği üzerindeki uygulanan voltajın etkisini araştırmak amacıyla, 10 ile 30 V arasında çalışılmıştır. Voltaj optimizasyonu için reaktör işletme koşulları: hacim = 500 mL, voltaj = 10 V, 20 V, 30 V, pH = 3, karıştırma hızı = 200 rpm, H₂O₂ konsantrasyonu = 20 mL/L'dir. Şekil 3a, uygulanan voltajın 10V'den 30 V'e çıkarılmasının KOİ giderim verimliliğini %40'tan %57'ye yükselttiğini göstermektedir. Benzer sonuçlar Panizza ve Cerisola, (2009) tarafından yapılan çalışmada da

gözlemlenmiştir. Ancak, voltajın 45. dakikadan sonra yüksek giderim verimliliğinde azalmaya neden olduğu görülmektedir. Bu nedenle, EF süreci için optimum zaman, KF oksidasyonunda olduğu gibi 45 dakika olarak belirlenmiştir. Voltaj arttıkça, KOİ giderim verimliliği de artmaktadır. Bu durum, anottan Fe^{+2} iyonlarının salınmasına yol açan reaksiyonlara bağlanabilir; Faraday kuralı dikkate alındığında, demir iyonlarının sayısı zaman ve akım ile birlikte artmaktadır (Santana-Martínez vd., 2016). Zaman ve voltaj arttıkça, üretilen demir iyonlarının sayısının, hidrojen peroksit ile reaksiyona girecek miktarla orantılı veya daha fazla olacağı varsayılmaktadır. EF süreci için optimum voltaj 30 V olarak belirlenmiştir. Uygulanan voltajın renk giderimi üzerindeki etkisi Şekil 3b'de gösterilmiştir. Şekilde görüldüğü gibi KOİ giderimi arttıkça renk giderimi de artmaktadır. Voltaj 10 V'dan 30 V'a çıkarıldığında, renk giderimi %70'ten %85'e yükselmiştir. Deneysel, voltajın artırılmasının renk giderimini hızlandırdığını göstermiştir. Ayrıca, voltajın artırılması her iki parametre için de giderim performansını artırmıştır.



Şekil 2. Fe²⁺ Konsantrasyonunun a) KOİ ve b) Renk Giderimi Üzerine Etkisi




Şekil 3. Voltajın a) KOİ ve b) Renk Giderimi Üzerine Etkisi

H₂O₂ Konsantrasyonunun Etkisi

H₂O₂ konsantrasyonu, EF prosesinin en önemli parametrelerinden biridir. Deneysel çalışmada, H₂O₂ konsantrasyonunun KOİ ve renk giderim verimliliği üzerindeki etkilerini araştırmak amacıyla 10, 20, 30, 40 ve 50

mL/L H₂O₂ konsantrasyon aralığı belirlenmiştir. H₂O₂ optimizasyonu için işletme koşulları: pH = 3, karıştırma hızı = 200 rpm, hacim = 500 mL, V = 30 V, zaman = 15-120 dakikadır. Şekil 4a'da H₂O₂ konsantrasyonunun KOİ giderim verimliliği üzerindeki etkisi gösterilmektedir. H₂O₂ konsantrasyonu 10 mL/L'den 50 mL/L'ye artırıldığında, KOİ giderimi %60'tan %90'ın üzerine ulaşmıştır (Şekil 4a). Optimum H₂O₂ konsantrasyonu 40 mL/L olarak belirlenmiş ve %95 KOİ giderimi sağlanmıştır. Daha fazla miktarda H₂O₂ eklenmesi ile giderim verimliliği azalmaktadır. Fenton reaksiyonuna göre H₂O₂ konsantrasyonu arttıkça, ortamda hidroksil radikallerinin seviyesi artar ve buna bağlı olarak bozunma derecesi ve giderim verimliliği artmaktadır. Ayrıca Fenton reaksiyonuna göre H₂O₂ konsantrasyonunun artmasıyla ortamdaki hidroksil radikalının seviyesi artmaktadır. Bunu bağlı olarak bozunma derecesi ve giderim etkinliği de artmaktadır. Dahası fazla oranlarda H₂O₂ dozlaması, radikal temizleyici rolüne sahiptir. Ek olarak burada hidroksil radikaliyle reaksiyona girerek, daha düşük reaktiviteye sahip olan ve organik bileşiklerin bozunmasında hiçbir rolü olmayan hidroksil radikalının üretimiyle sonuçlanmaktadır (Gürtekin & Şekerdağ, 2008).



Şekil 4. H₂O₂ konsantrasyonunun a) KOİ ve b) Renk Giderimi Üzerine Etkisi

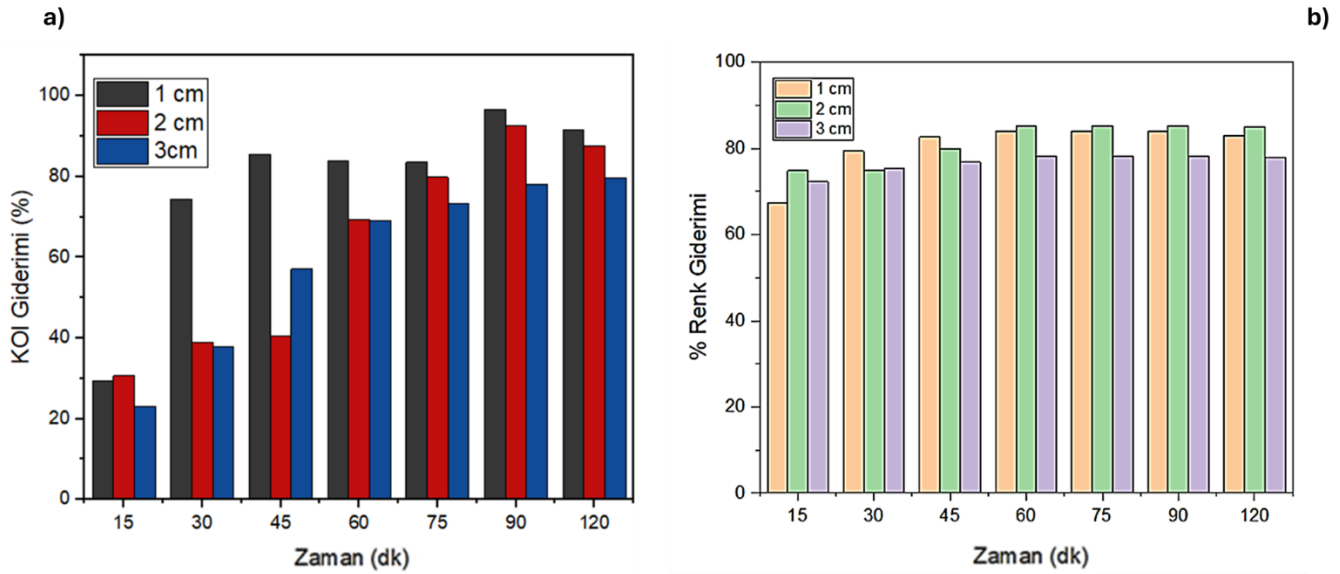
Şekil 4b'de H₂O₂ konsantrasyonu 10 mL/L'den 50 mL/L'ye artırıldığında, renk giderimi %74'ten %85'e yükselmiştir. 40 mL/L H₂O₂ konsantrasyon değeri hem KOİ hem de renk giderimi için optimum değer olarak bulunmuştur. Ayrıca, KOİ giderimi maksimum seviyesine 90. dakikada ulaşırken, renk giderimi 60. dakikada maksimum seviyesine ulaşmıştır. Bu durum rengin KOİ'den önce giderildiğini göstermektedir.

Elektrotlar Arası Mesafenin Etkisi

EF prosesinde, elektrotlar arasındaki mesafe kirleticilerin giderimini etkileyen bir diğer önemli faktördür. Deneysel çalışmada EF prosesinde elektrot aralığını optimize etmek için aşağıdaki işletme koşulları seçilmiştir: pH = 3, karıştırma hızı = 200 rpm, hacim = 500 mL, V = 30 V, H₂O₂ konsantrasyonu 40 mL/L'dir. Şekil 5a'da elektrotlar arasındaki mesafenin KOİ giderim verimliliği üzerindeki etkilerini gösterilmektedir. Elektrotlar arasındaki mesafe azaldıkça, KOİ giderim verimliliği %90'ın üzerine çıkmıştır. Ancak elektrotlar arasındaki mesafe 3 cm olduğunda, KOİ giderim verimliliği %70'e düşmüştür. Elektrot mesafesi 1 cm olduğunda %90'ın üzerinde bir KOİ giderim verimliliği elde edildiğinden, optimum değer 1 cm olarak belirlenmiştir. Bu durum, elektrotlar arasındaki mesafe arttıkça elektrik direncinin arttığı ve dolayısıyla çözeltinin iletkenliğinin azaldığı gerçeğiyle ilişkilendirilebilir. Bu aynı zamanda enerji tüketimini azaltarak, Fe²⁺ ve OH[•] iyonlarının üretimini azaltmaktadır. Ayrıca, elektrotlar arasındaki mesafe arttıkça üretilen Fe²⁺ ve OH[•] iyonları arasındaki çarpışmaların azalması ve böylece KOİ giderim verimliliğinin düşmesi beklenmektedir. Kim vd., (2002)'nin sonuçları, elektrokimyasal süreçte elektrotlar arasındaki mesafenin 0.5 cm'den 3 cm'ye artırılmasıyla mavi disperse boya 106'nın giderim verimliliğinin %80'den %46'ya düştüğünü göstermektedir. Malakootian & Moridi, (2017)'de elektrotlar arasındaki mesafenin 1 cm'den 3 cm'ye artırılmasının, Acid Red 18 boyasının gideriminde %74'lük bir düşüşe yol açtığını gözlemlemiştir. Elde edilen sonuçlar, literatür çalışmalarıyla uyumlu görünmektedir.

Elektrotlar arası mesafesinin renk giderimi üzerindeki etkisi Şekil 5b'de gösterilmektedir. Elektrotlar arasındaki mesafenin artırılması enerji gereksinimini artırdığı için, minimum enerji tüketimini sağlamak amacıyla elektrotlar arasındaki minimum mesafeler seçilmelidir. KOİ giderimi için elektrotlar arasındaki optimal mesafe 1 cm iken, renk giderimi için optimal mesafe 2 cm olarak kabul edilmektedir. Bu durum, hidroksil radikallerinin kirleticiyle daha

kolay bağlanmasıyla açıklanabilir. Elektrotlar arasındaki 2 cm mesafede %85 renk giderimi gözlemlenmiştir. Ancak, her iki parametre için de optimum mesafe 2 cm ise, KOİ gideriminde %10'luk bir kayıp gözlemlenebilir. 1 cm mesafede, renk gideriminde ise %5'lik bir azalma gözlemlenmiştir. Renk giderimindeki kayıp tolere edilebildiği için, bu yöntem için elektrotlar arasındaki optimum mesafe 1 cm olarak belirlenmiştir.



Şekil 5. Elektrotlar Arasındaki Mesafe a) KOİ ve b) Renk Giderimi Üzerine Etkisi

SONUÇLAR VE ÖNERİLER

Bu çalışmada çorap boyama atıksuyunun KF ve EF süreçleri ile arıtılabilirliği incelenmiştir. Çorap boyama atıksuyunun arıtılabilirliği renk ve KOİ parametreleri göz önünde bulundurularak değerlendirilmiştir. Her iki proseste de 120 dakikalık test süresi boyunca gerçekleştirilerek çalışma iki aşamada yürütülmüştür. Birinci aşamada KF oksidasyonu kullanılmış, ikinci aşamada ise EF oksidasyonu yapılmıştır. Çorap boyama atıksuyunun KF oksidasyonu ile arıtılması üzerine yapılan deneylerde Fe^{+2} miktarı (0.5, 1, 2.5 ve 5 g/L), H_2O_2 miktarı (25, 50, 100, 150 mL/L) ve zaman (15, 30, 45, 60, 75, 90 ve 120 dakika) etkileri araştırılarak Optimal koşullar belirlenmiştir. KF prosesi için 5 g/L Fe^{+2} konsantrasyonu, 100 mL/L H_2O_2 , pH=3, 45 dakika süresince yapılan deneylerde % 96 KOİ giderim verimliliği elde edilmiştir. Ayrıca, 2.5 g/L Fe^{+2} konsantrasyonunda %75 renk giderimi gözlemlenmiştir. EF prosesi için ise, voltaj (10, 20 ve 30 V), pH=3, H_2O_2 (10, 20, 30, 40 ve 50 mL/L) ve elektrotlar arasındaki mesafe (1, 2 ve 3 cm) giderim verimliliğini belirlemek amacıyla deneyler gerçekleştirilmiştir. EF prosesi için optimum koşullar 30 V voltaj, pH = 3, elektrotlar arasındaki mesafe 1 cm ve H_2O_2 40 mL/L olarak belirlenmiştir. Bu koşullar altında maksimum KOİ giderimi %99 ve elektrotlar arasındaki 1 cm mesafede renk giderimi %85 olarak belirlenmiştir. Sonuç olarak, çorap boyama tesisinden kaynaklanan atıksuyun düşük pH ve optimum Fe^{+2} ve H_2O_2 dozajlaması ile hem KF hem de EF oksidasyon süreçlerinde etkili arıtma verimliliğine sahip olduğu bulunmuştur. Bu sonuçlar, endüstriyel atıksuyun arıtılması için alternatif ve etkili yöntemlerin kullanılabilirliğini göstermektedir.

TEŞEKKÜR

Bu çalışma Niğde Ömer Halisdemir Üniversitesi'nde yürütülen "Çorap Boyama Fabrikası Atıksuyunun Fenton ve Elektro-Fenton Prosesleri ile Arıtılabilirliği" konulu yüksek lisans tezinden türetilmiştir. Ayrıca, bu çalışmada kullanılan atıksuyu temin eden Kayseri Organize Sanayi Bölgesi'nde faaliyet gösteren KARTESK A.Ş.'ye teşekkür ederiz.

KAYNAKLAR

Alkaya, E., & Demirer, G. N. (2014). Sustainable textile production: A case study from a woven fabric manufacturing mill in Turkey. *Journal of Cleaner Production*, 65, 595–603. <https://doi.org/10.1016/j.jclepro.2013.07.008>

Azanaw, A., Birlie, B., Teshome, B., & Jemberie, M. (2022). Textile effluent treatment methods and eco-friendly resolution of textile wastewater. *Case Studies in Chemical and Environmental Engineering*, 6(July), 100230. <https://doi.org/10.1016/j.cscee.2022.100230>

Ćurić, I., Dolar, D., & Karadakić, K. (2021). Textile wastewater reusability in knitted fabric washing process using

- UF membrane technology. *Journal of Cleaner Production*, 299, 126899. <https://doi.org/10.1016/J.JCLEPRO.2021.126899>
- GilPavas, E., Dobrosz-Gómez, I., & Gómez-García, M. Á. (2017). Coagulation-flocculation sequential with Fenton or Photo-Fenton processes as an alternative for the industrial textile wastewater treatment. *Journal of Environmental Management*, 191, 189–197. <https://doi.org/10.1016/j.jenvman.2017.01.015>
- Gürtekin, E., & Şekerdağ, N. (2008). Bir ileri oksidasyon prosesi: Fenton prosesi. *Journal of Engineering Sciences*, 14(3), 229–236.
- Karthikeyan, S., Titus, A., Gnanamani, A., Mandal, A. B., & Sekaran, G. (2011). Treatment of textile wastewater by homogeneous and heterogeneous Fenton oxidation processes. *Desalination*, 281(1), 438–445. <https://doi.org/10.1016/j.desal.2011.08.019>
- Kaur, P., Kushwaha, J. P., & Sangal, V. K. (2018). Transformation products and degradation pathway of textile industry wastewater pollutants in Electro-Fenton process. *Chemosphere*, 207, 690–698. <https://doi.org/10.1016/j.chemosphere.2018.05.114>
- Kim, T. H., Park, C., Shin, E. B., & Kim, S. (2002). Decolorization of disperse and reactive dyes by continuous electrocoagulation process. *Desalination*, 150(2), 165–175. [https://doi.org/10.1016/S0011-9164\(02\)00941-4](https://doi.org/10.1016/S0011-9164(02)00941-4)
- Kishor, R., Purchase, D., Saratale, G. D., Saratale, R. G., Ferreira, L. F. R., Bilal, M., ... Bharagava, R. N. (2021). Ecotoxicological and health concerns of persistent coloring pollutants of textile industry wastewater and treatment approaches for environmental safety. *Journal of Environmental Chemical Engineering*, 9(2), 105012. <https://doi.org/10.1016/J.JECE.2020.105012>
- Kuleyin, A., Gök, A., & Akbal, F. (2021). Treatment of textile industry wastewater by electro-Fenton process using graphite electrodes in batch and continuous mode. *Journal of Environmental Chemical Engineering*, 9(1). <https://doi.org/10.1016/j.jece.2020.104782>
- Luo, Z., Liu, M., Tang, D., Xu, Y., Ran, H., He, J., ... Sun, J. (2022). High H₂O₂ selectivity and enhanced Fe²⁺ regeneration toward an effective electro-Fenton process based on a self-doped porous biochar cathode. *Applied Catalysis B: Environmental*, 315(April), 121523. <https://doi.org/10.1016/j.apcatb.2022.121523>
- Malakootian, M., & Moridi, A. (2017). Efficiency of electro-Fenton process in removing Acid Red 18 dye from aqueous solutions. *Process Safety and Environmental Protection*, 111, 138–147. <https://doi.org/10.1016/j.psep.2017.06.008>
- Panizza, M., & Cerisola, G. (2009). Electro-Fenton degradation of synthetic dyes. *Water Research*, 43(2), 339–344. <https://doi.org/10.1016/j.watres.2008.10.028>
- Paździor, K., Bilińska, L., & Ledakowicz, S. (2019). A review of the existing and emerging technologies in the combination of AOPs and biological processes in industrial textile wastewater treatment. *Chemical Engineering Journal*, 376(December 2018), 120597. <https://doi.org/10.1016/j.cej.2018.12.057>
- Pelalak, R., Hassani, A., Heidari, Z., & Zhou, M. (2023). State-of-the-art recent applications of layered double hydroxides (LDHs) material in Fenton-based oxidation processes for water and wastewater treatment. *Chemical Engineering Journal*, 474(June). <https://doi.org/10.1016/j.cej.2023.145511>
- Raja, A. S. M., Arputharaj, A., Saxena, S., & Patil, P. G. (2019). Water requirement and sustainability of textile processing industries. *Water in Textiles and Fashion: Consumption, Footprint, and Life Cycle Assessment*, 155–173. <https://doi.org/10.1016/B978-0-08-102633-5.00009-9>
- Ramirez-Pereda, B., Álvarez-Gallegos, A., Bustos-Terrones, Y. A., Silva-Martínez, S., & Hernández-Pérez, A. (2020). Effective Electro-Fenton Treatment for a Real Textile Effluent: A Case Study. *Journal of Water Process Engineering*, 37(February). <https://doi.org/10.1016/j.jwpe.2020.101434>
- Ramos, M. D. N., Santana, C. S., Velloso, C. C. V., da Silva, A. H. M., Magalhães, F., & Aguiar, A. (2021). A review on the treatment of textile industry effluents through Fenton processes. *Process Safety and Environmental Protection*, 155, 366–386. <https://doi.org/10.1016/j.psep.2021.09.029>
- Santana-Martínez, G., Roa-Morales, G., Del Campo, E. M., Romero, R., Frontana-Urbe, B. A., & Natividad, R. (2016). Electro-Fenton and Electro-Fenton-like with in situ electrogeneration of H₂O₂ and catalyst applied to 4-chlorophenol mineralization. *Electrochimica Acta*, 195, 246–256. <https://doi.org/10.1016/j.electacta.2016.02.093>

Sobczak, M., Bujnowicz, S., & Bilińska, L. (2024). Fenton and electro-Fenton treatment for industrial textile wastewater recycling. Comparison of by-products removal, biodegradability, toxicity, and re-dyeing. *Water Resources and Industry*, 31(December 2023), 1–14. <https://doi.org/10.1016/j.wri.2024.100256>

Temur Ergan, B., Aydin, E. S., & Gengec, E. (2023). Improving electro-fenton degradation performance using waste biomass-derived-modified biochar electrodes: A real environment textile water treatment. *Journal of Environmental Chemical Engineering*, 11(6). <https://doi.org/10.1016/j.jece.2023.111439>

Uddin, F. (2021). Environmental hazard in textile dyeing wastewater from local textile industry. *Cellulose*, 28(17), 10715–10739. <https://doi.org/10.1007/s10570-021-04228-4>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 22.07.2024
Kabul Tarihi : 23.09.2024

Received Date : 22.07.2024
Accepted Date : 23.09.2024

UÇUCU KÜL VE GUAR SAKIZI İLE STABİLİZE EDİLMİŞ BİR KİL ZEMİNİN MUKAVEMET ÖZELLİKLERİNİN TAGUCHİ TEKNİĞİ KULLANILARAK DEĞERLENDİRİLMESİ

EVALUATION OF THE STRENGTH PROPERTIES OF A CLAY SOIL STABILIZED WITH FLY ASH AND BIOPOLYMER USING THE TAGUCHI TECHNIQUE

Mehmet Fatih YAZICI^{1*} (ORCID: 0000-0002-3557-7817)
Mehmet Fahri SARAÇ² (ORCID: 0000-0002-0760-5569)
Çağla AYDIN³ (ORCID: 0009-0009-9863-4522)
Melce Begüm POLAT³ (ORCID: 0009-0006-3411-5246)
Can Mustafa ÇALIK³ (ORCID: 0000-0003-3281-4925)
Caner ÖZEN³ (ORCID: 0000-0002-2728-706X)

¹Süleyman Demirel Üniversitesi, İnşaat Mühendisliği Bölümü, Isparta, Türkiye
²Süleyman Demirel Üniversitesi, Otomotiv Mühendisliği Bölümü, Isparta, Türkiye
³Yeşilirmak Elektrik Dağıtım Anonim Şirketi, YEDAŞ, Samsun, Türkiye

*Sorumlu Yazar / Corresponding Author: Mehmet Fatih YAZICI, mehmet yazici@sdu.edu.tr

ÖZET

Geoteknik mühendisliğinde problemleri zeminlerin iyileştirilmesinde araştırmacılar uzun yıllardır çimento ve kireç gibi geleneksel kimyasal katkıları yaygın bir şekilde kullanmaktadırlar. Bu malzemelerin zemin stabilizasyonunda sağladığı faydaların yanı sıra çevresel açıdan getirdiği zararlar göz ardı edilemeyecek seviyelerdedir. Bu sebeple araştırmacılar yıllardır farklı stabilizasyon malzemeleri ile laboratuvar ve arazi şartlarında deneyler yaparak çevre, sürdürülebilirlik, ekonomiklik ve sağladığı diğer faydalar açısından en iyiye ulaşabilmeyi amaçlamışlardır. Bu çalışma, yukarıda bahsi geçen amaca ulaşabilmek için mükemmel pozulanik özelliklere sahip bir atık olan uçucu kül ile çevre dostu ve sürdürülebilirlik açısından son zamanlarda geoteknik araştırmacıların gözdesi olan guar sakızının bir kil zeminin mukavemet özellikleri üzerindeki etkilerini değerlendirmiştir. Zaman, emek ve maliyet açısından tasarruf ederek deneysel sürecin yürütülebilmesi için Taguchi deney tasarımı yönteminden istifade edilmiştir. Sonuç olarak uçucu kül ve biyopolimer ilavesi ile doğal zeminin serbest basınç mukavemetinin 6,5, sekant elastisite modülünün ise 20,4 kata kadar artış gösterdiği görülmüştür. Elde edilen sonuçlar sadece uçucu kül ve sadece kireçle stabilize edilmiş numunelerin mukavemet özellikleri ile karşılaştırılmış ve kil zemine uçucu kül ile guar sakızı ilave etmenin çok daha yüksek mukavemet artışları verdiği gözlenmiştir.

Anahtar Kelimeler: Zemin stabilizasyonu, uçucu kül, guar gum, taguchi deney tasarımı

ABSTRACT

Researchers in geotechnical engineering have used traditional chemical additives such as cement and lime for many years to improve problematic soils. In addition to the benefits of these materials in soil stabilization, their environmental damage cannot be ignored. For this reason, researchers have been trying to achieve the best in environment, sustainability, economy, and other benefits by conducting tests with different stabilization materials in laboratory and field conditions for years. To achieve the goal mentioned above, this study assessed the combined effects of fly ash, a waste with excellent pozzolanic properties, and guar gum, which has recently become a favorite of geotechnical researchers in terms of environmental friendliness and sustainability, on the strength properties of clay soil. Taguchi's design of the experiment method was used to carry out the experimental process by saving time, labour, and cost. As a result, the unconfined compressive strength of the natural soil increased by 6.5 times, and the ToCite: YAZICI, M. F., SARAÇ, M. F., AYDIN, Ç., POLAT, M. B., ÇALIK, C. M., & ÖZEN, C., (2025). UÇUCU KÜL VE GUAR SAKIZI İLE STABİLİZE EDİLMİŞ BİR KİL ZEMİNİN MUKAVEMET ÖZELLİKLERİNİN TAGUCHİ TEKNİĞİ KULLANILARAK DEĞERLENDİRİLMESİ. Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi, 28(1), 89-103.

secant elasticity modulus increased by 20.4 times with the addition of fly ash and biopolymer. The results were compared with the strength properties of specimens stabilized only fly ash and lime, and it was observed that adding fly ash and guar gum to the clay soil increased strength much more.

Keywords: Soil stabilization, fly ash, guar gum, taguchi experimental design

GİRİŞ

Mühendislik yapılarının ekonomik ve güvenli bir şekilde inşa edilmesinde zemin ortamının oynadığı rol oldukça büyüktür. İnşaat mühendisliği uygulamalarında problemlili bir zemin ile karşılaşılması durumunda, inşası gerçekleştirilecek mühendislik yapılarının türüne göre zeminlerin mukavemet, geçirimsizlik, sıkışabilirlik ve durabilite gibi geoteknik özelliklerinde arzu edilen değerlere ulaşılabilmesi için kimyasal zemin stabilizasyon yöntemlerine sıklıkla başvurulmaktadır. Kimyasal stabilizasyon, zemine kimyasal katkıları eklenerek zemin özelliklerinin kimyasal olarak iyileştirilmesini ifade etmektedir. Portland çimentosu, kireç ve uçucu kül bu amaç için kullanılan geleneksel stabilizasyon malzemeleridir. Sahada zeminlerin stabilizasyonunda en çok tercih edilen kimyasal reaktifler çimento ve kireçtir (Eliaslankaran vd., 2021). Ancak bu stabilizasyon ajanlarının kullanmanın bazı dezavantajları mevcuttur. Üretim aşamasında yüksek enerji gerektirmeleri, ham madde kaynaklarını tüketmeleri, çevreye CO₂, SO₂ ve NO_x gibi zararlı gazlar yaymaları, zemin içerisinde kullanımı ile bitki gelişimini kısıtlamaları, toprağın pH'ında meydana getirdikleri değişiklikler ve yeraltı suyunun kirliliğine katkıları bu dezavantajlardan bazılarıdır. Çimento üretim tesisleri küresel CO₂ emisyonlarının yaklaşık olarak %5-8'inden sorumludur. Her bir ton çimento üretimi sonucu atmosfere bir ton, bir ton kireç üretimi ile ise yaklaşık olarak 0,86 ton CO₂ salınmaktadır (Thangaraj & Thenmozhi, 2013). Kömür santrallerinde yanma işlemi sırasında bir yan ürün olarak ortaya çıkan uçucu külün küresel üretim miktarı, 2005-2015 yılları arasında 500-750 milyon ton civarındadır. Ancak bu miktarın yalnızca %25'inin sahada efektif bir şekilde kullanıldığı ve arta kalan kısmın mükemmel puzolanik özelliklere sahip olmasına rağmen depolama sahalarında bertaraf edildiği görülmektedir (Blissett & Rowson, 2012). Uçucu külün zemin iyileştirmede katkı maddesi olarak kullanılması, zeminin mukavemet özelliklerinin iyileştirilmesinin yanı sıra, bu atığın depolama maliyetlerinin ve çevreye zararlı etkilerinin azaltılması veya ortadan kaldırılması anlamına gelmektedir (Sengul vd., 2023). Uçucu kül ilavesinin zeminlerin mukavemet özellikleri üzerindeki etkilerini inceleyen araştırmalardan elde edilen sonuçlar, zeminlerin mukavemeti, şişme-büzülme ve oturma gibi hacim değişimleri, geçirimsizliği ve durabilitesi gibi geoteknik özelliklerinde önemli miktarda iyileşmelerin elde edildiğini göstermiştir (Bakare vd., 2019; Parsons & Kneebone, 2015; Kang vd., 2014; Harichane vd., 2011; Tastan vd., 2011; Brooks vd., 2010; Kim & Prezzi, 2008; Zha vd., 2008; Phanikumar & Sharma, 2007; Nalbantoğlu, 2004; Prabakar vd., 2004). Zeminlerin kompaksiyon karakteristiği üzerine yapılan birçok araştırma, uçucu kül ile stabilize edilen zeminlerde optimum nem içeriğinin arttığını ve maksimum kuru birim hacim ağırlığının ise azaldığını göstermektedir (Mccarthy vd., 2009; Degirmenci vd., 2007; Senol vd., 2006; Sezer vd., 2006). Son zamanlarda doğal kaynaklardan üretilen ve ilaç, gıda, tarım ve kozmetik gibi birçok endüstride efektif bir şekilde kullanılan biyopolimerler, sürdürülebilir ve çevre dostu olmaları ve zeminlerin mühendislik özelliklerinin iyileştirilmesi üzerine sağladığı birçok fayda ile geleneksel kimyasal stabilizasyon malzemelerine bir alternatif olarak geoteknik araştırmacıların dikkatini çekmeyi başarmıştır. Üretildikleri kökenlere göre biyopolimerler bitki bazlı, hayvan bazlı ve mikroorganizma bazlı olmak üzere üç ayrı başlık altında sınıflandırılmaktadır. Guar sakızı (GG), lignin, agar, beta-glukan ve aljinat bitki bazlı biyopolimerlerdir. Süt ve süt ürünlerinden ekstrakte edilen protein bazlı bir biyopolimer olan kazein ve atık kabuklu deniz hayvanlarının atık kabuklarından üretilen kitosan hayvan bazlı biyopolimerlerdir. Ksantan gum, gellan gum ve dekstran gibi mikroorganizma bazlı biyopolimerler ise fermantasyon işlemi neticesinde üretilmektedir. Geoteknik literatürü incelendiğinde uygun fiyatları ve kararlı davranışları nedeniyle araştırmacıların daha çok guar ve ksantan gum üzerine araştırmalarını yoğunlaştırdığı görülmektedir. Farklı zeminlerin mühendislik özelliklerinin iyileştirilmesinde GG (Kumar vd., 2023; Sulaiman vd., 2022; Bagriacik vd., 2021; Bozyigit vd., 2021; Vydehi & Moghal, 2021; Soldo vd., 2020), ksantan gum (Hamza vd., 2023; Kumar vd., 2023; Oliveira & Reis, 2023; Berkane vd., 2022; ; Lee vd., 2022; Sulaiman vd., 2022; Zhang vd., 2022; Reddy & Varaprasad, 2021; Sujatha vd., 2021; Singh & Das, 2020; Soldo vd., 2020; Dehghan vd., 2019; Lee vd., 2019), karajenan (Fatehi vd., 2024; Ni vd., 2022), kazein (Ni vd., 2022), sodyum aljinat (Bagherinia, 2024; Ahn vd., 2021; Soldo vd., 2020), Beta 1,3/1,6 glukan (Chang & Cho, 2012), kitosan (Hataf vd., 2018), agar (Smitha & Rangaswamy, 2020; Smitha & Sachan, 2016) ve lignin (Zhang vd., 2015) gibi biyopolimerlerin oldukça etkili olduğu görülmektedir. Yapılan çalışmalar, genel olarak farklı zemin türlerinin mekanik özelliklerinin ve durabilitesinin artırılması, biyo-tıkanma yoluyla zemin geçirgenliğinin, sıkışabilirliğinin ve toprak erozyonunun önemli ölçüde azaltılması konusunda biyopolimer işleminin umut verici potansiyelini vurgulamaktadır. Zeminlerin stabilizasyonunda biyopolimer teknolojisini kullanmanın

detaylarının daha iyi anlaşılması için farklı zeminler ile biyopolimerin etkileşimleri ve bu etkileşimlerin doğal zeminlerin geoteknik özellikleri üzerinde meydana getireceği değişikliklerin detaylı bir şekilde araştırılması gerekmektedir. Hem bu amaca hizmet edebilmek hem de puzolanik reaksiyon ve biyopolimer hidrasyonu gibi farklı iki mekanizmanın etkilerinden faydalanabilmek için bu çalışmada uçucu kül ve GG ilavesinin yüksek plastisiteli bir kil zeminin mukavemeti üzerindeki etkilerinin araştırılması amaçlanmıştır. Deneysel tasarım sürecine ait plan Taguchi yönteminden faydalanarak oluşturulmuştur. Bu plana bağlı olarak hazırlanan iyileştirilmiş ve doğal zemin numuneleri serbest basınç deneyine tabi tutulmuştur. Elde edilen sonuçlar sadece uçucu kül ve sadece kireç içeren numunelere ait mukavemet değerleri ile karşılaştırılmıştır.


MATERYAL VE YÖNTEM

Test Edilen Zeminin Geoteknik Özellikleri

Deneylerde kullanılan zemin örneği Samsun ilinin Atakum ilçesinden alınmıştır. Alınan numune laboratuvar ortamında yere serilerek oda sıcaklığında kurutulmuş ve yapılacak deneyler için gerekli miktarlar, çeyrekleme yöntemi (TS 1900-1) kullanılarak bu numuneden alınmıştır. Zeminin geoteknik özelliklerinin belirlenmesi amacıyla piknometre, kıvam limitleri, elek analizi, hidrometre, standart proktor ve serbest basınç testleri yapılmıştır. Sonuç olarak zemine ait özellikler Tablo 1'de dane çapı dağılımı ise Şekil 1'de gösterilmiştir.

Tablo 1. Zeminin Geoteknik Özellikleri

Özellik	Değer	Deney Standardı
Kıvam Limitleri		
Likit limit (%)	59,97	ASTM (2000)
Plastik limit (%)	27,20	
Plastisite indisi (%)	32,77	
Kompaksiyon Karakteristikleri		
Maksimum kuru birim hacim ağırlık (kN/m ³)	1,455	ASTM (2007a)
Optimum su içeriği (%)	24	
#200 nolu elekten geçen yüzde (%)	86	ASTM (2007b)
Özgül Gravite	2,65	ASTM (2002)




Şekil 1. Kil Zeminin Granülometri Eğrisi

Birleştirilmiş zemin sınıflandırma sistemine (USCS) göre mevcut zemin, düşük plastisiteli inorganik killi zemin olarak sınıflandırılmıştır (Şekil 2).

Uçucu Kül

Uçucu kül, termik santrallerde toz kömürün yakılması sırasında baca gazlarındaki taneciklerin elektrostatik veya elektromekanik teknikler ile tutulmasıyla elde edilen bir küldür. Yakılan kömürün kaynağına ve mineralojik bileşimine, kömürün pulverizasyon derecesine, fırının türü ve oksidasyon koşullarına ve kullanımdan önce uçucu külün toplanması, yönetimi ve depolanmasına bağlı olarak, uçucu kül bileşenleri önemli ölçüde değişkenlik göstermektedir (Ahmad vd., 2024; De Belie vd., 2018). Ancak genel olarak uçucu küller önemli miktarlarda silisyum

dioksit (SiO_2), alüminyum oksit (Al_2O_3) ve kalsiyum oksit (CaO) içerir. Özet olarak uçucu kül esas olarak termik santrallerde kömürün yakılması neticesinde ortaya çıkan puzolanik, kristal olmayan, hafif çimentolu ve bertaraf edilmezse çevreye ve insan sağlığına zararları olan katı bir atık malzemedir.



Şekil 2. Kil Zeminin Plastisite Kartındaki Yeri

Uçucu Kül

Uçucu kül, termik santrallerde toz kömürün yakılması sırasında baca gazlarındaki taneciklerin elektrostatik veya elektromekanik teknikler ile tutulmasıyla elde edilen bir küldür. Yakılan kömürün kaynağına ve mineralojik bileşimine, kömürün pulverizasyon derecesine, fırının türü ve oksidasyon koşullarına ve kullanımdan önce uçucu külün toplanması, yönetimi ve depolanmasına bağlı olarak, uçucu kül bileşenleri önemli ölçüde değişkenlik göstermektedir (Ahmad vd., 2024; De Belie vd., 2018). Ancak genel olarak uçucu kül esas olarak termik santrallerde kömürün yakılması neticesinde ortaya çıkan puzolanik, kristal olmayan, hafif çimentolu ve bertaraf edilmezse çevreye ve insan sağlığına zararları olan katı bir atık malzemedir.

Uçucu külün sınıflandırılması ve geoteknik özellikleri


ASTM (2003) oksit bileşenlerinin yüzdelere göre küllü F ve C olmak üzere iki farklı sınıfa ayırmaktadır. Uçucu kül içerisindeki SiO_2 , Al_2O_3 , Fe_2O_3 oksitlerinin toplam yüzdesi 70'ten fazla ise uçucu kül, antrasit veya bitümlü kömürden üretilen F sınıfına girmektedir. Bu sınıfa mensup küllerde %10'dan daha düşük CaO bulunduğu için düşük kireçli uçucu kül olarak da adlandırılırlar. Ayrıca F sınıfı uçucu kül puzolanik özelliğe sahiptirler. SiO_2 , Al_2O_3 , Fe_2O_3 oksitlerinin toplam yüzdesi minimum %50 olan küller ise linyit veya alt bitümlü kömürden üretilen C sınıfı uçucu kül olarak sınıflandırılmaktadır. Bu sınıf küller %10'dan daha fazla CaO içerebilir. C sınıfı uçucu kül puzolanik özelliklere sahip olmasının yanı sıra bağlayıcı özelliğe de sahiptir.

X-Ray Diffraction (XRD) spektrometresi; minerallerin, kayaların, çökeltilerin, polimerlerin ve sıvıların tahribatsız kimyasal analizi için kullanılan, dalga boyu dağılım spektroskopisinin prensiplerine göre çalışan bir cihazdır. Uçucu külün kimyasal analizi neticesinde belirlenen oksit bileşenleri Tablo 2'de gösterilmektedir. Buna göre SiO_2 , Al_2O_3 , Fe_2O_3 oksitlerinin toplam yüzdesi %83,3>%70 olduğundan uçucu kül F tipi olarak sınıflandırılmıştır.

Tablo 2. Uçucu Külün Kimyasal Özellikleri

	SiO_2 (%)	Al_2O_3 (%)	Fe_2O_3 (%)	MgO (%)	CaO (%)	K_2O (%)	SO_3 (%)	TiO_2 (%)	Na_2O (%)	NiO (%)	BaO (%)	P_2O_5 (%)	MnO (%)	Cr_2O_3 (%)
Uçucu kül	78,8	2,7	1,8	0,9	4,4	1,3	0,9	2,2	3,0	0,3	1,6	0,4	0,6	1,1

Uçucu külün granülometrisinin tayini için #200 nolu elekte yıkama yapılmıştır. #200 nolu eleğin üzerinde kalan malzeme ASTM (2007b) standardına uygun olarak elek analizine, altında kalan ise hidrometre analizine tabi tutulmuştur. Sonuç olarak uçucu küle ait dane çapı dağılım eğrisi Şekil 3'te gösterilmiştir. Külün özgül gravite değerinin tayini için ASTM (2002) Metot B'ye göre piknometre deneyi yürütülmüş olup uçucu külün özgül gravite değeri 2,28 olarak hesaplanmıştır.



Şekil 3. Uçucu küle Ait Dane Çapı Dağılım Eğrisi

Guar Sakızı (Guar Gum)

Guar sakızı veya guaran, botanik adı *Cyamopsis tetragonolobus* olan baklagiller familyasına ait bir bitki olan guar fasulyesinin tohumundan üretilen bir biyopolimerdir. Guar sakızı (GG), 1:2 oranında D-galaktoz ve D-mannoz şekerlerini içeren bir polisakkarittir. (Chudzikowski, 1971) GG iyonik olmayan, geniş pH aralığına sahip (1,0-10,5), suda çözünebilir bir hidro-kolloidaldır (Ayeldeen vd., 2017; Mudgil vd., 2014). Hidrasyon ile GG, tiksotropik olan viskoz kolloidal dispersiyonlar oluşturmaktadır. GG, hidrate olduktan sonra jel benzeri kohezif yapıların oluşumuna neden olan borat iyonları içermektedir (Hamza vd., 2023; Eldaw, 1998). Bu jelimsi kohezif viskoz yapılar zemin danelerinin etrafını sararak onların adezyonunu arttırmaktadır. Ayrıca zemin ile GG arasında meydana gelen hidrojen bağları, zemin-GG matrisinin mukavemet kazanımına katkıda bulunmaktadır (Sujatha vd., 2020). Diğer biyopolimerlere nispeten daha fazla galaktoz dallanma noktasına ve çözünürlüğe sahip olması onu daha iyi bir stabilizör malzemesi yapmaktadır (Risica vd., 2005). Diğer biyopolimerlere nispeten daha ekonomik olan GG; %40,83 K₂O, %16,26 CaO, %10,24 Fe₂O₃, %7,03 SO₃, %5,84 P₂O₅, %4,5 PbO, %4,25 Cl, %3,18 MgO, %2,39 CuO, %1,62 SiO₂ ve %3,86 diğer oksitler içermektedir (Sujatha & Saisree, 2019). Bu nedenle bu çalışmada biyopolimer materyal olarak GG malzemesi seçilmiştir.

Taguchi Yöntemi

Taguchi (1987) tarafından geliştirilen Taguchi yöntemi, deneysel tasarımların performans kalitesi ve maliyet açısından optimizasyonu için basit, etkili ve sistematik bir yaklaşım sağlayan en yaygın Deney Tasarımı (DOE) analiz yöntemlerinden biridir. Taguchi deneysel tasarım yöntemini kullanmanın temel avantajı gerçekleştirilecek simülasyon sayısını azaltarak deneysel çabadan büyük oranda tasarruf sağlamaktır. Taguchi, her bir bağımsız faktörü veya bunların süreç özellikleri üzerindeki etkileşim etkilerini değerlendirmek için standart ortogonal diziler kullanır. Daha sonra deneysel değer ile istenen değer arasındaki sapmaları hesaplamak için bir kayıp fonksiyonu tanımlanır. Bu kayıp fonksiyonu ayrıca sinyal-gürültü (S/N) oranına aktarılır. Karakteristik türüne bağlı olarak genellikle üç S/N oranı mevcut olup her bir duruma karşılık gelen formülleri Eşitlik 1-3'te verilmiştir (Keleştemur vd., 2014).

1-) Daha düşük daha iyi,

$$S / N = -10 \log_{10} \left(\frac{1}{n} \sum_{i=1}^n Y_i^2 \right) \quad (1)$$

2-) Daha yüksek daha iyi

$$S / N = -10 \log_{10} \left(\frac{1}{n} \sum_{i=1}^n \frac{1}{Y_i^2} \right) \quad (2)$$

3-) Nominal daha iyi

$$S / N = 10 \log \frac{\mu^2}{\sigma^2} \quad (3)$$

Yukarıdaki eşitliklerde n , Y_i , σ^2 , ve μ^2 değerleri sırasıyla faktör düzeyi kombinasyonundaki yanıt sayısı, verilen faktör düzeyi kombinasyonuna ait yanıtları, tekrarlanan yanıt değerlerinin gözlemlerinin varyansını ve ortalamasının karesini temsil etmektedir.

Taguchi deney tasarımı aşamaları Şekil 4'te özetlenmiştir.



Şekil 4. Taguchi Deney Tasarım Aşamaları

Geoteknik literatürü incelendiğinde deneysel süreçlerin daha az emek ve maliyetle yürütülebilmesi ve deney parametrelerinin optimizasyonu amacıyla son zamanlarda Taguchi tekniğinden çokça faydalandığı görülmektedir. Abd Elaty vd. (2023), düşük geçirgenliğe ve yeterli mukavemete sahip bir bentonit-çimento harcı üretmek için bentonit, çimento tozu, kül, kireç ve polipropilen elyaf gibi farklı malzemelerin kullanımını Taguchi yöntemiyle incelemişlerdir. Ackah vd. (2022), Taguchi deney tasarım yöntemini kullanarak siltli bir kil zeminin serbest basınç dayanımı üzerine kireç, kuru yoğunluk ve su muhtevasının etkilerini araştırmışlardır. Hamed and Demiröz (2024), uçucu kül ve granüle yüksek fırın cürufu esaslı geopolimerin yüksek plastisiteli killi zeminlerin mekanik özellikleri üzerindeki etkilerini gözlemleyebilmek amacıyla Taguchi Yöntemini kullanarak deneysel çalışmalar yürütmüşlerdir. Ramezani vd. (2023), kötü derecelenmiş bir kum zeminin mekanik özelliklerindeki iyileşmeler açısından şeker kamışı küspesi külü, cam tozu ve silis dumanı bazlı geopolimerlerin miktarlarının optimize edilmesinde Taguchi yönteminden istifade etmişlerdir. Khaleghi and Heidarvand (2023), farklı kütleme ve başlangıç koşulları altında salep biyopolimeri ile stabilize edilmiş çöl kumunun tek eksenli mukavemetini Taguchi metodolojisini kullanarak incelemişlerdir. Bu çalışmada, Tablo 3'te gösterildiği gibi üç seviyeye sahip üç faktörün (uçucu kül miktarı, biyopolimer dozajı ve kür süresi) zeminin serbest basınç dayanımı (SBD) üzerindeki etkilerinin incelenmesi amaçlanmıştır. Bahsi geçen deney planında tam faktöriyel tasarım uygulanmak istenilirse mümkün olan tüm kombinasyonların tasarıma dahil edilmesi gerektiğinden 27 ($3 \times 3 \times 3$) adet deney yapılması gerekmektedir. Deney sayısını azaltarak zaman, iş gücü ve maliyetten tasarruf edebilmek için yalnızca 9 adet deney noktası veren L_9 (3×3) ortogonal dizisi benimsenerek kesirli faktöriyel tasarım uygulanmıştır. Mevcut çalışmada maksimum SBD değerini veren karışım oranının belirlenmesi amaçlandığından daha yüksek-daha iyi için S/N değerleri dikkate alınmıştır. Seçilen ortogonal diziyeye ait deney tasarım planı Tablo 4'te verilmiştir.

Tablo 3. Deney Tasarımında Kullanılan Faktörler ve Seviyeleri

Faktör	Birim	Seviye 1	Seviye 2	Seviye 3
Uçucu kül miktarı	%	5	10	20
GG dozajı	%	1	2	4
Kür süresi	gün	0	7	14

Numunelerin Hazırlanması

Biyopolimerle stabilize edilmiş karışımların hazırlanmasında iki tür karıştırma yöntemi kullanılmaktadır; ıslak karıştırma, kuru karıştırma. Islak karıştırma yönteminde karışımda kullanılacak biyopolimer yüzdesi ve karışımın su muhtevasına göre biyopolimer konsantrasyonu belirlenmekte ve ilk olarak bu konsantrasyona göre toz halindeki

biyopolimer suda çözülerek jel haline getirilmektedir. Jel haline getirilen biyopolimer genellikle kuru zemin ile karıştırılarak biyopolimer içeren karışımlar hazırlanmaktadır. Bazı araştırmacılar (Sujatha vd., 2020; Sujatha & Saisree, 2019) bu jeli, hidrate olabilmesi için 24 saat hava almayacak şekilde kapalı bir yerde bekletmiş ve daha sonra kuru zemin ile karıştırarak karışımlarını hazırlamışlardır. Kuru karıştırma yönteminde ise ilk olarak toz haldeki biyopolimer ile kuru zemin, biyopolimer zemin içerisinde eşit bir şekilde dağıtılana kadar karıştırılmaktadır. Daha sonra bu karışıma ilgili su muhtevası eklenerek biyopolimer-zemin karışımı hazırlanmaktadır. Islak karıştırma yönteminde, eklenen biyopolimer miktarının çözünürlük noktasından fazla olması durumunda biyopolimer çözeltisinin viskozitesi önemli ölçüde artmaktadır. Bu durum, işlenebilirliğin zayıf olmasına ve büyük ölçekli işler için karıştırma işleminin zorlaşmasına yol açmaktadır (Chang vd., 2015; Nugent vd., 2009). Bu nedenle özellikle arazi uygulamaları gibi büyük ölçekli işlerde kuru karıştırma yönteminin kullanılması daha uygun olacaktır (Vydehi & Moghal, 2021). Bu çalışmada biyopolimer ile zemin malzemesi kuru bir şekilde karıştırılmıştır. Uçucu kül-zemin karışımları ile ilgili literatür çalışmaları incelendiğinde ilk olarak kuru kül ile kuru zeminin karıştırıldığı ve daha sonra bu karışıma suyun ilave edildiği görülmüştür. Yukarıda bahsi geçen literatür bilgileri ışığında ve denemeyanılma deneyleri neticesinde numune hazırlama aşaması için tercih edilen ve uygulanan prosedür şu şekildedir. Etüvden çıkartılan zemin soğuduktan sonra sırasıyla %95 rölatif kompaksiyona karşılık gelen düşük su muhtevası ve kuru birim hacim ağırlık değerlerine göre kuru zemin ve su miktarları tartılmıştır. Tablo 2'deki deney planına göre kuru kil zeminin bir yüzdesi olarak toz halindeki biyopolimer ve uçucu kül miktarı tartılmıştır. İlk olarak kuru zemin ile uçucu kül karıştırılmış, daha sonra bu karışıma toz halindeki biyopolimer eklenmiştir. Zemin+biyopolimer+kül karışımına ilgili su miktarı ilave edilerek homojen bir karışım elde edilinceye kadar karıştırma işlemine devam edilmiştir. Karışım içerisindeki suyun eşit bir şekilde dağılabilmesi için zemin+biyopolimer+kül+su karışımı kapalı bir kutuda kilitli poşet içerisinde 18 saat bekletilmiştir. Nihai olarak bu karışım ayrılabilir silindir bir kalıp içerisinde statik olarak sıkıştırılarak 5 cm çap ve 10 cm yüksekliğe sahip silindir numuneler üretilmiştir.

Tablo 4. Taguchi L9 Ortogonal Dizi

Deney kodu	Uçucu kül miktarı (%)	GG Dozajı (%)	Kür süresi (gün)
1	5	1	0
2	5	2	7
3	5	4	14
4	10	1	7
5	10	2	14
6	10	4	0
7	20	1	14
8	20	2	0
9	20	4	7

Uçucu kül+biyopolimer hibrit karışımının zeminin mukavemeti üzerine etkisini yorumlayabilmek adına zeminin kuru ağırlığının %10'una eşdeğer miktarda sadece uçucu kül içeren numuneler de yukarıdaki prosedüre uygun olarak hazırlanmış ve 0, 7 ve 14 gün küre tabi tutulmuştur. Ayrıca geleneksel stabilizasyon malzemelerinden biri olan kireç ile stabilize edilmiş numuneler ile uçucu kül+biyopolimer içeren numunelerde meydana gelen mukavemet artışlarını karşılaştırmak amacıyla kireç içeren numuneler de hazırlanmıştır. Literatürde kirecin kireç ile stabilizasyonunda genellikle zeminin kuru ağırlığının maksimum %10'una eşdeğer miktarda kireç kullanılmış ve genellikle %4-6 oranında kirecin optimum mukavemet sağladığı tespit edilmiştir (Boz vd., 2018; Bell, 1996). Bu nedenle kireç ile stabilize edilen numunelerde ağırlıkça %6 dozajında sönmüş kireç kullanılmıştır. Bu amaç için ilk olarak etüvden çıkan ve soğumuş kuru zemine %6 dozajında kireç kuru olarak ilave edilmiş ve hazırlanan karışıma %95 rölatif kompaksiyona karşılık gelen düşük su muhtevası değerinde su eklenmiştir. Kireç+zemin+su karışımı da kilitli poşetler içerisinde 18 saat bekletildikten sonra mevcut karışım proktor enerjisinde sıkıştırılarak 5 cm çapa ve 10 cm yüksekliğe sahip silindir numuneler hazırlanmış ve 0, 7 ve 14 gün küre tabi tutulmuştur.

Serbest Basınç Deneyi

Hazırlanan numuneler Taguchi deney tasarımı yönteminin sunduğu deney programına uygun olarak kontrollü küre (20°C oda sıcaklığı ve >%99 rölatif nem) tabi tutulmuştur. Hem iyileştirilmiş hem de doğal zemin üzerinde ASTM (2006) standardına göre serbest basınç deneyleri gerçekleştirilmiştir. Serbest basınç deneyleri 1 mm/dak eksenel şekil değiştirme hızında göçme meydana gelene kadar yürütülmüştür.

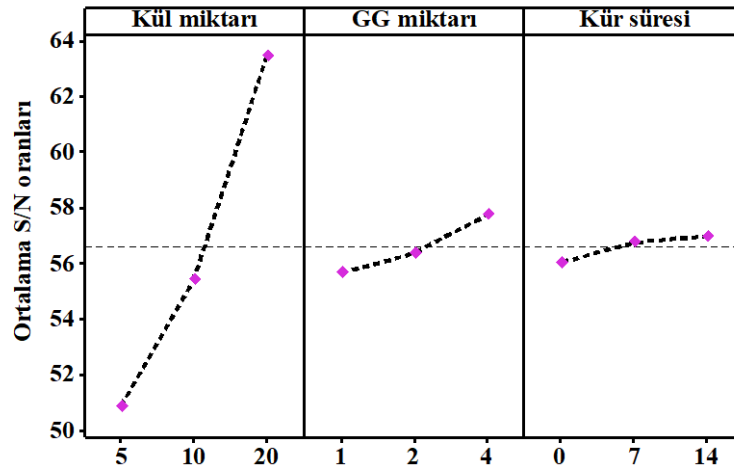
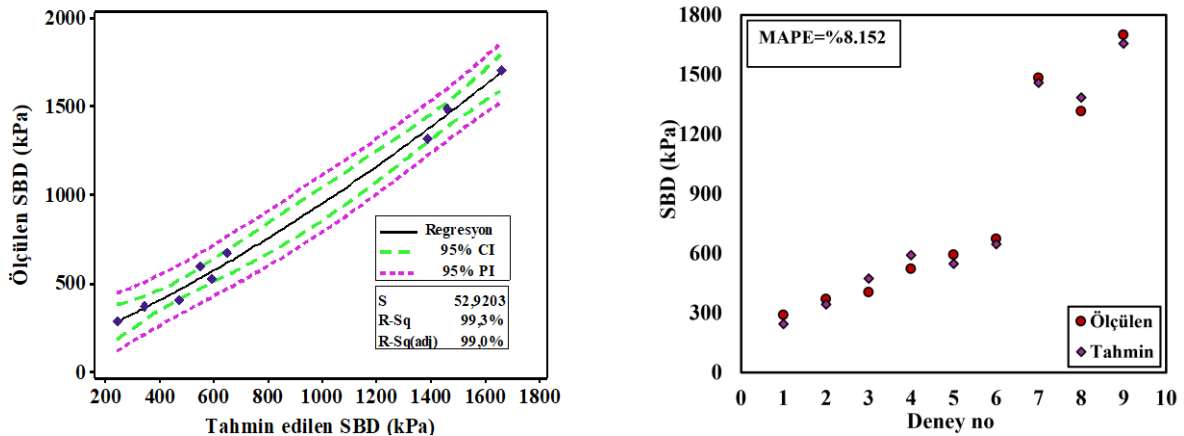
BULGULAR VE TARTIŞMA**Taguchi deney sonuçları**

Tablo 4'teki ortogonal diziyeye göre yürütülen deneyler neticesinde belirlenen SBD değerleri Tablo 5'te verilmiştir.

Tablo 5. Deney Sonuçları

Deney no	Uçucu kül miktarı (%)	GG Dozajı (%)	Kür süresi (gün)	Serbest Basınç Dayanımı (kPa)
1	5	1	0	288,516
2	5	2	7	368,849
3	5	4	14	403,254
4	10	1	7	521,996
5	10	2	14	591,983
6	10	4	0	671,826
7	20	1	14	1483,769
8	20	2	0	1315,315
9	20	4	7	1700,182

Taguchi analizlerinde en yüksek SBD değerinin elde edildiği karışım oranlarının belirlenmesi amaçlandığı için en büyük-en iyi koşulu göre S/N oranları hesaplanmış olup sonuçlar Şekil 5'te gösterilmiştir. Deneysel olarak ölçülen ve Taguchi tarafından tahmin edilen SBD değerlerinin karşılaştırıldığı grafikler ise Şekil 6'da verilmiştir.

**Şekil 5. S/N Oranları için Ana Etki Grafiği****Şekil 6. Tahminler ile Ölçülen Değerlerin Karşılaştırılması**

Şekil 5 incelendiğinde diğer faktörlere nispeten SBD üzerinde en etkili parametrenin uçucu kül miktarı olduğu görülmüştür. Şekil 5'te her bir faktöre ait grafiğin pik noktaları, en yüksek yanıt değerinin elde edileceği faktör seviyelerini göstermektedir. Buna göre, kül ve GG materyallerinden en yüksek miktarlarında kullanıldığında ve en

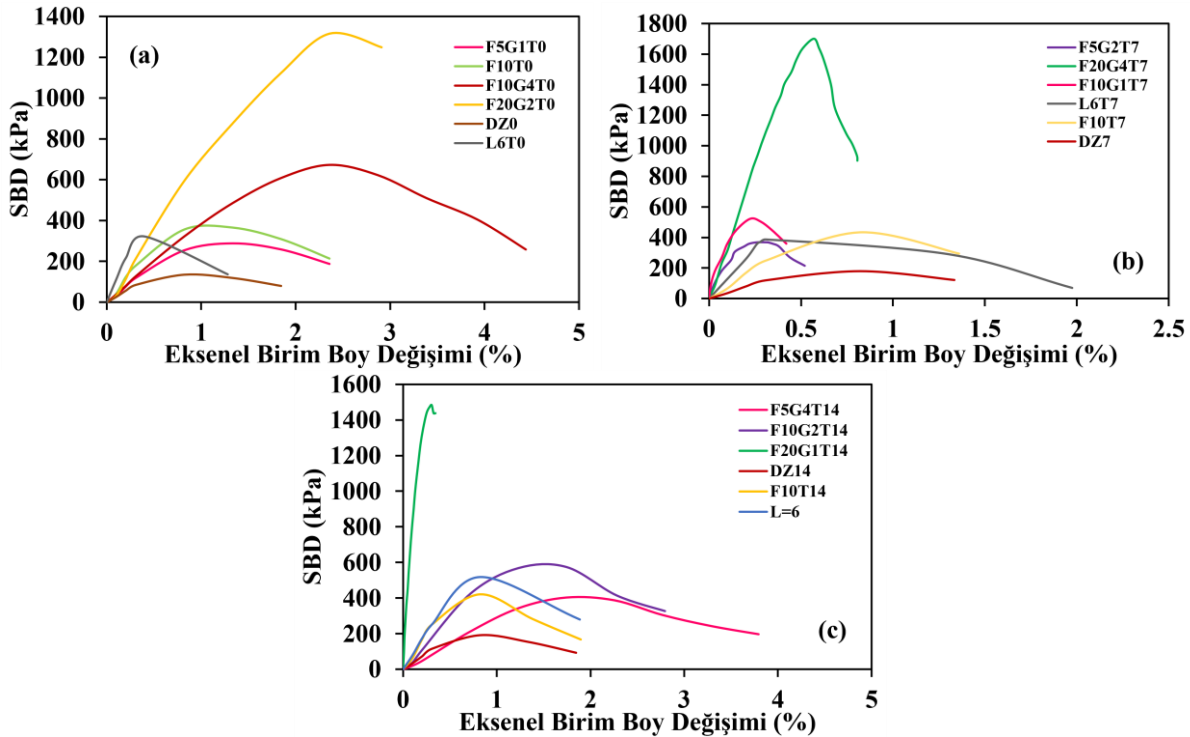
uzun küreleme sağlandığında en yüksek SBD değerinin elde edildiği söylenebilir. Taguchi tarafından tahmin edilen ve deneysel olarak ölçülen SBD değerleri, %95 güven (CI) ve tahmin aralığı (PI) için Şekil 6'da karşılaştırılmıştır. Şekil 6'dan Taguchi tahminlerinin %8,152 büyüklüğünde ortalama mutlak yüzde hata (MAPE) ile ölçülen değerlere oldukça yakın olduğu görülmektedir.

Gerilme-Şekil Değiştirme Analizi

Bu çalışma kapsamında serbest basınç deneyinde kırılan numunelere Tablo 6'daki sembol isimler verilmiştir. Tablo 4'te verilen Taguchi numunelerine ilave olarak doğal zemin, %6 kireç muhteva eden zemin ve sadece %10 oranında uçucu kül içeren zemin numunelerine ait gerilme-şekil değiştirme eğrileri Şekil 7'de sunulmuştur.

Tablo 6. Deney Numunelerinin Sembol İsimleri


Deney kodu	Deney sembolü	Uçucu kül miktarı (%)	GG Dozajı (%)	Kireç dozajı (%)	Kür Süresi (gün)
1	F5G1T0	5	1	0	0
2	F5G2T7	5	2	0	7
3	F5G4T14	5	4	0	14
4	F10G1T7	10	1	0	7
5	F10G2T14	10	2	0	14
6	F10G4T0	10	4	0	0
7	F20G1T14	20	1	0	14
8	F20G2T0	20	2	0	0
9	F20G4T7	20	4	0	7
10	F10T0	10	0	0	0
11	F10T7	10	0	0	7
12	F10T14	10	0	0	14
13	DZ0	0	0	0	0
14	DZ7	0	0	0	7
15	DZ14	0	0	0	14
16	L6T0	0	0	6	0
17	L6T7	0	0	6	7
18	L6T14	0	0	6	14



Şekil 7. a. 0 Gün b. 7 Gün c. 14 Gün Küre Karşılık İyileştirilmiş ve İyileştirilmemiş Zemine Ait Gerilme-Şekil Değiştirme Tepkileri

Tüm numunelere ait gerilme-şekil değiştirme tepkileri, genel olarak kırılmanın %0,22-2,36 şekil değiştirme seviyelerinde meydana geldiğini göstermektedir. İyileştirilmiş ve iyileştirilmemiş tüm numunelerin genel olarak gevrek kırılma davranışı sergilediği gözlenmiştir (Şekil 7).

Tüm zemin numunelerine ait sekant elastisite modülü (E_{50}), pik gerilmenin yarısına eşit olan gerilmenin gerilme-şekil değiştirme eğrisini kestiği nokta ile orijinden geçen doğrunun eğimi olarak hesaplanmıştır (Şekil 8).

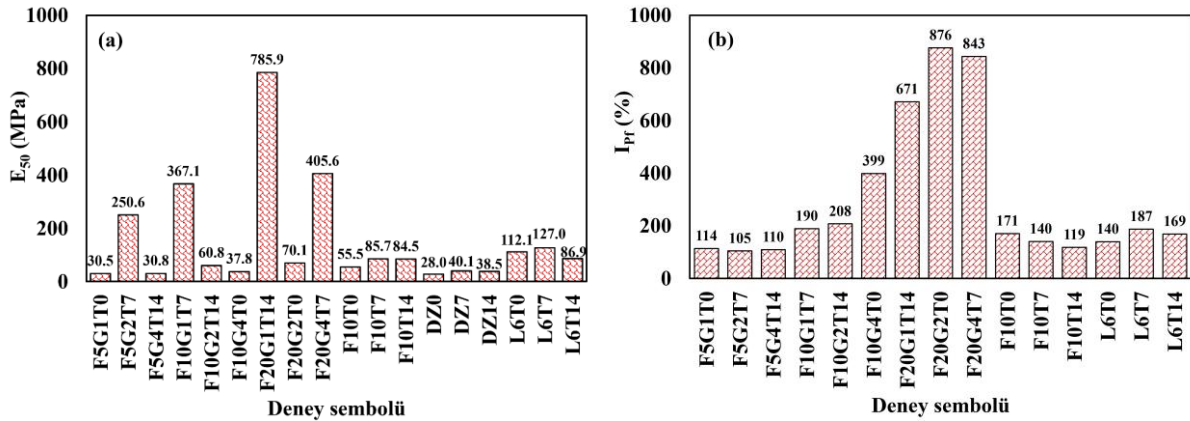


Şekil 8. Sekant Elastisite Modülü (E_{50}) Hesabı (Lee vd., 2022)

Serbest basınç dayanımında meydana gelen iyileşme faktörü (I_{Pf}) Eşitlik 4 ile hesaplanmıştır:

$$I_{Pf} = \frac{SBD_i - SBD_d}{SBD_d} * 100 \quad (4)$$

Burada SBD_i ve SBD_d sırasıyla iyileştirilmiş ve doğal zemin numunesinin serbest basınç dayanımını temsil etmektedir. Bahsi geçen bu prosedürlere göre hesaplanan E_{50} ve I_{Pf} değerleri Şekil 9'da gösterilmiştir.



Şekil 9. İyileştirilmiş ve İyileştirilmemiş Zemine Ait a. Sekant Elastisite Modülü b. I_{Pf} Değerleri

14 gün kür süresi sonunda doğal zeminin 38,5 MPa olan sekant elastisite modülü, uçucu kül+biyopolimer ilavesi ile yaklaşık 20,4 kat artarak F20G1T14 numunesinde 785,9 MPa seviyesine ulaşmıştır (Şekil 9a). En yüksek SBD değerine sahip F20G4T7 numunesi için E_{50} değeri, doğal zemininkine nispeten 10,13 kat artarak 405,6 MPa değerini almıştır. Bahsi geçen F20G1T14 ve F20G4T7 numunelerinde kireç ile stabilize edilmiş numunelere nispeten E_{50} değerleri 9,04 ve 3,19 kat artmıştır. Sadece %10 miktarında uçucu kül içeren numunelere göre ise bu artışlar sırasıyla 9,30 ve 4,74 kat mertebesinde meydana gelmiştir. SBD değerinde meydana gelen iyileşmeler incelendiğinde (Şekil 9b), doğal zemin numunelerine nispeten F20G2T0, F20G4T7 ve F20G1T14 numunelerinde sırasıyla %876, %843 ve %671 oranlarında en yüksek iyileşmelerin meydana geldiği görülmektedir (Şekil 9b). Şekil 5'te Taguchi analizleri neticesinde üretilen S/N oranlarına göre SBD üzerinde GG ilavesi ile kür süresinin etkilerinin zayıf olduğu sonucu elde edilmişti. Ancak Şekil 9b'den görüldüğü üzere, sadece uçucu kül içeren F10T0, F10T7 ve F10T14 numunelerine göre uçucu kül+GG içeren F10G4T0, F10G1T7 ve F10G2T14 numunelerinde mukavemet dikkate değer bir biçimde artmıştır. F10G4T0, F10G1T7 ve F10G2T14 numunelerinde SBD değerleri F10T0, F10T7 ve F10T14 numunelerine göre sırasıyla 1,84; 1,20 ve 1,41 kat daha yüksek çıkmıştır. Bu nedenle GG ilavesinin SBD üzerinde anlamlı bir etkiye sahip olduğu söylenebilir. En yüksek SBD değerlerine sahip F20G2T0, F20G4T7 ve F20G1T14

numunelerinde kireç içeren L6T0, L6T7 ve L6T14 numunelerine nispeten ise sırasıyla 4,07; 4,40 ve 2,86 kat daha yüksek SBD değerleri elde edilmiştir. Tüm bu sonuçlara dayanarak kil zemin içerisine belirli bir miktarda uçucu kül+GG ilave edilmesi ile doğal zeminin mukavemet özelliklerinin önemli miktarda iyileştirildiği sonucuna varılmaktadır.

Uçucu kül içeren zeminlerde stabilizasyon mekanizması genel olarak katyon değişimi, flokülasyon, puzolanik reaksiyon ve karbon sementasyonu yoluyla gerçekleşmektedir. Uçucu külle stabilize edilmiş zeminlerin mikro yapıları ve kimyasal süreçlerinin incelendiği araştırmalar (Saride & Dutta, 2016; Sharma vd., 2012; Akbulut & Arasan, 2010; Nalbantoğlu, 2004; Nalbantoglu & Gucbilmez, 2001) puzolanik reaksiyonun diğer mekanizmalardan daha etkili olduğunu göstermektedir. Zemin suyu ile GG'nin hidrasyonu neticesinde meydana gelen üç boyutlu jelimsi ağ yapısı zemin danelerini birbirine bağlayarak dengeleyici bir etki yaratmakta (Kumar vd., 2023) ve bu durum puzolanik reaksiyonlar neticesinde oluşan mukavemet sağlayıcı yapıların iyileştirme potansiyelini daha da arttırmaktadır. Hem uçucu kül hem de GG malzemelerini birlikte içeren numunelerde sadece uçucu kül ile stabilize edilmiş olanlara nispeten mukavemet artışlarının oldukça yüksek olması, GG'nin bahsi geçen bu potansiyelini desteklemektedir (Şekil 9b). Sonuç olarak yüksek plastisiteli bir kil zeminin mekanik özelliklerinin iyileştirilmesinde uçucu kül ve GG'yi birlikte kullanmanın, geleneksel stabilizasyon malzemeleri olan kireç ve uçucu külü bireysel olarak kullanmaktan daha verimli olduğu görülmektedir.

SONUÇLAR

Bu çalışmada yüksek plastisiteli bir kil zemin içerisine farklı miktarlarda uçucu kül ve GG materyallerinin birlikte katılması neticesinde SBD değerinde meydana gelen değişim araştırılmıştır. Elde edilen sonuçlar uçucu kül ve kirecin bireysel etkileri ile karşılaştırılmıştır. Deney planının oluşturulmasında Taguchi yönteminden faydalanılmıştır. Bu çalışmadan çıkarılan ana sonuçlar aşağıda özetlenmiştir:

1-) Gevrek kırılma davranışı sergileyen doğal zemine uçucu kül ve GG eklemenin kırılma davranışı üzerinde önemli bir etkiye sahip olmadığı görülmüştür.

2-) Kil zemin içerisine çok küçük miktarlarda da olsa uçucu kül ve GG eklenmesi neticesinde doğal zeminin mukavemetinde dikkate değer miktarda artışlar elde edilmiştir. Uçucu kül+GG ile stabilize edilmiş numunelerin doğal zemine nispeten erken dayanım özelliklerinin dahi önemli miktarda iyileştiği, yüksek miktarda uçucu kül ve GG içeren numunelerde (F20G2T0, F20G4T7 ve F20G1T14) kür süresinin de artması ile mukavemette 6,5 kata varan artışlara ulaşıldığı görülmüştür. Sadece kireç içeren numunelere kıyasla bu numunelerde (F20G2T0, F20G4T7 ve F20G1T14) meydana gelen mukavemet artışları 2,88-4,4 kat mertebelerindedir.

3-) Taguchi deney tasarımı ile iş gücü, zaman ve maliyetten tasarruf edilerek deney süreci tamamlanmış ve %95 güven aralığı içerisinde kalacak şekilde ortalama %8,152 hata ile başarılı tahminler üretilmiştir. Taguchi yöntemi SBD üzerinde en etkili parametrenin uçucu kül olduğunu, GG ve kür süresinin etkilerinin az olduğunu göstermektedir. Ancak sadece %10 oranında uçucu kül içeren numunelerin SBD değerleri, içlerine GG da ilave edilmesiyle ortalama 1,5 kat artmıştır. Bu da GG'nin SBD üzerindeki etkisinin anlamlı olduğunu somut olarak göstermektedir.

4-) Kil zemin içerisine uçucu kül+GG ilave edilmesiyle doğal zeminin sekant elastisite modülü yaklaşık 20,4 kat artarak en yüksek değeri olan 785,9 MPa seviyesine ulaşmıştır. En yüksek sekant elastisite modülüne sahip bu numune, sadece %10 miktarında uçucu kül ve sadece %6 oranında kireç içeren numunelerin sekant elastisite modülüne nispeten yaklaşık olarak 9 kat daha yüksektir.

TEŞEKKÜR

Bu çalışma, T.C. Enerji Piyasası Düzenleme Kurumu (EPDK) tarafından onaylanan "Poliüretan Stabilizatör ile Temel Dolgusunun Geliştirilmesi ve Saha Uygulamasının Yapılması" isimli Ar-Ge projesi kapsamında desteklenmektedir. Yazarlar bu destek için EPDK'ya teşekkür etmektedir.

KAYNAKLAR

Abd Elaty, M. A. A., Azzam, W. R., & Eldesoky, A. G. (2023). Properties of cement–bentonite mortar developed by mineral additives for primary firm secant pile by Taguchi method. *Innovative Infrastructure Solutions*, 8(10), 259.

- Ackah, F. S., Hailiang, W., Huaiping, F., Cheng, L., & Feng, L. Z. (2022). Use of Taguchi method to evaluate the unconfined compressive strength of quicklime stabilized silty clayey subgrade. *Case Studies in Construction Materials*, 17, e01417.
- Ahmad, S., Shah Alam Ghazi, M., Syed, M., & Al-Osta, M. A. (2024). Utilization of fly ash with and without secondary additives for stabilizing expansive soils: A review. *Results in Engineering*, 22, 102079. <https://doi.org/10.1016/J.RINENG.2024.102079>
- Ahn, S., Ryou, J.-E., Ahn, K., Lee, C., Lee, J.-D., Jung, J., ... Kopel, P. (2021). Evaluation of Dynamic Properties of Sodium-Alginate-Reinforced Soil Using A Resonant-Column Test. *Materials*, 14(11), 2743. <https://doi.org/10.3390/MA14112743>
- Akbulut, S., & Arasan, S. (2010). The Variations of Cation Exchange Capacity, pH, and Zeta Potential in Expansive Soils Treated by Additives. *Internatioanl Journal of Civil and Structural Engineering*, 1(2), 139–154.
- ASTM C 618-03, 2003. Standard Specification for Coal Fly Ash and Raw or Calcined Natural Pozzolan for Use in Concrete, ASTM, United States.
- ASTM D 2166-06, 2006. Standard Test Method for Unconfined Compressive Strength of Cohesive Soil, ASTM, United States.
- ASTM D 422-63, 2007b. Standard Test Method for Particle-Size Analysis of Soils, ASTM, United States.
- ASTM D 4318, 2000. Standard Test Methods for Liquid Limit, Plastic Limit, and Plasticity Index of Soils, ASTM, United States.
- ASTM D 698-07, 2007a. Standard Test Methods for Laboratory Compaction Characteristics of Soil Using Standard Effort, ASTM, United States.
- ASTM D 854-02, 2002. Standard Test Methods for Specific Gravity of Soil Solids by Water Pycnometer, ASTM, United States.
- Ayeldeen, M., Negm, A., El-Sawwaf, M., & Kitazume, M. (2017). Enhancing mechanical behaviors of collapsible soil using two biopolymers. *Journal of Rock Mechanics and Geotechnical Engineering*, 9(2), 329–339. <https://doi.org/10.1016/J.JRMGE.2016.11.007>
- Bagherinia, M. (2024). Mechanical, durability, and microstructure of soft clay stabilised with anionic biopolymer. *Construction and Building Materials*, 417, 135343. <https://doi.org/10.1016/J.CONBUILDMAT.2024.135343>
- Bagriacik, B., Ok, B., & Kahiyah, M. T. M. A. (2021). An experimental study on improvement of cohesive soil with eco-friendly guar gum. *Soils and Rocks*, 44(2), e2021060020. <https://doi.org/10.28927/SR.2021.060020>
- Bakare, M. D., Pai, R. R., Patel, S., & Shahu, J. T. (2019). Environmental Sustainability by Bulk Utilization of Fly Ash and GBFS as Road Subbase Materials. *Journal of Hazardous, Toxic, and Radioactive Waste*, 23(4), 04019011. [https://doi.org/10.1061/\(ASCE\)HZ.2153-5515.0000450](https://doi.org/10.1061/(ASCE)HZ.2153-5515.0000450)
- Bell, F. G. (1996). Lime stabilization of clay minerals and soils. *Engineering Geology*, 42(4), 223–237. [https://doi.org/10.1016/0013-7952\(96\)00028-2](https://doi.org/10.1016/0013-7952(96)00028-2)
- Berkane, H. A., Della, N., Benziane, M. M., Denine, S., Elroul, A. B., & Feknous, H. (2022). Laboratory investigation on the effect of a combination of xanthan gum and clay on the behavior of sandy soil. *Innovative Infrastructure Solutions*, 7(4), 1–12. <https://doi.org/10.1007/S41062-022-00867-Z/FIGURES/13>
- Blissett, R. S., & Rowson, N. A. (2012). A review of the multi-component utilisation of coal fly ash. *Fuel*, 97, 1–23. <https://doi.org/10.1016/J.FUEL.2012.03.024>
- Boz, A., Sezer, A., Özdemir, T., Hızal, G. E., & Azdeniz Dolmacı, Ö. (2018). Mechanical properties of lime-treated clay reinforced with different types of randomly distributed fibers. *Arabian Journal of Geosciences*, 11(6), 1–14. <https://doi.org/10.1007/S12517-018-3458-X/FIGURES/15>
- Bozyigit, I., Javadi, A., & Altun, S. (2021). Strength properties of xanthan gum and guar gum treated kaolin at different water contents. *Journal of Rock Mechanics and Geotechnical Engineering*, 13(5), 1160–1172. <https://doi.org/10.1016/J.JRMGE.2021.06.007>

- Brooks, R., Udoeyo, F. F., & Takkalapelli, K. V. (2010). Geotechnical Properties of Problem Soils Stabilized with Fly Ash and Limestone Dust in Philadelphia. *Journal of Materials in Civil Engineering*, 23(5), 711–716. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0000214](https://doi.org/10.1061/(ASCE)MT.1943-5533.0000214)
- Chang, I., & Cho, G. C. (2012). Strengthening of Korean residual soil with β -1,3/1,6-glucan biopolymer. *Construction and Building Materials*, 30, 30–35. <https://doi.org/10.1016/J.CONBUILDMAT.2011.11.030>
- Chang, I., Prasidhi, A. K., Im, J., Shin, H. D., & Cho, G. C. (2015). Soil treatment using microbial biopolymers for anti-desertification purposes. *Geoderma*, 253–254, 39–47. <https://doi.org/10.1016/J.GEODERMA.2015.04.006>
- Chudzickowski, J. R. (1971). Guar Gum and its Applications. *Journal of the Society of Cosmetics Chemists*, 22(1), 43.
- De Belie, N., Soutsos, M., & Gruyaert, E. (Eds.). (2018). Properties of Fresh and Hardened Concrete Containing Supplementary Cementitious Materials. 25. <https://doi.org/10.1007/978-3-319-70606-1>
- Degirmenci, N., Okucu, A., & Turabi, A. (2007). Application of phosphogypsum in soil stabilization. *Building and Environment*, 42(9), 3393–3398. <https://doi.org/10.1016/J.BUILDENV.2006.08.010>
- Dehghan, H., Tabarsa, A., Latifi, N., & Bagheri, Y. (2019). Use of xanthan and guar gums in soil strengthening. *Clean Technologies and Environmental Policy*, 21(1), 155–165. <https://doi.org/10.1007/S10098-018-1625-0/FIGURES/9>
- Eldaw, G. E. (1998, June 1). A study of guar seed and guar gum properties (Cyamopsis tetragonolabous). Retrieved from http://inis.iaea.org/Search/search.aspx?orig_q=RN:31037745
- Eliaslankaran, Z., Daud, N. N. N., Yusoff, Z. M., & Rostami, V. (2021). Evaluation of the effects of cement and lime with rice husk ash as an additive on strength behavior of coastal soil. *Materials*, 14(5), 1140.
- Fatehi, H., Ong, D. E. L., Yu, J., & Chang, I. (2024). Sustainable soil treatment: Investigating the efficacy of carrageenan biopolymer on the geotechnical properties of soil. *Construction and Building Materials*, 411, 134627. <https://doi.org/10.1016/J.CONBUILDMAT.2023.134627>
- Hamed, E., & Demiröz, A. (2024). Optimization of geotechnical characteristics of clayey soils using fly ash and granulated blast furnace slag-based geopolymer. *Construction and Building Materials*, 441, 137488.
- Hamza, M., Nie, Z., Aziz, M., Ijaz, N., Akram, O., Fang, C., ... Madni, M. F. (2023). Geotechnical behavior of high-plastic clays treated with biopolymer: macro–micro-study. *Environmental Earth Sciences*, 82(3), 1–18. <https://doi.org/10.1007/S12665-023-10760-2/TABLES/6>
- Harichane, K., Ghrici, M., Kenai, S., & Grine, K. (2011). Use of Natural Pozzolana and Lime for Stabilization of Cohesive Soils. *Geotechnical and Geological Engineering*, 29(5), 759–769. <https://doi.org/10.1007/S10706-011-9415-Z/FIGURES/6>
- Hataf, N., Ghadir, P., & Ranjbar, N. (2018). Investigation of soil stabilization using chitosan biopolymer. *Journal of Cleaner Production*, 170, 1493–1500. <https://doi.org/10.1016/J.JCLEPRO.2017.09.256>
- Kang, X., Kang, G.-C., Chang, K.-T., & Ge, L. (2014). Chemically Stabilized Soft Clays for Road-Base Construction. *Journal of Materials in Civil Engineering*, 27(7), 04014199. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0001156](https://doi.org/10.1061/(ASCE)MT.1943-5533.0001156)
- Keleştemur, O., Yildiz, S., Gökçer, B., & Arici, E. (2014). Statistical analysis for freeze–thaw resistance of cement mortars containing marble dust and glass fiber. *Materials & Design*, 60, 548–555. <https://doi.org/10.1016/J.MATDES.2014.04.013>
- Khaleghi, M., & Heidarvand, M. (2023). A novel study on hydro-mechanical characteristics of biopolymer-stabilized dune sand. *Journal of Cleaner Production*, 398, 136518.
- Kim, B., & Prezzi, M. (2008). Evaluation of the mechanical properties of class-F fly ash. *Waste Management*, 28(3), 649–659. <https://doi.org/10.1016/J.WASMAN.2007.04.006>
- Kumar, M. A., Moghal, A. A. B., Vydehi, K. V., & Almajed, A. (2023). Embodied energy in the production of guar and xanthan biopolymers and their cross-linking effect in enhancing the geotechnical properties of cohesive soil. *Buildings*, 13(9), 2304.

- Lee, M., Kwon, Y. M., Park, D. Y., Chang, I., & Cho, G. C. (2022). Durability and strength degradation of xanthan gum based biopolymer treated soil subjected to severe weathering cycles. *Scientific Reports*, 12(1), 1–15. <https://doi.org/10.1038/s41598-022-23823-4>
- Lee, S., Chung, M., Park, H. M., Song, K.-I., & Chang, I. (2019). Xanthan Gum Biopolymer as Soil-Stabilization Binder for Road Construction Using Local Soil in Sri Lanka. *Journal of Materials in Civil Engineering*, 31(11), 06019012. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0002909](https://doi.org/10.1061/(ASCE)MT.1943-5533.0002909)
- Mccarthy, M. J., Csetenyi, L. J., Sachdeva, A., & Jones, R. (2009, May). Role of Fly Ash in the Mitigation of Swelling in Lime Stabilised Sulfate-Bearing Soils. In *World of Coal Ash (WOCA) Conference* (pp. 1–18).
- Mudgil, D., Barak, S., & Khatkar, B. S. (2014). Guar gum: processing, properties and food applications-A Review. *Journal of Food Science and Technology*, 51(3), 409–418. <https://doi.org/10.1007/S13197-011-0522-X>
- Nalbantoğlu, Z. (2004). Effectiveness of Class C fly ash as an expansive soil stabilizer. *Construction and Building Materials*, 18(6), 377–381. <https://doi.org/10.1016/J.CONBUILDMAT.2004.03.011>
- Nalbantoglu, Z., & Gucbilmez, E. (2001). Improvement of calcareous expansive soils in semi-arid environments. *Journal of Arid Environments*, 47(4), 453–463. <https://doi.org/10.1006/JARE.2000.0726>
- Ni, J., Li, S. S., & Geng, X. Y. (2022). Mechanical and biodeterioration behaviours of a clayey soil strengthened with combined carrageenan and casein. *Acta Geotechnica*, 17(12), 5411–5427. <https://doi.org/10.1007/S11440-022-01588-4/FIGURES/11>
- Nugent, R., Zhang, G., & Gambrell, R. (2009). Effect of Exopolymers on the Liquid Limit of Clays and Its Engineering Implications. *Transportation Research Record*, 2101(1), 34–43. <https://doi.org/10.3141/2101-05>
- Oliveira, P. J. V., & Reis, M. J. F. C. C. (2023). Effect of the Organic Matter Content on the Mechanical Properties of Soils Stabilized with Xanthan Gum. *Applied Sciences*, 13(8), 4787. <https://doi.org/10.3390/APP13084787>
- Parsons, R. L., & Kneebone, E. (2015). Field performance of fly ash stabilised subgrades. *Proceedings of the Institution of Civil Engineers-Ground Improvement*, 9(1), 33–38. <https://doi.org/10.1680/GRIM.2005.9.1.33>
- Phanikumar, B. R., & Sharma, R. S. (2007). Volume Change Behavior of Fly Ash-Stabilized Clays. *Journal of Materials in Civil Engineering*, 19(1), 67–74. [https://doi.org/10.1061/\(ASCE\)0899-1561\(2007\)19:1\(67\)](https://doi.org/10.1061/(ASCE)0899-1561(2007)19:1(67))
- Prabakar, J., Dendorkar, N., & Morchhale, R. K. (2004). Influence of fly ash on strength behavior of typical soils. *Construction and Building Materials*, 18(4), 263–267. <https://doi.org/10.1016/J.CONBUILDMAT.2003.11.003>
- Ramezani, S. J., Toufigh, M. M., & Toufigh, V. (2023). Utilization of glass powder and silica fume in sugarcane bagasse ash-based geopolymer for soil stabilization. *Journal of Materials in Civil Engineering*, 35(4), 04023042.
- Reddy, J. J., & Varaprasad, B. J. S. (2021). Long-term and durability properties of xanthan gum treated dispersive soils – An eco-friendly material. *Materials Today: Proceedings*, 44, 309–314. <https://doi.org/10.1016/J.MATPR.2020.09.472>
- Risica, D., Dentini, M., & Crescenzi, V. (2005). Guar gum methyl ethers. Part I. Synthesis and macromolecular characterization. *Polymer*, 46(26), 12247–12255. <https://doi.org/10.1016/J.POLYMER.2005.10.083>
- Saride, S., & Dutta, T. T. (2016). Effect of Fly-Ash Stabilization on Stiffness Modulus Degradation of Expansive Clays. *Journal of Materials in Civil Engineering*, 28(12), 04016166. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0001678](https://doi.org/10.1061/(ASCE)MT.1943-5533.0001678)
- Sengul, T., Akray, N., & Vitosoglu, Y. (2023). Investigating the effects of stabilization carried out using fly ash and polypropylene fiber on the properties of highway clay soils. *Construction and Building Materials*, 400, 132590. <https://doi.org/10.1016/J.CONBUILDMAT.2023.132590>
- Senol, A., Edil, T. B., Bin-Shafique, M. S., Acosta, H. A., & Benson, C. H. (2006). Soft subgrades' stabilization by using various fly ashes. *Resources, Conservation and Recycling*, 46(4), 365–376. <https://doi.org/10.1016/J.RESCONREC.2005.08.005>
- Sezer, A., Inan, G., Yilmaz, H. R., & Ramyar, K. (2006). Utilization of a very high lime fly ash for improvement of Izmir clay. *Building and Environment*, 41(2), 150–155. <https://doi.org/10.1016/J.BUILDENV.2004.12.009>

- Sharma, N. K., Swain, S. K., & Sahoo, U. C. (2012). Stabilization of a Clayey Soil with Fly Ash and Lime: A Micro Level Investigation. *Geotechnical and Geological Engineering*, 30(5), 1197–1205. <https://doi.org/10.1007/S10706-012-9532-3/FIGURES/8>
- Singh, S. P., & Das, R. (2020). Geo-engineering properties of expansive soil treated with xanthan gum biopolymer. *Geomechanics and Geoengineering*, 15(2), 107–122. <https://doi.org/10.1080/17486025.2019.1632495>
- Smitha, S., & Rangaswamy, K. (2020). Effect of Biopolymer Treatment on Pore Pressure Response and Dynamic Properties of Silty Sand. *Journal of Materials in Civil Engineering*, 32(8), 04020217. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0003285](https://doi.org/10.1061/(ASCE)MT.1943-5533.0003285)
- Smitha, S., & Sachan, A. (2016). Use of agar biopolymer to improve the shear strength behavior of sabarmati sand. *International Journal of Geotechnical Engineering*, 10(4), 387–400. <https://doi.org/10.1080/19386362.2016.1152674>
- Soldo, A., Miletić, M., & Auad, M. L. (2020). Biopolymers as a sustainable solution for the enhancement of soil mechanical properties. *Scientific Reports*, 10(1), 1–13. <https://doi.org/10.1038/s41598-019-57135-x>
- Sujatha, E. R., Atchaya, S., Sivasaran, A., & Keerdthe, R. S. (2021). Enhancing the geotechnical properties of soil using xanthan gum—an eco-friendly alternative to traditional stabilizers. *Bulletin of Engineering Geology and the Environment*, 80(2), 1157–1167. <https://doi.org/10.1007/S10064-020-02010-7/FIGURES/8>
- Sujatha, E. R., & Saisree, S. (2019). Geotechnical behaviour of guar gum-treated soil. *Soils and Foundations*, 59(6), 2155–2166. <https://doi.org/10.1016/J.SANDF.2019.11.012>
- Sujatha, E. R., Sivaraman, S., & Subramani, A. K. (2020). Impact of hydration and gelling properties of guar gum on the mechanism of soil modification. *Arabian Journal of Geosciences*, 13(23), 1–12. <https://doi.org/10.1007/S12517-020-06258-X/FIGURES/8>
- Sulaiman, H., Taha, M. R., Abd Rahman, N., & Mohd Taib, A. (2022). Performance of soil stabilized with biopolymer materials – xanthan gum and guar gum. *Physics and Chemistry of the Earth, Parts A/B/C*, 128, 103276. <https://doi.org/10.1016/J.PCE.2022.103276>
- Taguchi, G. (1987). *System of Experimental Design*, Unipub/Kraus, International Publication.
- Tastan, E. O., Edil, T. B., Benson, C. H., & Aydilek, A. H. (2011). Stabilization of Organic Soils with Fly Ash. *Journal of Geotechnical and Geoenvironmental Engineering*, 137(9), 819–833. [https://doi.org/10.1061/\(ASCE\)GT.1943-5606.0000502](https://doi.org/10.1061/(ASCE)GT.1943-5606.0000502)
- Thangaraj, R., & Thenmozhi, R. (2013). Industrial and Environmental Application of High Volume Fly Ash in Concrete Production. *Nature Environment and Pollution Technology*, 12(2), 315.
- TS 1900-1, 2006. İnşaat Mühendisliğinde Zemin Laboratuvar Deneyleri-Bölüm 1: Fiziksel Özelliklerin Tayini. TSE, Ankara.
- Vydehi, K. V., & Moghal, A. A. B. (2021). Effect of Biopolymeric Stabilization on the Strength and Compressibility Characteristics of Cohesive Soil. *Journal of Materials in Civil Engineering*, 34(2), 04021428. [https://doi.org/10.1061/\(ASCE\)MT.1943-5533.0004068](https://doi.org/10.1061/(ASCE)MT.1943-5533.0004068)
- Zha, F., Liu, S., Du, Y., & Cui, K. (2008). Behavior of expansive soils stabilized with fly ash. *Natural Hazards*, 47, 509-523.
- Zhang, J., Meng, Z., Jiang, T., Wang, S., Zhao, J., & Zhao, X. (2022). Experimental Study on the Shear Strength of Silt Treated by Xanthan Gum during the Wetting Process. *Applied Sciences*, 12(12), 6053. <https://doi.org/10.3390/APP12126053>
- Zhang, T., Liu, S., Cai, G., & Puppala, A. J. (2015). Experimental investigation of thermal and mechanical properties of lignin treated silt. *Engineering Geology*, 196, 1–11. <https://doi.org/10.1016/J.ENGGEOL.2015.07.003>



Kahramanmaraş Sutcu Imam University

Journal of Engineering Sciences



Geliş Tarihi : 22.07.2024
Kabul Tarihi : 23.08.2024

Received Date : 22.07.2024
Accepted Date : 23.08.2024

YÜKSEK VERİMLİ STAIRMAND SİKLONDA SICAKLIK ETKİSİNİN İNCELENMESİ

INVESTIGATION OF THE TEMPERATURE EFFECT ON THE STAIRMAND HIGH EFFICIENCY CYCLONE

Nihan BABAĞLU^{1*} (ORCID: 0000-0003-3356-9407)
Mesut ARI¹ (ORCID: 0000-0002-5738-3079)

¹ Kahramanmaraş Sütçü İmam Üniversitesi, Çevre Mühendisliği Bölümü, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: Nihan BABAĞLU, nuygur@ksu.edu.tr

ÖZET

Bu çalışmada, yüksek verimli Stairmand (HE) tipi siklonda akışkan sıcaklığının toplama verimi ve basınç kayıplarına olan etkileri nümerik yöntemler kullanılarak ortaya koyulmuştur. 273,15 – 373,15 K (0 – 100 °C) aralığında altı farklı sıcaklık değeri için çalışmalar yapılmıştır. Sonuçların tutarlı olması için siklon geometrisi küçük elemanlar kullanılarak gridlenmiştir. Türbülanslı akışın çözülmesi için Reynolds Stress Model (RSM) kullanılmıştır. Çözümleme transient olarak 5 ms'lik 1000 adım ile 10000 iterasyon sonucunda ortaya koyulmuştur. Partikül boyut dağılımı için Rosin-Rammler boyut dağılımı kullanılmıştır. Çalışma sonucunda sıcaklık artışının toplama verimini olumsuz yönde etkilediği ve basınç kayıplarını azalttığı görülmüştür. Sıcaklık artışı akışkan vizkozitesini artırdığı için akışkan-partikül etkileşimi artmıştır. Buda partiküllerin akışkanla birlikte hareket etmesine ve toplama veriminin azalmasına neden olmuştur. Sıcaklık artışı ile birlikte, dönen akışın zayıflaması dolayısıyla basınç kaybının ve toplama verimliliğinin gözle görülür şekilde azaldığı görülmektedir. Sıcaklık artışıyla birlikte siklon duvarlarında oluşan basınçlar düşmüştür.

Anahtar Kelimeler: Yüksek verimli Stairmand siklon, basınç kaybı, toplama verimi, sıcaklık etkisi, akışkan vizkozitesi.

ABSTRACT

The present study aims at investigating numerically the effect of fluid temperature on the high-efficiency Stairmand type cyclone collection efficiency and pressure drop. Studies were conducted for six different temperature values in the range of 273.15 – 373.15 K (0 – 100 °C). Discretization of the solution domain generated fine meshes for consistent results. Reynolds Stress Model (RSM) was used to solve turbulent flow. The solution was performed as a transient in 1000 time-steps of 5 ms and 10000 iterations. Rosin-Rammler size distribution was used for particle size distribution. It was seen that the temperature increases negatively affected the collection efficiency and pressure drops. Fluid viscosity is increased effectively by increasing fluid temperature, then fluid-particle interaction increased. Increasing in temperature causes the particles move with the fluid and thus, collection efficiency decreased. Because of swirling flow weakening, conclusive results clearly seen that increasing the temperature of fluid reduces the pressure drop and collection efficiency. When increase the temperature, the pressures on the cyclone walls decreased.

Keywords: High efficiency Stairmand cyclone, pressure drop, collection efficiency, temperature effect, fluid viscosity

ToCite: Babaoğlu, N., & Arı, M., (2025). YÜKSEK VERİMLİ STAIRMAND SİKLONDA SICAKLIK ETKİSİNİN İNCELENMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 104-111.

GİRİŞ

Siklon ayırıcılar, gaz ve katı partikülleri ayırmada etkili, yaygın olarak kullanılan endüstriyel ekipmanlardır. Bu ayırıcılar, gaz akışını dönme hareketiyle yönlendirerek, merkezkaç kuvveti etkisiyle partiküllerin gazdan ayrılmasını sağlarlar. Siklon ayırıcılarda iç ve dış akış olmak üzere iki farklı akış türü mevcuttur. Dış akış, siklon duvarı boyunca toz haznesinin tabanına doğru dönerek iner ve toz haznesinin ucundan başlayıp ters yönde meydana çıkan bir iç akış oluşur. Merkezkaç kuvveti, partikülü siklon duvarına doğru iterken, sürüklenme kuvveti partikülü siklonun merkezine doğru iter. Başka bir deyişle, partiküllere etki eden merkezkaç kuvveti sürüklenme kuvvetinden büyük olduğunda partiküller sistemde tutulurlar (Wasilewski & Brar, 2019; Park & Go, 2020).

Siklonlar, çeşitli endüstrilerde bir hava ön arıtma prosesi olarak, hava temizleme ve toz toplama, amacıyla çok fazla tercih edilirler. Çimento fabrikaları, çelik fabrikaları, ziraat, eczacılık, enerji santralleri, gıda işleme tesisleri ve kimya endüstrisi gibi alanlarda toz toplama, hava temizleme, gaz soğutma ve ürün geri kazanımı amacıyla yaygın olarak kullanılırlar. Siklonların basit tasarımı ve düşük maliyetleri, onları endüstriyel uygulamalarda cazip bir seçenek haline getirir ve bu hava kirliliği kontrol ünitesini avantajlı kılar. Bir diğer önemli avantajları ise hareketli parçalar içermedikleri için bakım gereksinimlerinin çok fazla olmaması ve düşük enerji tüketimleri dolayısıyla işletme maliyetlerinin az oluşudur. Öte yandan siklonlar, yüksek sıcaklıklarda ve aşındırıcı ortamlar gibi zorlu koşullarda etkin bir şekilde çalışabilmektedirler. Tüm bu avantajlar bu ekipmanları daha kullanışlı hale getirirken, özellikle 5 µm ve daha küçük partiküllerin ayrıştırılmasında etkinliklerinin az olması, proseste yaşanan basınç kayıpları siklonlara ait dezavantajlar olarak sıralanabilir. Ayrıca, çok büyük veya çok küçük siklonların tasarimsal ve operasyonel zorlukları olabilmektedir (Abrahamson vd., 2002; Misiulia vd., 2017; Brar & Elsayed, 2018; Chen vd., 2018; Hosseini vd., 2022; Surahmanto vd., 2024).


Basit yapılarına rağmen siklon ayırıcılar son derece karmaşık akışkan dinamiği ve akış modellerine sahiptirler. Siklon içerisindeki gaz-partikül karışımının güçlü türbülanslı akışı anizotropik bir karaktere sahiptir. Siklon ayırıcılar için en popüler araştırma yöntemleri arasında deneysel çalışmalar, analitik modellere dayalı hesaplamalı yöntemler (klasik siklon tasarımı) ve akışların sayısal modellemesi (hesaplamalı akışkanlar dinamiği, CFD) yer alır (Parvaz vd., 2017; Wasilewski & Brar, 2019; Elsayed vd., 2020; Babaoğlu vd., 2022).

Literatürde, siklon performansını artırmak ve optimize etmek amacıyla birçok deneysel ve sayısal çalışma yapılmıştır. Yapılan çalışmalarda, siklonun geometrik özellikleri ve siklonun çalışma şartlarının değiştirilmesi ile basınç kaybı ve partikül ayırma verimi (performans) analizleri yapılmıştır ki, siklonlarda performans parametrelerini yapılacak olan bu konfigürasyonlar şekillendirmektedir (Demir, 2014; Babaoğlu vd., 2021). Zhao ve arkadaşları yaptıkları çalışmada bir siklonda spiral çift girişin siklon performansı üzerine olan etkisini değerlendirmişler ve spiral çift giriş kullanan siklon ayırıcının parçacık ayırma verimliliğini artırabileceği sonucunu elde etmişlerdir (Zhao vd., 2006). Balestrin ve arkadaşları, girdap bulucu çıkış kanalının yanı sıra gerilmiş silindirik gövdenin siklonun performansı üzerindeki etkisini değerlendirmişlerdir. Çalışmalarının sonucunda girdap bulucunun kesitinin azalmasıyla desteklenen ikincil bir girdap akışıyla siklonun verimliliğinin arttığını ortaya koymuşlardır (Balestrin vd., 2017). Safikhani ve arkadaşları yaptıkları çalışmada, bir siklon ayırıcının performansını belirlemek için parçacık dinamiğini ve akışkan akışını sayısal olarak araştırmışlardır ve girdap bulucunun girişinde türbülans kinetik enerjisinin yüksek değerlere sahip olduğunu belirtmişlerdir (Safikhani vd., 2018) Brar ve arkadaşları (2015) yaptıkları çalışmada Stairmand HE siklonların hem silindirik hem de konik segmentinin uzunluğunun artırılmasının performans ve akış alanı üzerindeki bireysel etkisini incelemişlerdir. Çalışmada, siklon uzunluğunun toz toplama verimliliği ve basınç kayıpları üzerinde belirleyici bir rol oynadığı bulunmuştur (Brar vd., 2015). Gimbin ve arkadaşları siklon basınç düşüşünde sıcaklık ve hızın rolünü araştırdıkları çalışmalarında, giriş sıcaklığı arttığında basınç kayıplarının azaldığını belirlemişlerdir (Gimbin vd., 2005).

Bu çalışmada, Stairmand HE tipi siklonlarda sıcaklığın toplama verimliliği ve basınç kayıplarına olan etkileri, sayısal yöntemlerle incelenecektir. Bu siklon geometrisi birçok yeni siklon tasarımına ilham veren ve en iyi optimize olmuş siklon türü olarak tanımlanabilir (Brar vd., 2015). Kimyasal madde imalatı, endüstriyel ünitelerin baca çıkış gazının temizlenmesi ve termik santrallerdeki çeşitli işlemler gibi çeşitli endüstriyel işlemlerde, yüksek sıcaklıktaki bir gazdan katı parçacıkların uzaklaştırılması önemlidir ve siklon ayırıcı performansını da etkileyebilmektedir (Siadaty vd., 2017). Bu çalışmanın amacı, sıcaklık değişimlerinin siklon performansı üzerindeki etkilerini belirlemektir.


MATERYAL VE METOT

Yapılan bu çalışmada 290 mm çapa (D) sahip Stairmand HE siklonda sıcaklığın ayırma verimi ve basınç kayıplarına olan etkileri incelenmiştir. Bu kapsamda kullanılan siklon geometrisinin izometrik görünümü Şekil 1’de verilmiştir. Akışkan (hava) sıcaklığının etkisini ortaya koymak amacıyla 273,15 – 373,15 K (0 – 100 °C) aralığında altı farklı sıcaklık değeri için çalışılmıştır. CFD tekniği kullanılarak yapılan çalışma ANSYS 2019 R0 programının Fluent modülü kullanılarak ortaya koyulmuştur. Çalışma transient olarak gerçekleştirilmiş, 5 milisaniyelik adımlarla 1000 adım sonucunda elde edilen veriler sunulmuştur.



Şekil 1. Stairmand HE Siklon Geometrisi (D = 290 mm)


Sonuçların daha tutarlı olması için siklon geometrisi maksimum skewness değeri 0,7 olan 1386629 adet altı yüzlü elemanlar kullanılarak gridleme işlemine tabi tutulmuştur Şekil 2. Giriş sınır koşulu Velocity-Inlet, çıkış sınır koşulu Pressure-Outlet ve diğer yüzeyler Wall olarak ayarlanmıştır. Rosin-Ramler boyut dağılımı metodu kullanılarak 0,1 µm ile 5 µm arasındaki 200 farklı çapa ve 2700 kg/m³ yoğunluğa sahip partiküller akışkan ile aynı sıcaklık ve hızla giriş yüzeyine dik şekilde siklona enjekte edilmiştir. Türbülanslı akışı hesaplamak için Reynold Stress Model kullanılmıştır. Partikül hareketlerinin modellenmesinde Discrete Random Walk (DRW) ve Random Eddy Lifetime (REL) ayarları yapılmıştır. Sınır koşullarının partikül kısmında giriş için Reflect, çıkış için Escape ve toz çıkışı için Trap olarak seçilmiştir. Çalışmada her geometri için 10000 iterasyon gerçekleştirilmiş olup süreklilik hatası 10⁻⁵ ‘ten küçüktür. Siklon üst yüzeyinden 0,75D kadar aşağıda yatay eksen doğrultusunda statik basınç, teğetsel ve eksenel hız profilleri elde edilmiştir. Elde edilen profiller Şekil 3, Şekil 4 ve Şekil 5’te sunulmuştur.



Şekil 2. Stairmand HE Siklon Grid Görünümü (1386629 eleman)


BULGULAR VE TARTIŞMA

Çalışma kapsamında Stairmand HE siklonda sıcaklığın toplama verimi ve basınç kayıplarına olan etkisi ortaya koyulmuştur. Şekil 3, Şekil 4 ve Şekil 5 siklon üst yüzeyinden $0.75D$ kadar uzakta, siklon merkezinden geçen yatay eksen doğrultusunda statik basınç, teğetsel ve aksenal hız profilleri sırasıyla sunulmuştur. Şekil 3 incelendiğinde siklon duvarlarından merkeze doğru basıncın düştüğü görülür. Sıcaklıkla birlikte siklon duvarlarındaki basınç azalmaktadır. Farklı sıcaklıklardaki basınç profilleri benzer trendler ortaya koymuştur. Siklon duvarından doğru gidildikçe basınç düşüşü artarak meydana gelmiştir.




Şekil 3. Statik Basınç Profilleri Farklı Sıcaklıklar İçin ($Z = 0,75D$)

Şekil 4’de görülen teğetsel hız profilleri incelenecek olursa hız profillerinde M şekli gözlemlenir. Teğetsel hız duvarla akışkan arasındaki sürtünme nedeniyle siklon duvarına doğru sıfıra yaklaşmaktadır. Siklon merkezine doğru gidildikçe önce arttığı sonra azalarak sıfıra yaklaştığı görülür. Bununla birlikte sıcaklık etkisiyle maksimum teğetsel hızın azaldığı söylenebilir. Siklonlarda teğetsel hızın artışı ayırma verimini artırmaktadır.



Şekil 4. Teğetsel Hız Profilleri Farklı Sıcaklıklar İçin ($Z = 0,75D$)

Şekil 5’te ise aksel hız profilleri mevcut olup, teğetsel hızla benzer şekilde siklon duvarına doğru aksel hızında sıfıra yaklaştığı görülür. Ayrıca bu profiller siklonda dış vorteksin aşağı yönde, iç vorteksin ise yukarı yönde olduğu görülür. Ayrıca siklon merkezine yakın yerlerde aşağı yönde akış görülür. Yukarı yöndeki akışın daha yüksek hızda olduğu görülür. Sıcaklıkla aksel hız arasında ilişki ise daha karmaşık olmakla birlikte 273,15 K’de maksimum aksel hızı ulaşılır.




Şekil 5. Aksel Hız Profilleri Farklı Sıcaklıklar İçin ($Z = 0,75D$)

Tablo 1’de sıcaklıkla kesme çapı ve basınç kaybının nasıl değiştiği görülmektedir. Şekil 6 ve Şekil 7’de bu durum grafik halinde sunulmuştur. Şekil 6’ya bakıldığında sıcaklık artışı ile kesme çapının arttığı, toplama veriminin azaldığı anlaşılır. Bu değişim neredeyse lineer olarak nitelendirilebilir. Şekil 7’ye bakıldığında ise basınç kayıplarının sıcaklık arttıkça azaldığı açıkça görülür. Buradaki durumda aynı kesme çapında olduğu gibi lineerlik özelliğine sahip, fakat azalan yöndedir. Sıcaklığın artışı dönen akışın zayıflaması dolayısıyla basınç kaybının ve toplama verimliliğinin

gözle görülür şekilde azaldığını göstermektedir. Ayrıca viskozitenin artması katı faz ile gaz faz arasındaki etkileşimin artmasına neden olduğu için, toplama verimi de azalma eğilimine girmiştir. Teğetsel hız ile toplama verimi arasında da bir ilişkiden söz edilebilir. Burada durum biraz daha farklıdır. Aynı teğetsel hıza sahip olan iki farklı akışkan içerisinde hareket eden partiküller göz önüne alınırsa, viskozitenin yüksek olduğu akışkan içinde hareket eden partiküller akışkandan daha fazla etkileneceklerdir ve tutulma verimleri daha düşük olacaktır. Ancak burada Şekil 4'ten de görüleceği üzere sıcaklık artışı ile teğetsel hız azalmıştır. Bu da toplama verimini olumsuz yönde etkilemiştir.

Tablo 1. Sıcaklığa Bağlı Kesme Çapı ve Basınç Kayıpları Değerleri

Sıcaklık (K)	Kesme Çapı (μm)	Basınç Kaybı (Pa)
273,15	1,649	540,11
293,15	1,719	534,28
313,15	1,776	529,24
333,15	1,815	524,38
353,15	1,855	519,13
373,15	1,919	514,42



Şekil 6. Sıcaklığa Bağlı Olarak Kesme Çapının Değişimi

SONUÇ

Bu çalışma kapsamında, Stairmand HE siklonda sıcaklık artışının toplama verimi ve basınç kaybına olan etkileri çalışılmıştır. Çalışma 6 farklı sıcaklık değerinde yapılmış olup, sıcaklıkla akış özellikleri arasındaki ilişkiler ortaya koyulmaya çalışılmıştır. Çalışma sonucunda elde edilen ana bulgular aşağıda listelenmiştir.

Sıcaklık artışıyla birlikte akışkan viskozitesi artmaktadır toplama veriminin düşüşüne sebep olmuştur.

Sıcaklık artışının teğetsel hızı azalttığı gözlemlenir.


Sıcaklık artışı neticesinde meydana gelen viskozite artışı partikül madde ile akışkan arasındaki etkileşimin artmasına neden olmuştur. Bu durum toplama veriminin azalmasına neden olmaktadır.

Sıcaklık artışı dönen akışın azalmasına, böylece basınç kayıplarının da azalmasına neden olmaktadır.

273.15 K'de maksimum aksel hızı ulaşılmıştır.

Sıcaklık artışıyla basınç kayıpları lineer olarak azalmıştır.

Sıcaklık artışıyla kesme çapının lineer olarak arttığı söylenebilir.
Siklon duvarlarındaki basınç sıcaklık artışıyla birlikte azalmıştır.



Şekil 7. Sıcaklığa Bağlı Olarak Basınç Kaybının Değişimi

KAYNAKLAR

- Abrahamson, J., Jones, R., Lau, A., & Reveley, S. (2002). Influence of entry duct bends on the performance of return-flow cyclone dust collectors. *Powder Technology*, 123(2–3), 126–137. [https://doi.org/10.1016/S0032-5910\(01\)00435-1](https://doi.org/10.1016/S0032-5910(01)00435-1)
- Babaoğlu, N. U., Hosseini, S. H., Ahmadi, G., & Elsayed, K. (2022). The effect of axial cyclone inlet velocity and geometrical dimensions on the flow pattern, performance, and acoustic noise. *Powder Technology*, 407(July). <https://doi.org/10.1016/j.powtec.2022.117692>
- Babaoğlu, N. U., Parvaz, F., Hosseini, S. H., Elsayed, K., & Ahmadi, G. (2021). Influence of the inlet cross-sectional shape on the performance of a multi-inlet gas cyclone. *Powder Technology*, 384, 82–99. <https://doi.org/10.1016/j.powtec.2021.02.008>
- Balestrin, E., Decker, R. K., Noriler, D., Bastos, J., & Meier, H. F. (2017). An alternative for the collection of small particles in cyclones: Experimental analysis and CFD modeling. *Separation and Purification Technology*, 184. <https://doi.org/10.1016/j.seppur.2017.04.023>
- Brar, L. S., & Elsayed, K. (2018). Analysis and optimization of cyclone separators with eccentric vortex finders using large eddy simulation and artificial neural network. *Separation and Purification Technology*, 207, 269–283. <https://doi.org/10.1016/j.seppur.2018.06.013>
- Brar, L. S., Sharma, R. P., & Elsayed, K. (2015). The effect of the cyclone length on the performance of Stairmand high-efficiency cyclone. *Powder Technology*, 286, 668–677. <https://doi.org/10.1016/j.powtec.2015.09.003>
- Chen, L., Xie, H., Xu, J., Dai, R., & Chen, J. (2018). Experimental and numerical study on the performance of an axial fan with a Gurney flap. In *Advances in Mechanical Engineering* (Vol. 10, Issue 10, p. 9). <https://doi.org/10.1177/1687814018803804>
- Demir, S. (2014). A practical model for estimating pressure drop in cyclone separators: An experimental study. *Powder Technology*, 268, 329–338. <https://doi.org/10.1016/j.powtec.2014.08.024>
- Elsayed, K., Parvaz, F., Hosseini, S. H., & Ahmadi, G. (2020). Influence of the dipleg and dustbin dimensions on performance of gas cyclones: An optimization study. *Separation and Purification Technology*, 239(September 2019). <https://doi.org/10.1016/j.seppur.2020.116553>

- Gimbun, J., Chuah, T. G., Fakhru'l-Razi, A., & Choong, T. S. Y. (2005). The influence of temperature and inlet velocity on cyclone pressure drop: A CFD study. *Chemical Engineering and Processing: Process Intensification*, 44(1), 7–12. <https://doi.org/10.1016/j.cep.2004.03.005>
- Hosseini, E., Fatahian, H., & Fatahian, E. (2022). New understanding of the effect of particle mass loading on the performance of a square cyclone at low and high gas temperatures. *Korean Journal of Chemical Engineering*, 39(12), 3482–3496. <https://doi.org/10.1007/s11814-022-1205-1>
- Misiulia, D., Andersson, A. G., & Lundström, T. S. (2017). Effects of the inlet angle on the collection efficiency of a cyclone with helical-roof inlet. *Powder Technology*, 305, 48–55. <https://doi.org/10.1016/j.powtec.2016.09.050>
- Park, D., & Go, J. S. (2020). Design of cyclone separator critical diameter model based on machine learning and cfd. *Processes*, 8(11), 1–13. <https://doi.org/10.3390/pr8111521>
- Parvaz, F., Hosseini, S. H., Ahmadi, G., & Elsayed, K. (2017). Impacts of the vortex finder eccentricity on the flow pattern and performance of a gas cyclone. *Separation and Purification Technology*, 187, 1–13. <https://doi.org/10.1016/j.seppur.2017.06.046>
- Safikhani, H., Zamani, J., & Musa, M. (2018). Numerical study of flow field in new design cyclone separators with one, two and three tangential inlets. *Advanced Powder Technology*, 29(3), 611–622. <https://doi.org/10.1016/j.apt.2017.12.002>
- Siadaty, M., Kheradmand, S., & Ghadiri, F. (2017). Study of inlet temperature effect on single and double inlets cyclone performance. *Advanced Powder Technology*, 28(6), 1459–1473. <https://doi.org/https://doi.org/10.1016/j.apt.2017.03.015>
- Surahmanto, F., Pamungkas, A., Agung Mutoha, D., Leman Soemowidagdo, A., Tri Sasongko, B., Sukardi, S., Lutfianto, R., & Rizky Pratama Hakim, M. (2024). Performance Evaluation of Square Cyclone Separator with Cone Geometry Variations. *CFD Letters*, 16(7), 136–149. <https://doi.org/10.37934/cfdl.16.7.136149>
- Wasilewski, M., & Brar, L. S. (2019). Effect of the inlet duct angle on the performance of cyclone separators. *Separation and Purification Technology*, 213(December), 19–33. <https://doi.org/10.1016/j.seppur.2018.12.023>
- Zhao, B., Su, Y., & Zhang, J. (2006). Simulation of gas flow pattern and separation efficiency in cyclone with conventional single and spiral double inlet configuration. *Chemical Engineering Research and Design*, 84(12 A), 1158–1165. <https://doi.org/10.1205/cherd06040>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 27.07.2024
Kabul Tarihi : 18.09.2024

Received Date : 27.07.2024
Accepted Date : 18.09.2024

ŞEBEKE BAĞLANTILI GÜNEŞ ENERJİSİ SANTRALİ YATIRIMI İÇİN MODELLEME VE SİMÜLASYON ANALİZİ: ILGIN/KONYA ÖRNEĞİ

MODELING AND SIMULATION ANALYSIS FOR GRID CONNECTED SOLAR POWER PLANT INSTALLATION: A CASE STUDY OF ILGIN/KONYA

*Furkan Dinçer** (ORCID: 0000-0001-6787-0850)

Kahramanmaraş Sütçü İmam Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: furkandincer@ksu.edu.tr

ÖZET

Güneş enerjisi santrallerinin ekonomik ömrü 25-30 yıl olarak verilmektedir. Birçok panel üreticisi 10-12 yıl fiziksel garanti, 25-30 yıl süre için ise performans garantileri sunmaktadır. Bu süreler sonunda kullanılan güneş paneli ömrünü yitirmemekte sadece performansı azalmaktadır. Bu da 10 yıl süre sonunda %90 performans garantisi şeklinde gerçekleşmektedir. Bundan ötürü yatırım yapılmadan önce fizibilite raporlarının yapılması ve simülasyon çalışmalarının gerçekleştirilmesi büyük önem arz etmektedir. Arazinin yapısı, jeopolitik konumu, topografik yapısı, enerji nakil hattına olan mesafesi, hattın akım taşıma kapasitesi, gerilim düşümü, trafo merkezi kapasitesi, gölgeleme faktörü vb. birçok parametre göz önünde bulundurulmalı ve hesaplamalar da buna göre yapılmalıdır. Bu çalışmada, Konya İli, Ilgın İlçesinde kurulumu planlanan 1.250 kWe AC, 1.658,80 kWp DC elektriksel güç değerlerinden oluşacak bir güneş enerjisi santrali için modelleme ve simülasyon analizi gerçekleştirilmiştir. Bu analizler ile arazinin topografik yapısı, azimut açısı, eğim durumu, gölgeleme faktörü, kullanılacak malzeme seçimi, elektrik enerjisi üretim durumu ve finansal değerlendirmeler detaylı olarak yapılmıştır.

Anahtar Kelimeler: Güneş enerjisi, modelleme, Ilgın, invertör

ABSTRACT

The economic life of solar power plants is given as 25-30 years. Many panel manufacturers offer a physical guarantee for 10-12 years and performance guarantees for 25-30 years. At the end of these periods, the solar panel used does not lose its life, only its performance decreases. This is realized as a 90% performance guarantee at the end of 10 years. Therefore, it is of great importance to conduct feasibility reports and simulation studies before making an investment. Many parameters such as the structure of the land, geopolitical position, topographic structure, distance to the power transmission line, current carrying capacity of the line, voltage drop, substation capacity, shading factor, etc. should be taken into consideration and calculations should be made accordingly. In this study, a modeling and simulation analysis was performed for a solar power plant that will consist of 1,250 kWe AC and 1,658.80 kWp DC electrical power values planned to be installed in Ilgın District of Konya Province. With these analyzes, the topographical structure of the land, azimuth angle, slope condition, shading factor, material selection, electrical energy production status and financial evaluations were made in detail.

Keywords: Solar energy, modeling, Ilgın, inverter

GİRİŞ

Elektrik enerjisi hayatımızın vazgeçilmez bir parçası olmaya başlamıştır. Çünkü günümüzde kullandığımız elektrikli ev aletleri, telefon, bilgisayar, internet, robotlar, araçlar vs. hepsi elektrik enerjisine ihtiyaç duymaktadır. Nüfus ve sanayinin de gelişimi ile birlikte elektrik enerjisi tüketimi hızlı bir şekilde artmaktadır. Artan elektrik enerjisi ihtiyacını karşılamak için yenilenebilir ve çevre dostu enerji kaynaklarına ihtiyaç duyulmaktadır. Çünkü konvansiyonel olarak fosil tabanlı kaynaklar belirli bir sınırdan olup hem tükenmekte hem de kullanılırken çevreye zarar vermektedir. Yenilenebilir enerji kaynakları güneş, rüzgâr, biyokütle, gelgit, jeotermal vb. şeklinde sıralanabilir. Bu kaynaklar ile günümüzde elektrik enerjisi üretilebilmekte ve kullanılmaktadır. Bu kaynaklar içerisinde en bol, sınırsız, çevre dostu ve modüler olan kaynak ise güneş enerjisidir (Şahin ve ark., 2022).

Ülkemizde elektrik enerjisi üretiminde yenilenebilir enerji kaynaklarının payı hızlı bir şekilde artmaktadır. Özellikle güneş enerjisi kaynağı bakımından ülkemiz avantajlı bir jeopolitik konuma sahiptir. Ülkemizde modüler olarak yıl boyu güneş enerjisinden elektrik enerjisi üretilebilmektedir. Modüler olması avantajı ile de küçük güçlerde güneş enerjisi santrali kurulabildiği gibi çok büyük güç seviyelerinde de güneş enerjisi santrali kurulabilmektedir (Dinçer ve Karadağ, 2022; Dincer ve Ozer, 2023)

Güneş enerjisi santrallerinin ekonomik ömrü 25-30 yıl olarak verilmektedir. 30 yıl süre sonunda kullanılan güneş paneli ömrünü yitirmemekte sadece performansı azalmaktadır. Dolayısı ile bir güneş enerjisi santrali yatırımı uzun vadeli ve ömürlü bir yatırımdır. Bu yatırımlar modüler olduğu için binlerce lira ile de kurulabildiği gibi yüz milyonlarca liralara da kurulabilmektedir. Bundan ötürü bu yatırımlar yapılırken yatırım yapılmadan önce dikkatli ve özenli bir şekilde fizibilite raporlarının yapılması ve simülasyon çalışmalarının gerçekleştirilmesi de büyük önem arz etmektedir. Arazinin yapısı, jeopolitik konumu, topografik yapısı, enerji nakil hattına olan mesafesi, hattın akım taşıma kapasitesi, gerilim düşümü, trafo merkezi kapasitesi, gölgelenme faktörü vb. birçok parametre göz önünde bulundurulmalı ve hesaplamalar da buna göre yapılmalıdır. Çeşitli simülasyon programları ile de bu parametreler analiz edilebilmekte ve böylece finansal analizler de yapılabilmektedir.

Yapılan bir literatür çalışmasında İç Anadolu Bölgesinde yer alan illerin güneş enerjisinden elektrik enerjisi üretim potansiyeli araştırılmıştır. Çalışmada; Ankara ve Konya iklim şartları altında TRNSYS programı ile simülasyon çalışması gerçekleştirilmiş ve Karaman ilinin en yüksek potansiyele sahip olduğu tespit edilmiştir (Öztürk ve Kayabaşı, 2023). Bir tez çalışmasında; şebeke bağlantılı 1 MW güce sahip bir güneş enerjisi santrali için performans değerlendirmesi amacı ile PVsyst simülasyon programı ile bir modelle çalışması yapılmıştır (Yiğit, 2023). Başka bir makale çalışmasında Bursa ilinde bulunan bir firmanın elektrik enerjisi ihtiyacını karşılamak için PVsyst simülasyon programıyla bir modelleme çalışması yapılmıştır (Kılıç ve Kurtaran, 2024). Yapılan başka bir makale çalışmasında ise lisanssız elektrik enerjisi üretiminde mevzuatlardan kaynaklı yaşanan üretim kayıplarına değinilmiştir (Bayrak ve Aslan, 2023).

Bu çalışmada, Konya ili, Ilgın ilçesinde yatırımı yapılacak bir güneş enerjisi santrali için modelleme ve simülasyon analizi gerçekleştirilmiştir. Kurulumu yapılacak santral güçleri; 1.250 kWe AC, 1.658,80 kWp DC elektrikli güç değerlerinden oluşmaktadır. Projenin lokasyonu Konya İli, Ilgın İlçesi, Göstere Mahallesi 202 Ada 3,7 Parseller şeklindedir. Bu analizler ile arazinin topografik yapısı, azimut açısı, eğim durumu, gölgelenme faktörü, kullanılacak malzeme seçimi, elektrik enerjisi üretim durumu ve finansal değerlendirmeler detaylı olarak yapılmıştır. Böyle bir çalışma örneği farklı illerdeki lokasyonlar için de uygulanabilir ve çalıştırılabilir. Zaten bu güneş enerjisi santrali yatırımları da yapılmadan önce bu detaylı analiz ve çalışmaların gerçekleştirilmesi yatırımın geri dönüş süresi ve uygunluğu bakımından da büyük önem arz etmektedir.

Tüketim Tesisinin Elektrik Enerjisi Sarfıyatı

Tesise ait son 12 aya ait elektrik enerjisi tüketim değerleri Tablo 1'de gösterilmiştir. Genel toplamda yıllık bazda yaklaşık 10.000.000 (onmilyon) kWh elektrik enerjisi ile ciddi bir tüketim yapılmaktadır.

Tablo 1. Tesisin Elektrik Enerjisi Tüketim Dağılımı

Dönem	Tüketim (kWh)
Temmuz 2023	870.395,40
Ağustos 2023	725.454,45
Eylül 2023	457.118,80
Ekim 2023	543.923,10
Kasım 2023	511.711,20
Aralık 2023	653.908,50
Ocak 2024	822.247,65
Şubat 2024	798.327,81
Mart 2024	953.788,50
Nisan 2024	932.284,40
Mayıs 2024	1.171.520,60
Haziran 2024	920.581,83
Genel Toplam	9.361.262,23

Tüketim tesisinin elektrik enerjisi tüketim profili incelendiğinde, Ağustos 2023'ten Eylül 2023'e kadar enerji tüketiminde belirgin bir düşüş gözlemlenmektedir. Kasım 2023'ten Ocak 2024'e kadar tüketimde belirgin bir artış gözlemlenmektedir. Kış aylarında enerji tüketiminde genel olarak bir artış görülmektedir. İlkbahar ve yaz aylarında tüketim dalgalı bir seyir izlemektedir. En yüksek tüketim Mayıs 2024 (1.171.520,60 kWh), en düşük tüketim ise Eylül 2023 (457.118,80 kWh) aylarında gerçekleşmiştir. Genel toplam ise 9.361.262,23 kWh olmuştur.

Sözleşme Gücü ve Abone Bilgileri

Tesise ait elektrik abone tarife grubu "Sanayi" şeklindedir. Tablo 2'de Enerji Piyasası Düzenleme Kurumu tarafından belirlenen 1/7/2024'ten itibaren geçerli olan Elektrik Piyasası Tarifeler Listesi, Elektrik Faturalarına Esas Tarife Tablosu (EPDK, 2024) gösterilmektedir. Bu tüketim tesisi sözleşme gücü ise 11.040 kW şeklindedir.

Tablo 2'de farklı dağıtım sistemi kullanıcılar için detaylı olarak 1/7/2024'ten itibaren geçerli olan elektrik tarifeleri tablosu sunulmaktadır. Burada yatırım yapılacak ve tüketim tesisi ile ilişkilendirilecek abone tipi sanayi olduğu için çift terimli sanayi abone grubuna ait tüketim değerleri baz alınmıştır.

Mevzuat Durumu

6446 sayılı Elektrik Piyasası Kanunu (Resmi Gazete, 2024a) (Kanun)'nun 14 üncü maddesi kapsamında (Yönetmelik) 12 Mayıs 2019 tarihli ve 30772 sayılı Resmî Gazete'de (Resmi Gazete, 2024b) yayımlanarak yürürlüğe girmiştir. Çeşitli tarihlerde iyileştirmeler yapılmış ve son olarak 11 Ağustos 2022 Perşembe günü Resmî Gazete Sayı: 31920 (Resmi Gazete, 2024c) ile güncellenmiştir.

09/05/2019 tarihli Cumhurbaşkanı Kararı (Resmi Gazete, 2024d) ile lisanssız elektrik enerjisi tüketim santralleri kurulu güç sınırları tüketim tesisleri sözleşme güçleri ile ilişkili hale getirilmiştir. Mevzuat değişikliği ile Sanayi ve Tarımsal Sulama abone grupları ile ilişkilendirilecek lisanssız güneş enerjisi santrallerinin tüketim sözleşme güçlerinin 2 katı kadar güneş enerjisi santrali kurma imkanı getirilmiştir. Böylece yenilenebilir enerji kaynakları yatırımlarının daha fazla yapılabilmesi adına önü açılmıştır.

Kurulacak lisanssız güneş enerjisi santrallerinde ürettiği elektrik enerjisini kendi ihtiyacını üretmesi kadar amaçlanmaktadır. Lisanssız üreticiler ürettikleri tüketim fazlası yani ihtiyaç fazlası elektrik enerjisini dağıtım şirketleri aracılığı ile satabilmektedirler. Burada EPDK'nın belirlemiş ve ilan etmiş olduğu abone grubu tek terimli tarife birim fiyatı esas alınmaktadır. Böylece ihtiyaç fazlası üretilen elektrik enerjisi devletin alım garantisi

altındadır. Ancak, suiistimalleri önlemek amacı ile abonenin tükettiği enerjiden daha fazlasını satmaması için tüketim miktarı kadar satış durumuna sınırlandırma getirilmiştir. Böylece üretim amaçlı değil de asıl tüketicinin kendi elektrik enerjisini üretmesi amaçlanmaktadır.

Tablo 2. EPDK Elektrik Faturalarına Esas Tarife Tablosu (EPDK, 2024)

EPDK Tarafından Onaylanan ve 1 Temmuz 2024 Tarihi Faaliyet Bazlı Tarifeler						
	1/7/2024	Faaliyet Bazlı Tüketici Tarifeleri (kr/kWh)				
	Dağıtım Sistemi Kullanıcıları	Perakende Tek Zamanlı Enerji Bedeli	Perakende Gündüz Enerji Bedeli	Perakende Puant Enerji Bedeli	Perakende Gece Enerji Bedeli	Dağıtım Bedeli
Dağıtım Sistemi Kullanıcıları	Orta Gerilim					
	Çift Terimli					
	Sanayi	274,2853	278,1487	462,8456	129,0797	60,2673
	Kamu ve Özel Hizmetler Sektörü ile Diğer	306,6641	310,2889	517,9165	145,0883	93,9251
	Mesken	151,8262	155,3345	283,1156	53,1505	93,0324
	Tarımsal Faaliyetler	200,9917	203,5594	350,1303	86,4353	77,3544
	Aydınlatma	311,4197				90,1476
	Tek Terimli					
	Sanayi	284,7019	288,7020	479,8624	134,4163	66,5704
	Kamu ve Özel Hizmetler Sektörü ile Diğer	306,0686	309,6935	517,3211	144,4918	117,1606
	Mesken	145,9788	149,4873	277,2666	47,3019	114,8713
	Tarımsal Faaliyetler	198,2802	200,8482	347,4192	83,7224	96,3144
	Aydınlatma	311,8006				112,4522
	Alçak Gerilim					
	Tek Terimli					
	Sanayi	267,5627	271,3632	453,0836	124,6970	102,9981
	Kamu ve Özel Hizmetler Sektörü ile Diğer (30 kWh/gün ve altı)	246,3661	310,4593	518,0865	145,2583	139,5844
	Kamu ve Özel Hizmetler Sektörü ile Diğer (30 kWh/gün üstü)	306,8350	310,4593	518,0865	145,2583	139,5844
	Mesken (8 kWh/gün ve altı)	49,4065	142,6273	270,4077	40,4418	136,5179
	Mesken (8 kWh/gün üstü)	139,1181	142,6273	270,4077	40,4418	136,5179
	Şehit Aileleri ve Muharip Malul Gaziler	6,1590				82,8453
	Tarımsal Faaliyetler	195,0087	201,7331	344,1485	80,4509	114,6937
	Aydınlatma	314,2697				133,6912
	Genel Aydınlatma	389,0440				133,6912

11 Ağustos 2022 tarihli iyileştirilen yönetmelik (Resmi Gazete, 2024e) ile “Madde 16, (Fıkra 16) 12/5/2019 tarihinden sonra yapılan başvurular neticesinde bağlantı anlaşmasına çağrı mektubu almaya hak kazanan kişilerin, ihtiyacının üzerinde satışa konu edilebilecek üretim miktarı, ilişkili tüketim tesisinin toplam elektrik enerjisi tüketimini geçemez.” denilmektedir. Tüketim miktarı kadar, üretim miktarı satış yapılabilir. Tüketim tesisi sözleşme gücü 11.040 kW şeklindedir. Mevcut mevzuata göre bu abonenin 22.080 kW lisanssız üretim tesisi kurma hakkı vardır. Tabii, kurulumu yapılacak arazinin marjinal tarım arazisi olması, tarıma elverişli olmaması, enerji nakil hattı yakınlığı, bağlı bulunduğu trafo merkezinde yeterli kapasite olup olmaması vb. hususlar büyük önem arz etmektedir. Güneş enerjisi kesikli bir kaynak olup 24 saat esaslı elektrik enerjisi üretememektedir. Bundan ötürü bağlı bulunan trafo merkezinde güneş enerjisi kaynaklı üretim tesisleri için sınırlı kapasite verilebilmektedir.

Santral Lokasyon Bilgileri

Proje; 1.250 kW_e AC, 1,658,80 kW_p DC elektriksel güç değerlerinden meydana gelmektedir. Projenin lokasyonu Konya İli, Ilgın İlçesi, Göstere Mahallesi 202 Ada 3,7 Parseller şeklindedir. Koordinatları; Enlem: 38.2027, Boylam: 31.8380 şeklindedir. Şekil 1’de kurulum yapılacak santral lokasyonuna ait (Google Maps, 2024) görüntü sunulmaktadır. Ilgın ilçesi, Konya iline bağlı olup İç Anadolu Bölgesi içerisinde yer almaktadır. Şekil 2’de ise arazilere ait parcel sorgu uygulama görüntüleri gösterilmektedir. İlgili dağıtım şirketinden bağlantı görüşüne çağrı mektubu izni alındıktan sonra kurulum yapılacak arazi için kurum görüşleri ve imar çalışmaları yürütülmektedir. 1/5000’lik ve 1/1000’lik uygulamalı imar planları yapıldıktan sonra niteliği mevcut durumda “Tarla” olarak geçen araziler yenilenebilir enerji alanı ilan edilmekte ve imar planı değişikliği ile “Arsa” vasfına dönüşmektedir.



Şekil 1. Kurulum Yapılacak Santral Lokasyonu (Google Maps, 2024)



Şekil 2. Arazilere Ait Parsel Sorgu Uygulama Görüntüleri (TKGM, 2024)

Şekil 3’te kurulum yapılacak araziye ait topografik yapı, orta bölüm kuzey-güney yükseklik profili sunulmaktadır. Arazinin rakımı 1176 metre civarlarındadır. Orta kısımdan kuzeyden güneye doğru yükseklik profiline bakıldığında kuzey ile güney arasında çok hafif bir meyil olduğu görülmektedir. Noktasal uzunluk göz önünde bulundurulduğunda neredeyse kuzey-güney yükseklik farkı 0’a yakındır.



Şekil 3. Kurulum Yapılacak Araziye Ait Topografik Yapı, Orta Bölüm Kuzey-Güney Yükseklik Profili (Google Earth, 2024)


Şekil 4'te kurulum yapılacak araziye ait topografik yapı, doğu bölüm kuzey-güney yükseklik profili sunulmaktadır. Arazinin doğu kısmında; kuzeyden güneye doğru yükseklik profiline bakıldığında kuzey ile güney arasında çok hafif bir meyil olduğu görülmektedir. En yüksek kısım ile en düşük kısım arasındaki rakım farkı 4 metre civarındadır. Noktasal uzunluk göz önünde bulundurulduğunda neredeyse kuzey-güney yükseklik farkı 0'a yakındır.



Şekil 4. Kurulum Yapılacak Araziye Ait Topografik Yapı, Doğu Bölüm Kuzey-Güney Yükseklik Profili (Google Earth, 2024)


Şekil 5'te kurulum yapılacak araziye ait topografik yapı, batı bölüm kuzey-güney yükseklik profili gösterilmektedir. Arazinin batı kısmında; kuzeyden güneye doğru yükseklik profiline bakıldığında kuzey ile güney arasında çok hafif

bir meyil olduğu görülmektedir. En yüksek kısım ile en düşük kısım arasındaki rakım farkı 2 metre civarındadır. Noktasal uzunluk göz önünde bulundurulduğunda neredeyse kuzey-güney yükseklik farkı 0'a yakındır.




Şekil 5. Kurulum Yapılacak Araziye Ait Topografik Yapı, Batı Bölüm Kuzey-Güney Yükseklik Profili (Google Earth, 2024)

Şekil 6'da kurulum yapılacak araziye ait topografik yapı, orta bölüm batı-doğu yükseklik profili sunulmaktadır. Arazinin orta kısmından; batıdan doğuya doğru yükseklik profiline bakıldığında batı ile doğu arasında hafif bir meyil olduğu görülmektedir. En yüksek rakım farkı 7 metredir.



Şekil 6. Kurulum Yapılacak Araziye Ait Topografik Yapı, Orta Bölüm Batı-Doğu Yükseklik Profili (Google Earth, 2024)

Şekil 7'de kurulum yapılacak araziye ait topografik yapı, güney bölüm batı-doğu yükseklik profili sunulmuştur. Arazinin bir miktar güney kısmında; batıdan doğuya doğru yükseklik profiline bakıldığında batı ile doğu arasında bir meyil olduğu görülmektedir. En yüksek rakım farkı 19 metredir.



Şekil 7. Kurulum Yapılacak Araziye Ait Topografik Yapı, Güney Bölüm Batı-Doğu Yükseklik Profili (Google Earth, 2024)

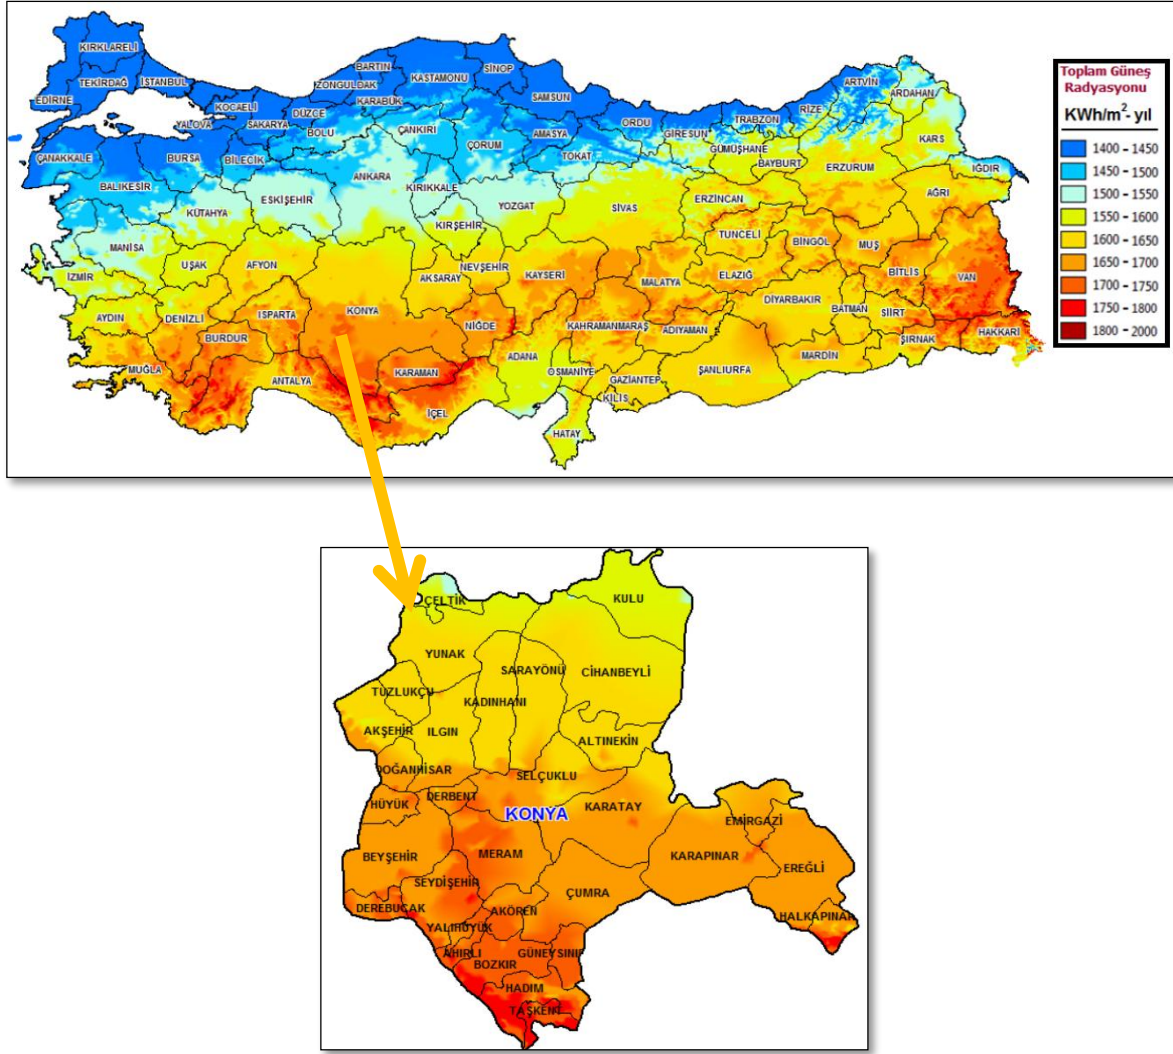
Özetle; arazinin kuzey-güney kısmında yer yer hafif meyiller bulunmaktadır. Doğu ile batı arasında bir miktar meyil farkı olsa da santralin güneye bakıp bir kısmın batı, diğer kısmın doğu çalışması santral için daha verimli olacaktır. Bundan ötürü kuzeyden güneye bir miktar hafif bir arazi tesviyesi yapılırken, doğu-batı kısmında arazi üzerinde tesviye yapmamak daha iyi olacaktır. Arazinin jeopolitik konumu güneş enerjisi santrali kurulumu için oldukça verimli ve uygundur.

Santral Lokasyonu için Güneş Enerjisi Potansiyeli


Ülkemiz güneş enerjisi potansiyeli bakımından Avrupa ülkeleri ortalamasının üzerinde önemli bir potansiyele sahiptir. Günümüzde santral kurulumu için özel bir lokasyon seçimi yeterli olmayıp; arazinin niteliği yani tarıma elverişli olup olmaması, resmi yolu olup olmaması, enerji nakil hattı yakınlığı, ilgili trafo merkezinde lisanssız üretim tesisi için yer olup olmaması vb. hususlar büyük önem arz etmektedir. Şekil 8’de ülkemiz için hazırlanan güneş enerjisi potansiyeli haritası sunulmaktadır. Ayrıca kurulum yapılacak arazinin bulunduğu bölgenin güneş ışınım haritası da sunulmuştur (GEPA, 2024)

MODELLEME VE SİMÜLASYON

Kurulması planlanan santral için PVSyst demo programında simüle edilerek üretim ve performans durumu detaylı olarak analiz edilmiştir. Simülasyon ortamında kurulması planlanan santral analiz edilerek elde edilen veriler ardından finansal analizde kullanılmıştır. Simülasyon programında öncelikle arazinin koordinatları programa girilmektedir. Böylece bölgenin ışınım ve iklim verileri simülasyonda dikkate alınmaktadır. Şekil 9’da kurulum yapılacak lokasyona ait değişen azimut açılarına göre güneş ışınım dağılımı sunulmaktadır.



Şekil 8. Kurulum Yapılacak Lokasyona Ait Güneş Işınım Haritası (GEPA, 2024)



Şekil 9. Kurulum Yapılacak Lokasyona Ait Değişen Azimut Açılarında Güneş Işınım Dağılımı

Şekil 9’da değişen azimut değerlerine göre güneş ışınım dağılımı ifade edilmektedir. Bilindiği üzere güneş ışınım dağılımı mevsimlere göre değişmektedir. 22 Haziran tarihinde azimut açısı değerinin 0 olduğu zaman güneş açısı en yüksek değerdeyken, 22 Aralık tarihinde ise aynı azimut açısı değerinde güneş çok daha alçak yükseklikten geçmekte ve güneş ışınım dağılımı düşmektedir. Global güneş ışınımı azimut açısı değeri 0’dan uzaklaştıkça her mevsimde güneş ışınım dağılımı azalmaktadır.

Projede toplam 2.912 adet 580 Wp gücünde güneş paneli kullanılmaktadır. Toplam DC panel kurulu güç değeri 1.688,96 kWp şeklindedir. AC kurulu güç değeri ise 1.250 kWe olup DC yüklenme oranı % 35,12 değerindedir. DC Yüklenme değeri farklı eksenler için artırılarak daha fazla elektrik enerjisi üretilebilir ve performans artırımı sağlanabilir. Tablo 3’te santrale ait özet bilgiler sunulmaktadır.

Tablo 3. Santralin Özet Bilgileri


Toplam Parsel Alanı	65.045 m ²
Toplam Santral Alanı	20.000 m ²
Santral Adı	İlgin / Konya
Santral Gücü (kWe)	1.250 kWe
PV Gücü (kWp)	1.688,96 kWp
Yüklenme Oranı	% 35,12
Bir Panel Gücü (W)	580 W
Panel Sayısı	2.912 adet
Modül Yüzey Alanı	7.522 m ²
Bir İnvörtör Gücü (kWe)	300 kWe
İnvörtör Sayısı	5 adet

Panel gücü olarak 580 Wp gücünde fotovoltaik panel tercih edilmiştir. 2.912 adet kullanılacaktır. Panel tipi Bifacial Topcon Monokristal ve 16BB n-type şeklindedir. Projede 5 adet 300 kW solar invörtör kullanılmıştır. Smart String Inverter şeklindedir. İnvörtör 800 Vac çıkışlı olup santral trafosunun da bu şekilde imal edilmesi gerekmektedir. İnvörtörlerin verimlilik seviyeleri %99 civarlarındadır.

Güneş panellerinin montajı için arazi tipi uygulamalarda çelik konstrüksiyona ihtiyaç duyulmaktadır. Şekil 10’da çelik konstrüksiyona ait ölçüler ve 3 boyutlu çizim görselleri sunulmuştur.

Şekil 11’de kurulacak santral lokasyonu için aylara göre üretim ve iklim değerlerinin değişimleri detaylı olarak gösterilmektedir. Toplam kWh/m² değeri yıllık 1701,4 elde edilirken, sıcaklık ortalaması 12,3 °C, rüzgar hızı 3,5 m/s, ortalama nem değeri %56,7 olarak bulunmuştur.

2.912 adet 580 Wp gücünde güneş paneli ve 5 adet 300 kW solar invörtör kullanılarak panel – invörtör uygunluk hesapları gerçekleştirilmiştir. 26’lı seriler şeklinde diziler oluşturularak 112 adet dizi kullanılmıştır. Şekil 12 ve 13’te sırasıyla simülasyon tasarım parametreleri ve panel – invörtör uygunluk hesaplarına ait simülasyon ekran görüntüleri sunulmuştur.



Şekil 10. Güneş Paneli Sehpaı İçin Statik Projelendirme

	Global horizontal irradiation kWh/m ² /mth	Horizontal diffuse irradiation kWh/m ² /mth	Temperature °C	Wind Velocity m/s	Linke turbidity [-]	Relative humidity %
January	65.5	27.9	-0.1	3.01	2.755	79.4
February	82.1	38.8	1.8	3.30	3.068	73.3
March	125.1	56.3	6.8	3.69	3.599	59.3
April	161.5	70.1	11.0	3.59	4.037	54.8
May	206.8	76.1	16.1	3.40	3.728	53.3
June	221.8	66.6	20.8	4.10	3.334	44.2
July	227.5	63.5	24.9	4.61	3.272	34.8
August	202.8	60.3	24.6	4.40	3.265	35.6
September	163.8	49.9	19.3	3.50	3.092	42.6
October	112.0	39.1	13.4	3.10	3.135	55.8
November	74.5	35.8	6.6	2.60	2.874	68.3
December	58.1	26.9	1.6	2.71	2.742	79.3
Year	1701.4	611.5	12.3	3.5	3.242	56.7

Global horizontal irradiation year-to-year variability 4.7%

Şekil 11. Aylara Göre Üretim Ve İklim Değerlerinin Değişimleri

Sub-array

Sub-array name and Orientation

Name:

Orient: **Fixed Tilted Plane** Tilt: **25°** Azimuth: **0°**

Pre-sizing Help

No sizing Planned power kWp

Resize ... or available area (modules) m²

Select the PV module

Available Now: Approx. needed modules: **2912**

Since 2023 Manufacturer 2023

Use optimizer

Sizing voltages: V_{mpp} (60°C) **38.0 V**
V_{oc} (-10°C) **55.3 V**

Select the inverter

Available Now: Output voltage 800 V Tri 50Hz 50 Hz 60 Hz

Since 2023

Nb of MPPT inputs: Operating voltage: **550-1500 V** Inverter power used: **1250 kWac**

Use multi-MPPT feature Input maximum voltage: **1500 V** **inverter with 6 MPPT** **No power sharing between MPPTs**

Design the array

Number of modules and strings

Mod. in series: between 15 and 27

Nb. strings: between 83 and 120

Overload loss: **1.4 %**

P_{nom} ratio: **1.35**

Nb. modules: **2912** Area: **7522 m²**

Operating conditions

V_{mpp} (60°C) 987 V
V_{mpp} (20°C) 1125 V
V_{oc} (-10°C) 1437 V

Plane irradiance: **1000 W/m²**

I_{mp} (STC) 1512 A
I_{sc} (STC) 1603 A

I_{sc} (at STC) 1603 A


The inverter power is slightly undersized.

Max. in data STC

Max. operating power (at 1094 W/m² and 50°C): **1708 kW**

Array nom. Power (STC) 1689 kWp

Şekil 12. Simülasyon Tasarım Parametreleri



Şekil 13. Panel – İnvörtör Uygunluk Hesaplamaları

Şekil 14 ve 15'te sırasıyla panel tasarım parametreleri ve invertör tasarım parametreleri ayrı ayrı sunulmuştur. Panel olarak 580 W gücünde panel seçilmiştir. İnvvertör olarak da 300 kW gücünde invertör seçimi yapılmıştır. İnvvertör şebeke gerilimi 800 Vac olarak belirlenmiştir. Bu durum için OG tarafında 800 V primer gerilime sahip özel trafo kullanılması planlanmıştır. 800 Vac seçiminin bazı avantajları bulunmaktadır. Böylece 400 Vac gerilim değerine göre akım değeri daha düşük olduğu için daha ince kesitte kablo seçimi yapılabilmektedir. Akım değeri daha düşük olunca primer teçhizat malzemeleri de buna göre seçilmektedir. Dolayısı ile hem kablo tarafında hem de AG pano şalt malzemelerinde daha uygun maliyetler yakalanabilmektedir. Ancak, santralin iç ihtiyaç elektrik enerjisi için örneğin; kamera, aydınlatma, bekçi evi, koruma ekipmanları gibi kısımlar için ayrı bir iç ihtiyaç trafosu konumlandırılmaktadır.

Model		Manufacturer	
Model	CWT580 - 144TN10 - V	Manufacturer	CW Enerji
File name	CWEnerji_CWT580_144TN10_V.PAN	Data source	Manufacturer 2023
Original PVsyst database		Prod. Since 2023	

Nom. Power (at STC)		Tol. +/-	
Nom. Power	580.0 Wp	0.0	3.0 %
Technology	Si-mono		

Manufacturer specifications or other measurements				
Reference conditions	GRef	1000 W/m ²	TRef	25 °C
Short-circuit current	Isc	14.310 A	Open circuit Voc	50.98 V
Max Power Point	Imp	13.500 A	Vmp	42.95 V
Temperature coefficient	muIsc	5.7 mA/°C	Nb cells in series	72 x 2
	or muIsc	0.040 %/°C		

Internal model result tool				
Operating conditions	GOper	1000 W/m ²	TOper	25 °C
Max Power Point	Pmpp	580.2 W	Temper. coeff.	-0.30 %/°C
Current	Imp	13.63 A	Voltage Vmp	42.6 V
Short-circuit current	Isc	14.31 A	Open circuit Voc	51.0 V
Efficiency	/ Cells area	24.33 %	/ Module area	22.46 %

Model summary	
Main parameters	
R shunt	600 Ω
Rsh(G=0)	2500 Ω
R serie model	0.19 Ω
R serie max.	0.19 Ω
R serie apparent	0.32 Ω
Model parameters	
Gamma	1.009
IoRef	0.02 nA
muVoc	-125 mV/°C
muPMax fixed	-0.30 /°C

Şekil 14. Panel Tasarım Parametreleri

Tablo 4'te simülasyon üretim sonuçları gösterilmektedir. Aylara göre üretim sonuçları detaylı bir şekilde çıkarılmıştır. Bu sonuçlara göre yıllık toplam üretimin 2.798.600 kWh olduğu gözlemlenmektedir. Yaz aylarında daha fazla üretim yapılırken kış aylarında daha az üretim yapılmaktadır. Güneş ışınım değerleri ve güneşlenme süreleri aylara göre farklılık göstermektedir. Ayrıca, Şekil 16'da ışınım değerlerine bağlı olarak üretim koşullarında modül sıcaklık değişimleri de ayrıntılı olarak sunulmaktadır. Işınım değerinin artması ile beraber modülün akım değeri artmakta ve sıcaklık değerleri de artışa geçmektedir. Şekil 17'de santralin aylara göre normalize edilmiş üretim ve kayıp ortalama değerleri de gösterilmektedir. Üretimin en yüksek olduğu aylar Haziran, Temmuz ve Ağustos ayları olmaktadır. Üretim ile birlikte kayıp değerleri de artmaktadır.

Model: SUN2000-330KTL-H1
Manufacturer: Huawei Technologies
File name: Huawei_Sun2000_330KTL_H1.OND
Data source: Datasheet 2023
Original PVsyst database
Prod. Since 2023

Input side (DC PV field)

- Minimum MPP Voltage: 550 V
- Min. Voltage for PNom: 770 V
- Maximum current per MPPT: 65.6 A
- Nominal MPP Voltage: 1080 V
- Maximum MPP Voltage: 1500 V
- Absolute max. PV Voltage: 1500 V
- Power Threshold: 1500 W (Default)

Output side (AC grid)

- Frequency: 50 Hz (checked)
- Grid voltage: 800 V
- Nominal AC Power: 300 kVA
- Maximum AC Power: 330 kVA
- Nominal AC current: 217 A (checked)
- Maximum AC current: 238 A (checked)

Efficiency

- Maximum efficiency: 99.00%
- CEC efficiency: 98.53%
- Efficiency defined for 3 voltages:


Contractual specifications, without real physical meaning: Required

Nominal PV Power: N/A kW
Maximum PV Power: N/A kW
Maximum PV Current: 65 A


Şekil 15. İnvörtör Tasarım Parametreleri

Tablo 4. Simülasyon Üretim Sonuçları

Months	GlobHor (kWh/m ²)	DiffHor (kWh/m ²)	T_Amb (°C)	GlobInc (kWh/m ²)	GlobEff (kWh/m ²)	EArray (kWh)	E_Grid (kWh)	PR (ratio)
January	65,5	27,9	-0,05	97,5	95,6	156.744	154.216	0,936
February	82,1	38,84	1,82	109	106,7	173.023	170.523	0,926
March	125,1	56,31	6,82	148,5	145,5	227.170	223.880	0,892
April	161,5	70,09	11,05	172,6	168,3	258.316	254.753	0,874
May	206,8	76,09	16,13	206,5	201,4	302.993	298.790	0,857
June	221,8	66,64	20,8	212	207,1	305.130	300.949	0,84
July	227,5	63,47	23,76	221,7	216,3	313.078	308.763	0,825
August	202,8	60,33	23,1	211,4	206,7	297.983	293.987	0,823
September	163,8	49,94	18,41	191,6	187,4	277.345	273.799	0,846
October	112	39,14	13,42	143,2	143,2	218.652	215.541	0,874
November	74,5	35,83	6,14	106,8	106,8	166.268	163.831	0,913
December	58,1	26,94	1,64	88,5	86,6	141.907	139.569	0,934
Year	1701,4	611,53	12,32	1911,7	1868,9	2.838.609	2.798.600	0,867



Şekil 16. Işınım Değerlerine Bağlı Olarak Üretim Koşullarında Modül Sıcaklık Değişimleri



Şekil 17. Santralin Aylara Göre Normalize Edilmiş Üretim Ve Kayıp Ortalama Değerleri

Tablo 5'te santralin ekonomik analizi detaylı olarak sunulmaktadır. Öncelikle santrale ait özet bilgiler sunulmuş ardından santralin lokasyonu, yüzölçümü, ortalama yıllık üretim tahmini, yıllık tüketim tahmini, elektrik birim fiyatı, dağıtım bedeli değerleri üzerinden yıllık net faydalanma tutarı belirlenmektedir. Böyle bir santral için yatırım maliyeti hesaplanarak yapılacak yatırımın amorti süresi hesaplanmaktadır.

Tablo 5. Santralin Ekonomik Analizi

AC / Elektriksel Gücü	1.250 kWe
DC / Panel Gücü	1.688,96 kWp
Ada	202
Parsel	3 ve 7
Lokasyon	Konya / Ilgın / Göstere
Yüzölçümü (Parsel)	65.045 m ²
Yüzölçümü (Santral Sahası)	20.000 m ²
Mülkiyet	Var
Ortalama Yıllık Üretim Tahmini (kWh/Yıl)	2.798.600 kWh
Elektrik Birim Fiyatı (TL/kWh) (Sanayi)	2,74 TL/kWh
Dağıtım Bedeli (TL/kWh) (GES Veriş)	0,369 TL/kWh
Veriş için Net Elektrik Birim Fiyatı (TL/kWh) (Sanayi)	2,371 TL/kWh
Yıllık Net Faydalanma, Vergi Hariç (TL)	6.635.480 TL/Yıl
Yıllık Gelir (USD) (1 USD=33 TL)	201.075 USD/Yıl
GES Birim Maliyeti (USD/MWp)	570.000 USD/MWp
1.688,96 kWp için GES Maliyeti (USD)	962.707,20 USD
Amorti Süresi (Yıl)	4,79 Yıl

Böyle bir yatırım ile kurulacak santral için Ortalama Yıllık Üretim Tahmini 2.798.600 kWh olarak bulunmuş olup Yıllık Net Faydalanma, Vergi Hariç (TL) tutarı 6.635.480 TL olarak elde edilmiştir. GES Birim Maliyeti 570.000 USD/MWp olduğu varsayılır ise 1.688,96 kWp için GES Maliyeti 962.707,20 USD olarak bulunur. Böylece elde edilen sonuçlara göre amorti süresi 4,79 Yıl olarak hesaplanmaktadır. Bu çalışma farklı lokasyonlar için de uyarlanabilir ve değerlendirilebilir. Santral kurulumları yapılmadan önce mutlaka bu tarz çalışmaların yapılması büyük önem arz etmektedir.

DEĞERLENDİRME VE SONUÇ

Öncelikle tüketim tesisinin aylara göre tükettiği elektrik enerjisi, ihtiyacı belirlenerek bu ihtiyacı karşılamak için kurulması planlanan santral lokasyonu için ayrıntılı değerlendirmeler sunulmuştur. Arazi seçimleri her zaman istenildiği şekilde gerçekleşmemektedir. En önemli nedeni, bağlantı yapılacak ilgili trafo merkezinde lisanssız üretim için ayrılmış bir kapasite olması gerekmektedir. Kapasiteler de sınırlı durumdadır. Ardından enerji nakil hattı bağlantısı yapılabilecek lokasyona yakın, tarıma elverişli olmayan bir arazinin temin edilmesi gelmektedir. Bu araziye ait resmi bir kadastro yolunun bulunması gerekmektedir. Ardından 1/5000 ve 1/1000 ölçekli imar planlarının yapılması, kurum görüşlerinin alınması ve ruhsatlandırma süreçleri bulunmaktadır. Bundan ötürü her zaman ihtiyacın karşılanması mümkün olmayabilmektedir.

Yapılan modelleme ve simülasyon sonuçları neticesinde belirlenen lokasyon için üretilebilecek elektrik enerjisi miktarının aylara göre değişimleri detaylı olarak analiz edilmiştir. Elde edilen sonuçlar ile santralin ekonomik analizi gerçekleştirilmiş ve sonuçlar sağlanmıştır.

KAYNAKLAR

Bayrak, M. ve Aslan, E. (2023). Türkiye'deki Lisanssız Güneş Enerjisi Santrallerinde Üretim Kayıplarının Belirlenmesi. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 26(1), 233-240. <https://doi.org/10.17780/ksujes.1210936>.

Dinçer, F. ve Karadağ, F. (2022). Tekstil Fabrikalarında Öz Tüketim Modeli Güneş Enerjisi Santralinde Enerji Kalitesi Analizi. *Journal of the Institute of Science and Technology, Iğdir University*, 12(2), s. 704-714. <https://doi.org/10.21597/jist.985473>.

Dincer, F. ve Ozer, E. (2023). Assessing the Potential of a Rooftop Grid-Connected Photovoltaic System for Gaziantep Islamic Science and Technology University/Turkey. *Jordan Journal of Electrical Engineering*, 9(2), 149-165. <https://doi.org/10.5455/jjee.204-1670146602>.

EPDK. (2024). Enerji Piyasası Düzenleme Kurumu, Elektrik Faturalarına Esas Tarife Çizelgelari, <https://www.epdk.gov.tr/Detay/Icerik/3-1327/elektrik-faturalarina-esas-tarife-Çizelgelari>, Erişim Tarihi: 24 Temmuz 2024.

GEPA. (2024). Güneş Enerjisi Potansiyel Atlası, (GEPA), <https://gepa.enerji.gov.tr/>, Erişim Tarihi: 17 Temmuz 2024.

Google Earth. (2024). <https://earth.google.com/>, Erişim Tarihi: 17 Temmuz 2024.

Google Maps. (2024). <https://www.google.com/maps>, Erişim Tarihi: 21 Temmuz 2024.

Kılıç, M.Y. ve Kurtaran, M. (2024). Sürdürülebilir Enerji Üretimi İçin Fotovoltaik Sistem Tasarımı ve PVsyst Programı İle Simülasyonu: Bursa İli Örneği. *Türk Tarım Ve Doğa Bilimleri Dergisi*, 11(1), 239-248. <https://doi.org/10.30910/turkjans.1333711>.

Öztürk, M. ve Kayabaşı, R. (2023). Güneş enerjisinin İç Anadolu bölgesinde kullanılabilirliği ve sistem analizi. *NÖHÜ Müh. Bilim. Derg.*, 12(4), 1351-1359. <https://doi.org/10.28948/ngumuh.1310627>.

Resmi Gazete. (2024a). Elektrik Piyasası Kanunu, <https://www.mevzuat.gov.tr/mevzuatmetin/1.5.6446.pdf>, Erişim Tarihi: 24 Temmuz 2024.

Resmi Gazete. (2024b). 12 Mayıs 2019 Tarihli ve 30772 Sayılı Resmî Gazete, <https://www.resmigazete.gov.tr/12.05.2019>, Erişim Tarihi: 24 Temmuz 2024.

Resmi Gazete. (2024c). 11 Ağustos 2022 Tarihli ve 31920 Sayılı Resmî Gazete, <https://www.resmigazete.gov.tr/11.08.2022>, Erişim Tarihi: 24 Temmuz 2024.

Resmi Gazete. (2024d). 09/05/2019 tarihli Cumhurbaşkanı Kararı, <https://www.resmigazete.gov.tr/eskiler/2019/05/20190510-10.pdf>, Erişim Tarihi: 24 Temmuz 2024.

Resmi Gazete. (2024e). 11 Ağustos 2022 Tarihli ve 31920 Sayılı Resmî Gazete, <https://www.resmigazete.gov.tr/11.08.2022>, Erişim Tarihi: 24 Temmuz 2024.

Şahin, Z.R., Dinçer, F., Yılmaz, A.S. (2022). 4 Kişilik Bir Ailenin Elektrik Enerjisi İhtiyacı İçin Şebeke Bağlantılı Güneş Enerjisi Santrali Tasarımı ve Simülasyonu. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 25, 46-56. <https://doi.org/10.17780/ksujes.1163049>.

TKGM. (2024). Parsel Sorgu Uygulaması, <https://parselsorgu.tkgm.gov.tr/>, Erişim Tarihi: 20 Temmuz 2024.

Yiğit, F. (2023). Şebekeye bağlı 1 MW güneş enerji santralinin PVsyst ile simülasyonu ve performans parametrelerinin değerlendirilmesi. *Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik ve Elektronik Anabilim Dalı Yüksek Lisans Tezi*, Konya.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 29.07.2024
Kabul Tarihi : 08.10.2024

Received Date : 29.07.2024
Accepted Date : 08.10.2024

BİTKİ ÖRTÜSÜ İNDEKSLERİ KULLANILARAK BİTKİ ÖRTÜSÜ YOĞUNLUKLARININ ARAŞTIRILMASI: KARATEPE-ASLANTAŞ MİLLİ PARKI ÖRNEĞİ

INVESTIGATION DENSITIES OF VEGETATION USING VEGETATION INDICES: THE CASE OF KARATEPE-ASLANTAS NATIONAL PARK

Sevim Yasemin OTURANÇ¹ (ORCID: 0000-0002-8140-1265)

¹ Çukurova Üniversitesi, Jeoloji Mühendisliği, Adana, Türkiye

*Sorumlu Yazar / Corresponding Author: Sevim Yasemin OTURANÇ, s.y.cicekli@gmail.com

ÖZET

Karatepe- Aslantaş milli parkı, bölgede bulunan Geç Hititler 'den kalan tarihi ve arkeolojik eserler ve sahip olduğu meşe türleri, kserofitik çalı ve orman toplulukları ve maki örtüsü açısından önemli bir konumda olup, milli park ve çevresinde bitki örtüsünün düzenli gözlemlenmesi gerekmektedir. Bu çalışmanın temel amacı Karatepe Aslantaş Milli Parkı çevresinde bitki örtüsü yoğunluklarını Sentinel-2B uydu görüntülerine bant oranlama teknikleri uygulayarak belirlemektir. Bu çalışmada Karatepe Aslantaş Milli Parkı ve çevresine ait 10 Mart 2024 tarihinde alınan Sentinel-2B görüntüsüne Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), Yeşil Bant Normalize Edilmiş Fark Bitki Örtüsü İndeksi (GNDVI), Dönüştürülmüş Normalize Fark Bitki Örtüsü İndeksi (TNDVI) ve Toprak Ayarlı Bitki Örtüsü İndeksi (SAVI) bant oranlama teknikleri uygulanarak bitki örtüsü dağılımı ve yoğunlukları belirlenmiştir. NDVI %89, GNDVI %82, TNDVI %86, SAVI %88 doğruluk sağlamıştır. Tüm yöntemlerin beklenen doğruluğu karşılarken, en yüksek doğruluğu NDVI yönteminin sağladığı ve tüm yöntemlerle oluşturulmuş oluşturulmuş bitki örtüsü yoğunluk sınıflarının birbiri ile uyumlu olduğu tespit edilmiştir.

Anahtar Kelimeler: Normalize edilmiş fark bitki örtüsü indeksi, yeşil bant normalize edilmiş fark bitki örtüsü indeksi, dönüştürülmüş normalize fark bitki örtüsü indeksi, toprak ayarlı bitki örtüsü indeksi

ABSTRACT

Karatepe-Aslantas National Park is in an important position in terms of historical and archaeological artifacts from the Late Hittites in the region and its oak species, xerophytic shrub and forest communities and maquis cover, so regular observation of land use and land cover is necessary. The main purpose of this study is to determine densities of vegetation around Karatepe Aslantaş National Park by using band ratio techniques on Sentinel-2B satellite images. In this study, Normalized Difference Vegetation Index (NDVI), Green Band Normalized Difference Vegetation Index (GNDVI), Transformed Normalized Difference Vegetation Index (TNDVI) and Soil Adjusted Vegetation Index (SAVI) were applied to the Sentinel-2B image of Karatepe Aslantaş National Park taken on March 10, 2024. to determine vegetation distribution and densities. NDVI method provided an accuracy of 89%, GNDVI method provided an accuracy of 82%, TNDVI method provided an accuracy of 86%, and SAVI method provided an accuracy of 88%. It has been determined that all methods provided the expected accuracy, NDVI method provided the best accuracy and vegetation densities classes created by these methods are compatible with each other.

Keywords: The normalized difference vegetation index, the green normalized difference vegetation index, the transformed normalized difference vegetation index, the soil-adjusted vegetation index

GİRİŞ

Uydu teknolojilerinde meydana gelen yenilikler ve gelişmeler ile birlikte orman alanlarının gözlemlenmesinde ve değişim analizinde uzaktan algılama tekniklerinin kullanımını mümkün olmuştur. Uzaktan algılama, teknolojileri arazi örtüsünün araştırılması, su alanlarının yönetimi, orman çalışmaları ve deformasyonların izlenmesinde en çok tercih edilen yöntemlerden biridir.

Karatepe ve çevresindeki alan 1958'de milli park ilan edilmiştir. Akdeniz Bölgesi'nde Osmaniye ili Kadiri ilçesi sınırları içinde yer almaktadır. Karatepe tepesinden adını almakta olup, alan Ceyhan nehri ile ikiye bölünmektedir (Artar, 2008). Karatepe- Aslantaş, içerisinde 9000 yıllık Geç Hititler 'den kalan tarihi ve arkeolojik eserleri barındırmaktadır (Altan vd., 2005). Bölgede meşe türleri, kserofitik çalı ve orman toplulukları ve sıklıkla tarım alanları ile parçalanmış maki örtüsü yaygındır (Yılmaz vd., 2005). Karatepe- Aslantaş Milli Park ve çevresinin Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), Yeşil Bant Normalize Edilmiş Fark Bitki Örtüsü İndeksi (GNDVI), Dönüştürülmüş Normalize Fark Bitki Örtüsü İndeksi (TNDVI) ve Toprak Ayarlı Bitki Örtüsü İndeksi (SAVI) bant oranlama teknikleri kullanılarak bitki örtüsü haritalarının oluşturulması bu çalışmanın konusunu oluşturmaktadır.

Literatürde bitki örtüsü bant oranlama teknikleri üzerine çalışmalar bulunmaktadır. Essaadia vd. (2022) Sentinel-2A, ASTER ve Landsat uydu görüntülerine NDVI bant oranlama tekniği ve diğer bitki örtüsü indekslerini uygulamış, iklim ve çevresel ortam arasındaki uzaysal-zamansal korelasyonu tespit etmiş, NDVI tekniğinin kuraklık çalışmalarında verimli sonuçlar verdiği tespit edilmiştir (Essaadia vd., 2022). Muniyati (2022), Sentinel-2 uydu görüntülerine NDVI, Zenginleştirilmiş Bitki Örtüsü İndeksi (EVI), SAVI, Normalize Edilmiş Fark Su İndeksi (NDWI), Normalize Edilmiş Fark Kırmızı-Kenar İndeksi (NDRE) gibi birçok bant oranlama tekniğini mera alanlarının tespiti için uygulamış, mera alanlarında en iyi sonucu EVI ve SAVI yönteminin sağladığını tespit etmiştir (Muniyati, 2022). Isip vd. (2020) bitki hastalıklarını araştırmak için Sentinel-2 görüntülerine ISODATA kontrolsüz sınıflama tekniği, NDVI, GNDVI, Pigment Spesifik Basit Oran (Klorofil A) İndeksi (PSSra), yöntemlerini uygulamıştır. En yüksek doğruluğu %83.33 ile GNDVI tekniği sağlamıştır (Isip vd., 2020). Kuc ve Chormański (2019), şehir haritaları oluşturmak için Warsaw bölgesine ait Sentinel-2 görüntüleri kullanarak Normalize Fark Bina İndeksi (NDBI) ve NDVI yöntemi kullanmıştır (Kuc ve Chormański, 2019). Özdarıcı Ok (2014) GeoEye uydu görüntülerini kullanarak NDVI yöntemi ile Mersin bölgesindeki ağaçları %65-%90 doğrulukla tespit etmiştir (Özdarıcı Ok, 2014). Gündoğdu (2018) buğday ekili alanlardaki zamansal değişimini Landsat-8 uydu görüntülerine NDVI tekniği uygulayarak tespit etmiştir (Gündoğdu, 2018). Vani ve Venkata (2017) yarı kurak alanlara ait Landsat uydu görüntülerine NDVI ve SAVI yöntemlerini uygulamış ve doğruluğunu karşılaştırmıştır. SAVI yönteminin en uygun toprak faktörü seçildiğinde, yarı kurak alanlarda en doğru sonucu verdiğini tespit etmiştir (Vani ve Venkata, 2017). Ustuner vd. (2014) RapidEye uydu görüntülerine NDVI, GNDVI, NDRE bant oranlama teknikleri ve Destek Vektör Makineleri (SVM) görüntü sınıflama yöntemi uygulamış ve ürün tipi sınıflaması yapmıştır, çalışma sonucunda NDRE yönteminin görüntü sınıflandırma doğruluğu konusunda diğer indekslere göre yüksek olduğu ve ürün sınıflandırmasında SVM yönteminin başarılı olduğu tespit edilmiştir (Ustuner vd. 2014). Kaya ve Polat (2021a) buğday rekoltesi için çiçeklenme öncesi, çiçeklenme evresi ve çiçeklenme sonrası algılanmış Sentinel-2 ve Landsat-8 uydu görüntülerine NDVI, GNDVI ve Değiştirilmiş Toprak Ayarlı Bitki Örtüsü İndeksi (MSAVI) bant oranlama teknikleri uygulamış, en yüksek doğruluğu çiçeklenme evresinde %82 ile NDVI tekniği sağlamıştır (Kaya ve Polat, 2021a). Kaya ve Polat (2021b) Sentinel-2 ve Landsat-8 uydu görüntülerine NDVI, GNDVI, SAVI ve MSAVI bant oranlama tekniklerini uygulayarak, sulu tarım ve kuru tarım alanlarındaki doğruluklarını karşılaştırmıştır. Sulu tarım alanlarında çiçeklenme öncesi %99 ile NDVI, çiçeklenme sonrası GNDVI en yüksek doğruluğu sağlarken, kuru tarım alanlarında SAVI çiçeklenme sonrası en yüksek doğruluğu sağlamıştır (Kaya ve Polat, 2021b). Türk ve Balçık (2023), Sentinel-2 görüntülerine RO (Rastgele Orman) sınıflandırma tekniği, NDVI, GNDVI ve NDRE bant oranlama teknikleri uygulamış, hata matrisleri oluşturmuştur. RO, %98.98 genel doğruluk sağlamıştır. NDVI tekniği %98.71, NDRE %98.34 ile en yüksek doğruluğu sağlayan bant oranlama teknikleri olmuştur (Türk ve Balçık, 2023).


Sentinel-2B görüntüleri için NDVI, GNDVI gibi bitki örtüsü indeksleri kullanımı birçok çalışmada incelenmiştir. Bitki örtüsü yoğunluklarının araştırılması için Sentinel-2B görüntüleri için bitki örtüsü indekslerinin potansiyel kullanımının araştırılması gerekmektedir. Bu çalışmada Sentinel-2B uydu görüntüleri için dört farklı bitki örtüsü indeksinin bitki örtüsü yoğunluğu sınıflandırmasında kullanım potansiyeli ve her bir indeksin sınıflandırma doğruluğuna etkisi araştırılmıştır. 10 Mart 2024 tarihinde algılanmış Sentinel-2B uydu görüntülerine NDVI, GNDVI, TNDVI ve SAVI bant oranlama yöntemleri uygulanmış, Otsu eşik belirleme yöntemi ile bitki örtüsü yoğunluk sınıfları oluşturulmuş ve her yöntem için doğruluk analizi yapılarak sonuçlar incelenmiştir.

MATERYAL VE METOT

Sentinel-2B uydu görüntülerine NDVI, GNDVI, TNDVI ve SAVI bant oranlama teknikleri uygulanmış ve bitki örtüsü yoğunluk haritaları oluşturulmuştur.

Çalışma Alanı

Karatepe-Aslantaş Milli parkı ve çevresi çalışma alanı olarak seçilmiştir. Bölge, Osmaniye ili Kadırlı ilçesinde yer almakta olup, Ceyhan Irmağı çalışma alanının içinden geçmektedir (Osmaniye İl Kültür ve Turizm Müdürlüğü, 2024). Milli park içerisinde kızılçam ormanları, meşelikler ve makilikler bulunmaktadır. Ayrıca bölgeye özgü flora ve fauna türleri yaşamaktadır (Şekil 1).



Şekil 1. Çalışma Alanı (ESA, 2024; T.C. Milli Savunma Bakanlığı Harita Genel Müdürlüğü, 2024)

Materyal

Bu çalışmada 10 Mart 2024 tarihinde algılanmış Sentinel-2B uydu görüntüsü kullanılmıştır (ESA, 2024). Sentinel-2B uydusunun bantlarının özellikleri Tablo1.'de yer almaktadır.

Tablo 1. Sentinel-2B Bantları ve Özellikleri

Sentinel-2 Uydu Bantları	Özellikler	
	Dalgaboyu (micrometre)	Çözünürlük (m)
Bant-1 Kıyı Aerosol	0,442	60
Bant-2 Mavi	0,492	10
Bant-3 Yeşil	0,559	10
Bant-4 Kırmızı	0,665	10
Bant-5 Bitki Örtüsü Kırmızı Kenar	0,703	20
Bant-6 Bitki Örtüsü Kırmızı Kenar	0,739	20
Bant-7 Bitki Örtüsü Kırmızı Kenar	0,779	20
Bant-8 NIR	0,833	10
Bant-8A Bitki Örtüsü Kırmızı Kenar	0,864	20
Bant-9 Su Buharı	0,943	60
Bant-10 SWIR Cirrus	1,376	60
Bant-11 SWIR	1,610	20
Bant-12 SWIR	2,185	20

Yöntem

Normalize Edilmiş Fark Bitki Örtüsü İndeksi (NDVI), bitki örtüsünü tespit etmek için NIR ve kırmızı bantları kullanır (Rouse vd., 1974; Pettorelli vd., 2011). Formülü aşağıdaki gibidir (1).

$$NDVI = \frac{BANT_{NIR} - BANT_{KIRMIZI}}{BANT_{NIR} + BANT_{KIRMIZI}} \quad (1)$$

Yeşil Bant Normalize Edilmiş Fark Bitki Örtüsü İndeksi (GNDVI) NIR ve yeşil bantları kullanarak bitki örtüsünü tespit eden bir yöntemdir (Gitelson vd., 1996). Klorofil konsantrasyonuna NDVI yöntemine göre daha duyarlıdır (Popescu vd., 2020). Formülü aşağıdaki gibidir (2).

$$GNDVI = \frac{BANT_{NIR} - BANT_{YEŞİL}}{BANT_{NIR} + BANT_{YEŞİL}} \quad (2)$$

Dönüştürülmüş Normalize Fark Bitki Örtüsü İndeksi (TNDVI), bitkilerdeki yeşil biyokütle miktarını ve klorofil kompozisyonunu ölçen bir indekstir, pozitif değer elde edebilmek için NDVI değerine 0.5 eklenerek ve karekökü hesaplanır (Tucker, 1979). Formülü aşağıdaki gibidir (3).

$$TNDVI = \sqrt{NDVI + 0.5} \quad (3)$$


Toprak Ayarlı Bitki Örtüsü İndeksi (SAVI), Bitki örtüsü düşük olduğu arazi örtüsü için toprak parlaklığının etkisini azaltmak amacıyla kullanılan bir yöntem olup formülü (4) aşağıdaki gibidir (Huete, 1988). L toprak faktörü, bitki yoğunluğuna bağlı 0-1 arasında değişen bir değerdir. Bu çalışmada 0.5 olarak seçilmiştir.

$$SAVI = \frac{BANT_{NIR} - BANT_{KIRMIZI}}{BANT_{NIR} + BANT_{KIRMIZI} + L} * (1 + L) \quad (4)$$

Otsu yöntemi, bir görüntüde eşik değerlerini otomatik olarak belirlemek için gri seviye görüntüler üzerinde sınıf içi varyansı maksimize eder (Otsu, 1979). Otsu yöntemi, sınıf içi veya sınıf arası varyans değerini hesaplayarak sınıfların birbirinden ayrılması işlemi gerçekleştirilirken en uygun eşik değerini belirleyerek çalışır (Kaygısız ve Çakır, 2020). Çalışmada bitki örtüsü yoğunluklarını belirlemek için eşik değerlerinin tespit edilmesinde kullanılmıştır.


BULGULAR

Sentinel-2B görüntüleri, ESA web sayfasından temin edilmiştir (ESA, 2024). Kullanılan Sentinel-2B görüntüleri, L1C serisidir ve atmosferik düzeltmeleri yapılmış halde sunulmaktadır. Bu nedenle ön işleme aşamasında yalnızca görüntüler kesilmiştir. (Şekil 2).



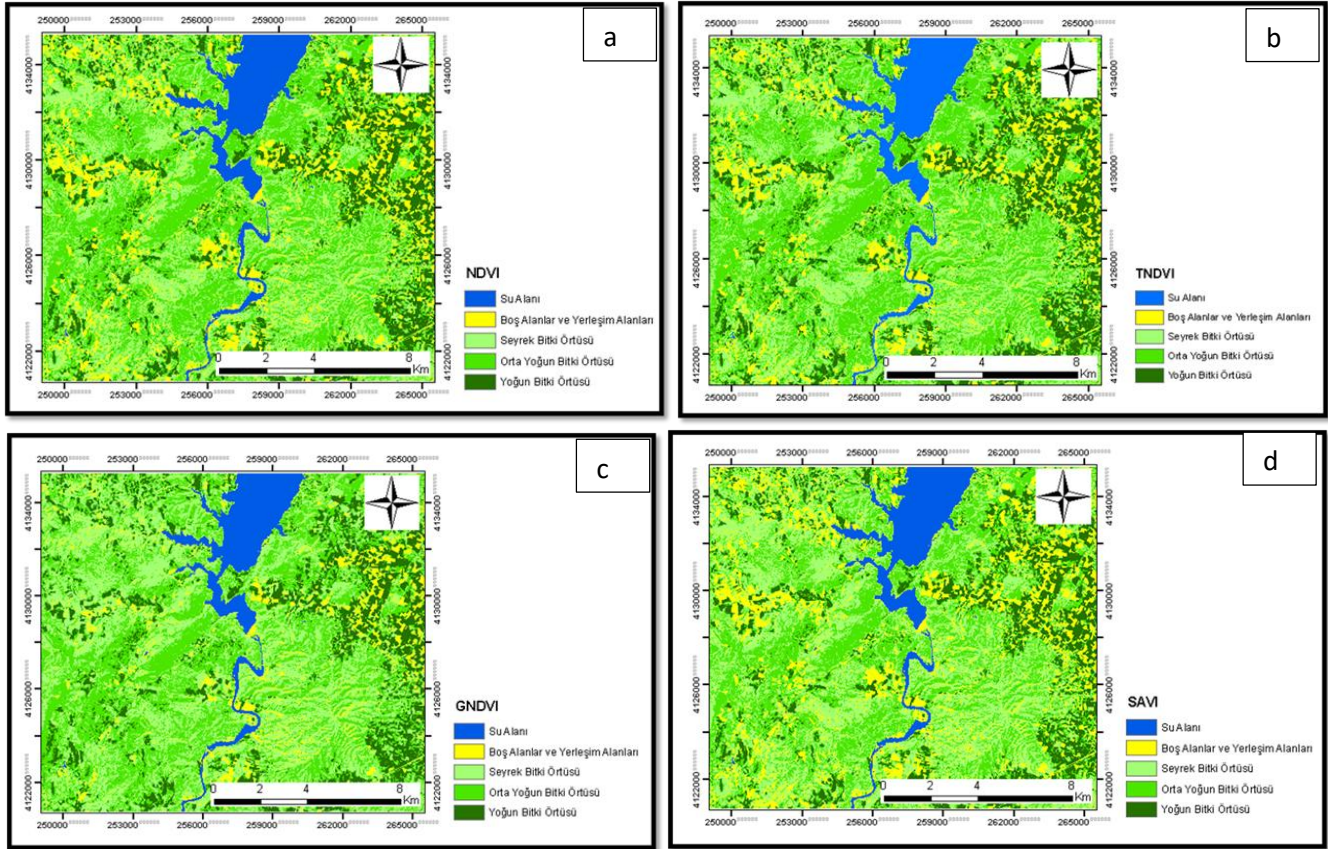
Şekil 2. İş Akış Diyagramı

10 metre çözünürlüğe sahip kırmızı ve NIR bantları kullanılarak NDVI, TNDVI ve SAVI bant oranlama tekniği, 10 metre çözünürlüğe sahip yeşil ve NIR bantları kullanılarak GNDVI bant oranlama tekniği uygulanmıştır (Şekil 3.).



Şekil 3. a. NDVI b. TNDVI c. GNDVI d. SAVI Görüntüleri

NDVI için Otsu yöntemi ile eşik değerleri, 0.0291, 0.1861, 0.2964, 0.4367, GNDVI için Otsu yöntemi ile belirlenen eşik değerleri, 0.0161, 0.1880, 0.2727, 0.3859, TNDVI için Otsu yöntemi ile belirlenen eşik değerleri, 0.6309, 0.7503, 0.8483, 0.9523, SAVI için Otsu yöntemi ile belirlenen eşik değerleri, 0.0416, 0.2658, 0.4233, 0.6236 olarak tespit edilmiştir ve bitki örtüsü yoğunluk haritaları oluşturulmuştur (Şekil 4).



Şekil 4. Otsu Yöntemi ile Oluşturulmuş a. NDVI b. TNDVI c. GNDVI d. SAVI Yoğunluk Haritaları

Bant Oranlama teknikleri ile elde edilen bitki örtüsü yoğunluk sınıflarının piksel sayısı ve alanları Tablo 2.'de sunulmuştur.

Tablo 2. Oranlama Teknikleri ile Elde Edilen Bitki Örtüsü Yoğunluk Sınıflarının Piksel Sayısı ve Alanları

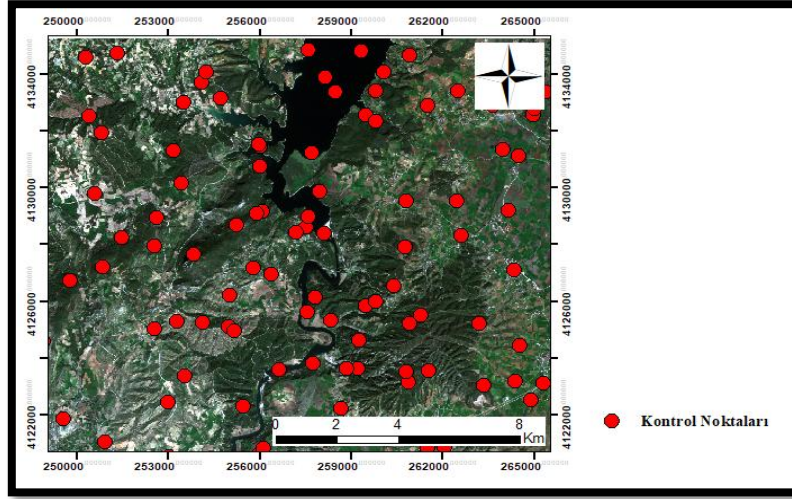
Yöntem	Su Alanı		Boş Alanlar ve Yerleşim Alanları		Seyrek Bitki Örtüsü		Orta Yoğun Bitki Örtüsü		Yoğun Bitki Örtüsü	
	Piksel Sayısı	Alan (km ²)	Piksel Sayısı	Alan (km ²)	Piksel Sayısı	Alan (km ²)	Piksel Sayısı	Alan (km ²)	Piksel Sayısı	Alan (km ²)
NDVI	152281	15,2	366367	36,6	794648	79,4	939551	93,9	403073	40,3
GNDVI	153241	15,3	181799	18,1	969696	96,9	941780	94,1	403676	40,3
TNDVI	152801	15,2	312298	31,2	802656	80,2	958999	95,5	423166	42,3
SAVI	153575	15,3	397947	39,79	953976	95,3	778728	77,8	365792	36,5

TARTIŞMA

100 adet kontrol noktası ile doğruluk analizi yapılmıştır. Kontrol noktalarının rastgele seçilmiştir. Arazi üzerinde her yoğunluk derecesini temsil edecek yeterli sayıda kontrol noktası bulunmasına dikkat edilmiştir (Şekil 5). Kontrol noktaları kullanılarak Şekil 6'da sunulan hata matrisleri oluşturulmuş ve yapılan doğruluk analizleri Tablo 3 ve Tablo 4'te sunulmuştur.

Tüm bant oranlama teknikleri beklenen doğruluğu sağlamıştır. GNDVI yöntemi, seyrek bitki örtüsü, boş alanlar ve yerleşim alanları sınıfında diğer tekniklerden göre daha küçük bir alan tespit etmiştir. Bunun nedeni GNDVI yönteminin klorofille olan duyarlılığıdır. SAVI yöntemi toprak faktörüne bağlı olduğu için, yoğun bitki örtüsü alanlarında, diğer tekniklerden göre daha küçük bir alan tespit etmiştir.

Su alanları, boş alanlar ve yerleşim alanları, seyrek bitki örtüsü, orta yoğun bitki örtüsü ve yoğun bitki örtüsü sınıfları için ortalama NDVI, TNDVI, GNDVI, SAVI değerleri grafiği Şekil 7.'deki gibidir. Değerler birbiri ile uyumludur.



Şekil 5. Kontrol Noktalarının Çalışma Alanına Dağılımı

		NDVI					
		Yerleşim ve Boş Alanlar	Orta Yoğun Bitki Örtüsü	Seyrek Bitki Örtüsü	Su Alanı	Yoğun Bitki Örtüsü	toplam
GERÇEK	Yerleşim ve Boş Alanlar	11	0	1	0	0	12
	Orta Yoğun Bitki Örtüsü	1	32	6	0	1	40
	Seyrek Bitki Örtüsü	0	2	21	0	0	23
	Su Alanı	0	0	0	7	0	7
	Yoğun Bitki Örtüsü	0	0	0	0	18	18
	Toplam	12	34	28	7	19	100

		TNDVI					
		Yerleşim ve Boş Alanlar	Orta Yoğun Bitki Örtüsü	Seyrek Bitki Örtüsü	Su Alanı	Yoğun Bitki Örtüsü	toplam
GERÇEK	Yerleşim ve Boş Alanlar	11	0	1	0	0	12
	Orta Yoğun Bitki Örtüsü	1	29	8	0	2	40
	Seyrek Bitki Örtüsü	0	2	21	0	0	23
	Su Alanı	0	0	0	7	0	7
	Yoğun Bitki Örtüsü	0	0	0	0	18	18
	Toplam	12	31	30	7	20	100

		GNDVI					
		Yerleşim ve Boş Alanlar	Orta Yoğun Bitki Örtüsü	Seyrek Bitki Örtüsü	Su Alanı	Yoğun Bitki Örtüsü	toplam
GERÇEK	Yerleşim ve Boş Alanlar	7	0	5	0	0	12
	Orta Yoğun Bitki Örtüsü	1	29	8	0	2	40
	Seyrek Bitki Örtüsü	0	2	21	0	0	23
	Su Alanı	0	0	0	7	0	7
	Yoğun Bitki Örtüsü	0	0	0	0	18	18
	Toplam	8	31	34	7	20	100

		SAVI					
		Yerleşim ve Boş Alanlar	Orta Yoğun Bitki Örtüsü	Seyrek Bitki Örtüsü	Su Alanı	Yoğun Bitki Örtüsü	toplam
GERÇEK	Yerleşim ve Boş Alanlar	11	0	1	0	0	12
	Orta Yoğun Bitki Örtüsü	1	31	8	0	0	40
	Seyrek Bitki Örtüsü	0	1	22	0	0	23
	Su Alanı	0	0	0	7	0	7
	Yoğun Bitki Örtüsü	0	1	0	0	17	18
	Toplam	12	31	30	7	20	100

Şekil 6. Hata Matrisleri

Tablo 3. Genel Doğruluklar ve Kappa Değerleri


Yöntem	Genel doğruluk	Kappa değeri
NDVI	%89	0,853
GNDVI	%82	0,759
TNDVI	%86	0,814
SAVI	%88	0,839

Tablo 4. Bant Oranlama Teknikleri ile Elde Bitki Örtüsü Yoğunluklarının Doğrulukları

Yöntem	Su Alanı		Boş Alanlar ve Yerleşim Alanları		Seyrek Bitki Örtüsü		Orta Yoğun Bitki Örtüsü		Yoğun Bitki Örtüsü	
	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu	Kullanıcı Doğruluğu	Üretici Doğruluğu
NDVI	100	100	91,6	91,6	75	91,3	94,1	80	94,7	100
GNDVI	100	100	87,5	58,3	61,7	91,3	93,5	71,5	90	100
TNDVI	100	100	91,6	91,6	70	91,3	93,5	71,5	90	100
SAVI	100	100	91,6	91,6	67,7	91,3	93,9	77,5	100	94,4

Çalışma Alanı içerisinde, su alanları, boş alanlar ve yerleşim alanları, seyrek bitki örtüsü, orta yoğun bitki örtüsü ve yoğun bitki örtüsü sınıflarını bulundurmaktadır. Literatür incelendiğinde, tarım arazileri içeren çalışma alanlarında NDVI en yüksek doğruluğu sağlamıştır (Kaya ve Polat, 2021a; Türk ve Balçık 2023). Mera alanlarında, kurak

alanlarda ve kuru tarım alanlarında SAVI yönteminin yüksek doğruluğu sağladığı tespit edilmiştir (Vani ve Mardla, 2017; Kaya ve Polat, 2021b; Munyati, 2022). Bu çalışmada en yüksek doğruluğu NDVI yönteminin sağladığı olup, sonuç literatürdeki çalışmalarla uyumludur (Özdarıcı Ok, 2014; Isip vd., 2020; Kaya ve Polat, 2021a; Türk ve Balçık, 2023). SAVI yöntemi, NDVI yönteminden daha düşük doğruluk sağlamıştır ancak doğruluk değeri çok yakındır. Çalışma alanı boş alanlar, yerleşim alanları da içerdiğinden, sonuç literatürdeki çalışmalarla uyum sağlamaktadır (Vani ve Mardla, 2017; Kaya ve Polat, 2021b; Munyati, 2022).



Şekil 7. Oluşturulan Her Sınıf İçin Ortalama NDVI, GNDVI, TNDVI ve SAVI Değerleri

SONUÇ

Çevrenin ve doğal kaynakların korunması, global anlamda da büyük önem taşımaktadır. Bu çalışmada birçok bitki ve hayvan türünü barındıran Karatepe-Aslantaş Milli Parkı ve çevresindeki bitki örtüsü yoğunlukları uzaktan algılama teknikleri ile incelenmiştir. Bölgedeki bitki örtüsü NDVI, GNDVI, TNDVI VE SAVI bant oranlama teknikleri ile tespit edilmiş ve bant oranlama tekniklerinin bitki örtüsü analizindeki başarısı ortaya konmuştur.

NDVI, bant oranlama tekniği oldukça yüksek doğrulukla bitki örtüsünü belirlemiştir. Klorofile daha duyarlı olan GNDVI yoğun bitki örtüsü içeren alanlarda oldukça başarılıdır. Düşük yoğunluklu bitki örtüsü içeren çalışmalarda SAVI yöntemi kullanılabilir. SAVI yöntemi uygulanırken kullanılacak toprak faktörü değerinin seçimi doğruluk açısından önemlidir.

Sentinel-2 uydu görüntüsüne uygulanan bant oranlama teknikleri yüksek doğruluklu sonuçlar vermiş, çalışma alanı için bitki örtüsü yoğunluğunu analiz edilmiştir. Özellikle bitki örtüsü bulunmayan su alanları, boş alanlar ve yerleşim alanları ile bitki örtüsüne sahip alanların birbirinden ayırt edilmesinde oldukça başarılı olup, tüm yöntemlerin bitki örtüsü belirleme çalışmalarında kullanılabileceği tespit edilmiştir.

KAYNAKLAR

- Artar, M. (2008). Karatepe-Aslantaş Milli Parkı örneğinde korunan alanlar için bir izleme yönteminin geliştirilmesi. Ç.Ü., Fen bilimleri enstitüsü Doktora Tezi, Adana.
- Altan, T., Artar, M. & Erdoğan, R. (2005). Karatepe Aslantaş Milli Parkı Örneğinde Ülkemizde Korunan Alan Planlaması. Korunan Doğal Alanlar Sempozyumu, (pp. 295-303).
- ESA. (2024). Copernicus Browser. <https://browser.dataspace.copernicus.eu/> Erişim Tarihi: 20.03.2024.
- Essaadia, A., Abdellah, A., Ahmed, A., Abdelouahed, F. & Kamal, E. (2022). The normalized difference vegetation index (NDVI) of the Zat valley, Marrakech: comparison and dynamics. *Heliyon*, 8(12):1-10.
- Gitelson, A. A., Kaufman, Y.J. & Merzlyak, M. N. (1996). Use of a green channel in remote sensing of global vegetation from EOS-MODIS. *Remote sensing of Environment*, 58(3), 289-298.

- Gündoğdu, K. S. (2018). Buğday ekili parsellerde NDVI değerlerinin konumsal ve zamana bağlı değişiminin belirlenmesi. *Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi*, 21(4), 492-499.
- Huete, A. R. (1988). A Soil-Adjusted Vegetation Index (SAVI), *Remote Sensing of Environment*, 25(3), 295-309.
- Isip, M. F., Alberto, R. T., & Biagtan, A. R. (2020). Exploring vegetation indices adequate in detecting twister disease of onion using Sentinel-2 imagery. *Spatial Information Research*, 28, 369-375.
- Kaya, Y., & Polat, N. (2021a). Bitki indeksleri kullanarak buğday bitkisinin rekolte tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(1), 99-110.
- Kaya, Y., & Polat, N. (2021b). Sulu ve kuru tarım alanlarında buğday verim tahmininde bitki örtüsü indekslerinin kullanımı. *Türk Tarım ve Doğa Bilimleri Dergisi*, 8(3), 736-746.
- Kaygısız H. & Çakır A. (2020). FPGA kullanılarak görüntülerin gerçek zamanlı olarak otsu metodu ile bölütlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, 18, 911-917.
- Kuc, G. & Chormański, J. (2019). Sentinel-2 Imagery for Mapping and Monitoring Imperviousness in Urban Areas. *The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, 42, 43-47.
- Munyati, C. (2022). Detecting the distribution of grass above ground biomass on a rangeland using Sentinel-2 MSI vegetation indices. *Advances in Space Research*, 69(2), 1130-1145.
- Osmaniye İl Kültür ve Turizm Müdürlüğü. (2024). Korunan Alanlar. <https://osmaniye.ktb.gov.tr/TR-60821/korunan-alanlar.html/> Erişim Tarihi: 20.03.2024.
- Otsu, N. (1979). A threshold selection method from gray-level histograms. *IEEE Trans. Syst. Man. Cybern.* 9, 62-66.
- Özdarıcı, O. A. (2014). Yüksek Mekânsal Çözünürlüklü Uydu Görüntülerinden Otomatik Ağaç Tespiti: Yeni Bir Yaklaşım. 5. Uzaktan Algılama-CBS Sempozyumu, İstanbul, Türkiye.
- Pettorelli, N., Ryan, S., Mueller, T., Bunnefeld, N., Jędrzejewska, B., Lima, M. & Kausrud, K. (2011). The Normalized Difference Vegetation Index (NDVI): unforeseen successes in animal ecology. *Climate Research*, 46(1), 15-27.
- Popescu, C. A., Herbei, M. V. & Sala, F. (2020). Remote sensing in the analysis and characterization of spatial variability of the territory. a study case in Timis County, Romania. Scientific Papers Series Management, *Economic Engineering in Agriculture and Rural Development*, 20(1), 505-514.
- Rouse, J. W., Haas, R. H., Schell, J. A., Deering, D.W. & Harlan, J. C. (1974). Monitoring the vernal advancements and retrogradation (greenwave effect) of nature vegetation; NASA/GSFC final report; NASA: Greenbelt, MD, USA.
- T.C. Milli Savunma Bakanlığı Harita Genel Müdürlüğü. (2024). <https://www.harita.gov.tr/urunler/> Erişim Tarihi 07.07. 2024.
- Tucker, C. J. (1979). Red and photographic infrared linear combinations for monitoring vegetation. *Remote sensing of Environment*, 8(2), 127-150.
- Türk, S. T., & Balçık, F. (2023). Rastgele orman algoritması ve Sentinel-2 MSI ile fındık ekili alanların belirlenmesi: Piraziz Örneği. *Geomatik*, 8(2), 91-98.
- Ustuner, M., Sanli, F.B., Abdikan, S., Esetlili, M.T. & Kurucu, Y. (2014) Crop type classification using vegetation indices of Rapideye imagery. *The International Archives of The Photogrammetry, Remote Sensing and Spatial Information Sciences*, 40, 195-198.
- Vani, V. & Mandla, V. R. (2017). Comparative study of NDVI and SAVI vegetation indices in Anantapur District semi-arid areas. *International Journal of Civil Engineering and Technology*, 8(4), 559-566.
- Yılmaz, K. T., Düzenli, A., Çakan, H. & İzçankurtaran, Y. (2005). Nemrut Dağı Ve Karatepe-Aslantaş Milli Parkları Örneğinde Bitki Örtüsüne Ait Verilerin Koruma Planlamasında Kullanımı. *Korunan Doğal Alanlar Sempozyumu, SDÜ, Isparta*, (pp. 639-646).



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 29.07.2024
Kabul Tarihi : 02.12.2024

Received Date : 29.07.2024
Accepted Date : 02.12.2024

TRAFİK İŞARETLERİNİN TESPİTİNDE FARKLI YOLO MODELLERİNİN KARŞILAŞTIRILMASI

THE COMPARISON OF DIFFERENT YOLO MODELS FOR TRAFFIC SIGN DETECTION

Mehmet Fatih Bekçioğulları^{1*} (ORCID: 0000-0002-0056-9526)

Bünyamin Dikici¹ (ORCID: 0000-0000-0001-6722-5894)

Hakan Açıkgöz² (ORCID: 0000-0002-6432-7243)

Serkan Özbay³ (ORCID: 0000-0001-5973-8243)

¹ Gaziantep İslam Bilim ve Teknoloji Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Gaziantep, Türkiye

² Kahramanmaraş İstiklal Üniversitesi, Yazılım Mühendisliği Bölümü, Kahramanmaraş, Türkiye

³ Gaziantep Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Gaziantep, Türkiye

*Sorumlu Yazar / Corresponding Author: Mehmet Fatih BEKÇİOĞULLARI, mehmetfatih.bekciogullari@gibtu.edu.tr

ÖZET

Trafik işaretleri, karayolunda seyahat eden sürücülere yol kısıtlamaları açısından uyarıda bulunmak amacıyla karayollarına yerleştirilmektedir. Bu işaretlerin doğru bir şekilde algılanması ve trafik işaretinin gerektirdiği kısıtlamaya uyulması, sürüş güvenliği açısından önemlidir. Son yıllarda, derin öğrenme algoritmalarının nesne sınıflandırılmasında ve tespitinde başarılı olduğu birçok çalışma ile gösterilmiştir. Bu çalışmada, derin öğrenme tabanlı “You Only Look Once” (YOLO) algoritmaları trafik işaretleri tespiti açısından karşılaştırılmıştır. İlk olarak 877 görüntüden oluşan dört sınıflı trafik işaretleri veri seti elde edilmiştir. Daha sonra YOLOv5, YOLOv8 ve YOLOv9 algoritmaları trafik işareti tanınması açısından incelenmiştir. Deneysel çalışmalarda, tespit algoritmalarının performanslarını değerlendirmek amacıyla duyarlılık, kesinlik, f1 skor ve mAP performans değerlendirme kriterleri açısından incelenmiştir. Elde edilen deneysel sonuçlara göre YOLOv9’un Duyarlılık metriği %90.8, mAP@0.5 metriği %93.1 ve mAP@0.5:0.95 metriği %77.7 olarak hesaplanmıştır. Bu sonuçlar YOLOv9 algoritmasının en iyi trafik işareti tespit algoritması olduğunu doğrulamaktadır.

Anahtar Kelimeler: Derin öğrenme, yolo, trafik işaret tespiti

ABSTRACT

Traffic signs are placed on highways to warn drivers travelling on the highway in terms of road restrictions. It is important for driving safety that these signs are correctly detected and that the restrictions required by the traffic sign are obeyed. In recent years, many studies have shown that deep learning algorithms are successful in object classification and detection. In this study, deep learning based ‘You Only Look Once’ (YOLO) algorithms are compared in terms of traffic sign detection. Firstly, a four-class traffic sign dataset consisting of 877 images is collected. Then, YOLOv5, YOLOv8 and YOLOv9 algorithms are analyzed in terms of traffic sign recognition. In the experimental studies, in order to evaluate the performance of the detection algorithms, recall, precision, f1 score and mAP performance evaluation criteria are analyzed. According to the experimental results obtained, the Recall metric of YOLOv9 is 90.8%, mAP@0.5 metric is 93.1% , and mAP@0.5:0.95 metric is 77.7%. These results validate that YOLOv9 is the best traffic sign detection algorithm.

Keywords: Deep learning, yolo, traffic sign detection

ToCite: BEKÇİOĞULLARI, M.F., DİKİCİ, B., AÇIKGÖZ H., ÖZBAY S. (2025). TRAFİK İŞARETLERİNİN TESPİTİNDE FARKLI YOLO MODELLERİNİN KARŞILAŞTIRILMASI. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 138-150.

GİRİŞ

Gelecekte insan gücünün azalacağı ve birçok işin otomatikleşeceği açıkça görülmektedir. Bunun bir örneği de son yıllarda görüntü işleme teknolojisinin gelişmesiyle beraber, akıllı ulaşım sistemlerinin daha popüler hale gelmesi ile görülmektedir. Bununla birlikte, akıllı ulaşım sistemlerinin bazı avantajları ile beraber dezavantajları da bulunmaktadır (Han vd., 2024). Akıllı sürüş sistemlerinin sürüş güvenliği açısından trafik işaretlerini hatasızca yakın bir şekilde algılaması ve doğru bir şekilde işlemesi gerekmektedir. Ancak trafikte zorlu hava koşulları ve düşük ışık yoğunluğu trafik işareti görüntüsünde bulanıklığa sebep olabilmektedir. Ayrıca, trafik işareti tüm görüntüde küçük bir parçada bulunabilmektedir. Bu gibi nedenlerden dolayı gerçek zamanlı trafik işareti algılamakta zorluklar vardır. Bu işaretlerin göz ardı edilmesi veya algılanamaması ise ne yazık ki ölümcül kazaları beraberinde getirebilmektedir (Chen & Luo, 2024).

ImageNet yarışmasında 2012 yılında Krizhevsky ve arkadaşları tarafından önerilen AlexNet büyük ilgi çekmiştir. Özellikle görüntü sınıflandırma konusunda dikkat çekici bir performans sergilemiştir (Krizhevsky vd., 2012). Bununla birlikte Evrişimli Sinir Ağı (ESA) algoritmasına dayalı nesne tespiti çalışmaları hız kazanmıştır. Yapılan çalışmalarda hesaplama yükünün ağır olduğu ve fazla depolama alanına gereksinim duymakta olduğu gösterilmiştir. Ancak, trafik işareti tanıma sistemlerinin hızlı ve doğru karar vermesi gerekmektedir. Dolayısıyla ESA tabanlı algoritmalar trafik işareti tanıma görevi için uygun değildir (Saxena vd., 2024). YOLO hızlı ve efektif bir nesne tanıma algoritması olması sebebiyle, gerçek zamanlı nesne tespitinde en yaygın kullanılan algoritmadır. Nesne tespiti için sınırlayıcı kutular kullanan bu algoritma nesneyi sınıflandırma olasılığı ile tahmin eder. Hesaplama yükünün azlığı ve depolama alanı gereksiniminin ESA algoritması kadar fazla olmaması sebebiyle trafik işareti tespitinde kullanmak için uygun bir algoritmadır (Saxena vd., 2024).

Son yıllarda literatürde trafik işaretlerinin tespiti amacıyla ESA ve YOLO tabanlı yapılan birçok çalışma bulunmaktadır. Küçük vd. çalışmalarında akıllı otonom araçlar için Daha Hızlı R-ESA tabanlı bir algoritma önermişlerdir (Küçük vd., 2021). Aykılıç vd. çalışmalarında trafik işaretlerini sınıflandırmada transfer öğrenme yöntemi kullanarak ESA tabanlı algoritma önermiştir (Aykılıç vd., 2024). Çetinkaya ve Acarman, çalışmalarında ESA tabanlı bir trafik işareti tespiti yöntemi önermişlerdir. Algoritmanın daha hızlı sonuç vermesi amacıyla istatistiksel yöntemlerden yararlanılarak görüntüde trafik işaretinin olma ihtimalinin düşük olduğu bazı yerler elenmiştir. Açık kaynak veri seti ile yapılan çalışma sonucunda belirtilen algoritmanın trafik işareti tespitinde başarılı olduğu performans metrik sonuçları ile gösterilmiştir (Çetinkaya & Acarman, 2020). Çınarer, çalışmasında farklı YOLOv5 algoritmalarının trafik işaretleri tespitinde performanslarını karşılaştırmıştır. Açık kaynak veri seti kullanmışlardır. Elde edilen deneysel sonuçlar hesaplanan, kesinlik, duyarlılık ve mAP performans kriterleri ile değerlendirilmiştir (Çınarer, 2024). Rani vd. çalışmalarında trafik işareti tespitinde görüntülerin birçok sebebe bağlı olarak bulanık olabileceğini belirtmiştir. Çalışmada amaçladıklarının zorlu çevre koşullarında dahi trafik işaretlerinin doğru bir şekilde tanınması olduğuna dikkat çekmişlerdir. Buna çözüm olarak ise HRU-Net tabanlı derin öğrenme algoritmasını görüntüde bulunan bulanıklığı giderici olarak önermişlerdir (Rani vd., 2024). Trappey ve Shen çalışmalarında iki aşamalı trafik işareti tanıma sistemi önermişlerdir. Birinci aşamasında YOLOv7 algoritması ile yerleştirme ve işlemlerinin yapılması hedeflenmiştir. İkinci aşamada ise siyam sinir ağı tabanlı bir ESA algoritması ile birinci aşamada tespit edilen trafik işaretlerinin sınıflandırılması işlemi yapılmıştır (Trappey & Shen, 2024). Saxena vd. çalışmalarında gerçek zamanlı trafik işareti tespiti için güçlendirilmiş YOLOv4 tabanlı algoritma önermişlerdir. Çapa kutularının hesaplanmasında k-ortalamlar kümeleme tekniği kullanılmıştır. Oluşturulan modelin sağlamlığını göstermek amacıyla elde edilen deneysel sonuçlar YOLOv3 ve YOLOv4 algoritmalar ile karşılaştırılmıştır. Ayrıca çalışmada, elde edilen gece görüntülerini iyileştirmek amacıyla gece aydınlatma modeli kullanıldığı belirtilmiştir (Saxena vd., 2024). Megalingam vd. çalışmalarında trafik işaretlerinin tespitinde R-ESA tabanlı bir algoritma önermişlerdir. Modelin geliştirilmesi amacıyla mimarisinde iyileştirmeler yapılmıştır. Ayrıca, veri setinde çeşitli veri artırma yöntemleri uygulanarak modelin güçlendirilmesi hedeflenmiştir. Önerilen modelin performansı Hızlı R-ESA ve Maske R-ESA algoritmaları ile karşılaştırılmıştır (Megalingam vd., 2023). Han vd. çalışmalarında trafik işaretlerinin tespitinde YOLOv5-s tabanlı EDN-YOLO adlı bir algoritma önermişlerdir. Önerilen bu modelde omurga olarak EfficientVit modülü kullanılmıştır. Bu modül ile ağırlık karmaşıklığının artırılmadan özellik algılama performansının artırılması hedeflenmiştir. Buna ek olarak, etkili bir ayrıştırılmış algılama başlığı ile sınıflandırma ve regresyon işlemleri yapılmıştır. Ayrıca, optimize edilmiş bir kayıp fonksiyonu ile trafik işaretleri gibi küçük nesnelerin tespitinde etkili bir algoritma tasarlandığı belirtilmiştir (Han vd., 2024). Bu çalışmada, trafik işaretlerinin tespiti için YOLOv9 algoritması önerilmiştir. Eğitim için ayrılan veri setine farklı veri artırma yöntemleri uygulanmıştır. Bununla birlikte algoritmanın genelleme potansiyelinin artırılması hedeflenmiştir. Deneysel çalışmalarda, YOLOv5-n, YOLOv5-s, YOLOv5-m, YOLOv5-l, YOLOv5-x, YOLOv8 ve YOLOv9


algoritmalarının performansları nesne tespiti çalışmalarında sıklıkla kullanılan performans değerlendirme kriterlerine göre karşılaştırılmıştır. Bu çalışmanın geri kalanı veri seti, yöntem, performans değerlendirme ölçütleri, deneysel çalışmalar ve sonuç bölümlerinden oluşmaktadır.

Trafik Işığı

Dur İkazı

Hız Limiti

Yaya Geçidi



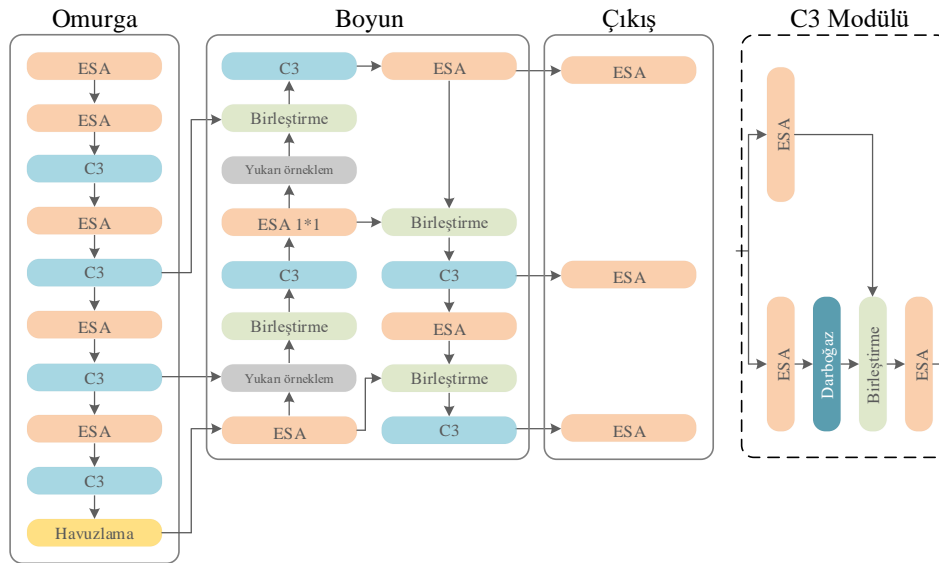
Şekil 1. Veri Setine Ait Bazı Örnek Resimler

VERİSETİ

Bu çalışmada yaya geçidi, hız limiti, dur işareti ve trafik ışıkları sınıflarından oluşan dört sınıflı halka açık bir veri seti kullanılmıştır¹. Veri setinde toplam 877 adet görüntü bulunmaktadır. Veri setinin deneysel çalışmalarda kullanılması amacıyla öncelikle eğitim, test ve doğrulama görüntüleri sırasıyla %70, %15, %15 oranında rastgele ayrılmıştır. Daha sonra tüm görüntüler 640x640 olarak yeniden boyutlandırılmıştır. Veri setinin artırılması ve ağır genelleştirme potansiyelinin iyileştirilmesi amacıyla sadece eğitim veri setinde döndürme, ortaya çıkarma (exposure) ve bulanıklaştırma veri artırma yöntemlerine başvurulmuştur. Bu işlemlerin sonucunda eğitim veri seti 1839, test veri seti 132 ve doğrulama (validasyon) veri seti 130 görüntüden oluşmaktadır. Şekil 1’ de veri setine ait bazı örnek resimler verilmiştir.

YÖNTEM

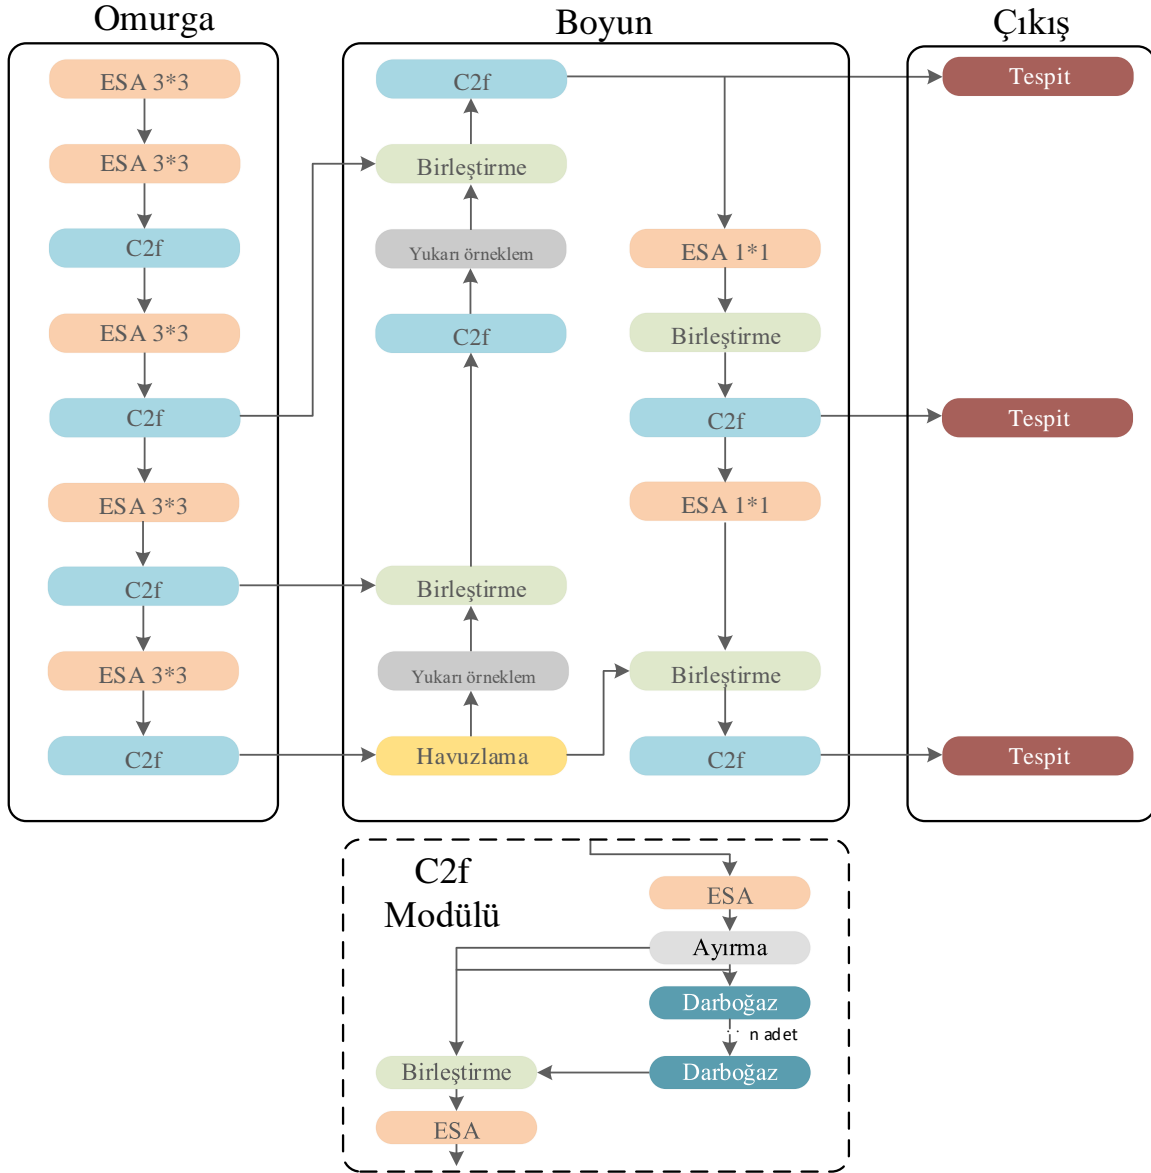
Literatürde; R-ESA ailesi (Girshick vd., 2014) (Ren vd., 2017) gibi bölge bazlı nesne tespiti algoritmalarının yanı sıra YOLO ailesi ve SSD (Liu vd., 2016) gibi tek-atış nesne tespiti algoritmaları mevcuttur. Bu çalışmada YOLO algoritması nesne tespiti çalışması yapılmıştır. 2016 yılında Redmon ve arkadaşları bölge bazlı nesne tespiti algoritmalarından daha farklı ve hızlı çalışan bir model önermişlerdir. “You Only Look Once” (YOLO) (Redmon vd., 2016) ismini verdikleri bu modelde; tek bir evrişimli ağ ile sınırlayıcı kutular ve bu kutuların sınıf olasılıkları tahmin edilmektedir. Bu da modelin çok hızlı sonuç vermesine ve gerçek zamanlı uygulamalarda sıklıkla tercih edilmesine sebep olmaktadır. YOLO algoritmalarının temel çalışma mantığı şu şekilde özetlenebilir: Giriş resmi AxA boyutta ızgaralara ayrılarak, n tane sınırlayıcı kutu oluşturulmaktadır. Burada A ve n birer doğal sayıyı temsil etmektedir. Daha sonra ağ her bir sınırlayıcı kutu için olasılık hesaplamaktadır. Sonrasında bir hiperparametre olarak belirlenen belli bir eşik değerinin üstünde değere sahip olan sınırlayıcı kutular seçilmektedir. Seçilen sınırlayıcı kutular ile nesnenin resim içindeki konumu belirlenmektedir. YOLO’ nun YOLOv1 (Redmon vd., 2016), YOLOv2 (Redmon & Farhadi, 2017), YOLOv3 (Redmon & Farhadi, 2018), YOLOv4 (Bochkovskiy vd., 2020), YOLOR (Redmon vd., 2016), YOLOX (Ge vd., 2021), YOLOv5, YOLOv6 (Li vd., 2022), YOLOv7 (C.-Y. Wang vd., 2023), YOLOv8 ve YOLOv9 (C.-Y. Wang vd., 2024), YOLOv10 (A. Wang vd., 2024) gibi farklı versiyonları bulunmaktadır. YOLOv5 2020 yılında, Glen Jocher tarafından tanıtılmıştır. Bir önceki versiyonuna kıyasla algoritmada temel iki değişiklik bulunmaktadır. Bunlardan ilki, EfficientNet temelli EfficientDet algoritmasının kullanılmasıdır. Bu değişiklik ile amaçlanan şey; yüksek doğruluk oranı elde ederken, hesaplama ve hafıza kullanımı açısından daha verimli bir ağ oluşturmaktır. İkinci önemli değişiklik ise bağlantı kutularını üretmek için geliştirilen bir metot olan dinamik bağlantı kutularının kullanılmasıdır. Bu değişiklik YOLOv5’ in; algılanan nesnelerin boyut ve şekline daha uygun bağlantı kutuları oluşmasına olanak tanımaktadır. Ayrıca bu modelde, standart batch normalizasyon yerine çapraz mini-batch normalizasyon kullanılmıştır. Son olarak, YOLOv4’ de de karşımıza çıkan, bir tür havuzlama katmanı olan mekansal piramit havuzlamada (spatial pyramid pooling) bazı iyileştirmeler yapılarak kullanılmıştır. Bu iyileştirmenin amacı, tespit edilmek istenen küçük nesnelerin daha iyi belirlenebilmesini sağlamaktır. YOLOv5 algoritmasının yapısı Şekil 2’ de gösterilmiştir.



Şekil 2. YOLO-V5 Yapısı

¹ <https://www.kaggle.com/datasets/andrewmvd/road-sign-detection/data>


YOLOv8 mimarisi, CSPNet modülü yerine c2f modülünün kullanılması gibi birkaç değişiklik sonucunda YOLOv5 ile aynı mimariyi takip etmektedir (Terven vd., 2023). Ayrıca bu modelde nesnellik, sınıflandırma ve sınırlayıcı kutu tahmin görevlerini bağımsız olarak işlemek için ayrılmış kafalar (decoupled heads) tanıtılmıştır. Nesnellik puanı tahmini için son katman olarak sigmoid katmanı ve sınıflandırma için ise softmax katmanı kullanılmıştır. Öte yandan, sınırlayıcı kutu kaybı için Clou ve DFL kaybı işlevleri kullanılmıştır. Ayrıca sınıflandırma kaybı için ise ikili çapraz entropi kullanılmıştır. Bu kayıplar, özellikle daha küçük nesnelere tespitinde nesne algılama performansını iyileştirmektedir. YOLOv8 algoritmasının yapısı Şekil 3’de sunulmuştur.



Şekil 3. YOLO-V8 Yapısı

Chien-Yao Wang ve diğerleri 2024’te “YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information” başlıklı çalışmaları ile YOLOv9’u tanıtmıştır. Bu makalede tartışılan dört önemli kavram vardır. Bunlar Programlanabilir Gradyan Bilgisi (PGI), Genelleştirilmiş Verimli Katman Toplama Ağı (GELAN), bilgi darboğazı ilkesi ve tersine çevrilebilir işlevlerdir. YOLOv9 nesne algılama, segmentasyon ve sınıflandırma yeteneğine sahiptir (C.-Y. Wang vd., 2024). Bu algoritmanın mimarisi ise Şekil 4’de gösterilmiştir.

Bu çalışmada YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l, YOLOv5x, YOLOv8 ve YOLOv9 algoritmalarından elde edilen performans sonuçları kıyaslanmıştır.



Şekil 4. YOLO-V9 Yapısı

PERFORMANS DEĞERLENDİRME ÖLÇÜTLERİ

DeneySEL sonuçların değerlendirilmesinde, nesne tespiti çalışmalarında çoğunlukla tercih edilen performans değerlendirme ölçütleri olan Kesinlik (P), Duyarlılık (R), F1-skor ve Ortalama Kesinlik (mAP) metrikleri kullanılmıştır. Kesinlik, tüm pozitif tahminlerden Doğru Pozitifleri (DP) bulma oranıdır. Duyarlılık, DP'lerin gerçek pozitif örneklere oranını ifade etmektedir. F1-skor ise duyarlılık ve kesinlik metriklerinin harmonik ortalamasıdır. Bu performans değerlendirme metrikleri, YOLO algoritmalarının nesne tespiti performansını değerlendirmek için nesnel bir yol göstermektedir (Acikgoz, 2024).

$$Kesinlik = \frac{DP}{DP+YP}$$

(1)

$$Duyarlılık = \frac{DP}{DP+YN} \quad (2)$$

$$F1 - skor = 2 * \frac{Kesinlik * Duyarlilik}{Kesinlik + Duyarlilik} \quad (3)$$

Denklem (1), (2) ve (3)'te sırasıyla kesinlik, duyarlılık ve F1-skor metriklerine ait formüller verilmiştir. Denklem(1) ve (2)'de belirtilen DP, YP ve YN Tablo-1'de verilen hata matrisinde sırasıyla “Doğru Pozitif (DP)”, “Yanlış Pozitif (YP)” ve “Yanlış Negatif (YN)” ifade etmektedir. DP doğru tahmin edilen pozitif örnekleri, YP yanlışlıkla pozitif tahmin edilen örnekleri, YN yanlışlıkla negatif tahmin edilen örnekleri ifade etmektedir. Ayrıca gerçekte negatif olan örneklerin negatif olarak tahmin edildiği Doğru Negatif “DN” ile belirtilmiştir.

Tablo 1. Hata Matrisi

	DP	YP
Gerçekteki Sınıf	Doğru Pozitif	Yanlış Pozitif
	YN	DN
	Yanlış Negatif	Doğru Negatif
	Tahmin Edilen Sınıf	

mAP metriği ise nesne tespit algoritmasının davranışı hakkında bilgi içermektedir. AP değeri kesinlik ve duyarlılık parametreleri kullanılarak hesaplanır. Öte yandan bu metrik, birden fazla nesne kategorisinin işlenmesine ve birleşim üzerinden kesişim (IoU) kullanılarak pozitif tahminin tanımlanmasına dayanmaktadır. Bir başka ifadeyle IoU, nesne tespit algoritmasının oluşturduğu örtüşme alanının nesnenin birlik alanına bölünmesi ile elde edilir. Sıfır ile bir arasında değer almaktadır (Terven vd., 2023).

$$AP = \int_0^1 P_r(R_e) dR_e \quad (4)$$

mAP@0.5 metriğinde IoU eşiği 0.5 olarak belirlenmiştir. Bu durumda, IoU 0.5'den büyük hesaplanan değerler için mAP metriği hesaplanmıştır. Bir başka ifadeyle, mAP@0.5 0.5 IoU eşiğinde ortalama hassasiyeti vermektedir. mAP@0.5:0.95 %50'den %95'e kadar farklı IoU eşik değerlerinde ortalama hassasiyet puanlarını göstermektedir.

$$mAP = \frac{1}{n} \sum_{k=1}^n AP_r k \quad (5)$$

Denklem (4) ve (5)'te AP ve mAP formülleri verilmiştir

DENEYSEL ÇALIŞMALAR

Bu çalışmada kullanılan tüm modellerin performans sonuçları Google Colab üzerinden Tesla T4 16 GB ekran kartı, 12 GB RAM ve 80 GB ROM kullanılarak hesaplanmıştır.

Bu çalışmada, YOLO algoritmalarının trafik işaretlerini tespit etmedeki performansını analiz edebilmek adına; YOLOv5-n, YOLOv5-s, YOLOv5-m, YOLOv5-l, YOLOv5-x, YOLOv8 ve YOLOv9 modellerinden elde edilen performans sonuçları değerlendirilmiştir. Gerçekleştirilen deneysel çalışmalar sonucunda hesaplanan tüm performans metrik sonuçları Tablo 2' de verilmiştir. Kıyaslamalar sonucunda en iyi sonuçların alındığı performans metrikleri koyu renkte belirtilmiştir. Öte yandan, performans metriklerine ait grafikler Şekil 5' de, mAP@0.5 ve mAP@0.5:0.95 metriklerine ait grafikler Şekil 6' da gösterilmiştir.

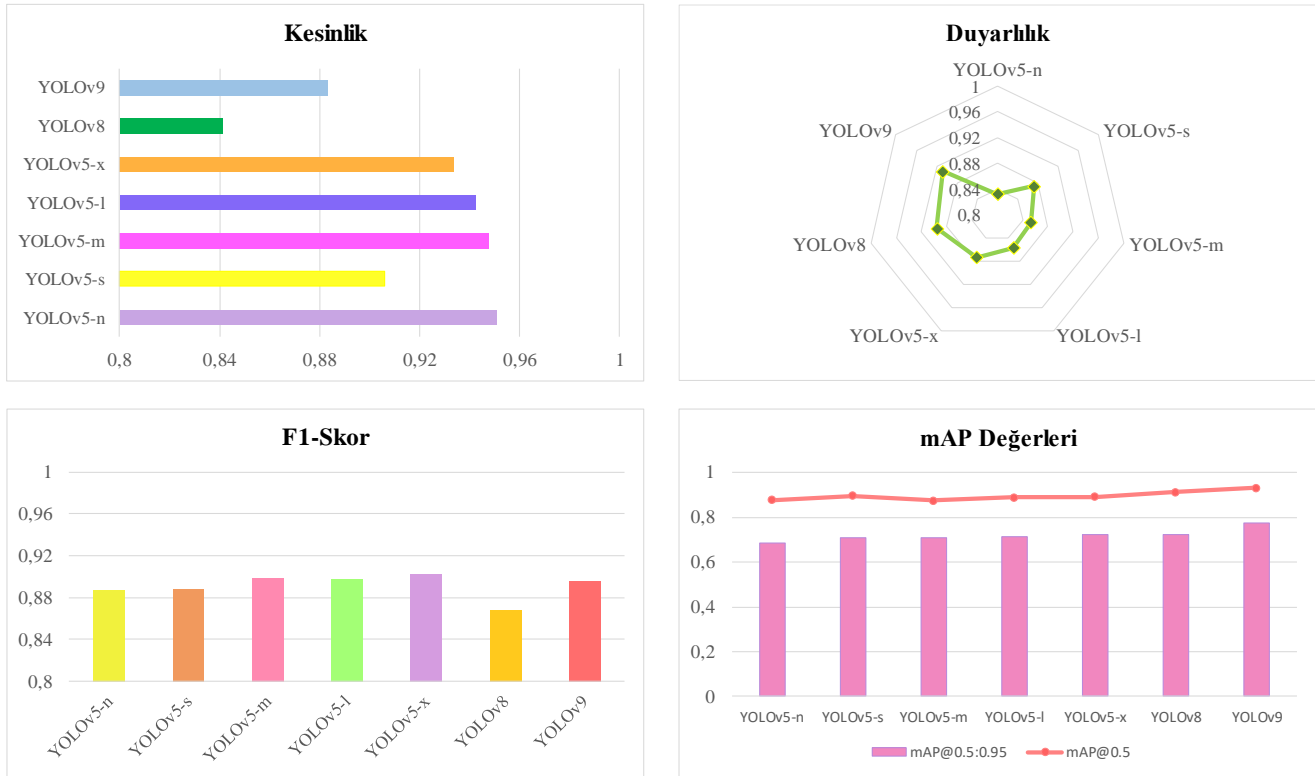
Tablo 2. Tüm Modellerin Performans Metrik Sonuçlarının Kıyaslanması


Model	Kesinlik	Duyarlılık	F1-Skor	mAP@0.5	mAP@0.5:0.95
YOLOv5-n	0,951	0,832	0,888	0,878	0,685
YOLOv5-s	0,906	0,872	0,889	0,896	0,710
YOLOv5-m	0,948	0,853	0,898	0,876	0,710
YOLOv5-l	0,943	0,857	0,898	0,890	0,712
YOLOv5-x	0,934	0,873	0,902	0,892	0,723
YOLOv8	0,841	0,896	0,868	0,913	0,724
YOLOv9	0,884	0,908	0,896	0,931	0,777

Tablo-2' de verilen mAP metrikleri ile duyarlılık metriği genel olarak incelendiğinde; YOLOv5-n YOLOv5-s, YOLOv5-m, YOLOv5-l ve YOLOv5-x modellerinin en kötü sonuçları verdiği görülmektedir. Bununla beraber ilgili metriklerde, YOLOv8 ve YOLOv9' un tüm YOLOv5 modellerine kıyasla daha yüksek performans sonuçları verdiğini söylemek mümkündür.

Elde edilen sonuçlar kesinlik parametresi yönünden incelendiğinde; YOLOv5 modellerinin genel bir üstünlüğü görülmektedir. En kötü mAP sonuçlarına sahip YOLOv5-n ve YOLOv5-m bu metrikte en iyi sonuçları vermiştir. Duyarlılık parametresi göz önüne alınarak analiz yapıldığında; en iyi sonucun 0.908 ile YOLOv9 modelinde hesaplandığı görülürken en iyi ikinci sonucu ise 0.896 ile YOLOv8 modeli vermiştir. En kötü sonucu ise 0.832 ile YOLOv5-n modelinin verdiği görülmektedir. Duyarlılık metriğinde tüm YOLOv9 ve YOLOv8 modellerinin tüm YOLOv5 modellerine trafik işareti tespitinde açık bir üstünlük kurduğu görülmektedir.

Tablo-2'de yer alan tüm modeller F1-Skor bakımından incelendiğinde; YOLOv5-n YOLOv5-s, YOLOv5-m, YOLOv5-l, YOLOv5-x, YOLOv8 ve YOLOv9 modelleri için sırasıyla 0.888, 0.889, 0.898, 0.898, 0.902, 0.868 ve 0.896 değerleri elde edilmiştir.

**Şekil 5.** Tüm Modeller İçin Performans Metriklerinin Grafikleri



Şekil 6. Tüm Modeller için mAP@0.5 ve mAP@0.5:0.95 Değerleri


YOLOv8 ve YOLOv9 modelleri, mAP@0.5 metriği ele alındığında sırasıyla 0.913 ve 0.931 ile en iyi sonuçları vermişlerdir. Tüm YOLOv5 algoritmaları arasında 0.896 ile en iyi sonucu veren YOLOv5-s modeli, tüm modeller arasında YOLOv8'in ardından en iyi üçüncü model olmuştur. Buna ek olarak, tüm modeller mAP@0.5:0.95 performans metriği göz önünde bulundurularak değerlendirildiği takdirde 0.777 ile en iyi sonucun YOLOv9' a ait olduğu görülmektedir. En iyi ikinci sonucu veren YOLOv8'in ise bu metrikte hesaplanan değeri 0.724'tür.

Elde edilen deneysel sonuçlar YOLOv9' da kullanılan REPNCSPPLAN4 modülünün trafik işareti tespitinde olumlu bir etki yaparak YOLOv5 ve YOLOv8 ağlarına kıyasla performans sonuçlarını arttırdığını göstermiştir.


Tablo-2' de yer alan YOLOv5-n, YOLOv5-s, YOLOv5-m, YOLOv5-l, YOLOv5-x, YOLOv8 ve YOLOv9 modelleri tüm metrikler bakımından değerlendirildiğinde; en iyi sonuçların çoğunlukla YOLOv9 ile en iyi ikinci sonuçların ise genellikle YOLOv8 ile elde edildiği gözlemlenmektedir. Öte yandan, YOLOv5 modellerinin birbirine yakın ve düşük performans sonuçları verdiği görülmektedir. Duyarlılık, mAP@0.5 ve mAP@0.5:0.95 metriklerinde en yüksek performans sonuçlarını veren YOLOv9 için sırasıyla; 0.908, 0.931 ve 0.777 değerleri elde edilmiştir.

Ayrıca Şekil 7'de test görüntülerinden rastgele seçilen beş örneğin, çalışmada kullanılan YOLO algoritmaları tarafından elde edilen çıktıları sunulmuştur. Buna ek olarak, deneysel çalışmada elde edilen YOLO modellerine ait hata matrisleri Şekil 8'de verilmiştir.

Tablo-3'te YOLO modelleri parametreler, katmanlar, floplar, eğitim süreleri ve tahmin süreleri açısından karşılaştırılmıştır. Eğitim süresine göre modeller karşılaştırıldığında en kısa sürede eğitim sürecini tamamlayan modelin yaklaşık bir saat ile YOLOv5-n olduğu görülürken en uzun eğitim süresine sahip olan model yaklaşık altı saat ile YOLOv9 olmuştur. Öte yandan, tahmin süresinin de beklendiği gibi YOLOv5-n'de en kısa olduğu görülmektedir. En uzun tahmin süresi ise 113 milisaniye ile YOLOv9'a aittir. Önerilen YOLOv9 modelinin karşılaştırma modellerine nispeten daha güvenilir ve sağlam olduğu görülmektedir. Önerilen modelin daha gelişmiş GPU'lar ile tahmin süresinin kısaltılabileceği ve akıllı ulaşım sistemlerinde kabul edilebilir seviyeye düşürülebileceği ön görülmektedir.



Şekil 7. Farklı YOLO Algoritmalarından Elde Edilen Test Sonucu Görüntüleri



Şekil 8. Bu Çalışmada Kullanılan Tüm YOLO Modellerine Ait Hata Matrisleri

SONUÇ

Bu çalışmada, trafik işaretlerinin tespitinin gerçekleştirilmesi için YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l, YOLOv5x, YOLOv8 ve YOLOv9 modellerinden elde edilen sonuçlar kıyaslanmıştır. Trafik işaretleri veri seti test, eğitim ve doğrulama olmak üzere üç gruba ayrılmıştır. Adil bir değerlendirme ortamının oluşabilmesi için bu çalışmada yer verilen tüm modeller aynı resimlerle eğitilmiş ve aynı resimlerle test edilmiştir. Öte yandan tüm modeller için batch boyutu 16 olarak seçilirken, dönem sayısı (epoch) 200 olarak belirlenmiştir. Performans değerlendirme sonuçları incelendiğinde YOLOv9 modelinin en iyi duyarlılık, mAP@0.5 ve mAP@0.5:0.95 değerlerini sırasıyla 0.908, 0.931 ve 0.777 olarak verdiği görülmüştür. İlgili metriklere göre en iyi ikinci sonucu ise YOLOv8 modelinin verdiği görülmüştür. YOLOv9 modeli ile YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l, YOLOv5x ve YOLOv8 modellerinin tespit yeteneğinin önemli ölçüde iyileştirildiği tespit edilmiştir. En iyi ikinci sonucu veren YOLOv8 modelinin mAP@0.5:0.95 metriğinin %7.226 iyileştirildiği hesaplanırken aynı metrikte

YOLOv5-x'in %7.470, YOLOv5-l'nin %9.03, YOLOv5-m'nin %9.334, YOLOv5-s'nin %9.448 ve YOLOv5-n'nin %13.448 iyileştirildiği görülmüştür. Ayrıca önerilen modelin, en iyi ikinci sonucu veren modeli duyarlılık metriğinde %1.354, mAP@0.5 metriğinde ise yaklaşık %2 oranında iyileştirmiştir.

Tablo 3. Bu Çalışmada Kullanılan Tüm YOLO Modellerinin Performans ve Parametre Karşılaştırması

Model	Parametre (M)	Katmanlar	Floplar (G)	Eğitim Süresi (saat)	Tahmin Süresi (ms)
YOLOv5-n	1,769	214	4,2	1,119	5,8
YOLOv5-s	7,030	214	16	1,185	7,1
YOLOv5-m	20,883	291	48,3	1,634	15,9
YOLOv5-l	46,154	368	108,3	2,531	27,9
YOLOv5-x	86,238	445	204,7	3,874	44,8
YOLOv8	11,137	225	28,7	1,783	9,9
YOLOv9	25,440	621	103,2	5,56	113

Elde edilen performans değerlendirme ölçütlerine ve iyileştirme yüzdelerine bakıldığında, YOLOv9 modelinin trafik işaretlerinin tespitinde güvenilir bir model olduğu sonucuna varılmıştır. Bununla birlikte akıllı ulaşım sistemlerinde kullanılması için önemli bir potansiyel taşıdığı değerlendirilmektedir.

KAYNAKLAR

- Acikgoz, H. (2024). An automatic detection model for cracks in photovoltaic cells based on electroluminescence imaging using improved YOLOv7. *Signal, Image and Video Processing*, 18(1), 625-635. <https://doi.org/10.1007/s11760-023-02724-7>
- Aykılıç, Ö., Başarslan, M. S., & Bal, F. (2024). Classification of Traffic Signs Using Transfer Learning Methods. *Afyon Kocatepe Üniversitesi Fen Ve Mühendislik Bilimleri Dergisi*, 24(4), 829-838. <https://doi.org/10.35414/akufemubid.1420978>
- Bochkovskiy, A., Wang, C.-Y., & Liao, H. M. (2020). *YOLOv4: Optimal Speed and Accuracy of Object Detection*. <http://arxiv.org/abs/2004.10934>
- Chen, Y., & Luo, H. (2024). VisioSignNet: A Dual-Interactive Neural Network for enhanced traffic sign detection. *Expert Systems with Applications*, 255. <https://doi.org/10.1016/j.eswa.2024.124688>
- Çetinkaya, M., & Acarman, T. (2020). Trafik İşaret Levhası Tespiti için Derin Öğrenme Yöntemi. *Akıllı Ulaşım Sistemleri Ve Uygulamaları Dergisi*, 3(2), 140-157.
- Çınarer, G. (2024). Deep Learning Based Traffic Sign Recognition Using YOLO Algorithm. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 12(1), 219-229. <https://doi.org/10.29130/dubited.1214901>
- Ge, Z., Liu, S., Wang, F., Li, Z., & Sun, J. (2021). *YOLOX: Exceeding YOLO Series in 2021*. 1-7. <http://arxiv.org/abs/2107.08430>
- Girshick, R. (2015). Fast R-CNN. *Proceedings of the IEEE International Conference on Computer Vision, 2015 Inter*, 1440-1448. <https://doi.org/10.1109/ICCV.2015.169>
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 580-587. <https://doi.org/10.1109/CVPR.2014.81>
- Han, Y., Wang, F., Wang, W., Zhang, X., & Li, X. (2024). EDN-YOLO: Multi-scale traffic sign detection method in complex scenes. *Digital Signal Processing: A Review Journal*, 153. <https://doi.org/10.1016/j.dsp.2024.104615>
- Krizhevsky, A., Sutskever, I., & Hinton, G.E. (2012). ImageNet classification with deep convolutional neural networks. *Communications of the ACM*, 60(6), 84 - 90. <https://doi.org/10.1145/3065386>

- Küçük, Ö., Yavşan, E., & Gökçe, B. (2021). Otonom Tabanlı İşaret ve Şerit Tanıma Amacı ile Bir Öğrenme Sisteminin Geliştirilmesi. *International Journal of Engineering Research and Development*, 13(3), 19-25. <https://doi.org/10.29137/umagd.1037237>
- Li, C., Li, L., Jiang, H., Weng, K., Geng, Y., Li, L., Ke, Z., Li, Q., Cheng, M., Nie, W., Li, Y., Zhang, B., Liang, Y., Zhou, L., Xu, X., Chu, X., Wei, X., & Wei, X. (2022). *YOLOv6: A Single-Stage Object Detection Framework for Industrial Applications*. <http://arxiv.org/abs/2209.02976>
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C. Y., & Berg, A. C. (2016). SSD: Single shot multibox detector. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9905 LNCS, 21-37. https://doi.org/10.1007/978-3-319-46448-0_2
- Megalingam, R. K., Thanigundala, K., Musani, S. R., Nidamanuru, H., & Gadde, L. (2023). Indian traffic sign detection and recognition using deep learning. *International Journal of Transportation Science and Technology*, 12(3), 683-699. <https://doi.org/10.1016/j.ijst.2022.06.002>
- Rani, A. R., Anusha, Y., Cherishama, S. K., & Laxmi, S. V. (2024). Traffic sign detection and recognition using deep learning-based approach with haze removal for autonomous vehicle navigation. *e-Prime - Advances in Electrical Engineering, Electronics and Energy*, 7. <https://doi.org/10.1016/j.prime.2024.100442>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-Decem*, 779-788. <https://doi.org/10.1109/CVPR.2016.91>
- Redmon, J., & Farhadi, A. (2017). YOLO9000: Better, faster, stronger. *Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017, 2017-Janua*, 6517-6525. <https://doi.org/10.1109/CVPR.2017.690>
- Redmon, J., & Farhadi, A. (2018). *YOLOv3: An Incremental Improvement*. <http://arxiv.org/abs/1804.02767>
- Ren, S., He, K., Girshick, R., & Sun, J. (2017). Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(6), 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>
- Saxena, S., Dey, S., Shah, M., & Gupta, S. (2024). Traffic sign detection in unconstrained environment using improved YOLOv4. *Expert Systems with Applications (C. 238)*. Elsevier Ltd. <https://doi.org/10.1016/j.eswa.2023.121836>
- Terven, J., Córdova-Esparza, D. M., & Romero-González, J. A. (2023). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction (C. 5, Sayı 4, ss. 1680-1716)*. Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/make5040083>
- Trappey, A. J. C., & Shen, O. T. C. (2024). A universal traffic sign detection system using a novel self-training neural network modeling approach. *Advanced Engineering Informatics*, 62. <https://doi.org/10.1016/j.aei.2024.102674>
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., & Ding, G. (2024). *YOLOv10: Real-Time End-to-End Object Detection*. <http://arxiv.org/abs/2405.14458>
- Wang, C.-Y., Bochkovskiy, A., & Liao, H.-Y. M. (2023). *YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors*. 7464-7475. <https://doi.org/10.1109/cvpr52729.2023.00721>
- Wang, C.-Y., Yeh, I.-H., & Liao, H.-Y. M. (2024). *YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information*. <http://arxiv.org/abs/2402.13616>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 08.08.2024
Kabul Tarihi : 22.10.2024

Received Date : 08.08.2024
Accepted Date : 22.10.2024

AKTİVİTE-SEYAHAT SEÇİMLERİ VE ARAÇ SAHİPLİĞİNİN KESİKLİ SEÇİM MODELLERİ İLE İNCELENMESİ

ANALYSIS OF ACTIVITY-TRAVEL CHOICES AND VEHICLE OWNERSHIP USING DISCRETE CHOICE MODELS

Gözde BAKİOĞLU^{1*} (ORCID: 0000-0003-3754-2631)

¹ Marmara Üniversitesi, İnşaat Mühendisliği, İstanbul, Türkiye

*Sorumlu Yazar / Corresponding Author: Gözde BAKİOĞLU, gozde.bakioglu@marmara.edu.tr

ÖZET

Boş zaman aktiviteleri, bireylerin sosyal, fiziksel ve zihinsel refahını artırmasının yanı sıra, bu aktiviteler için yapılan seyahatlerin ulaşım ağlarının kullanımını ve planlanmasını doğrudan etkileyen önemli bir unsurdur. Bu çalışma, bireylerin boş zaman aktivitelerine katılımını etkileyen demografik, seyahat ve teknolojik faktörlerin incelenmesini amaçlamaktadır. Bu kapsamda, aktivite seçimleri üzerinde etkili olan değişkenleri belirlemek için kesikli seçim modellerinden Multinomial lojit (MNL) ve ikili lojit modelleri kullanılmıştır. MNL modeli, bireylerin çeşitli aktiviteler arasında yaptığı seçimleri analiz ederken, ikili lojit modeli araç sahibi bireylerin aktivitelere katılımını ve bunun diğer demografik ve teknolojik özelliklerle ilişkisini incelemiştir. Analiz sonuçları, kadınların kapalı alan aktivitelerine daha fazla katılma eğiliminde olduğunu, yaş ilerledikçe kapalı alan ve spor aktivitelerine katılımın azaldığını, ancak araç sahibi olma olasılığının arttığını göstermiştir. Ayrıca, evli bireylerin araç sahibi olma eğilimi yüksekken, düşük dijital bilgi seviyesine sahip bireylerin hem aktiviteler hem de araç sahipliği konusunda daha düşük katılım eğilimi gösterdiği tespit edilmiştir. Bu bulgular, ulaşım sektörü profesyonelleri ve araştırmacılar için, bireylerin aktivite tercihlerini etkileyen faktörleri daha iyi anlamalarını sağlayarak, bu bilgileri hedefe yönelik politikalar geliştirmek için kullanmalarına yardımcı olacaktır.

Anahtar Kelimeler: Aktivite seçimleri, araç sahipliği, multinomial lojit model, ikili lojit model

ABSTRACT

Leisure activities are crucial for enhancing individuals' social, physical, and mental well-being, and the travel associated with these activities directly impacts the use and planning of transportation networks. This study aims to examine the demographic, travel, and technological factors influencing individuals' participation in leisure activities. To achieve this objective, discrete choice models, specifically the Multinomial Logit (MNL) and binary logit models, were utilized to identify variables affecting activity choices. The MNL model analyzes individuals' choices among various activities, while the binary logit model examines the participation of vehicle-owning individuals in activities and its relationship with other demographic and technological characteristics. The analysis results revealed that women tend to participate more in indoor activities, while participation in indoor and sports activities decreases with age, although the likelihood of vehicle ownership increases. Furthermore, it has been found that married individuals have a higher propensity for vehicle ownership, while individuals with low digital knowledge levels exhibit lower participation tendencies in both activities and vehicle ownership. These findings provide transportation sector professionals and researchers with a deeper understanding of the factors influencing individuals' activity preferences, enabling them to use this information to develop targeted policies.

Keywords: Activity choices, vehicle ownership, multinomial logit model, binary logit model

GİRİŞ

Boş zaman aktiviteleri, bireylerin günlük rutinlerinin dışında kalan serbest zamanlarını değerlendirme isteğiyle gerçekleştirdikleri etkinlikler olarak tanımlanabilir. Bu aktiviteler hobi, spor, sosyal etkileşimler, açık ve kapalı alan faaliyetleri ve diğer çeşitli etkinlikleri kapsamaktadır (Páez ve Farber, 2012). Bu aktiviteler, bireylerin iş dışında gönüllü olarak gerçekleştirdikleri etkinlikler olup, bu süreç pozitif duygular sağladığı ve kaygıyı azalttığı için yaşamın önemli bir parçasını oluşturmaktadır. Artan refah, yaşlanan nüfus ve değişen yaşam tarzları gibi etkenler, boş zaman aktivitelerine olan talebi son yıllarda artırmış ve bu aktiviteler, fiziksel ve psikolojik iyilik hali ile ilişkilendirilmiştir (Pressman vd., 2009).

Boş zaman aktivitelerinin seçimi, sosyo-demografik etkiler, fiziksel çevrenin özellikleri ve aktivitelerin kendine özgü yönleri gibi çeşitli faktörlerden etkilenmektedir. Örneğin, ulaşım türü seçimi veya haftanın hangi gününde aktivitenin gerçekleştirildiği gibi unsurlar, belirli boş zaman aktivitelerine olan eğilimi artırabilir ya da azaltabilir (Limtanakool vd., 2006, Bhat ve Gossen, 2004).

Boş zaman etkinliklerine katılımı önemli ölçüde etkileyen faktörler genellikle kişisel özelliklerle veya aktivitenin kendisiyle ilgilidir. Son yıllarda yapılan çeşitli çalışmalar, yaş gibi bireylere bağlı faktörlerin boş zaman aktivitelerine katılım üzerinde belirleyici olduğunu vurgulamış ve yaşlı bireylerin daha az aktiviteye katıldığını ortaya koymuştur (Zijlstra ve Vlaskamp, 2005). Eğitim düzeyi de boş zaman aktivitelerine katılım ile güçlü bir şekilde ilişkilidir; eğitim görmek ve orta öğretimi tamamlamak, bireylerin arkadaşlarıyla sosyal aktivitelere katılma olasılığını artırmaktadır (Imms vd., 2009). Diğer taraftan, düşük gelir düzeyi, boş zaman aktivitelerine katılımı olumsuz etkileyen önemli bir faktör olarak belirtilmiştir (Badia vd., 2011). Gramsch Calvo ve Axhausen (2024), bireylerin boş zaman etkinlikleri için mekân seçiminin çalışma durumu, yaş, gelir ve kültürel köken gibi çeşitli sosyoekonomik özelliklere bağlı olduğunu bulmuştur.

Aktivite tercihleriyle ilgili yapılan literatür taraması, aktivite seçimlerinin çevresel faktörler, ulaşım türü seçimleri ve zamansal etkilere göre şekillendiğini göstermektedir. Kemperman vd. (2005) kentsel parklara yapılan ziyaretlerde zaman dilimi, hafta içi ile hafta sonu farkı ve yılın mevsimleri gibi değişkenlerin önemli rol oynadığını ortaya koymuşlardır. Araştırmalarında, daha küçük mahalle parkları ile daha büyük bölge ve şehir parkları arasındaki ziyaretçi tercihlerinin nasıl değiştiğini incelemişler ve bu tercihlerde demografik özelliklerin de belirleyici olduğunu göstermişlerdir. Ferdous vd. (2010), yetişkinlerin hafta içi gerçekleştirdikleri aktivite bölümlerini inceleyerek, fiziksel olarak aktif (spor) ve pasif (kültürel ve sosyal faaliyetler) aktiviteler arasındaki farkları araştırmışlardır. Ayrıca, Bhat ve Gossen (2004), hafta sonları gerçekleştirilen ev içi ve ev dışı rekreasyonel aktiviteleri incelemiş ve bu aktivitelerin seçiminde bireylerin sosyal çevresi ile mesafenin etkili olduğunu göstermişlerdir. Bunlara ek olarak, Limtanakool vd. (2006), orta ve uzun mesafeli gezilerde tercih edilen ulaşım türlerinin, bireylerin boş zaman aktivitelerine katılımını nasıl etkilediğini ortaya koymuşlardır. Murat ve Uludağ (2008), Denizli ilindeki geçki seçim problemini anket verileriyle bulanık mantık modeli kullanarak incelemiştir. Çalışma, yolculuk süresi, trafik güvenliği, tıkanma olasılığı ve çevresel etki gibi parametrelerin dikkate alındığı modelin, lojistik regresyon modellerine göre daha gerçekçi sonuçlar sunduğunu göstermektedir. Demir ve Gerçek (2006), Eskişehir'deki orta gelir grubu için ulaşım türü seçim modellerini lojit, yapay sinir ağları, bulanık mantık ve sinir-bulanık yöntemlerle karşılaştırmıştır. Çalışmada, sinir-bulanık modellerin, lojit modele kıyasla daha yüksek tahmin başarımları gösterdiği bulunmuştur. Tablo 1 literatür taraması sonucu öne çıkan yayınları ve aktivite seçimlerine etki eden faktörleri göstermektedir.


Mevcut literatür taraması özetinde, boş zaman aktivitelerinin seçimine yönelik demografik özellikler, çevresel faktörler, ulaşım türü ve zamansal parametrelerin etkilerinin incelendiği birçok çalışmaya rastlanmaktadır. Bu çalışmalar, boş zaman aktivitelerinin belirlenmesinde önemli iç görüler sağlamaktadır. Ancak, literatürde eksikliği hissedilen daha kapsamlı bir model, dijital bilgi seviyesi gibi faktörlerin ve bu faktörlerin diğer demografik ve seyahat parametreleri ile etkileşimlerinin de dikkate alınmasını gerektirmektedir. Bu çalışma, demografik ve seyahat etkilerinin yanı sıra, teknolojik özellikler gibi modern yaşamın bir parçası olan unsurların da boş zaman aktiviteleri seçiminde nasıl bir rol oynadığını inceleyerek literatüre katkıda bulunmaktadır. Ayrıca, İstanbul ilinde boş zaman aktivite seçimlerine etki eden demografik, seyahat ve teknolojik faktörlerin etkilerini inceleyen bir çalışmanın literatürde bulunmaması, bu çalışmanın motivasyonunu oluşturmaktadır.

Araç sahipliği, bireylerin günlük yaşamındaki aktivitelere katılımını ve bu süreçteki seyahat davranışlarını doğrudan etkileyen önemli bir faktördür. Türkiye İstatistik Kurumu (TÜİK) verilerine göre, 2024 Haziran ayı sonu

Tablo 1. Aktivite Seçimleri Literatür Taraması

Referanslar	Demografik Özellikler	Çevresel Faktörler	Ulaşım Türü Etkisi	Zamansal Faktörler
Kemperman vd. (2005)	+	+		+
Ferdous vd. (2010)		+		+
Bhat ve Gossen (2004)		+	+	+
Limtanakool vd. (2006)		+	+	
Zijlstra ve Vlaskamp (2005)	+		+	
Imms vd. (2009)	+			+
Badia vd. (2011)	+	+		
Páez ve Farber (2012)		+		
Pressman vd. (2009)	+	+		+

itibarıyla trafiğe kayıtlı taşıtların %52.5'ini otomobiller oluştururken, Ocak-Haziran 2024 döneminde bir önceki yılın aynı dönemine göre trafiğe kaydı yapılan taşıt sayısı %19.2 artmıştır (TÜİK, 2024). Şekil 1'de 2013-2023 yılları arasında trafiğe kaydedilen otomobil sayıları gösterilmektedir. Yıllar içerisinde gözlemlenen dalgalanmalar mevcut olup, 2015 ve 2016 yıllarında 746 bin seviyelerine ulaşan kayıtlar, 2018 ve 2019'da düşüş göstererek 526 bin ve 386 bin seviyelerine inmiştir. 2020'den itibaren tekrar artışa geçen otomobil kayıtları, 2023 yılında 945 bin ile on yılın en yüksek seviyesine ulaşmıştır.

**Şekil 1.** 2013-2023 Yılları Arasında Trafığe Kaydedilen Otomobil Sayıları

Literatür taramaları, seyahat davranışı ile aktivitelere katılım arasındaki karmaşık etkileşimi inceleyerek, özellikle otomobil erişimi olan bireylerin aktivitelere daha kolay katılabildiklerini ve bu durumun refah seviyelerini artırdığını ortaya koymuştur (Bhat, 1998). Otomobil kullanımı, bireylere seyahat esnekliği ve hız kazandırarak daha geniş coğrafi alanlardaki aktivitelere katılım imkânı sağlamaktadır. Bu da, özellikle şehir merkezi dışındaki bölgelerde yaşayanlar için önemli bir avantaj oluşturmaktadır (Tana ve Chai, 2016).

Araç sahipliği üzerine etki eden faktörler çeşitli çalışmalarda ayrıntılı olarak incelenmiştir. Özellikle gelir düzeyi, bireylerin araç sahibi olup olmamasında belirleyici bir demografik faktör olarak öne çıkmaktadır. Gelir düzeyi, araç sahibi olma kararında belirleyici demografik faktörlerden biridir; düşük gelirli bireyler, yüksek maliyetler nedeniyle araç sahibi olmaktan kaçınırken, daha yüksek gelirli haneler daha fazla araç sahibi olma eğilimindedir (Dargay vd., 2007). Araç sahipliği ayrıca yaş, cinsiyet ve hane halkı özellikleri gibi diğer sosyo-demografik faktörlerden etkilenmektedir (Nolan, 2010). Çelik vd. (2023), Türkiye'de hanehalkı araç ve taşıt sahipliğinin artışının trafik sıkışıklığı, enerji tüketimi ve hava kirliliği gibi sorunları beraberinde getirdiğini, bu davranışın ise konut tipi, park yeri durumu, hanehalkı gelir düzeyi ve toplu taşıma kullanımı gibi önemli etkenlerden etkilendiğini göstermiştir. Ögüt (2004), Türkiye'deki araç sahipliğini çeşitli ekstrapolasyon yöntemleri ile modellemiş ve 2020 yılına kadar kişi başına düşen gayri safi milli hâsıla eğilimlerine dayalı üç farklı senaryo ile tahminlerde bulunmuştur. Bir başka çalışmada, Türkiye'deki araç sahipliğini belirlemek için bulanık çoklu regresyon modeli geliştirilmiş, ekonomik, sosyal ve demografik faktörlerin etkileri analiz edilerek değişkenler arasındaki korelasyon sorununa bulanık olasılık regresyonu ile çözüm getirilmiştir (Ögüt, 2006).

Araç sahipliğini etkileyen bir diğer önemli faktör ise yerleşim çevresidir. Araştırmalar, yerleşim yerinin yapısının ve kullanım şeklinin, bireylerin araç sahibi olma olasılığını önemli ölçüde etkilediğini ortaya koymaktadır. Örneğin, karışık kullanım yoğunluğuna sahip ve nüfus yoğunluğu yüksek bölgelerde yaşayan bireylerin araç sahipliği oranı, daha az yoğunluklu bölgelerde yaşayanlara göre daha düşük olma eğilimindedir (Potoglou ve Kanaroglou, 2008). Buna ek olarak, şehir merkezlerine yakınlık, toplu taşıma seçeneklerinin daha cazip hale gelmesiyle birlikte, araç sahipliğini azaltan bir diğer faktör olarak karşımıza çıkmaktadır (Cervero, 2002). Yin vd. (2024), yoğun ve merkezi bölgelerde yaşayan bireylerin araç sahibi olma olasılığının düşük olduğunu ve bu nedenle spor aktivitelerine daha fazla katıldıklarını tespit etmiştir. Doddamani ve Manoj (2023), mahalle çekiciliği ve temizliğine ilişkin algıların araç ve iki tekerlekli taşıt sahipliği kararlarını etkileyen önemli faktörler olduğunu göstermiştir.

Mevcut literatürde, araç sahipliği ile boş zaman aktiviteleri arasındaki bağlantıların yeterince incelenmemiş olması ve teknolojik özellikler ile diğer faktörlerin etkilerinin de göz önünde bulundurulduğu bir modellemenin eksikliği, bu çalışmanın literatüre önemli bir katkı sağlayacağını göstermektedir. Bu bağlamda çalışmanın iki temel amacı bulunmaktadır:

- (i) Kesikli seçim modellerinden multinomial lojit model ile aktivite seçimlerine etki eden demografik, seyahat ve teknolojik özelliklerin etkilerinin belirlenmesi,
- (ii) ikili lojit model kullanarak araç sahibi olan bireylerin aktivitelere katılımları ile diğer demografik ve teknolojik özelliklerin incelenmesidir.

Bu makalenin materyal, yöntem ve araştırma bulguları bölümleri şu şekilde organize edilmiştir: Materyal ve Tanıtıcı İstatistikler Bölümü, çalışmanın materyalini ve tanıtıcı istatistiklerini sunmaktadır. Yöntem Bölümü, çalışmada tercih edilen yöntemi tanıtarak kesikli seçim modelleri, ikili lojit model ve multinomial lojit modeli detaylı bir şekilde açıklamaktadır. Modelde kullanılacak yarar fonksiyonları, değişkenler ve analiz sonuçları ise Bulgular Bölümünde ele alınmış olup, Sonuç ve Tartışma Bölümünde bulgular tartışılmış ve çalışmanın sonuçlarına yer verilmiştir.

MATERYAL VE TANITICI İSTATİSTİKLER

Çalışmanın materyalini İstanbul ili içerisinde gerçekleştirilen “sayısal uçurum analizi” anketleri oluşturmaktadır. İstanbul Büyükşehir Belediyesi, İstanbul ile ilgili verilerin akademik ve diğer amaçlarla ücretsiz erişilebilmesi için İBB Açık Veri Portalı'nı kurmuştur (İBB Açık veri, 2024). Bu portal üzerinde yer alan, 2021 yılı içerisinde gerçekleştirilmiş anket verilerinden bir kısmı çalışma kapsamında değerlendirilmiştir. Sayısal uçurum analizi çalışması içerisinde kişilere ait demografik özellikler, seyahat özellikleri ve internet ve teknoloji kullanımına ait özellikler sorulmuştur. 39 ilçe ve 959 mahalleden oluşan İstanbul ili için mahalleler bazında yapılan bu anket çalışmasına 6224 katılmış olup, 18 yaş üstü kişilerden veri toplandı portal üzerinde belirtilmektedir.

Çalışma kapsamında boş zaman aktiviteleri verilen cevaplara göre dört farklı kategoriye ayrılmıştır. Kapalı alan aktivitelerini gazete/kitap okuma, müzik dinleme ve sinema/televizyon izleme oluştururken, açık alan aktivitelerini seyahat etme, piknik yapma ve yürüyüş yapma etkinlikleri oluşturmaktadır. Spor aktiviteleri için futbol/voleybol oynama ve egzersiz yapma cevaplarını verenler gruplandırılmıştır. Boş zaman aktivitelerinde diğer cevabını verenler diğer kategorisinde değerlendirilmiştir. Ayrıca, tercih edilen 15 farklı ulaşım türü kendi içerisinde 3 ayrı kategoriye ayrılmıştır. Bu kategoriler toplu taşıma, özel araç ve motorsuz ulaşım şeklindedir.

Veri temizleme sonucunda anket sorularına cevap verilmeyenler, herhangi bir kategoriye ait olmayan cevaplar çıkarılmıştır, böylece 4474 veri elde edilmiştir. Tablo 2 katılımcıların demografik özelliklerini, seyahat özelliklerini ve teknolojik özelliklerini göstermektedir. Ankete katılanların %51.9'u erkek, %48.1'i kadınlardan oluşmaktadır. Katılımcıların %62.9'u evli iken %36.6'sı bekârdır. Çalışma durumu incelendiğinde, %47.1'i çalışıyor ve %52.7'si çalışmıyor. Yaş ortalaması 45.54 olan katılımcıların standart sapması 67.86'dır. Ulaşım türü olarak %70.3'ü toplu taşıma, %26'sı özel araç, %3.6'sı ise motorsuz ulaşımı tercih etmektedir. Araç sahipliği oranları %44.8 araç sahibi ve %54.2 araç sahibi değil şeklindedir. Teknoloji bilgisi ve kullanımını içeren dijital bilgi seviyesi değerlendirildiğinde, %12.2'si düşük, %30.1'i orta ve %28.5'i yüksek bilgi seviyesine sahiptir. Boş zaman aktiviteleri arasında %25.8 açık alan, %62.1 kapalı alan, %6.5 spor ve %5.6 diğer aktiviteler yer almaktadır.


Verileri ikişerli çapraz değerlendirerek yorumlamak, verilerin daha kapsamlı ve derinlemesine anlaşılmasını sağlamaktadır. Şekil 2 boş zaman aktivitelerine katılımın cinsiyetlere göre dağılımını göstermektedir. Buna göre,

Tablo 2. Katılımcıların Demografik, Seyahat Ve Teknolojik Özellikleri

Değişkenler	Frekans	Yüzde
-------------	---------	-------

<i>Cinsiyet</i>		
Erkek	2320	51,9
Kadın	2154	48,1
<i>Medeni Durum</i>		
Evli	2815	62,9
Bekâr	1636	36,6
<i>Çalışma Durumu</i>		
Çalışıyor	2108	47,1
Çalışmıyor	2361	52,7
Yaş	Ortalama: 45,54	Standart Sapma: 67,86
<i>Ulaşım Türü</i>		
Toplu Taşıma	3148	70,3
Özel Araç	1165	26
Motorsuz Ulaşım	161	3,6
<i>Araç Sahipliği</i>		
Araç sahibi	2005	44,8
Araç sahibi değil	2428	54,2
<i>Dijital Bilgi Seviyesi</i>		
Düşük	544	12,2
Orta	1347	30,1
Yüksek	1276	28,5
<i>Boş Zaman Aktiviteleri</i>		
Açık Alan Aktivitesi	1153	25,8
Kapalı Alan Aktivitesi	2778	62,1
Spor Aktivitesi	293	6,5
Diğer	250	5,6

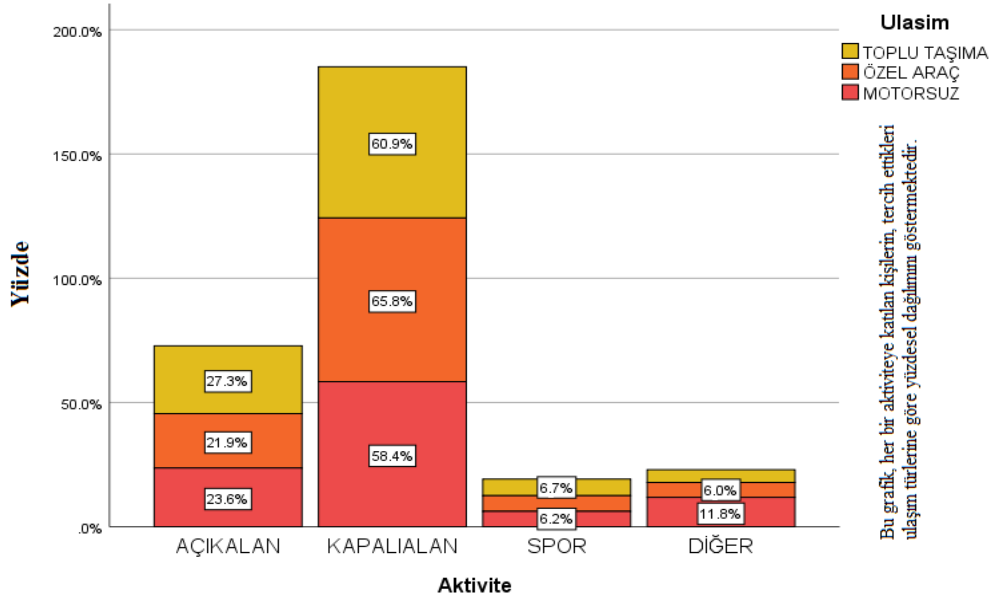
kadınların %26.3'ü ve erkeklerin %25.2'si açık alan aktiviteleri yaparken, kadınların %65.3'ü ve erkeklerin %58.7'si kapalı alan aktivitelerine katılmaktadır. Kadınlar ve erkekler arasında açık alan aktiviteleri yapma oranı benzer seviyelerdeyken, kadınların kapalı alan aktivitelerine erkeklerden daha fazla katıldığı görülmektedir. Kapalı alan aktiviteleri, hem kadınlar hem de erkekler arasında en popüler aktivitedir. Kadınların sadece %2.5'i spor aktiviteleriyle ilgilenirken, erkeklerin %11'i spor aktivitelerine katılmaktadır. Bu, toplamda %6.5'lik bir oranı temsil etmektedir. Spor aktiviteleri, erkekler arasında üçüncü en popüler aktiviteyken, kadınlar arasında dördüncü sırada yer almaktadır. Kadınların %6'ı ve erkeklerin %5.2'si diğer aktiviteleri yapmaktadır.



Şekil 2. Aktivitelerine Katılımın Cinsiyetlere Göre Dağılımı

Şekil 3 aktivitelere katılım ve bu aktiviteleri yapan kişilerin seçtikleri ulaşım türüne ait dağılımı yığılmış çubuk grafiği ile sunmaktadır. Toplu taşıma kullananların %27.3'ü, özel araç kullananların %21.9'u ve motorsuz ulaşımı

tercih edenlerin %23.6'sı açık alan aktiviteleri yapmaktadır. Bu veriler, toplu taşıma kullananların açık alan aktivitelerine diğer gruplara göre daha fazla katıldığını göstermektedir. Toplu taşıma kullananların %60.9'u, özel araç kullananların %65.8'i ve motorsuz ulaşımı tercih edenlerin %58.4'ü kapalı alan aktivitelerine katılmaktadır. Özel araç kullananların kapalı alan aktivitelerine katılım oranı en yüksek iken, motorsuz ulaşımı tercih edenler arasında bu oran biraz daha düşüktür. Toplu taşıma kullananların %6.7'si, özel araç kullananların %6.3'ü ve motorsuz ulaşımı tercih edenlerin %6.2'si spor aktiviteleri ile ilgilenmektedir. Spor aktivitelerine katılım oranı tüm ulaşım türleri arasında oldukça benzerdir. Toplu taşıma kullananların %5.1'i, özel araç kullananların %6.0'ı ve motorsuz ulaşımı tercih edenlerin %11.8'i diğer aktivitelerle ilgilenmektedir. Diğer aktiviteler, özellikle motorsuz ulaşımı tercih edenler arasında daha popüler görünmektedir.



Şekil 3. Tercih Edilen Aktivite Ve Ulaşım Türleri Dağılımı

YÖNTEM

Kesikli seçim modeli, bireylerin veya varlıkların sınırlı sayıda alternatif arasından seçim yaptığı durumları analiz eden bir istatistiksel modeldir. Bu modeller, bireylerin belirli bir alternatifi seçme olasılığını tahmin etmeye ve seçimlerini etkileyen faktörleri ortaya çıkarmaya yardımcı olmaktadır. Çalışma kapsamında, kişilerin hareketlilik içeren aktivite seçimleri ve bu seçimlere etki eden çeşitli seyahat ve demografik faktörlerin incelenmesi için kesikli seçim modellerinden yararlanılmıştır. Böylece, bireylerin seçim sürecindeki davranışları ve bu davranışları etkileyen faktörler daha etkili bir modelleme yöntemiyle analiz edilmiştir.

Ayrıştırılmış talep analizi büyük ölçüde rastgele fayda teoremi çerçevesi altında türetilen ayrık seçim modellerine dayanmaktadır (McFadden, 1974). Bu modeller, karar vericilerin, bireylerin seçim yaparken memnuniyetlerini veya faydalarını en üst düzeye çıkarmak için rasyonel olarak hareket ettikleri, faydayı en üst düzeye çıkaran davranışla hareket ettikleri varsayımına dayanmaktadır. Rastgele fayda teoremine göre seçimlerin faydası sistematik (deterministik) terim ve rassal (stokastik) terimin toplanması ile elde edilir. Burada, sistematik terim bireylerin seçimlerinde belirli ve gözlemlenebilir faktörlerin etkisini temsil ederken rassal terim bireylerin seçimlerinde gözlemlenemeyen veya modellenemeyen faktörlerin etkisini temsil etmektedir. Seçim kümesi içerisinde, C_n , tercih yapan n kişisi $J = 1, \dots, J$ alternatifleri ile karşılaşmaktadır. Bu durumda, fayda fonksiyonu Eşitlik 1'de olduğu şekilde tanımlanmaktadır.

$$U_{nj} = V_{nj} + \varepsilon_{nj} \quad (1)$$

Eşitlikte, U_{nj} , n bireyinin j alternatifinden faydasını, V_{nj} , sistematik terimi, ε_{nj} , rassal terimi ifade etmektedir. Rassal terimin varlığı iki seçenek arasında faydası daha büyük olan seçeneğin seçilme olasılığının daha fazla olduğunu ortaya çıkartmaktadır. Böylece, "i" ve "j" gibi iki seçenek için, "n" bireyinin "i" seçeneğini seçme olasılığı, "n" bireyinin "i" seçeneğinden elde ettiği faydanın "j" seçeneğinden elde ettiği faydadan büyük olma olasılığına eşittir. Bu olasılık Eşitlik 2'de gösterilmektedir.

$$\begin{aligned}
P_{ni} &= Prob(U_{ni} > U_{nj} \forall j \neq i) \\
&= Prob(V_{ni} + \varepsilon_{ni} > V_{nj} + \varepsilon_{nj} \forall j \neq i) \\
&= Prob(\varepsilon_{nj} - \varepsilon_{ni} < V_{ni} - V_{nj} \forall j \neq i)
\end{aligned} \tag{2}$$

Alternatiflere ait stokastik terimlerinin varyanslarının birbirinden bağımsız ve aynı dağılıma (IID) sahip oldukları kabul edilmektedir. Buna göre stokastik terimlerin varyansları Tip 1 uç değer (Gumbel) dağılımına uyması durumunda lojit model, normal dağılıma uyması durumunda probit model olarak adlandırılmaktadır. “i” ve “j” şeklinde iki farklı seçenek arasında tercih yapılması gerektiğinde ikili lojit model kullanılmaktadır. Bu modele göre “i” alternatifinin “i” ve “j” alternatifleri arasından tercih edilme olasılığı Eşitlik 3 ve Eşitlik 4’te verilmiştir.

$$\begin{aligned}
P_{ni} &= Prob(V_{ni} + \varepsilon_{ni} > V_{nj} + \varepsilon_{nj} \forall j \neq i) \\
&= Prob(\varepsilon_{nj} < \varepsilon_{ni} + V_{ni} - V_{nj}) \\
P_{ni} &= \prod_{j \neq i} e^{-e^{\varepsilon_{ni} + V_{ni} - V_{nj}}}
\end{aligned} \tag{3}$$

$$P_{ni} = \int \left(\prod_{j \neq i} e^{-e^{\varepsilon_{ni} + V_{ni} - V_{nj}}} \right) e^{-\varepsilon_{ni}} e^{-e^{-\varepsilon_{ni}}} d\varepsilon_{ni} \tag{3}$$

$$P_{ni} = \frac{e^{V_{ni}}}{\sum_j e^{V_{nj}}} \tag{4}$$

Çalışma kapsamında ikili lojit model (LM) ve Multinomial lojit model (MNL) tercih edilmiştir. İkili lojit model, bireylerin iki alternatif arasında seçim yaptığı durumları analiz etmek için kullanılırken, multinomial lojit model, bireylerin ikiden fazla alternatif arasından seçim yaptığı durumları değerlendiren kesikli seçim modellerinden biridir. Bu model, her bir alternatifin seçilme olasılığını belirlerken, alternatiflerin özelliklerini ve bireylerin bu özelliklere verdiği değerlendirmeleri dikkate almaktadır. Eşitlik 5 MNL model için kullanılan olasılık fonksiyonunu vermektedir.

$$P_{ni} = \frac{\exp(v_i)}{\exp(v_1) + \exp(v_2) + \dots + \exp(v_j)} \tag{5}$$

Multinomial lojit modelinin önemli avantajları bulunmaktadır. MNL modelinin, "Independence of Irrelevant Alternatives" (IIA) özelliğine sahip olması, yani herhangi iki alternatif arasındaki göreceli seçilme olasılığı oranının, diğer alternatiflerin varlığından bağımsız olması, bu avantajlardan biridir (Ben-Akiva ve Lerman, 1985). Bu özellik, yeni bir alternatifin seçim kümesine eklenmesi durumunda talep tahminlerinin kolaylaştırılmasına olanak tanır. Başka bir deyişle, yeni bir alternatif tanıtılmadan önce, mevcut alternatifler üzerinde yapılan seçim modellemesi, yeni alternatifin eklenmesinden sonra da geçerliliğini korumaktadır.

Model tahminlerinin ölçülmesi, çeşitli istatistiksel testler yapılarak gerçekleştirilmektedir. Modelin anlamlılığını test etmek için yaygın olarak kullanılan istatistiksel yöntemler arasında Log olabilirlik testi (LR testi), Pseudo R², ki-kare testi, Hosmer-Lemeshow testi ve t-istatistiği testi bulunmaktadır (Hensher vd., 2005; Domencich ve McFadden, 1975). Bu çalışmada, modelin anlamlılığını test etmek amacıyla log olabilirlik testi, Pseudo R² ve t-istatistiği değerleri kullanılacaktır. İkili lojit ve multinomial lojit modellerin geçerliliğini ve uygunluğunu değerlendirmek için bu istatistiksel yöntemler, modelin açıklayıcı gücünü ve tahmin edilen sonuçların güvenilirliğini ölçmede önemli bir rol oynamaktadır.

Log olabilirlik testi, iki modelin uyum iyiliğini değerlendirmek için kullanılan istatistiksel bir testtir. Bu test, modellerin olabilirlik oranları üzerinden karşılaştırma yaparak, tahmin edilen modelin temel modele kıyasla daha iyi bir uyum sağlayıp sağlamadığını değerlendirir. Temel model (sadece sabitleri içeren model), her alternatif için

ortalama faydayı temsil eder. Bu model, sabitlerin olmadığı bir boş model veya yalnızca sabitlerin bulunduğu bir model olabilir. Tahmin edilen modelin olabilirlik oranı fonksiyonu, temel modele kıyasla istatistiksel olarak daha iyi bir değere sahipse, bu durumda tahmin edilen model anlamlı bir model olarak kabul edilir. Hensher vd. (2005), log-olabilirlik testi değerini hesaplamak için kullanılacak denklemleri tanıtmışlardır. Bu test, modelin açıklayıcılığını ve veriyle olan uyumunu değerlendirerek modelin doğruluğu hakkında bilgi sağlamaktadır. Eşitlik 6'da log olabilirlik oranı formülü gösterilmektedir.


$$LR = -2 \times (\log_0 - \log_1) \quad (6)$$

Burada, LR log olabilirlik oranı, \log_0 , temel modelin log-olabilirlik değerini, \log_1 tahmin edilen modelin değerini göstermektedir.

Pseudo R^2 , kesikli seçim modellerinde modelin açıklayıcı gücünü değerlendirmek için kullanılan bir ölçüttür. Bu değer, modelin bağımlı değişkeni ne kadar iyi açıkladığını ifade eder. Geleneksel doğrusal regresyonda kullanılan R^2 , sürekli değişkenler için uyum iyiliğini ölçerken, Pseudo R^2 , kesikli bağımlı değişkenlerin kullanıldığı modellerde uyum iyiliğini değerlendirmek amacıyla geliştirilmiştir. Pseudo R^2 değeri, sabit terimleri içeren temel modelin olabilirlik değeri ile tahmin edilen modelin olabilirlik değerinin farkının, temel modelin olabilirlik değerine bölünmesi ile edilmektedir. Eşitlik 7 Pseudo R^2 değerinin formülünü vermektedir.

$$\rho^2 = \frac{\log_0 - \log_1}{\log_0} \quad (7)$$

Eşitlikte, ρ^2 Pseudo R^2 değerini, \log_0 , temel modelin log-olabilirlik değerini, \log_1 tahmin edilen modelin değerini yansıtmaktadır. Yönteme ait akış şeması Şekil 4'de gösterilmektedir. İlk aşamada çalışma materyali toplanıp, veriler çalışma amacına göre düzenlenmiş ve veriler temizlenmiştir. Düzenlenen verilere ait tanıttıcı istatistikler hesaplandıktan sonra modellerde kullanılacak yarar fonksiyonları belirlenmiştir. Ardından, verilerin uygunluğunu kontrol etmek ve alternatifler arasında bağımsızlık varsayımı (IIA) özelliğinin kontrol edilmesi için Hausman - McFadden testi gerçekleştirilir. Test sonucunun uygun bulunması halinde Multinomial lojit model uygulanmaktadır. Aynı şekilde, ikili lojit model uygulanıp, modellerin sonuçlarını değerlendirmek amacıyla Hosmer-Lemeshow testi, Log olabilirlik testi (LR testi), Pseudo R^2 değerleri kontrol edilmiştir.



Şekil 4. Yönteme ait Akış Şeması

BULGULAR

2021 yılında gerçekleştirilen sayısal uçurum anket verileri kullanılarak, ilk aşamada MNL modeli ile aktivite seçimlerine etki eden demografik, seyahat ve teknolojik özelliklerin etkileri incelenmiştir. İlk modelde boş zaman aktivite tercihlerinden açık alan aktiviteleri, kapalı alan aktiviteleri ve spor aktiviteleri bağımlı değişken olarak alınmış olup, son kategori olan 'diğer aktivite' seçeneği referans alternatif olarak ele alınmıştır. Ayrıca, çalışma kapsamında ikili lojit model kullanılarak araç sahibi olanların aktivitelere katılımları ile diğer demografik ve teknolojik özellikleri incelenmiştir. Çalışmada kullanılan modeller, model içerisinde yer alan değişkenler ve bu değişkenlere ait gösterimler Tablo 3'te sunulmaktadır.

Tablo 3. Model İçerisinde Yer Alan Değişkenler Ve Gösterimleri

Modeller ve Değişkenler	Alternatifler	Alternatiflerin Gösterimi	
1. Model: Aktivite Tercihleri	Açık Alan Aktivitesi	AA	
	Kapalı Alan Aktivitesi	AK	
	Spor Aktivitesi	S	
	Diğer	D	
2. Model: Araç Sahipliği	Araç sahibi	AS	
	Araç sahibi değil	AD	
	Değişkenler	Cinsiyet	E
			K
		Yaş	Y
	Medeni Durum	EV	
		BE	
	Çalışma Durumu	Ç	
		ÇM	
	Ulaşım Türü	TT	
	ÖA		
	MU		
Etkileşim	Dijital Bilgi Seviyesi	DŞ	
	Düşük	O	
	Orta	YÜ	
		E	

Modellerde kullanılan yarar fonksiyonları aşağıdaki şekilde belirlenmiştir. Eşitlik 7'de tüm boş zaman aktivitelerinde kullanılan yarar fonksiyonu gösterilmektedir. Açık alan, kapalı alan ve spor aktiviteleri için alternatif-spesifik sabit terim tanımlanmış (ASC) olup, modelde kullanılan demografik, seyahat ve teknolojik değişkenlere ait sabit terimler her bir alternatif için değişkenlik gösterecek şekilde tanımlanmıştır. İkinci model kapsamında geliştirilen ikili lojit yaklaşımı ile araç sahibi olan katılımcıların çeşitli özelliklerinin incelendiği modelin yarar fonksiyonu Eşitlik 8'de gösterilmektedir. Eşitlikte, araç sahibi olma durumu için alternatif-spesifik sabit terim tanımlanmış olup, model içerisinde kullanılan diğer değişkenler için alternatif-spesifik özellik gösteren, yani her bir alternatif için farklı değerlere sahip katsayılar tercih edilmiştir.

$$U_{AA,AK,S} = ASC_{AA,AK,S} + \beta_{C-AA,AK,S} * C + \beta_{Y-AA,AK,S} * Y + \beta_{MD-AA,AK,S} * MD + \beta_{ÇD-AA,AK,S} * ÇD + \beta_{UT-AA,AK,S} * UT + \beta_{DBS-AA,AK,S} * DBS + \beta_{EI} * EV * Y + \beta_{E2} * Ç * Y + \beta_{E3} * K * Ç + \epsilon_{AA,AK,S} \quad (7)$$

$$U_{AS} = ASC_{AS} + \beta_{C-AS} * C + \beta_{Y-AS} * Y + \beta_{MD-AS} * MD + \beta_{ÇD-AS} * ÇD + \beta_{UT-AS} * UT + \beta_{DBS-AS} * DBS + \beta_{AA,AK,S-AS} * AK + \epsilon_{AS} \quad (8)$$

Modelde kullanılacak bağımsız değişkenler seçilirken ulaşım modelleri ve literatürden yararlanılmıştır. Modelde kullanılan hanehalkı yaş ortalaması, medeni durum, cinsiyet, kullanılan ulaşım türü gibi değişkenler, literatürde yer alan ulaşım tür seçim modellemelerinde yer alan değişkenlerdir (Bhat, 1998; Chen vd., 2013). Multinomial lojit modelin bu anket verilerine uygun olup olmadığının test edilebilmesi için, alternatifler arasında bağımsızlık varsayımı (IIA) özelliğinin kontrol edilmesi gerekmektedir. Bu bağlamda, Hausman testi kullanılmış (Hausman ve McFadden, 1984) ve hesaplanan değer önem seviyesinden büyük olduğu için, herhangi iki alternatif arasındaki görece seçilme olasılığı oranının, diğer alternatiflerin varlığından bağımsız olması anlamına gelen IIA varsayımının sağlandığı görülmüştür. Böylece, bu verilere MNL modelinin uygulanmasında bir sorun olmadığı anlaşılmıştır. Tablo 4'te aktivite seyahat seçimleri için MNL model sonuçları gösterilmektedir. Tabloda %90 ve %95 güven aralığında

istatistiksel olarak anlamlı bulunan değişkenler belirtilmiş olup, tüm değişkenlere ait katsayı ve t-istatistik değerleri gösterilmektedir.

Multinomial lojit modelde kategorik değişkenler için bir referans kategorisi belirlenir ve bu referans kategoriler modelde yer almamaktadır. Modelde referans alınan kategoriler şunlardır: cinsiyet değişkeninde, erkek olma referans olarak alınmıştır; medeni durum değişkeninde, bekar olma referans olarak alınmıştır; çalışma durumu değişkeninde, çalışmıyor alt kategorisi referans olarak alınmıştır; ulaşım türü değişkeninde, motorsuz ulaşım türü referans olarak alınmıştır; dijital bilgi seviyesi değişkeninde ise yüksek bilgi seviyesi referans olarak alınmıştır.

Model sonuçlarının değerlendirilebilmesi için ve modellerin uyum iyiliğini değerlendirmek adına olabirlik-oranı testi (likelihood ratio tests) ve Pseudo R² testi sonuçları Tablo 4' te gösterilmektedir. Buna göre, olabirlik-oranı test sonucu 597.515 (Sig.: 0.00) olarak hesaplanmış olup, Pseudo R² testi sonucu 0.103 bulunmuştur. Olabirlik-oranı testi sonuçlarına göre modelde kullanılan tüm değişkenlerin %90 güven aralığında anlamlıdır. Sınıflandırma tablo sonuçlarına göre ise % 62.4 oranında aktivitelerin doğru sınıflandırıldığı gözlemlenmiştir.

Tablo 4. MNL Model Sonuçları

Değişkenler	Açık Alan Aktivitesi		Kapalı Alan Aktivitesi		Spor Aktivitesi	
	Katsayı	t-istatistik	Katsayı	t-istatistik	Katsayı	t-istatistik
Alternatif-spesifik Sabit						
Sabit Terim	1,946	2.651**	4.147	5.891**	2.877	3.437**
Cinsiyet						
Kadın	0,072	0.346	0.301	1.663*	-1.449	-5.660**
Medeni Durum						
Evli	-0,528	1.748*	-2.019	2.965**	-1.089	1.771*
Katılımcı Yaşı						
Yaş	0,011	0.786	-0.025	1.786*	-0.037	2.176**
Çalışma Durumu						
Çalışıyor	0,419	1.724*	-0.070	-0.106	0.122	0.159
Ulaşım Türü						
Toplu Taşıma	1,158	3.208**	1.035	3.000**	1.187	2.547**
Özel Araç	0,660	1.650*	0.960	2.513**	1.139	2.251**
Dijital Bilgi Seviyesi						
Düşük bilgi seviyesi	-0,686	1.815*	-1.701	4.610**	-1.260	2.727**
Orta bilgi seviyesi	-0,554	1.810*	-1.207	4.078**	-0.671	2.065**
Etkileşimler						
Medeni durum:Evli*Yaş	0,013	1.733*	0.034	2.429**	0.007	0.389
Çalışma durumu:Çalışıyor*Yaş	-0,012	1.687*	-0.003	0.231	-0.004	0.250
Cinsiyet:Kadın*Çalışma durumu:Çalışıyor	-0,208	0.509	-0.183	0.460	-0.593	1.172
LR İstatistiği				597,515		
Pseudo R ²				0,103		
Doğru tahmin oranı				62,4		

* Parametre %90 güven aralığında anlamlıdır.

** Parametre %95 güven aralığında anlamlıdır.

Modelde referans olarak seçilen değişkenler dışında bulunan alt kategorilerin anlamlılık düzeyleri ve değişkenlere ait katsayı değerleri sunulmuştur. Buna göre, alternatif-spesifik sabitlerin pozitif ve %95 güven aralığında anlamlı değerleri, her bir aktivite türünün bireyler tarafından tercih edilme olasılığını artıran temel caziplik faktörleri olduğunu göstermektedir. Kapalı alan aktivitelerinin en yüksek ASC değerine sahip olması, bu aktivite türünün en çok tercih edilen olduğunu belirtirken, açık alan ve spor aktiviteleri de önemli derecede tercih edilmektedir. Bu sabitler, modeldeki diğer değişkenlerin etkilerinden bağımsız olarak, her bir aktivite türünün genel olarak ne kadar popüler olduğunu ölçmektedir. Bu sabit terimlerin %95 güven aralığında anlamlı olmaları, bu bulguların istatistiksel olarak güvenilir olduğunu ve modelin sağlamlığını desteklediğini göstermektedir.

Kapalı alan aktivitesi tercihinde, kadın olma değişkeninin %90 güven aralığında anlamlı ve katsayısının pozitif olduğu bulunmuştur. Bu bulgu, kadınların kapalı alan aktivitelerini tercih etme eğilimlerinin erkeklere göre daha yüksek olduğunu göstermektedir. Kadın olma değişkeninin açık alan aktivitesi tercihinde ise anlamlı bir etkisi bulunmamakla birlikte, katsayısının pozitif işaretli olduğu görülmüştür. Bu durum, kadınların açık alan aktivitelerine katılım eğilimlerinin erkeklere göre daha yüksek olduğunu ima etmektedir. Spor aktivitesi tercihinde ise, kadın olma

değişkeninin %95 güven aralığında anlamlı ve katsayısının negatif olduğu görülmüştür. Bu sonuç, kadınların spor aktivitelerine katılma eğilimlerinin erkeklere göre daha düşük olduğunu göstermektedir. Gosens ve Rouwendal (2018) erkek bireylerin ormanda yürüyüş yapma gibi açık alan aktivitelerine daha az meyilli olduklarını tespit etmiştir.

Evli olma değişkeni, açık alan aktivitesi tercihinde %90 güven aralığında anlamlı bir etki göstermekle birlikte, negatif katsayıya sahiptir. Bu, evli bireylerin açık alan aktivitelerine katılım eğilimlerinin bekârlara göre daha düşük olduğunu göstermektedir. Kapalı alan aktivitelerinde ise evli olma değişkeni %95 güven aralığında anlamlı ve negatif katsayıya sahiptir, bu da evli bireylerin kapalı alan aktivitelerini bekârlara göre daha az tercih ettiğini gösterir. Spor aktivitesi tercihinde de evli olma değişkeni %90 güven aralığında anlamlı ve katsayısının negatif işaretli olduğu saptanmıştır. Bu, evli bireylerin spor aktivitelerine katılma eğilimlerinin bekârlara göre daha düşük olduğunu göstermektedir. Üç aktivite türü karşılaştırıldığında, bekâr bireylerin kapalı alan aktivitelerini açık alan ve spor aktivitelerine göre daha fazla tercih ettiği görülmektedir.

Açık alan aktivitesi tercihinde yaş değişkeninin anlamlı bir etkisi bulunmamakla birlikte, katsayısının pozitif işaretli olduğu saptanmıştır. Bu, yaşın açık alan aktivitelerine katılım eğiliminde belirgin bir etki yaratmadığını göstermektedir. Kapalı alan aktivitelerinde yaş değişkeni %90 güven aralığında anlamlı ve negatif katsayıya sahiptir, bu durum yaş ilerledikçe kapalı alan aktivitelerine katılma eğiliminin azaldığını gösterir. Spor aktivitelerinde ise yaş değişkeni %95 güven aralığında anlamlı ve negatif katsayıya sahiptir, bu bulgu yaş ilerledikçe spor aktivitelerine katılma eğiliminin azaldığını belirtmektedir. Hassan vd. (2019) spor salonu ve park aktivitelerini seçmede kullanıcı yaşının önemini vurgulamışlardır. Spor salonu aktivite seçimlerinin yaşın azalması ile artarken, park aktivitelerinin yaşın artması ile arttığını gözlemlemişlerdir.

Çalışıyor olma değişkeni, açık alan aktivitesi tercihinde %90 güven aralığında anlamlı ve katsayısının pozitif işaretli olduğu gözlemlenmiştir. Bu bulgu, çalışan bireylerin açık alan aktivitelerine katılma eğilimlerinin çalışmayanlara göre daha yüksek olduğunu göstermektedir. Kapalı alan aktivitesi ve spor aktivitesi tercihlerinde çalışan olma değişkeni anlamlı bir etkisi olmadığı saptanmıştır. Buna göre, çalışma durumunun kapalı alan ve spor aktivitelerine katılma eğiliminde belirgin bir etki yaratmadığı anlaşılmaktadır. Sola ve Vilhelmsen (2022), emekli olan bireylerin herhangi bir aktiviteyi yapmaya istekli olma düzeyinin, çalışan bireylere kıyasla daha düşük olduğunu ortaya koymuştur.

Toplu taşıma kullanmanın açık alan aktivitesi tercihinde %95 güven aralığında anlamlı ve katsayısının pozitif işaretli olduğu görülmektedir. Bu sonuç, toplu taşıma kullanan bireylerin açık alan aktivitelerine katılma eğilimlerinin yüksek olduğunu göstermektedir. Kapalı alan ve spor aktiviteleri tercihlerinde de toplu taşıma kullanmanın %95 güven aralığında anlamlı ve katsayılarının pozitif işaretli olduğu saptanmıştır. Bu durum, toplu taşıma kullanan bireylerin kapalı alan ve spor aktivitelerine katılma eğilimlerinin de yüksek olduğunu göstermektedir. Özel araç kullanmanın açık alan ve kapalı alan aktiviteleri tercihlerinde %90 güven aralığında anlamlı ve katsayılarının pozitif işaretli olduğu bulunmuştur. Spor aktiviteleri tercihinde ise özel araç kullanmanın %95 güven aralığında anlamlı ve katsayısının pozitif işaretli olduğu saptanmıştır. Bu bulgular, özel araç kullanan bireylerin açık alan, kapalı alan ve spor aktivitelerine katılma eğilimlerinin yüksek olduğunu göstermektedir. Sonuç olarak, toplu taşıma kullanan bireylerin açık alan ve kapalı alan aktivitelerine katılma eğilimleri, özel araç kullanan bireylere kıyasla daha yüksektir. Spor aktivitelerine katılma eğilimleri ise her iki ulaşım türü için de benzer seviyededir ve yüksektir.

Teknoloji bilgisi ve kullanımını içeren dijital bilgi seviyesinin düşük olması değişkeni, açık alan aktivitesi tercihinde %90 güven aralığında anlamlı ve katsayısının negatif işaretli olduğu tespit edilmiştir. Bu bulgu, düşük bilgi seviyesine sahip bireylerin açık alan aktivitelerine katılma eğilimlerinin düşük olduğunu göstermektedir. Kapalı alan ve spor aktiviteleri tercihlerinde de düşük bilgi seviyesinin %95 güven aralığında anlamlı ve katsayılarının negatif işaretli olduğu saptanmıştır. Buna göre, düşük bilgi seviyesine sahip bireylerin kapalı alan ve spor aktivitelerine katılma eğilimlerinin düşük olduğu anlaşılmaktadır. Orta bilgi seviyesi değişkeni, açık alan aktivitesi tercihinde %90 güven aralığında anlamlı ve katsayısının negatif işaretli olduğu bulunmuştur. Kapalı alan ve spor aktiviteleri tercihlerinde de orta bilgi seviyesinin %95 güven aralığında anlamlı ve katsayılarının negatif işaretli olduğu saptanmıştır. Bu bulgular, orta bilgi seviyesine sahip bireylerin de genel olarak boş zaman aktivitelerine katılma eğilimlerinin düşük olduğunu göstermektedir.

Etkileşimler kısmında, medeni durum ve yaş etkileşimi, kapalı alan aktivitesi tercihinde %95 güven aralığında anlamlı ve katsayısının pozitif işaretli olduğu bulunmuştur. Bu sonuç, evli bireylerin yaşları arttıkça kapalı alan

aktivitelerine katılma eğilimlerinin arttığını göstermektedir. Açık alan aktiviteleri için medeni durum ve yaş etkileşimi %90 güven aralığında anlamlıdır ve katsayısının pozitif olduğu görülmüştür. Buna göre, evli bireylerin yaşları arttıkça açık alan aktivitelerine katılma olasılığının arttığını gözlemlenmektedir. Çalışma durumu ve yaş etkileşimi ise açık alan aktiviteleri için %90 güven aralığında anlamlı bulunmuş ve katsayısının negatif olduğu gözlemlenmiştir. Bu bulgu, çalışan bireylerin yaşları arttıkça açık alan aktivitelerine katılma olasılığının azaldığını göstermektedir. Cinsiyet ve çalışma durumu etkileşimi ise spor aktiviteleri için %90 güven aralığında anlamlı ve katsayısının negatif olduğu tespit edilmiştir. Bu sonuç, kadın ve çalışan bireylerin spor aktivitelerine katılma olasılığının azaldığını göstermektedir. Diğer etkileşim terimlerinin aktiviteler üzerinde istatistiksel olarak anlamlı bir etkisi bulunmamaktadır.

Etkileşim terimlerinin modele eklenmesinin temel nedeni, değişkenler arasındaki ilişkilerin daha karmaşık olabileceğini ve bu ilişkilerin tek başlarına ele alınan bağımsız değişkenlerle tam olarak açıklanamayabileceğini göstermektedir. Örneğin, cinsiyetin etkisi çalışma durumu veya yaşa bağlı olarak değişebilir; bu durumda, bu etkileşimleri modele dâhil etmek, gerçekte var olan daha karmaşık yapının daha iyi yakalanmasına olanak sağlamaktadır. Böylece model, gerçeğe daha yakın tahminler üretebilir. Ayrıca, etkileşim terimleri eklemek, bağımsız değişkenlerin birleşik etkilerini inceleyerek, belirli gruplar için farklı sonuçlar ve etkiler ortaya çıkmasını sağlamaktadır. Bu, verilerdeki varyasyonların nedenlerinin daha iyi anlaşılmasını sağlayarak, verilerle daha uyumlu bir model oluşturmanın ötesinde, politika yapıcılar veya uygulayıcılar için daha hedeflenmiş öneriler geliştirilmesine de olanak tanımaktadır.

Çalışma kapsamında ikinci model olarak ikili lojit model kullanılmış ve araç sahibi olan bireylerin aktivitelerine katılım durumları, demografik ve teknolojik özelliklerin etkileri bu model ile değerlendirilmiştir. Bağımlı değişken olarak kukla değişken olan araç sahibi olma ya da olmama değişkeni seçilmiştir. Modelde bağımlı değişken olan araç sahibi olmama durumu referans seçilmiştir. Bağımsız değişkenler için multinomial lojit modelde referans alınan değişkenler, bu modelde de aynı şekilde referans olarak kullanılmıştır.

Tablo 5, araç sahibi olan katılımcılar için ikili lojit model sonuçlarını göstermektedir. Tabloda, %90 ve %95 güven aralığında istatistiksel olarak anlamlı bulunan değişkenler belirtilmiş ve tüm değişkenlere ait katsayı ile t-istatistik değerleri gösterilmiştir. Model sonuçlarının ve modellerin uyum iyiliğinin değerlendirilebilmesi için, olabilirlik-oranı testi ve Pseudo R² testi sonuçları aynı tabloda verilmiştir. Uygulanan ikili lojit model sonuçlarına göre, olabilirlik-oranı test istatistiği (ki-kare istatistiği) %95 güven aralığında anlamlı, 9 serbestlik derecesinde ve 265.944 (Sig.: 0.00) olarak hesaplanmış olup, Pseudo R² testi sonucu 0.110 bulunmuştur. Ayrıca, modelin uyum iyiliğini incelemek amacıyla, doğru sınıflandırma yüzdesi ve Hosmer-Lemeshow ölçütleri çalışma kapsamında kullanılmıştır. Hosmer-Lemeshow testine göre, anlamlılık değeri 0.05'ten az ise düşük bir uyum olduğu anlaşılmaktadır. Test sonucunda anlamlılık düzeyi 0.05 değerinden yüksek çıkarak (Sig.: 0.646) modelin veriler için uygun olduğu sonucuna ulaşılır. Buna ek olarak, sınıflandırma tablosu sonucu %74.4 ile araç sahibi olup olmama durumlarının doğru sınıflandırılma oranı tespit edilmiştir.

Modelde referans olarak seçilen değişkenlerin dışındaki alt kategorilerin anlamlılık düzeyleri ve bu değişkenlere ait katsayı değerleri sunulmuştur. Buna göre, alternatif-spesifik sabitlerin %90 güven aralığında anlamlı olduğu ve katsayısının negatif işaretli olduğu belirlenmiştir. Bu durum, referans kategori olan "araç sahibi olmama" durumuna kıyasla, sabit terimden kaynaklanan etkilerin araç sahibi olma olasılığını azalttığını göstermektedir. Böylece, modeldeki diğer değişkenlerden bağımsız olarak genel eğilimlerin araç sahibi olmamaya yöneldiği ve alternatif-spesifik sabitin negatif ve anlamlı olmasının, diğer değişkenlerin etkileri kontrol edildiğinde bile temel eğilimlerin araç sahibi olmamaya doğru olduğu anlaşılmaktadır.

Kadın olma değişkeni ile araç sahibi olma durumu arasındaki ilişkinin %95 güven aralığında anlamlı ve katsayısının negatif işaretli olduğu görülmüştür. Bu durum, kadınların araç sahibi olma olasılığının erkeklere kıyasla daha düşük olduğunu göstermektedir. Cinsiyet değişkeninin kadın olması, araç sahibi olmama olasılığını artıran bir faktördür. Shoham vd. (2015) Amerika Birleşik Devletleri, Seyşeller, Jamaika, Güney Afrika, ve Gana ülkelerinde yaptıkları araştırmada kadın olma cinsiyet faktörü ile araç sahibi olma durumu arasında negatif bir bağlantı ortaya çıkarmışlardır.

Tablo 5. İkili Lojit Model Sonuçları

Değişkenler	Katsayı	t-istatistiği
-------------	---------	---------------

<i>Alternatif-spesifik Sabit</i>		
Sabit Terim	-0.399	-1.691*
<i>Cinsiyet</i>		
Kadın	-0.176	-2.286**
<i>Medeni Durum</i>		
Evli	0.843	9.580**
Katılımcı Yaşı		
Yaş	0.006	1.875*
<i>Çalışma Durumu</i>		
Çalışıyor	-0.040	-0.533
<i>Dijital Bilgi Seviyesi</i>		
Düşük bilgi seviyesi	-1.665	-11.327**
Orta bilgi seviyesi	-1.038	-10.813**
<i>Boş Zaman Aktiviteleri</i>		
Açık Alan Aktivitesi	0.290	1.687*
Kapalı Alan Aktivitesi	0.375	1.761*
Spor Aktivitesi	0.105	0.482
LR İstatistiği		265.944
Pseudo R ²		0.111
Doğru tahmin oranı		74.400

* Parametre %90 güven aralığında anlamlıdır.

** Parametre %95 güven aralığında anlamlıdır.

Araç sahibi olma durumu ile evli olma değişkeni arasındaki ilişkinin %95 güven aralığında anlamlı ve katsayısının pozitif işaretli olduğu belirlenmiştir. Bu sonuç, evli bireylerin bekarlara kıyasla araç sahibi olma olasılığının daha yüksek olduğunu ortaya koymaktadır. Evli bireyler, ailevi sorumluluklar ve ihtiyaçlar nedeniyle araç sahibi olma konusunda daha fazla eğilim gösterebilirler. Oakil vd. (2014) hanehalkı sayısı arttıkça, araç sahibi olma eğiliminin arttığını, hanehalkında bulunan kişi sayısı azaldıkça araç sahibi olma meyilinin azaldığını gözlemlemiştir.

Yaş değişkeninin araç sahibi olma durumu üzerindeki etkisinin %90 güven aralığında anlamlı ve katsayısının pozitif işaretli olduğu gözlemlenmektedir. Bu durum, yaş arttıkça araç sahibi olma olasılığının arttığını göstermektedir. Yaşın artmasıyla birlikte bireylerin gelir düzeyleri ve araç sahibi olma eğilimleri de artabilir. Literatürde de bu durumu destekleyen bulgular mevcuttur. Örneğin, Birleşik Krallık'ta yapılan bir çalışmada (Clark vd., 2016), yetişkinler ve yaşlıların, özellikle emeklilik dönemindeki bireylerin, genç bireylere kıyasla daha fazla araç sahibi olduklarını göstermiştir.

Çalışma durumu ile araç sahibi olma durumu arasındaki ilişkinin %90 veya %95 güven aralığında anlamlı olmadığı belirlenmiştir. Bu bulgu, çalışma durumunun araç sahibi olma olasılığı üzerinde anlamlı bir etkisinin olmadığını göstermektedir. Bununla birlikte, Blumenberg vd. (2020) iş sahibi olmanın araç sahipliğini arttırdığını, emekli olmak ya da işten çıkarılmanın araç sahibi olma durumunu azalttığını belirtmektedir.

Düşük dijital bilgi seviyesi ile araç sahibi olma durumu arasındaki ilişkinin %95 güven aralığında anlamlı ve katsayısının negatif işaretli olduğu tespit edilmiştir. Buna göre, düşük dijital bilgi seviyesine sahip bireylerin araç sahibi olma olasılığının daha düşük olduğunu göstermektedir. Orta dijital bilgi seviyesi için de benzer bir sonuç gözlenmiştir; %95 güven aralığında anlamlı ve negatif işaretlidir. Dijital bilgi seviyesi düşük olan bireyler, araç sahibi olma konusunda daha az eğilim gösterirken, orta dijital bilgi seviyesine sahip olanlar araç sahibi olmaya daha fazla meyillidir.

Boş zaman aktivitelerinden açık alan aktivitesi değişkeni ile araç sahibi olma durumu arasındaki ilişkinin %90 güven aralığında anlamlı ve katsayısının pozitif işaretli olduğu anlaşılmaktadır. Bu bulgu, açık alan aktivitelerine katılımın araç sahibi olma olasılığını artırdığını göstermektedir. Kapalı alan aktivitesi için de benzer bir durum söz konusudur; %90 güven aralığında anlamlı ve pozitif işaretlidir. Spor aktivitesi değişkeni ise %90 veya %95 güven aralığında anlamlı değildir. Açık ve kapalı alan aktivitelerine katılan bireylerin, araç sahibi olma olasılıklarının daha yüksek olduğu söylenebilir.

SONUÇ VE TARTIŞMA

Bu çalışma, boş zaman aktivitelerinin seçimine etki eden faktörleri ve araç sahibi olan bireylerin aktivitelere katılımları ile diğer demografik, seyahat ve teknolojik özellikleri analiz ederek, kentsel planlama ve ulaşım politikalarına yönelik daha bilinçli stratejiler geliştirilmesine katkı sağlamaktadır. Mevcut literatürde boş zaman aktivitelerinin seçiminde demografik özellikler, çevresel faktörler, ulaşım türü ve zamansal parametrelerin etkileri incelenmiş olsa da dijital bilgi seviyesi ve araç sahipliği gibi faktörlerin diğer demografik ve seyahat parametreleriyle etkileşimleri yeterince ele alınmamıştır. Bu eksikliklerin giderilmesi amacıyla, İstanbul'da bu faktörlerin boş zaman aktivite seçimlerine etkisini inceleyen kapsamlı bir modelin geliştirilmesi, bu çalışmanın literatüre önemli bir katkı sağladığını göstermektedir.

Çalışma kapsamında ilk aşamada MNL model kullanılarak aktivite seçimlerine etki eden demografik, seyahat ve teknolojik özelliklerin etkileri incelenmiştir. İkinci aşamada ise ikili lojit model uygulanarak araç sahibi olanların aktivitelere katılımları ile diğer demografik ve teknolojik özellikleri incelenmiştir. Modellerin sonucunda çıkan %90 ve %95 güven aralığında istatistiksel olarak anlamlı bulunan değişkenler belirtilmiş ve tüm değişkenlere ait katsayı ile t-istatistik değerleri verilmiştir. Model sonuçlarının ve modellerin uyum iyiliğinin değerlendirilebilmesi için, olabirlik-oran testi, Hosmer-Lemeshow testi ve Pseudo R² testi sonuçları gösterilmiştir.

Bu çalışmanın bulguları, ulaşım politikaları ve endüstriyel stratejilerin geliştirilmesinde önemli katkılar sunmaktadır. Modellerin sonuçlarına göre, kadınların spor aktivitelerine katılma ve araç sahibi olma konusundaki düşük eğilimleri, toplumsal normlar ve spora erişim olanaklarının farklılığından kaynaklanıyor olabilir. Bu bulgular, karar vericilere cinsiyet odaklı politika geliştirme konusunda yol gösterebilir. Özellikle kadınların spor aktivitelerine katılımını artırma hedefli programlar geliştirilmesi, kadınların ulaşım ihtiyaçlarına özel olarak odaklanılması, toplu taşıma altyapısının iyileştirilmesi veya kadınların araç sahibi olma önündeki engellerin azaltılması gibi teşvik edici politikaların oluşturulmasına katkı sağlayabilir.

Evli olma değişkeninin tüm aktivite türleri üzerinde negatif etkisi ve araç sahipliği üzerinde pozitif etkisi, evli bireylerin ailevi sorumlulukları, zaman kısıtlamaları ve daha fazla hareketliliğe ihtiyaç duymalarıyla açıklanabilir. Karar vericiler ve endüstriyel profesyoneller, bu bulgular doğrultusunda evli bireylerin ihtiyaçlarına yönelik daha esnek ve erişilebilir aktivite seçenekleri sunarak, onların katılımını artırmayı hedefleyebilirler. Aynı şekilde, ailelerin ihtiyaçlarını karşılayacak uygun fiyatlı araç sahipliği programları veya aile dostu ulaşım politikaları da geliştirilebilir.

Modeller sonucunda, yaş ilerledikçe kapalı alan ve spor aktivitelerine katılımın azaldığı, ancak araç sahibi olma olasılığının arttığı tespit edilmiştir. Kapalı alan ve aktiviteleri genellikle daha fazla fiziksel enerji ve dinamizm gerektirebilir; bu da yaş ilerledikçe katılımı azaltabilir. Diğer yandan, yaşla birlikte bireylerin iş hayatında daha fazla deneyim kazanmaları ve ailevi sorumluluklarının artması, araç sahibi olma gerekliliğini artırmaktadır. Bu bulgulara göre, yaşlı bireylerin katılımını teşvik etmek amacıyla açık alan aktiviteleri için daha erişilebilir ve cazip seçenekler sunulabilir. Ayrıca, genç bireyler için araç sahibi olmayı teşvik edici politikalar geliştirilebilir.

Çalışıyor olma değişkeninin açık alan aktivitelerini tercih etme üzerinde pozitif ve anlamlı bir etkisi olması, çalışan bireylerin bu tür aktivitelere katılma eğilimlerinin daha yüksek olduğunu göstermektedir. Bu durum, çalışanların genellikle hafta sonları veya işten sonra açık havada vakit geçirme ihtiyacı ve isteğiyle açıklanabilir. Kapalı alan ve spor aktivitelerine katılımın ve araç sahibi olma durumunun anlamlı bulunmaması ise, bir bireyin araç sahibi olma olasılığının çalışıyor olup olmamasından bağımsız olduğunu, ayrıca kapalı alan ve spor aktivitelerinin genellikle zamandan bağımsız olarak tercih edildiğini veya iş yoğunluğunun bu tür aktivitelere katılımı sınırlamadığını göstermektedir. Bu bulgular doğrultusunda, ulaşım ve şehir planlamacıları, çalışan bireylerin açık alan aktivitelerine yönelik taleplerini karşılayacak altyapı ve hizmetleri geliştirmeli, ayrıca araç sahipliğini artırmaya yönelik politikaların yalnızca istihdam durumuna odaklanmayıp, daha geniş kapsamlı stratejiler geliştirilmesi gerektiğini göz önünde bulundurmalıdır.

Model sonucunda elde edilen bulgular, toplu taşıma kullanan bireylerin daha geniş bir yelpazede aktivitelere katılma eğiliminde olduklarını, özellikle açık alan ve kapalı alan aktivitelerinde bu eğilimin özel araç kullanan bireylere göre daha yüksek olduğunu göstermektedir. Toplu taşımanın daha erişilebilir ve yaygın olduğu bölgelerde yaşayanların, çeşitli aktivitelere bulunma fırsatlarının daha fazla olduğu düşünülebilir. Özel araç kullananların da hem açık hem kapalı alan aktivitelerine katılım eğilimlerinin yüksek olduğu görülmektedir, bu da özel araç sahipliğinin bireylerin aktivitelere olan etkileşimlerini artırdığını gösterebilir. Sonuç olarak, her iki ulaşım türü de spor aktivitelerine

katılımı teşvik etmektedir, ancak toplu taşımanın özellikle farklı aktiviteler arasında geçiş yapmayı kolaylaştırdığı söylenebilir. Bu bulgular, ulaşım politikalarının çeşitlendirilmesi ve erişilebilirliğin artırılması gerektiğini, böylece bireylerin farklı aktivitelere daha kolay erişebilmelerinin sağlanabileceğini işaret etmektedir. Ulaşım planlarının, bireylerin çeşitli aktivitelere katılımını arttırabilmeleri için ulaşım türlerini çeşitlendirmeleri, ulaşım ağlarının erişilebilir ve entegre hale getirilmesi, hizmet kalitesinin artırılması ve uygun fiyatlandırma ile teşvikler sağlanması gerekmektedir.

Çalışma bulguları, düşük ve orta seviyede dijital bilgiye sahip bireylerin hem açık alan hem de kapalı alan aktivitelerine ve spor aktivitelerine katılım eğilimlerinin düşük olduğunu, ayrıca bu bireylerin araç sahibi olma olasılığının da düşük olduğunu ortaya koymaktadır. Özellikle dijital platformlar üzerinden sunulan bilgilere erişim eksikliği veya bu platformları etkin kullanamama durumu, bu kişilerin etkinlikleri planlama ve katılma kapasitelerini sınırlayabilir ve araç sahibi olma isteklerini azaltabilir. Bu durum, karar vericilere dijital bilgi seviyesinin artırılması yoluyla bireylerin sosyal ve fiziksel aktivitelere katılımını teşvik etme gerekliliğini vurgulamaktadır. Eğitim programları ve dijital becerilerin geliştirilmesine yönelik girişimler, toplumsal katılımın artırılmasına ve bireylerin yaşam kalitesinin yükseltilmesine katkıda bulunabilir.

Model sonuçları, demografik ve çalışma durumu gibi değişkenlerin etkisinin yaş, medeni durum ve cinsiyet gibi faktörlerle etkileşim halinde değerlendirildiğinde önemli farklılıklar ortaya çıkabileceğini göstermektedir. Evli bireylerin yaşlandıkça hem kapalı hem de açık alan aktivitelerine katılım eğilimlerinin artması, bu yaş grubunun ev içi veya daha az fiziksel güç gerektiren aktiviteleri tercih etme eğiliminde olduğunu ortaya koymaktadır. Diğer yandan, çalışma durumu ve yaş etkileşiminin açık alan aktivitelerinde negatif bir etkisi olması, çalışan bireylerin yaşlandıkça bu tür aktivitelerden uzaklaştığını göstermektedir. Bu, iş yükü ve yaşlanmanın getirdiği fiziksel kısıtlamalarla ilişkili olabilir. Son olarak, cinsiyet ve çalışma durumu etkileşiminin spor aktiviteleri üzerinde negatif bir etki yapması, özellikle çalışan kadınların bu tür aktiviteleri daha az tercih ettiğini işaret etmektedir. Bu sonuçlar, politika yapımcıların ve endüstriyel profesyonellerin, demografik ve çalışma durumu etkileşimlerinin aktiviteler üzerindeki etkilerini dikkate alarak daha hedeflenmiş ve etkili stratejiler geliştirmelerine olanak tanıyabilir.

Modelde yer alan cinsiyet ve çalışma durumu etkileşimi, bireylerin aktivite seçimleri üzerindeki karmaşık ilişkilerin daha derinlemesine anlaşılmasını sağlamaktadır. Cinsiyetin sosyal normlar ve kültürel yapılar çerçevesinde bireylerin boş zaman aktivitelerini şekillendirdiği bilinmektedir. Özellikle kadınlar, toplumdaki rolleri ve beklentileri doğrultusunda belirli aktivitelere katılmada farklı tercihler gösterebilirler. Bu durum, çalışma hayatındaki rollerle birleştiğinde daha belirgin hale gelmektedir. Kadınların çalışma durumu ile aktivite tercihleri arasındaki ilişki, hem zaman yönetimi hem de iş-yaşam dengesi ile doğrudan bağlantılıdır. Çalışan kadınlar, iş yoğunluğu nedeniyle daha az zaman bulurken, iş dışı zamanlarında genellikle daha sınırlı veya belirli aktivitelere yönelme eğilimindedir. Bu nedenle, cinsiyet ve çalışma durumu etkileşimi, bireylerin aktivite tercihlerindeki çeşitliliği ve dinamikleri daha iyi açıklamak adına önem taşımaktadır.

Elde edilen bulgulara göre, cinsiyet ve çalışma durumu etkileşimi, özellikle spor aktiviteleri gibi zaman ve enerji gerektiren aktivitelere katılmada anlamlı farklılıklar yaratmaktadır. Kadınların çalışma durumu, bu tür aktivitelerdeki katılım seviyelerini düşürebilirken, bu etkinin erkeklerde daha az belirgin olduğu gözlemlenmiştir. Bu durum, çalışma koşulları ile bireylerin cinsiyete dayalı boş zaman aktivitelerine yönelik fırsatlarının farklılaşmasına işaret eder. Bu bağlamda, modelde bu etkileşimlerin yer alması, bireylerin günlük hayatlarına ve toplumsal normlara bağlı olarak nasıl farklı aktivitelere yöneldiğini anlamaya yardımcı olmakta ve politika yapımcıların daha özel ve hedefe yönelik stratejiler oluşturmasını sağlamaktadır.

Benzer şekilde, medeni durum ve yaş ile çalışma durumu ve yaş etkileşimleri de, bireylerin yaşam evrelerine bağlı olarak değişen sosyal roller ve sorumluluklar doğrultusunda boş zaman aktivitelerine katılım tercihlerine ışık tutmaktadır. Evli bireyler yaşlandıkça, fiziksel kısıtlamalar ve aile odaklı yaşam biçimleri nedeniyle kapalı alan aktivitelerini daha fazla tercih edebilmektedir. Bu durum, yaşla birlikte enerji gereksinimlerinin değişmesi ve sosyal etkileşimlerin ev ve aile çevresine odaklanmasıyla ilişkilendirilebilir. Benzer şekilde, çalışan bireylerin yaşlandıkça iş dışı zamanlarını daha stratejik kullanmaları, fiziksel olarak daha az zorlayıcı aktiviteleri tercih etmelerine yol açabilir. Çalışan ve daha yaşlı bireyler, açık alan veya spor gibi fiziksel aktivite gerektiren seçenekler yerine, kapalı alan aktivitelerine veya daha az enerji harcanan seçeneklere yönelebilirler. Bu etkileşimlerin analizi, farklı demografik grupların değişen ihtiyaçları ve tercihleri doğrultusunda daha etkili ve özgün çözümler üretilmesine zemin hazırlar.

Ulaştırma sektöründeki uygulayıcılara ve araştırmacılara bireylerin demografik, sosyo-ekonomik ve dijital bilgi seviyeleri gibi çeşitli faktörlerin ulaşım tercihleri ve boş zaman aktivitelerine katılım üzerindeki etkilerini anlamak açısından değerli bilgiler sunmaktadır. Özellikle, farklı yaş grupları, medeni durumlar, çalışma durumları ve cinsiyetin aktiviteler üzerindeki etkileri, ulaşım planlamasında daha kişiselleştirilmiş yaklaşımlar geliştirilmesine olanak tanıyabilir. Ayrıca, dijital bilgi seviyesinin araç sahibi olma ve aktivitelere katılım üzerindeki etkisi, teknolojik gelişmelerin ve dijital eşitsizliklerin ulaşım davranışları üzerindeki etkilerini anlamak için önemli ipuçları vermektedir. Bu bulgular, politika yapımcıların ve sektör profesyonellerinin ulaşım hizmetlerini daha verimli, kapsayıcı ve kullanıcı dostu hale getirecek stratejiler geliştirmelerine yardımcı olabilir.

Gelecek çalışmalarda, daha geniş bir veri seti ile farklı sosyo-ekonomik grupların ve bölgelerin dâhil edilmesi, sonuçların kapsamını artırabilir. Ayrıca, zaman içindeki değişimleri izlemek için uzun dönemli panel veri analizleri yapılması önerilmektedir. Ek olarak, çevresel faktörler, yaşam tarzı, sağlık durumu ve psikolojik özellikler gibi yeni değişkenlerin modele dâhil edilmesi, bireylerin ulaşım ve aktivite tercihleri üzerinde daha kapsamlı bir anlayış sunabilir. Ulaşım politikalarının simülasyonları yapılarak, bu politikaların olası etkileri değerlendirilebilir ve hızla gelişen teknolojilerin ulaşım tercihleri üzerindeki etkileri daha derinlemesine araştırılabilir. Bunun yanı sıra, sonraki çalışmalarda aktivite türlerinin daha detaylı olarak ayrıştırılması, literatüre daha fazla katkı sağlayabilir. Bu öneriler, ulaşım sektöründeki uygulayıcılar ve araştırmacılar için daha etkili ve hedefe yönelik politikalar geliştirilmesine yardımcı olacaktır.

KAYNAKLAR

- Badia, M., Orgaz, B. M., Verdugo, M. A., Ullan, A. M., & Martínez, M. M. (2011). Personal factors and perceived barriers to participation in leisure activities for young and adults with developmental disabilities. *Research in Developmental Disabilities*, 32(6), 2055-2063. <https://doi.org/10.1016/j.ridd.2011.08.007>
- Ben-Akiva, M. E., & Lerman, S. R. (1985). *Discrete choice analysis: theory and application to travel demand* (Vol. 9). MIT press.
- Bhat, C. R. (1998). Analysis of travel mode and departure time choice for urban shopping trips. *Transportation Research Part B: Methodological*, 32(6), 361-371. [https://doi.org/10.1016/S0191-2615\(98\)00004-6](https://doi.org/10.1016/S0191-2615(98)00004-6)
- Bhat, C. R., & Gossen, R. (2004). A mixed multinomial logit model analysis of weekend recreational episode type choice. *Transportation Research Part B: Methodological*, 38(9), 767-787. <https://doi.org/10.1016/j.trb.2003.10.003>
- Blumenberg, E., Brown, A., & Schouten, A. (2020). Car-deficit households: determinants and implications for household travel in the US. *Transportation*, 47, 1103-1125. <https://doi.org/10.1007/s11116-018-9956-6>
- Çelik, A. K., Kabakuş, N., & Tortum, A. (2023). Influential factors of household car and vehicle ownership in urban areas of Turkey. *Transportation Research Record*, 2677(6), 218-240. <https://doi.org/10.1177/03611981221145138>
- Cervero, R. (2002). Built environments and mode choice: toward a normative framework. *Transportation Research Part D: Transport and Environment*, 7(4), 265-284. [https://doi.org/10.1016/S1361-9209\(01\)00024-4](https://doi.org/10.1016/S1361-9209(01)00024-4)
- Chen, X., Liu, X., & Li, F. (2013). Comparative study on mode split discrete choice models. *Journal of Modern Transportation*, 21(4), 266-272. <https://doi.org/10.1007/s40534-013-0028-5>
- Clark, B., Chatterjee, K., & Melia, S. (2016). Changes in level of household car ownership: the role of life events and spatial context. *Transportation*, 43, 565-599. <https://doi.org/10.1007/s11116-015-9589-y>
- Dargay, J., Gately, D., & Sommer, M. (2007). Vehicle ownership and income growth, worldwide: 1960-2030. *The Energy Journal*, 28(4), 143-170. <https://doi.org/10.5547/ISSN0195-6574-EJ-Vol28-No4-7>
- Demir, Y. K., & Gerçek, H. (2010). Ulaştırma türü seçiminde esnek hesaplama yöntemleri. *İTÜDERGİSİ/d*, 5(6).
- Doddamani, C., & Manoj, M. (2023). Analysis of the influences of built environment measures on household car and motorcycle ownership decisions in Hubli-Dharwad cities. *Transportation*, 50(1), 205-243. <https://doi.org/10.1007/s11116-021-10242-z>
- Domencich, Thomas and McFadden, Daniel. *Urban travel demand*. Amsterdam: North- Holland, 1975.
- Ferdous, N., Eluru, N., Bhat, C. R., & Meloni, I. (2010). A multivariate ordered-response model system for adults' weekday activity episode generation by activity purpose and social context. *Transportation Research Part B: Methodological*, 44(8-9), 922-943. <https://doi.org/10.1016/j.trb.2010.02.002>

- Gosens, T., & Rouwendal, J. (2018). Nature-based outdoor recreation trips: Duration, travel mode and location. *Transportation Research Part A: Policy and Practice*, 116, 513-530. <https://doi.org/10.1016/j.tra.2018.06.024>
- Gramsch Calvo, B., & Axhausen, K. W. (2024). The Importance of the Social Environment on Leisure Destination Choice: A Mixed Multinomial Analysis of Homophilic Preferences. *Arbeitsberichte Verkehrs-und Raumplanung*, 1853. <https://doi.org/10.3929/ethz-b-000682385>
- Hassan, M. N., Najmi, A., & Rashidi, T. H. (2019). A two-stage recreational destination choice study incorporating fuzzy logic in discrete choice modelling. *Transportation Research Part F: Traffic Psychology and Behaviour*, 67, 123-141. <https://doi.org/10.1016/j.trf.2019.10.015>
- Hausmann, J. and McFadden, D. L. (1984) A specification test for the multinomial logit model, *Econometrica*, 52, 1219-40. <https://doi.org/10.2307/1910997>
- Hensher, D. A., Rose, J. M., & Greene, W. H. (2005). *Applied choice analysis: a primer*. Cambridge University Press.
- Imms, C., Reilly, S., Carlin, J., & Dodd, K. J. (2009). Characteristics influencing participation of Australian children with cerebral palsy. *Disability and Rehabilitation*, 31(26), 2204-2215. <https://doi.org/10.3109/09638280902971406>
- İstanbul Büyükşehir Belediyesi, Dijital Uçurum Haritası Verileri, <https://data.ibb.gov.tr/dataset/dijital-ucurum-haritasi-verileri>, (Erişim Tarihi: 05.08.2024).
- Kemperman, A. D., Ponjé, M. M., & Timmermans, H. J. (2005). Analyzing heterogeneity and substitution in trip-making propensity to urban parks: A mixed logit model. *Tourism Analysis*, 10(3), 223-232. <https://doi.org/10.3727/108354205775322925>
- Limtanakool, N., Dijst, M., & Schwanen, T. (2006). The influence of socioeconomic characteristics, land use and travel time considerations on mode choice for medium-and longer-distance trips. *Journal of Transport Geography*, 14(5), 327-341. <https://doi.org/10.1016/j.jtrangeo.2005.06.004>
- McFadden, D. (1974). The measurement of urban travel demand. *Journal of Public Economics*, 3(4), 303-328. [https://doi.org/10.1016/0047-2727\(74\)90003-6](https://doi.org/10.1016/0047-2727(74)90003-6)
- Murat, Y. Ş., & Uludağ, N. (2008). Bulanık mantık ve lojistik regresyon yöntemleri ile ulaşım ağlarında geçki seçim davranışının modellenmesi. *Teknik Dergi*, 19(92), 4363-4379.
- Nolan, A. (2010). A dynamic analysis of household car ownership. *Transportation Research Part A: Policy and Practice*, 44(6), 446-455. <https://doi.org/10.1016/j.tra.2010.03.018>
- Oakil, A. T. M., Ettema, D., Arentze, T., & Timmermans, H. (2014). Changing household car ownership level and life cycle events: an action in anticipation or an action on occurrence. *Transportation*, 41, 889-904. <https://doi.org/10.1007/s11116-013-9507-0>
- Öğüt, K. S. (2004). S-curve models to determine the car ownership in Turkey. *ITU ARI Bulletin of Istanbul Technical University*, 54(02), 65-69.
- Öğüt, S. K. (2006). Modeling car ownership in Turkey using fuzzy regression. *Transportation Planning and Technology*, 29(3), 233-248.
- Páez, A., & Farber, S. (2012). Participation and desire: leisure activities among Canadian adults with disabilities. *Transportation*, 39, 1055-1078. <https://doi.org/10.1007/s11116-012-9385-x>
- Potoglou, D., & Kanaroglou, P. S. (2008). Modelling car ownership in urban areas: a case study of Hamilton, Canada. *Journal of Transport Geography*, 16(1), 42-54. <https://doi.org/10.1016/j.jtrangeo.2007.01.006>
- Pressman, S. D., Matthews, K. A., Cohen, S., Martire, L. M., Scheier, M., Baum, A., & Schulz, R. (2009). Association of enjoyable leisure activities with psychological and physical well being. *Psychosomatic Medicine*, 71(7), 725-732. DOI: 10.1097/PSY.0b013e3181ad7978
- Shoham, D. A., Dugas, L. R., Bovet, P., Forrester, T. E., Lambert, E. V., Plange-Rhule, J., ... & Luke, A. (2015). Association of car ownership and physical activity across the spectrum of human development: Modeling the Epidemiologic Transition Study (METS). *BMC Public Health*, 15, 1-10. <https://doi.org/10.1186/s12889-015-1435-9>
- Sola, A. G., & Vilhelmson, B. (2022). To choose, or not to choose, a nearby activity option: Understanding the gendered role of proximity in urban settings. *Journal of Transport Geography*, 99, 103301. <https://doi.org/10.1016/j.jtrangeo.2022.103301>

Tana, Kwan, M. P., & Chai, Y. (2016). Urban form, car ownership and activity space in inner suburbs: A comparison between Beijing (China) and Chicago (United States). *Urban Studies*, 53(9), 1784-1802. <https://doi.org/10.1177/0042098015581123>

TÜİK, Ulaştırma ve Haberleşme İstatistikleri, "Motorlu Kara Taşıt Sayısı", Haziran 2024, <https://www.tuik.gov.tr/>, (Erişim Tarihi: 05.08.2024).

Yin, C., Chen, Y., & Sun, B. (2024). Examining the relationship between car ownership, car use, and exercise: Role of the built environment. *Cities*, 149, 104943. <https://doi.org/10.1016/j.cities.2024.104943>

Zijlstra, H. P., & Vlaskamp, C. (2005). Leisure provision for persons with profound intellectual and multiple disabilities: quality time or killing time?. *Journal of Intellectual Disability Research*, 49(6), 434-448. <https://doi.org/10.1111/j.1365-2788.2005.00689.x>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 10.08.2024
Kabul Tarihi : 03.10.2024

Received Date : 10.08.2024
Accepted Date : 03.10.2024

İGNİMBİRİTLERE AİT FARKLI TANE BÜYÜKLÜĞÜNE SAHİP TAŞ TOZU VE EPOKSİ REÇİNE ESASLI KOMPOZİTLERİN TUZ ETKİSİNE BAĞLI HASARLARA KARŞI KORUMA POTANSİYELİNİN İNCELENMESİ

INVESTIGATION OF THE PROTECTION POTENTIAL OF STONE POWDER WITH DIFFERENT GRAIN SIZES BELONGING TO İGNİMBRITES AND EPOXY RESIN BASED OF COMPOSITES AGAINST DAMAGE DUE TO SALT EFFECT

Ahmet Cihat ARI¹ (ORCID: 0000-0002-4690-8968)

¹ Yozgat Bozok Üniversitesi, Mimarlık ve Şehir Planlama Bölümü, Yozgat, Türkiye

*Sorumlu Yazar / Corresponding Author: Ahmet Cihat ARI, a.cihat.ari@bozok.edu.tr

ÖZET

Yapıların inşasında kullanılan taşlar nem oranı, tuz kristalleşmesi, iklimsel etkiler, hava kirliliği ve biyolojik faktörler gibi nedenlerden dolayı bozulmaya uğramaktadır. Tuz kristalleşmesi taşların bozulmasında en etkili faktörlerden birisidir. Taşlarda tuz kristalleşmesi yoluyla; çürümeler, çatlaklar ve aşınmalar gibi tahribatlara yol açmaktadır. Bu çalışmada, ignimbirit taş tozu (İTT) ve epoksi reçine (ER) esaslı kompozitlerin, yapı taşlarında tuz kristalleşmesi hasarlarına karşı onarımında kullanılması amaçlanmaktadır. Bu amaçla, Nevşehir ili ve çevresinden çıkarılan, yapıların inşaatında kullanılan ignimbiritlere ait farklı tane büyüklüğüne (63 µm, 150 µm, 250 µm, 500 µm, 1000 µm) sahip taş tozu ve matriks olarak epoksi reçine ile kompozitler hazırlanmıştır. Kompozitlerin tuz etkisine bağlı hasarlara karşı koruma potansiyelinin incelenmesi için; su emme, görünür yoğunluk, açık gözeneklilik ve tuz kristalleşmesi deneyleri yapılmıştır. Deney sonucuna göre, % 70 oranında <63 µm büyüklüğüne sahip İTT örneğinin, diğer örneklerle göre tuz etkisine karşı daha dirençli olduğu belirlenmiştir. Bu kompozit, yapı taşlarının tuz etkisine karşı korunmasında etkili olduğundan, yapıların tuz kristalizasyonu ile oluşan çürümüş kısımlarının onarımı için harç enjeksiyon uygulamasıyla kullanılabilirliği sonucuna varılmıştır.

Anahtar Kelimeler: Epoksi matrisli kompozitler, tuz direnci, güçlendirme, onarım, ignimbirit taşı

ABSTRACT

The stones used in the construction of buildings are subject to deterioration due to reasons such as humidity, salt crystallization, climatic effects, air pollution and biological factors. Salt crystallization is one of the most effective factors in the deterioration of stones. It causes damages such as decay, cracks and abrasions in stones through salt crystallization. This study aims to use ignimbrite stone powder (ISP) and epoxy resin (ER) based composites in the repair of salt crystallization damages in building stones. For this purpose, composites were prepared with stone powder of different grain sizes (63 µm, 150 µm, 250 µm, 500 µm, 1000 µm) belonging to ignimbrites extracted from Nevşehir province and its surroundings and used in the construction of structures, and epoxy resin as matrix. To investigate the protection potential of the composites against salt-induced damage; water absorption, apparent density, open porosity and salt crystallization experiments were carried out. According to the experiment results, it was determined that the ISP sample with a size of <63 µm at 70 wt.% was more resistant to salt effects than other samples. Since this composite is effective in protecting building stones against salt effects, it has been concluded that it can be used with mortar injection application for the repair of decayed parts of structures caused by salt crystallization.

Keywords: Epoxy matrix composites, salt resistance, reinforcement, repair, ignimbrite stone

ToCite: ARI, A. C., (2025). İGNİMBİRİTLERE AİT FARKLI TANE BÜYÜKLÜĞÜNE SAHİP TAŞ TOZU VE EPOKSİ REÇİNE ESASLI KOMPOZİTLERİN TUZ ETKİSİNE BAĞLI HASARLARA KARŞI KORUMA POTANSİYELİNİN İNCELENMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 169-178.

GİRİŞ

Tuz kristalleşmesi yapı malzemelerinin bozulmasına neden olan temel faktörlerden biri olarak kabul edilmektedir (Moropoulou vd., 2003). Özellikle gözenekli taşlarda tuz kristalleşmesi; çiçeklenme, kabuklanma ve yüzey aşınmaları gibi çürüme biçimlerine neden olmaktadır. Taşın gözeneklerinin içine giren tuz kristallerinin büyümesi ve hızlı buharlaşma koşulları taşta iç kuvvetleri oluşturmaktadır. Bu durum taşlarda hasarların boyutunu arttırmakta ve yapıların dayanıklılığına ciddi şekilde zarar vermektedir (da Fonseca vd., 2023). Malzemedeki bu hasarların oluşmasında özellikle gözenek oranı ve geometrisi etkili olmaktadır. Gözeneklilik malzemenin sıvı hareketlerini düzenlediği için, tuz kristalleşme sürecinde bozulmanın oluşmasında başlıca parametrelerden biridir. Ayrıca su emme oranı, yoğunluk ve ağırlık miktarındaki değişim gibi faktörler taşıdaki bozulmanın bir göstergesi olarak kabul edilmektedir. Dolayısıyla taşlarda tuz etkisine bağlı hasarların azaltılmasını, önlenmesini ve yapıların dayanıklılığını sağlamak için bu bozulma faktörlerinin incelenmesi önemlidir (Ruffolo vd., 2017). Literatürde taşların tuz etkisine bağlı bozulma faktörleri üzerinde birkaç çalışma yürütülmüştür. Örneğin Benavente vd. (1999) yaptıkları çalışmada, yüksek gözenek içeren taşların tuzlu su emme oranı, kristalleşme olasılığını önemli ölçüde arttırdığı tespit edilmiştir. Lubelli vd. (2007) tarafından yapılan başka bir çalışmada ise, taşlarda sodyum klorür tuzunun hidrofilik yüzeylere göre hidrofobik yüzeylerde daha çok kristalleştirdiğini göstermişlerdir.

Yapılardaki hasarların onarımı ve korunmasında polimer matriksli kompozitlerin kullanımı günümüzde giderek hız kazanmaktadır. Polimer matriksli kompozitler, harç enjeksiyon uygulamasıyla hasar gören malzemenin iç kısımlarına enjekte edilerek, çürüme kaynaklı oluşan boşluklar doldurulmaktadır. Bu uygulama yöntemi, yapıya zarar vermeden yapının hasar gören kısımlarının ve taşıma gücünün iyileştirilmesini sağlamaktadır (D'Arienzo vd., 2008). Tuz kristalleşmesine bağlı hasarların azaltılması için kullanılacak kompozitlerde, polimer matriks ile dolgu maddesi arasındaki arayüz etkileşimi önemli yere sahiptir. Bu etkileşim sonucunda bazı bileşiklerde, malzemenin iç basıncı artarak genleşme sorunları görülmektedir. Bu durum tuz kristallerinden daha fazla hasarlara neden olabilmektedir (Granneman vd., 2019). Bu nedenle polimer matriksli kompozitlerin, tuz etkisine bağlı bozulma süreçleri incelendikten sonra yapıların onarımında kullanılması gerekmektedir. Taşları hasarlara karşı korumak için kullanılan polimer malzemelere; epoksi reçine, akrilik reçine, etil silikat, polietilen glikol örnek olarak verilebilir (Chen vd., 2023). Literatürde, taşların tuz kristalleşmesi hasarlarında kullanılabilecek polimer matriksli kompozit malzemelere yönelik çalışmalar yapıldığı görülmektedir. Örneğin Andreotti vd. (2019) yaptıkları çalışmada, poliakrilik esaslı kompozitlerin, taşların gözenek oranını iyileştirerek, tuz emiliminin azaldığını ve tuz kristalleşmesi hasarlarına karşı daha dirençli olduğunu belirlemişlerdir. Jia vd. (2021) tarafından yapılan çalışmada, kumtaşı ve silikat esaslı kompozitler, taşların gözenek yüzeylerini doldurarak tuz etkisine bağlı hasarlara karşı önleyici performans gösterdiği tespit edilmiştir. Luan vd. (2008) tarafından yapılan başka bir çalışmada ise, epoksi reçine ve silikat esaslı kompozitler, taşların gözenek ve su emme oranının azalmasını sağlayarak, tuz kristalleşmesi hasarları üzerinde belirgin bir koruyucu etkiye sahip olduğunu göstermişlerdir. Görüldüğü gibi polimer matriksli kompozitlerde, matriks ve dolgu arasındaki kimyasal tepkime sonucunda oluşan bağ kuvveti, taşların gözenek ve su emme oranlarını azaltarak, tuz kristalizasyon hasarlarına karşı direncini arttırmaktadır. Ancak taşların ve polimer malzemelerin farklı özelliklere sahip olması, farklı yapısal davranış göstermesine neden olmaktadır. Ayrıca matriks ve dolgu malzemelerinin bileşimi sırasında oluşan etkileşim türüne göre, kompozitlerin tuz etkisine bağlı hasarlara karşı koruma potansiyelleri değişmektedir.

Nevşehir ili; peri bacaları, ören yerleri, eşsiz doğal güzellikleri, yeraltı şehirleri ve çeşitli dönem uygarlıklarına ait mimari eserleriyle tarihi ve kültürel miras açısından önemli bir yere sahiptir. Nevşehir ilindeki tarihi yapılarda ve piroklastik kayaç özelliğine sahip ignimbirit taşı kullanılmıştır (Kaşmer vd., 2013). Ayrıca bu taş günümüzde yapılarda süsleyici görünümleri nedeniyle dış cephe kaplamasında, yapı elemanlarında ve restorasyon uygulamalarında kullanılmaktadır (Korkanç, 2007). Ancak ignimbirit taşının yüksek gözenekliliği nedeniyle kılcal su emme potansiyelini arttırmaktadır. Bölgede inşa edilen birçok tarihi ve doğal miras yapısının bozulmasında ve ayrışmasında ignimbirit taşının su emme potansiyeli önemli rol oynamaktadır (Dinçer ve Bostancı, 2019). Bu durum, ignimbirit taşının aşınma mekanizmalarıyla ilgili çalışmaların yapılmasına neden olmuştur. Literatürde ignimbirit taşının ayrışması üzerinde; tuz kristalleşmesinin etkisi (Özşen vd., 2017), nem nedeniyle oluşan dayanıklılığın azalması (Topal ve Doyuran, 1997), kılcal su emme özelliklerinin bozulmasındaki rolü (Dinçer ve Bostancı, 2019), liken büyümesinden dolayı oluşan hasarlar (Garcia-Vallès vd., 2003) ve rüzgar erozyonuna bağlı oluşan bozulmalar (Aydar ve Akkaş, 2022) incelenmiştir. Ancak, epoksi matriksli kompozitlerin ignimbirit taşların tuz etkisine bağlı bozulma süreçleriyle oluşan hasarları önleme yetenekleri üzerine literatürde herhangi bir çalışmaya rastlanılmamıştır.

Bu nedenle, kompozitlerin tuz etkisine bağlı bozulma süreçlerine yönelik davranışının belirlenmesi ve yapıların bakım, onarım ve koruma projeleri için oldukça önemlidir.

Bu çalışma kapsamında yapı taşlarında tuz kristalleşmesi hasarlarının onarımında kullanılmak amacıyla Nevşehir ili ve çevresinden çıkarılan, yapıların inşaatında kullanılan ignimbirit taş tozu (İTT) ve epoksi reçine (ER) ile kompozitler üretilmiştir. Kompozitlerin üretiminde; ignimbiritlere ait farklı tane büyüklüğüne (63 µm, 150 µm, 250 µm, 500 µm, 1000 µm) sahip taş tozu ve matriks olarak epoksi reçine kullanılmıştır. Elde edilen kompozitlerin; su emme, görünür yoğunluk, açık gözeneklilik ve tuz kristalleştirmesi deneyleri yapılmıştır. Bu deneylerle, elde edilen kompozitlerin tuz etkisine karşı korunmasında etkili olup olmadığı belirlenmiştir.

MATERYAL VE METOT

Materyal

İgnimbirit, volkanik hareketler sonucu yeryüzüne çıkan pomza ve volkanik kaya parçaları sonucu oluşan piroklastik kayaların yüksek sıcaklık etkisi altında birikmesi ve soğumasıyla oluşmaktadır (Moon, 1993; Walker, 1983). Nevşehir ilinde geniş alanlarda yüzeylenen Kavak ignimbiritleri bölgedeki yapıların inşaatlarında yaygın bir şekilde kullanılmaktadır (Korkanç, 2007). Ürgüp Formasyonunun en alt bölümünde Kavak ignimbiritleri en eski piroklastik yatakları temsil etmektedir. Kavak ignimbiritinin kimyasal bileşimlerine göre dasit, trakiandezit ve riyolit bileşimine sahiptir (Tablo 1) (Çiflikli, 2020).

Tablo 1. Kavak İgnimbiritlerinin Kimyasal Bileşimi (Korkanç, 2007)

Oksit	Ağırlık (%)
SiO ₂	78,44
Al ₂ O ₃	13,9
Fe ₂ O ₃	0,78
MgO	0,02
CaO	0,05
Na ₂ O	0,03
K ₂ O	0,13
TiO ₂	0,23
P ₂ O ₅	0,04
MnO	<0,01
Cr ₂ O ₃	<0,001
A.K. (1000°C)	6,4
Toplam	100,05

Bu çalışmada kompozitlerin üretiminde dolgu olarak ignimbirit taş tozu (İTT) ve matriks olarak epoksi reçine (ER) kullanılmıştır. İTT Nevşehir ilinde taş üretimi yapan firmadan temin edilmiştir. Kompozitlerde matriks olarak kullanılan ER'de A ve B olarak iki bileşen bulunmaktadır. ER'nin A bileşeni bisfenol-A tipi kimyasal bileşiği içerirken, ER'nin B bileşeni ise cycloalifatik poliamin sertleştirici maddesini içermektedir. Deneylerde kullanılan malzemelerin bazı özellikleri Tablo 2'de verilmiştir.


Tablo 2. Çalışma Kapsamında Kullanılan Malzemelerin Bazı Özellikleri (Url1; Url2)

Kullanılan Malzemeler	Fiziksel Özellikleri
İgnimbirit Taş Tozu (İTT)	Renk: Sarı
	Yoğunluk (g.cm ⁻³ , 20°C'de): 1,50–1,58
	Su emme (% , 23°C'de): 24,83
Epoksi Reçine (ER)	Renk ve Görünüm: Şeffaf ve Parlak
	Yoğunluk (g.cm ⁻³ , 20°C'de): 1,10
	Karışım Oranı (A/B): 5/3
	Viskozite (cps, 20°C'de): 520–550
	Karışım Ömrü (25°C): 30 dakika
	Kuruma Süresi (25°C): 12 saat
Mekanik Mukavemet: 7 gün	

Kompozit Örneklerin Hazırlanması

İgnimbirit taşlarının çıkarılması sırasında ve yapıların inşaatlarında kullanılmasında taş kesim atıkları oluşmaktadır. Taşların uygun boyutlara getirilmesinde ve işlenme sırasında ortaya çıkan kesim atıkları Retsch AS 200 elek cihazıyla farklı boyutlarda (63 µm, 150 µm, 250 µm, 500 µm ve 1000 µm) elek set aparatları kullanılarak elenmiştir. Her bir elek set aparatlarına 100 g taş kesim atıkları yerleştirilerek 10 dakika boyunca sarsma işlemi uygulanmıştır. Eleme işlemin sonunda istenilen boyutlarda ignimbirit taş tozu (İTT) elde edilmiştir.

İgnimbirit taşının kesim atığı olan İTT, reçine üretimine göre maliyetsiz olarak kabul edilir. Ayrıca taş atıklarının birikimini azaltmak, çevre kirliliğini önlemek ve ekonomiye kazandırmak bu atıkların inşaat sektöründe yeniden kullanımı açısından daha fazla avantajlara sahiptir. Bu nedenle bu çalışmada, kompozitlerin hazırlanmasında taş tozlarının mümkün olduğu kadar yüksek oranda kullanılması hedeflenmiştir. Bunun için en yüksek İTT oranına sahip kompozitlerin geliştirilmesi için ön çalışmalar yapılmıştır. Ön çalışmalarda % 30, % 50, % 70 ve % 80 İTT oranına sahip kompozitler hazırlanmıştır. Bu ön çalışmalar sonucunda örnek bütünlüğünü koruyan en yüksek İTT oranının ağırlıkça % 70 olduğu belirlenmiştir. Ancak kompozitlerin hazırlanmasında % 70 İTT oranı aşıldığında, matris miktarının örnek bütünlüğünü korumada yetersiz olduğu gözlemlenmiştir (Şekil 1). Bu nedenle, deney çalışmaları için % 30 oranında epoksi matrisi ve % 70 oranında İTT'lerin olduğu kompozitler seçilmiştir.

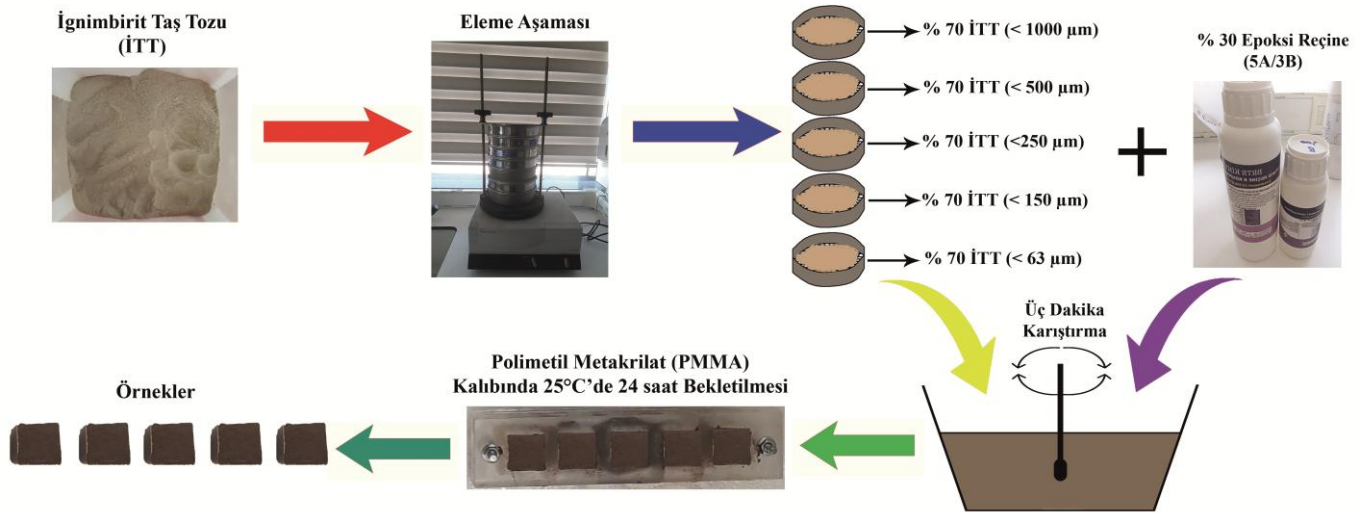


Şekil 1. a. % 70 İTT Oranının Üzerinde Hazırlanan Örneğin Parçalanması b. % 70 İTT Oranına Sahip Örneğin Yapı Bütünlüğünü Koruması

Kompozit örneklerinin hazırlanmasında el yatırma yöntemi kullanılmıştır. Bu yöntem; herhangi bir ısı işlem gerektirmemesi, daha az miktarda ekipman kullanarak üretim maliyetinin azalması, uygulama koşullarında sertleşerek hızlı ve kolay şekilde üretimin yapılması gibi nedenlerden tercih edilmiştir. ER/İTT kompozit örneklerinin hazırlanması için % 30 oranında epoksi reçine ve % 70 oranında <63 µm büyüklüğüne sahip İTT'ler bir kaba koyulmuştur. Daha sonra bu karışım üç dakika boyunca elle karıştırılmıştır. ER'nin A ve B iki bileşenin karışım oranı, üretici firmanın tavsiye ettiği 5:3 oranına göre hazırlanmıştır. Bileşenleri 5:3 oranında karıştırmak için 5 birim A bileşeni, 3 birim B bileşeni ilave edilmiştir. Taş tozu ve epoksi reçine ilave edilmiş bu karışım üç dakika kadar tekrar karıştırılmış olup, 20x20x20 mm boyutlarında polimetil metakrilat (PMMA) kalıbına dökülmüştür. Kalıpta bu karışım 25°C'de 24 saat bekletilmiştir. Bu süre sonunda kompozit örneklerin sertleşmesi tamamlanmış olup, deneysel çalışmalarında gerçekleştirmek için kalıptan çıkarılmıştır. Kalıptan çıkarılan bu örnekler KÖ63 olarak isim verilmiştir. Benzer işlem süreçleri epoksi matrisine, <150 µm, <250 µm, <500 µm ve <1000 µm tane büyüklüklerine sahip ignimbirit taş tozlarının ilavesi ile tekrarlanmış olup, sırasıyla KÖ150, KÖ250, KÖ500 ve KÖ1000 olarak isimlendirilen diğer kompozit örnekler hazırlanmıştır. Tüm kompozit türlerinin her birinden 5'er adet küp örnekler hazırlanarak deney çalışmalarının ölçümüne hazır hale getirilmiştir. Deney çalışmaları kapsamında üretilen kompozit örneklerin kısaltmaları ve içerikleri Tablo 3'de verilmiştir. Kompozit örneklerin hazırlama aşamaları Şekil 2'de kısaca özetlenmiştir.

Tablo 3. Deney Çalışmaları Kapsamında Üretilen Kompozit Örneklerin Kısaltmaları Ve İçerikleri

Kompozit Örneklerin (KÖ) Kısaltmaları	ER/İTT Oranı (%)	İTT Boyutları (µm)
KÖ63	30/70	<63
KÖ150	30/70	<150
KÖ250	30/70	<250
KÖ500	30/70	<500
KÖ1000	30/70	<1000



Şekil 2. Kompozit Örnekleri Hazırlama Aşamaları

Yöntem

Tuz Kristalizasyonu Deneyi

Kompozitlerin tuz kristalleşme deneyi TS EN 12370 (2001) standardına göre, % 14'lük çözeltiler hazırlanarak yapılmıştır. Bu çözeltiler içerisine kompozit örnekler 20°C'de 2 saat bekletilmiştir. Bu süre sonunda kompozit örnekler 16 saat etüv fırında 105°C'de kurutulduktan sonra 2 saat oda sıcaklığında soğuması için bekletilmiştir. Bu işlemler 10 kez tekrar edilmiş olup, 10. işlemin sonunda, örneğinin ağırlığı ile deney öncesi örneğinin kuru ağırlığı arasındaki fark not edilmiştir.

Su Emme Deneyi

Kompozit örneklerin su emme deneyi ASTM D570-98 (2005) standardına göre gerçekleştirilmiştir. Deney öncesi kompozit örneklerin kuru ağırlıkları 0,001 g hassasiyetli hassas terazide ölçülmüştür. Daha sonra saf su dolu kaplarda bu örnekler 20°C'de 24 saat bekletilmiştir. Bu işlem sonrasında su emmiş örneklerin 0,001 g hassasiyetli hassas terazide ağırlıkları kaydedilmiştir. Son olarak örneklerin su emmiş ağırlığı ile kuru ağırlığı arasındaki fark kaydedilerek kompozit örneklerin su emme oranlarındaki değişim tespit edilmiştir.

Görünür Yoğunluk

Kompozit örneklerin görünür yoğunluk değerlerinin belirlenmesinde TS EN 1936 (2010) standardına göre gerçekleştirilmiştir. Görünür yoğunluk değerlerinin belirlenmesi için, su emmiş örneklerin öncelikle 100°C etüv fırında sabit kütleye gelinceye kadar kurutma işlemi yapılmıştır. Bu örnekleri nem ve rutubetten korumak için desikatörün içinde oda sıcaklığında 2 saat soğuması için bekletilmiştir. Bu işlemden sonra desikatörün içerisinden örnekler çıkarılarak 0,001 g hassasiyetli hassas terazide ağırlıkları not edilmiştir. Daha sonra su emmiş örneklerin ağırlıkları ve su içerisinde örneklerin ağırlıkları arasındaki fark kaydedilmiştir.

Açık Gözeneklilik

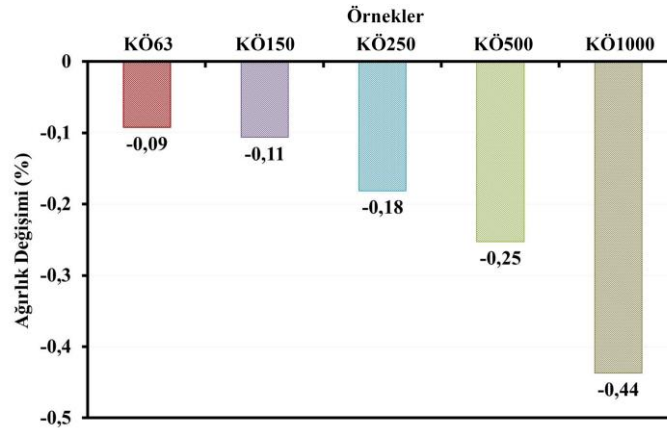
Kompozit örneklerin açık gözeneklilik değerlerinin belirlenmesi için, su emmiş örneklerin öncelikle 100°C etüv fırında sabit kütleye gelinceye kadar kurutma işlemi yapılmıştır. Yeterince kuruyan örnekler, desikatörün içine koyulmuş ve oda sıcaklığında 2 saat soğuması için bekletilmiştir. Bu süre sonrasında desikatörün içerisinden örnekler çıkarılarak 0,001 g hassasiyetli hassas terazide ağırlıkları tartılmıştır. Son olarak su emmiş örneklerin ağırlıkları ve su içerisinde örneklerin ağırlıkları arasındaki fark not edilerek, TS EN 1936 (2010) standardına göre hesaplanmıştır.

ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Tuz Kristalizasyonu Deneyinin Sonuçları

Kompozit örneklerin tuz kristalizasyon deneyinde ölçülen kuru ağırlık değişimi Şekil 3'de verilmiştir. Şekil 3'de verilen sonuca göre, kompozit örneklerin ağırlık değişiminde % 0,09 ile % 0,44 kadar azalış göstermiştir. Tuz kristalizasyon deneyinden sonra ağırlık değişimlerinin % 1 oranından daha düşük olması, kompozit örneklerin yapısal bütünlüğünün korunduğunu ifade etmektedir. Epoksi matriksine <63 µm büyüklüğüne sahip İTT

eklendiğinde elde edilen KÖ63 kompozitin tuz kristalizasyon deneyi sonunda % 0,09 oranında çok düşük bir ağırlık kaybı tespit edilmiştir. Ancak tanecik boyutu her ne olursa olsun tüm kompozitlerin tuz kristalizasyon deneyinden sonra fiziksel görünümü ve renginde herhangi bir değişiklik gözlemlenmemiştir. İTT'lerin boyutu 63 µm üstüne çıkarıldığında elde edilen kompozitlerde, tuz kristalizasyon deneyi sonrasında ağırlık kaybında lineer bir artış olduğu tespit edilmiştir. Bu sonuç, İTT'lerin boyutu 63 µm üstüne çıkarıldığında matriks ile etkileşime girebilen partiküllerin toplam yüzey alanının azalması, kompozitlerin tuz kristalizasyon direncinin azalmasına neden olduğunu göstermektedir.




Şekil 3. Kompozit Örneklerin Tuz Kristalizasyonu Deneyinin Sonunda Kuru Ağırlık Değişimi

Literatürde taşların ve polimer kompozitlerin tuz kristalleşme hasarlarına yönelik bazı çalışmaların yapıldığı görülmektedir (Andreotti vd., 2019; Pinna vd., 2011; Topal ve Doyuran, 1998). Örneğin, Topal ve Doyuran (1998) tarafından gerçekleştirilen çalışmada, ignimbirit taşının tuz kristalizasyon deneyi sonucunda % 1,62 ağırlık kaybı olduğu tespit edilmiştir. Dolayısıyla bu araştırma kapsamında, kompozit örneklerin tuz kristalizasyon deneyi sonunda kuru ağırlık değişimleri, ignimbirit taşının tuz kristalizasyon deneyi sonunda kuru ağırlık değişiminden daha az olduğu görülmektedir. Bu sonuç, polimer matriksli kompozitlerin yıpranmış taşların tuz etkisine bağlı hasarlarının restorasyonu için harç enjeksiyon uygulamasıyla kullanılabilirliğini göstermektedir. Benzer sonuç, Pinna vd. (2011) tarafından gerçekleştirilen çalışmada, kireçtaşı ve mermerlerin tuz etkisine bağlı hasarların restorasyonu için polimer matriksli kompozitler önerilmiştir. Aynı çalışmada, polimer matriksli kompozitlerin tuz kristallerinin büyümesini engellediği belirlenmiştir. Ayrıca polimerler gözeneklere su girişini önleyerek, tuzun çözünmesini engellemekte, kompozitler taşların tuz direncinin iyileştirmesine katkı sağlamaktadır (Andreotti vd., 2019; Vacchiano vd., 2008). Ancak literatürde taş tozu ve epoksi matriks esaslı kompozitlerin tuz kristalleşmesi hasarlarına yönelik yeterince çalışma bulunmamaktadır. Bundan dolayı bu araştırma kapsamında ER/İTT kompozitleri için tuz kristalizasyon deneyi sonunda kuru ağırlık değişimlerinin ölçülmesi, literatüre önemli bir katkı sağlayacağı beklenmektedir.

Açık Gözeneklilik Değerlerinin Sonuçları

Taşların gözenek yüzeylerinden emilen tuzun, buharlaşma sırasında kristalleşmesiyle basınç oluşmaktadır (Scherer, 1999). Bu durum sonucunda yeni çatlakların oluşması ve gözeneklerin genişlemesiyle; taşlarda parçalanma, ayrılma ve kırılma gibi hasarlara neden olabilmektedir (Scherer vd., 2001). Bu nedenle taşların onarımında kullanılacak kompozitlerin tuz etkisine karşı direncini araştırmak için kullanılan parametrelerden biri malzemenin gözenek oranıdır (Benavente vd., 2004). Kompozit örneklerin açık gözeneklilik değerlerinin sonuçları Şekil 4'de verilmiştir. Şekil 4'de verilen sonuca göre, kompozit örneklerin açık gözeneklilik değerleri % 6,64 ile % 11,61 arasında değişmektedir. Epoksi matriksine <63 µm büyüklüğüne sahip İTT eklendiğinde elde edilen KÖ63 kompozitin % 6,64 ile en düşük açık gözenek oranına sahip olduğu belirlenmiştir. Kompozitlerdeki İTT tanecik boyutunun büyüklüğünün artmasına bağlı olarak açık gözenek oranı da artmaktadır. Kompozitlerde daha fazla açık gözeneklilik oranının olması, tuz kristallerine karşı dayanıklılığının azalmasına neden olmaktadır (Şekil 3). Korkanç ve Solak (2016) tarafından gerçekleştirilen çalışmada, Kavak ignimbirit taşının gözenek oranının % 16,54 olduğu tespit edilmiştir. Bu araştırma kapsamında elde edilen ER/İTT kompozitlerin, ignimbirit taşlarından daha az gözeneklere sahiptir. Epoksi reçinesinin taş tozlarının gözeneklerini doldurarak kompozitlerin ignimbirit taşlarından daha az gözeneklilik sergilemesini sağlamaktadır. Ayrıca literatürde Alves vd. (2020) tarafından yapılan çalışmada, taş tozlarına epoksi reçinesi eklenmesiyle elde edilen kompozitin, taşlardan daha az bir gözenek sergilediği

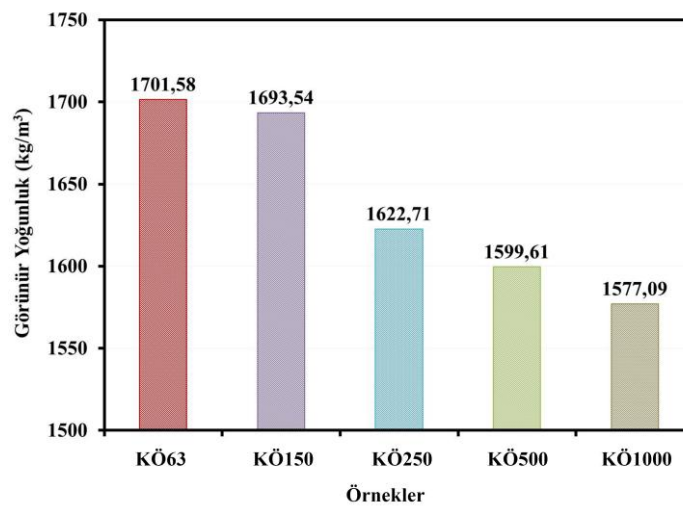
belirlenmiştir. Dolayısıyla bu araştırma kapsamında ölçülen açık gözeneklilik oranlarının literatürdeki ilgili çalışmaların sonuçlarıyla uyumlu olduğu görülmektedir.



Şekil 4. Kompozit Örneklerin Açık Gözeneklilik (%) Değerlerindeki Değişim

Görünür Yoğunluk Değerlerinin Sonuçları


Kompozit örneklerin görünür yoğunluk değerlerinin sonuçları Şekil 5’de verilmiştir. Şekil 5’de verilen sonuca göre, kompozit örneklerin görünür yoğunluk değerleri $1577,09 \text{ kg/m}^3$ ile $1701,58 \text{ kg/m}^3$ arasında değişmektedir. Kompozitler arasından en yüksek görünür yoğunluğu $1701,58 \text{ kg/m}^3$ değeri ile epoksi matrisine $<63 \mu\text{m}$ büyüklüğüne sahip İTT eklendiğinde elde edilen KÖ63 kompozitidir. Ancak İTT’lerin boyutu $63 \mu\text{m}$ üstüne çıkarıldığında elde edilen kompozitlerin görünür yoğunluk değerlerinin KÖ63 kompozitinin görünür yoğunluk değerlerine göre azaldığı tespit edilmiştir. Örneğin hazırlanan KÖ150, KÖ250, KÖ500 ve KÖ1000 kompozitlerinin görünür yoğunluk değerleri, KÖ63 örneğinin görünür yoğunluk değerine göre sırasıyla yaklaşık % 0,47, % 4,63, % 5,99 ve % 7,31 azalış göstermiştir. Kompozitlerin yoğunluğunun değişmesinde açık gözenek oranının birbirinden farklı olması etkili olmaktadır. Açık gözeneklilik oranının az olduğu kompozitin yüzeyinde tuz birikmesiyle kompozitte görünür yoğunluğunun artmasına neden olmaktadır (Şekil 4 ve Şekil 5). Bu nedenle KÖ63 kompozitin % 6,64 oranında açık gözeneklilik değeri, diğer kompozitler arasından en düşük değerde olması bu kompozit $1701,58 \text{ kg/m}^3$ görünür yoğunluğuyla diğer kompozitler arasında en yüksek değere sahip olmasını sağlamıştır. Literatürde Moropoulou vd. (2003) tarafından yapılan çalışmada, polimer kompozitler, taşların gözenek yüzeylerini azaltarak tuz kristallerini yüzey üzerinde biriktirerek malzemenin yoğunluğunu arttırdığı ifade edilmiştir. Bu nedenle bu çalışma kapsamında ölçülen görünür yoğunluk değerlerinin literatürdeki ilgili çalışmaların sonuçlarıyla uyumlu olduğu görülmektedir.



Şekil 5. Kompozit Örneklerin Görünür Yoğunluk (kg/m^3) Değerlerindeki Değişim

Su Emme Deneyinin Sonuçları

Yapı taşlarına, atmosferik ve nem etkileriyle suyun nüfuz etmesi tuz kristalleşmesi hasarlarına neden olmaktadır (Raneri vd., 2016). Bu nedenle, kompozitlerin tuz etkisine bağlı bozulma sürecini daha iyi anlamak için su emme deneyi yapılmıştır. Kompozit örneklerin su emme değerlerinin sonuçları Şekil 6'da verilmiştir. Şekil 6'da verilen sonuca göre, kompozit örneklerin su emme değerleri % 1,01 ile % 4,81 arasında değişmektedir. Kompozitlerdeki İTT tanecik boyutunun büyüklüğünün artmasına bağlı olarak su emme oranı da artmaktadır. Bu sonuç, açık gözeneklilik değerlerinin sonuçlarıyla uyumlu olarak, epoksi matriks ile etkileşime girebilen taş tozlarının yüzey alanının azalması su girişini önleyen koruyucu ince bir tabaka oluşturmasıyla ilişkilendirilebilir. Literatürde ignimbirit taşının su emme değerleri % 17 ile % 28,08 arasında değişmektedir (Erguler, 2009; Topal ve Doyuran, 1998). Dolayısıyla bu araştırma kapsamında, kompozit örneklerin su emme değerlerinin, ignimbirit taşının su emme değerlerinden daha az olduğu görülmektedir. Bu sonuç, kompozitlerin yıpranmış taşların su emmeden kaynaklı hasarlar için kullanılabileceğini göstermektedir. Literatürde polimer kompozitlerin su emmeden kaynaklı hasarlarına yönelik bazı çalışmaların yapıldığı görülmektedir. Örneğin Sahu vd. (2020) tarafından yapılan çalışmada, epoksi reçine ve taş tozu esaslı hibrit polimer esaslı kompozitlerin yaklaşık % 0,01 çok düşük bir su emilimi olduğunu göstermiştir. Arumugam vd. (2023) başka bir çalışmada ise, granit tozu ve epoksi matriks esaslı kompozitlerin suya karşı dirençli bir özellik sergilediğini belirlemiştir. Bu çalışmalarda, polimer malzemelerin suyun taşlara girişini önleyerek, çürüme sürecini yavaşlattığı belirtilmiştir. Bu nedenle ER/İTT kompozitlerin ölçülen su emme değerlerinin literatürdeki ilgili çalışmaların sonuçlarıyla uyumlu olduğu görülmektedir.



Şekil 6. Kompozit Örneklerin Su Emme (%) Değerlerindeki Değişim

SONUÇLAR

Polimer matriksli kompozitlerde, harç enjeksiyonu uygulaması, yapılarda çürümüş ve hasarlı kısımların restorasyonunda kullanılan yaygın uygulama yöntemlerinden biridir. Bu yöntem, yapıya zarar vermeden yapının hasar gören kısımlarını ve taşıma gücünü iyileştirmesi nedeniyle tercih edilmektedir. Ancak yapılardaki taşların ve polimer malzemelerin farklı özelliklere sahip olması, farklı yapısal davranış göstermesi nedeniyle, yapıların restorasyonundan önce polimer matriksli kompozitler hakkında yapılacak araştırmalar büyük önem taşımaktadır. Bu çalışmada, farklı tane büyüklüğüne sahip ignimbirit taş tozu (63 µm, 150 µm, 250 µm, 500 µm, 1000 µm) ve epoksi reçine kullanılarak elde edilen kompozitlerin, yapı taşlarının tuz kristalleşmesi hasarlarının onarımında kullanılmasına odaklanılmıştır. Bu bağlamda, çalışma kapsamında elde edilen kompozit malzemelerin, ignimbirit taşlarının tuz etkisine bağlı hasarlara karşı koruma potansiyelleri incelenmiştir. Kompozitlerdeki taş tozlarının tanecik büyüklüğünün artmasıyla, tuza karşı gösterdiği direnç azalmıştır. % 70 oranında <63 µm büyüklüğüne sahip İTT ile elde edilen KÖ63 kompozit örneğinin hem ignimbirit taşının hem de diğer kompozit örneklere göre tuz etkisine karşı daha dirençli olduğu belirlenmiştir. Bu kompozitin tuz kristalleşmesi (% 0,09), açık gözeneklilik (% 6,64), görünür yoğunluk (1701,58 kg/m³) ve su emme (% 1,01) deneylerindeki değerleri diğer kompozitlerin değerlerine göre teknik özellik açısından en iyi kompozit olduğu belirlenmiştir. Ayrıca tüm kompozitlerde epoksi reçinesi taş tozlarının gözeneklerini doldurarak suyun gözeneklerden nüfuz etmesini engellemiştir. Bu da kompozitlerin ignimbirit taşına göre tuzun çözünmesini önlemekte ve tuz kristallerini yüzey üzerinde biriktirerek tuz etkisi nedeniyle oluşabilecek hasarlara karşı daha dirençli hale getirmiştir. Sonuç olarak KÖ63 kompozitinin, tuz

etkisine bağlı hasarlara karşı dayanıklı özellikleri sayesinde, yapıların çürümüş kısımlarının restorasyonunda harç enjeksiyon uygulaması için büyük bir potansiyele sahip olduğunu göstermektedir.

KAYNAKLAR

- Alves, R. A., Strecker, K., Pereira, R. B., & Panzera, T. H. (2020). Mixture design applied to the development of composites for steatite historical monuments restoration. *Journal of Cultural Heritage*, 45, 152-159.
- Andreotti, S., Franzoni, E., Ruiz-Agudo, E., Scherer, G. W., Fabbri, P., Sassoni, E., & Rodriguez-Navarro, C. (2019). New polymer-based treatments for the prevention of damage by salt crystallization in stone. *Materials and Structures*, 52, 17.
- Arumugam, H., Iqbal, M. M., Ahn, C.-H., Rimdusit, S., & Muthukaruppan, A. (2023). Development of high performance granite fine fly dust particle reinforced epoxy composites: structure, thermal, mechanical, surface and high voltage breakdown strength properties. *Journal of Materials Research and Technology*, 24, 2795-2811.
- ASTM D570-98. (2005). Standard Test Method for Water Absorption of Plastics. American Society for Testing Materials. West Conshohocken, PA.
- Aydar, E., & Akkaş, E. (2022). The emission of natural harmful particulate matters by wind erosion and possible impact areas, Cappadocia province, Central Anatolia, Turkey. *Bulletin of Engineering Geology and the Environment*, 81, 20.
- Benavente, D., Del Cura, M. G. A., Fort, R., & Ordóñez, S. (1999). Thermodynamic modelling of changes induced by salt pressure crystallisation in porous media of stone. *Journal of Crystal Growth*, 204(1-2), 168-178.
- Benavente, D., Del Cura, M. G. A., Fort, R., & Ordóñez, S. (2004). Durability estimation of porous building stones from pore structure and strength. *Engineering Geology*, 74(1-2), 113-127.
- Chen, Z., Liu, X., Chen, H., Li, J., Wang, X., & Zhu, J. (2023). Application of epoxy resin in cultural relics protection. *Chinese Chemical Letters*, 35(4), 109194.
- Çiflikli, M. (2020). Hydrothermal alteration-related kaolinite/dickite occurrences in ignimbrites: an example from Miocene ignimbrite units in Avanos, Central Turkey. *Arabian Journal of Geosciences*, 13, 1044.
- D'Arienzo, L., Scarfato, P., & Incarnato, L. (2008). New polymeric nanocomposites for improving the protective and consolidating efficiency of tuff stone. *Journal of Cultural Heritage*, 9(3), 253-260.
- da Fonseca, B. S., Pinto, A. F., Rucha, M., Alves, M., & Montemor, M. (2023). Damaging effects of salt crystallization on a porous limestone after consolidation treatments. *Construction and Building Materials*, 374, 130967.
- Diñçer, İ., & Bostancı, M. (2019). Capillary water absorption characteristics of some Cappadocian ignimbrites and the role of capillarity on their deterioration. *Environmental Earth Sciences*, 78, 7.
- Erguler, Z. A. (2009). Field-based experimental determination of the weathering rates of the Cappadocian tuffs. *Engineering Geology*, 105(3-4), 186-199.
- Garcia-Vallès, M., Topal, T., & Vendrell-Saz, M. (2003). Lichenic growth as a factor in the physical deterioration or protection of Cappadocian monuments. *Environmental Geology*, 43, 776-781.
- Granneman, S. J., Lubelli, B., & van Hees, R. P. (2019). Mitigating salt damage in building materials by the use of crystallization modifiers—a review and outlook. *Journal of Cultural Heritage*, 40, 183-194.
- Jia, M., He, L., Pan, A., Ma, X., Huang, S., & Simon, S. (2021). Silica-based hybrids for adhesive coatings and their anti-salt damage in the protection of ancient sandstone. *Progress in Organic Coatings*, 151, 106037.
- Kaşmer, Ö., Ulusay, R., & Geniş, M. (2013). Assessments on the stability of natural slopes prone to toe erosion, and man-made historical semi-underground openings carved in soft tuffs at Zelve Open-Air Museum (Cappadocia, Turkey). *Engineering Geology*, 158, 135-158.
- Korkanç, M. (2007). İğnimbitlerin jeomekanik özelliklerinin yapı taşı olarak kullanımına etkisi: Nevşehir taşı. *Jeoloji Mühendisliği Dergisi*, 31(1), 49-60.

- Korkanç, M., & Solak, B. (2016). Estimation of engineering properties of selected tuffs by using grain/matrix ratio. *Journal of African Earth Sciences*, 120, 160-172.
- Luan, X. X., Xu, C. C., Wang, Z. S., & Ji, J. (2008). Preservation effect of modified waterborne epoxy resin emulsion for stone historical relic. *Corrosion and Protection*, 29(8), 451-453.
- Lubelli, B., Hees, R. v., Groot, C., & Gunneweg, J. (2007). Risks of the Use of Water Repellents on Salt Contaminated Masonry: the Case of a Windmill in the Netherlands. *Restoration of Buildings and Monuments*, 13(5), 319-330.
- Moon, V. G. (1993). Microstructural controls on the geomechanical behaviour of ignimbrite. *Engineering Geology*, 35(1-2), 19-31.
- Moropoulou, A., Kouloumbi, N., Haralampopoulos, G., Konstanti, A., & Michailidis, P. (2003). Criteria and methodology for the evaluation of conservation interventions on treated porous stone susceptible to salt decay. *Progress in Organic Coatings*, 48(2-4), 259-270.
- Özşen, H., Bozdağ, A., & İnce, İ. (2017). Effect of salt crystallization on weathering of pyroclastic rocks from Cappadocia, Turkey. *Arabian Journal of Geosciences*, 10, 258.
- Pinna, D., Salvadori, B., & Porcinai, S. (2011). Evaluation of the application conditions of artificial protection treatments on salt-laden limestones and marble. *Construction and Building Materials*, 25(5), 2723-2732.
- Raneri, S., Barone, G., Mazzoleni, P., & Rabot, E. (2016). Visualization and quantification of weathering effects on capillary water uptake of natural building stones by using neutron imaging. *Applied Physics A*, 122, 969.
- Ruffolo, S. A., La Russa, M. F., Ricca, M., Belfiore, C. M., Macchia, A., Comite, V., Pezzino, A., & Crisci, G. M. (2017). New insights on the consolidation of salt weathered limestone: the case study of Modica stone. *Bulletin of Engineering Geology and the Environment*, 76, 11-20.
- Sahu, R., Gupta, M. K., Chaturvedi, R., Tripaliya, S. S., & Pappu, A. (2020). Moisture resistant stones waste based polymer composites with enhanced dielectric constant and flexural strength. *Composites Part B: Engineering*, 182, 107656.
- Scherer, G. W. (1999). Crystallization in pores. *Cement and Concrete Research*, 29(8), 1347-1358.
- Scherer, G. W., Flatt, R., & Wheeler, G. (2001). Materials science research for the conservation of sculpture and monuments. *MRS Bulletin*, 26(1), 44-50.
- Topal, T., & Doyuran, V. (1997). Engineering geological properties and durability assessment of the Cappadocian tuff. *Engineering Geology*, 47(1-2), 175-187.
- Topal, T., & Doyuran, V. (1998). Analyses of deterioration of the Cappadocian tuff, Turkey. *Environmental Geology*, 34, 5-20.
- TS EN 1936. (2010). Türk Standartları, Doğal Taşlar Deney Metotları, Gerçek Yoğunluk, Görünür Yoğunluk, Toplam ve Açık Gözeneklilik. TSE, Ankara.
- TS EN 12370. (2001). Doğal Taşlar-Deney metotları-Tuz kristalleşmesine direncin tayini. TSE, Ankara.
- Url1. (2024). Öz kapadokya doğal sarıtaş kimyasal özellikleri. <https://www.google.com/url?sa=i&url=https%3A%2F%2Fwww.ozkapadokya.com.tr%2Fstorage%2Fapp%2Fmedia%2Fbelgeler%2Foz-kapadokya-saritas-analiz.docx&psig=AOvVaw2BudimwRVCxExTf9-xEcRL&ust=1727539155783000&source=images&cd=vfe&opi=89978449&ved=0CAQQn5wMahcKEwjIx4yCv-OIAxUAAAAAHQAAAAAQBA> (Erişim tarihi:27.09.2024).
- Url2. (2024). <https://brtr-kimya-as.business.site/> (Erişim tarihi:27.09.2024).
- Vacchiano, C. D., Incarnato, L., Scarfato, P., & Acierno, D. (2008). Conservation of tuff-stone with polymeric resins. *Construction and Building Materials*, 22(5), 855-865.
- Walker, G. P. (1983). Ignimbrite types and ignimbrite problems. *Journal of Volcanology and Geothermal Research*, 17(1-4), 65-88.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 13.08.2024
Kabul Tarihi : 22.10.2024

Received Date : 13.08.2024
Accepted Date : 22.10.2024

EMG SİNYALLERİ İLE DERİN ÖĞRENME YÖNTEMLERİNİ KULLANARAK EL/PARMAK HAREKETİ TANIMA

HAND/FINGER GESTURE RECOGNITION USING DEEP LEARNING METHODS WITH EMG SIGNALS

*Mehmet İsmail GÜRİSOY*¹ (ORCID: 0000-0002-2285-5160)

¹ Adıyaman Üniversitesi, Elektrik Elektronik Mühendisliği Bölümü, Adıyaman, Türkiye

*Sorumlu Yazar / Corresponding Author: Mehmet İsmail GÜRİSOY, mgursoy@adiyaman.edu.tr

ÖZET

Elektromiyografi (EMG) sinyalleri ile el/parmak hareketi tanıma sistemleri, insan – bilgisayara etkileşimi, sanal gerçeklik ve protezler gibi alanlarda önemli bir yere sahiptir. Son yıllarda, EMG sinyalleri ile el/parmak hareketi tanıma için çeşitli derin öğrenme yöntemleri geliştirilmiştir. Bu çalışmada, NinaPRO DB1 veri setinden alınan 10 kanallı EMG cihazı ile 10 farklı kişiden beş parmak hareketini içeren biyoelektrik sinyaller kullanılmıştır. Veriler 500 ms uzunluğunda pencerelere bölünerek %70 oranında kayan pencere yöntemi kullanılmıştır. El/parmak sınıflandırma için Evrişimli Sinir Ağları (CNN) ve Uzun Kısa Dönem Hafıza (LSTM) derin öğrenme yöntemleri kullanılmıştır. Geliştirilen modellerin performansını değerlendirmek için Doğruluk, Kesinlik, Duyarlılık ve F-skor istatistiksel parametreleri kullanılmıştır. Geliştirilen CNN ve LSTM ile modeller 40 defa tekrar edilerek istatistiksel parametreler elde edilmiştir. Sonuç olarak CNN model ile geliştirilen sistemde; doğruluk %100, Kesinlik %100, Duyarlılık %100 ve F-skor %100 en iyi sınıflandırma değerleri ile üstün performansa sahip olduğunu göstermiştir. LSTM modeli ile de doğruluk %99, Kesinlik %98, Duyarlılık %98 ve F-skor %98 sınıflandırma metrikleri elde edilmiştir. Bu çalışmada sunulan derin öğrenme modeli, EMG sinyalleri ile el/parmak hareketi tanıma veya sınıflandırmada güçlü potansiyel ve etkinliğini açıklamaktadır.

Anahtar Kelimeler: EMG, derin öğrenme, el/parmak hareketi tanıma.

ABSTRACT

Electromyography(EMG) signals and hand/finger gesture recognition systems have an important place in fields such as human-computer interaction, virtual reality and prostheses. In recent years, various deep learning methods have been developed for hand/finger gesture recognition with EMG signals. In this study, bioelectric signals containing five finger gesture from 10 different people were used with a 10-channel EMG device obtained from the NinaPRO DB1 dataset. The data was divided into 500 ms long windows and the sliding window method was used at a rate of 70%. Convolutional Neural Networks (CNN) and Long Short-Term Memory (LSTM) deep learning methods were used for hand/finger gesture classification. Accuracy, Precision, Sensitivity and F-score statistical parameters were used to evaluate the performance of the developed models. The developed CNN and LSTM models were repeated 40 times and statistical parameters were obtained. As a result, the system developed with the CNN model showed superior performance with the best classification values of 100% accuracy, 100% precision, 100% sensitivity and 100% F-score. With the LSTM model, 99% accuracy, 98% precision, 98% sensitivity and 98% F-score classification metrics were obtained. The deep learning model presented in this study explains its strong potential and effectiveness in hand/finger gesture recognition or classification with EMG signals.

Keywords: EMG, deep learning, hand/finger gesture recognition

GİRİŞ

El hareketi tanıma sistemleri, esas olarak insan – bilgisayar etkileşim sistemlerine duyulan ihtiyaç nedeniyle son yıllarda büyük ölçüde gelişim göstermektedir (Toro-Ossaba et al., 2022). El/parmak tanıma sistemleri, önceden tanımlanmış bir dizi hareket arasından belirli bir el hareketi sınıfının tanınması ve hareketin gerçekleştirildiği tam anın belirlenmesini içerir (Benalcazar et al., 2018). El/parmak tanıma sistemlerinin biyoteknoloji, protez el/kol kontrol edilebilmesi, 3boyutlu animasyonlar, video oyunları, işaret dili tanıma ve tıp dahil olmak üzere geniş uygulama alanları bulunmaktadır (Saggio et al., 2020; W. T. Shi et al., 2018). Elektromiyografi (EMG) sinyalleri kullanılarak El/parmak hareketlerine yönelik uygulamalar geliştirilebilir. EMG kayıtları kasların kasılmasıyla üretilen elektrik sinyalleridir. Bu sinyaller, incelenmek istenen kas dokusuna doğrudan bir iğneyle (invazif) veya deri yüzeyine küçük elektrotlar yerleştirilerek (invazif olmayan) kaydedilir (Hahne et al., 2016). Yüzeysel elektromiyografisi (sEMG) gibi invazif olmayan yöntemler genel kullanım için daha pratiktir. sEMG kas aktivasyonunun yoğunluğu ve süresi hakkında bilgi sağlayan biyoelektrik sinyallerdir (Barona López et al., 2024).

El/parmak hareketi tanıma, insan – bilgisayar etkileşimi sistemlerinde yaygın olarak kullanılan bir tekniktir. Çok sayıda çalışma parmak hareketleri tanımanın yüksek sınıflandırma doğruluğuna ulaşmak için farklı modeller oluşturmuştur. El/parmak hareketi tanıma modelinin yapısı temel olarak 4 aşamadan meydana gelir: Veri toplama, ön işleme, özellik çıkarma ve sınıflandırma. Veri toplama aşamasında, atalet ölçüm sistemleri, sensör eldivenleri ve EMG kullanılmaktadır (Benalcázar et al., 2020; Pallotti et al., 2021). Ön işleme aşaması sinyali düzenleme ve filtreleme gibi tekniklerden oluşmaktadır. Özellik çıkarma aşamasında yaygın olarak Ortalama mutlak değer (MAV) Ortalama karekök (RMS), Standart sapma (SD) gibi yöntemler (X. Chen et al., 2021) ve ayrıca Evrişimli Sinir Ağları (CNN) gibi otomatik özellik çıkarım yöntemleri kullanılır. Sınıflandırma aşamasında makine öğrenme algoritmalarından k-En yakın komşu (kNN) (Elsayed et al., 2017), Destek vektör Makineleri (SVM) (Günay & Alkan, 2010; Miron et al., 2019), Rastgele Orman (RF) (Bargellesi et al., 2019) ve İleri beslemeli yapay sinir ağları (ANN) (Özerdem & Bamwenda, 2019) yaygın olarak kullanılmaktadır.

El/parmak hareketi tanıma problemleri genellikle iki şekilde analiz edilmektedir. Genel modeller ve kullanıcıya özel (bireysel) modeller. Genel bir model birden fazla gönüllüden alınan veriler ile eğitilir ve herhangi bir kişiden alınan örnekler tanyacak şekilde model geliştirilir. Bireysel modeller ise belirli bir kişiden alınan veriler ile eğitilir ve yalnızca o kişiden alınan örnekler işleyebilir. Bireysel modeller için %90-95 doğruluk elde ediliyorken, genel modeller için %80-85 arası doğruluk elde edilmektedir (Barona López et al., 2024).

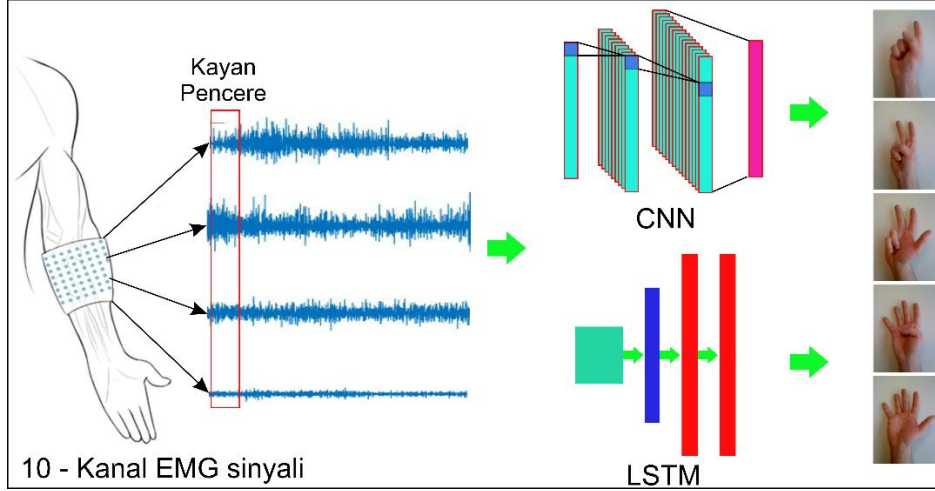
Son yıllarda ileri yapay zeka teknolojisinin gelişmesiyle birlikte, derin öğrenme teknikleri ile el hareketi tanıma ilgili alanlarda araştırmaların odak noktası haline gelmiştir. Geleneksel makine öğrenme algoritmalarıyla karşılaştırıldığında, derin öğrenme yöntemlerinin büyük veri kümeleri üzerinde daha güçlü öğrenme yeteneği vardır. Bu da bir çok sınıflandırma algoritmalarına karşı üstünlüğünü kanıtlamıştır (H. Shi et al., 2024). Lin et al. (Lin et al., 2022) 12 parmak hareketini 10 farklı kişi ile sınıflandırma yapmıştır. CNN yöntemi ile %74,34 başarı oranını elde etmiştir. Özdemir ve ark. (Özdemir et al., 2020) El hareketlerinin sınıflandırması için ResNet mimarisini temel alan 50 katmanlı bir CNN mimarisi kullanmışlardır. Kısa Zamanlı Fourier Dönüşümü (STFT) ile yapılan EMG sinyallerinin renkli spektrogramları derin öğrenme modelinde eğitmişlerdir. Karnam ve ark. (Karnam et al., 2022) NINNA-PRO DB1 veri setini kullanarak CNN ve Bidirectional-LSTM yöntemlerini kullanarak hibrit EMGHandNet modelini geliştirmiştir. Farklı giriş veri uzunluğu kullanarak sınıflandırma işlemi yapmıştır. 20 ms, 250 ms ve 500 ms giriş veri uzunluklarında en yüksek sınıflandırma başarımları olan %91,76 doğruluğu elde etmiştir. Shanmuganathan ve ark. (Shanmuganathan et al., 2020) EMG sinyallerini kullanarak el hareketi tanıma için R-CNN ve Dalgacık özelliği çıkarma yöntemi önermişlerdir. Geliştirdikleri model ile %96,48 doğruluk elde etmişlerdir. Çalışmalarında kullanılan veri kümesi, dört farklı el hareketini gerçekleştiren on denekten oluşmaktadır. Tuncer ve ark. (Tuncer & Alkan, 2022) Üst ekstremite protezlerinin işlevselliğini ve kontrol kolaylığını iyileştirmek amacıyla EMG sinyallerini dört farklı derin öğrenme yöntemleri ile analiz etmişlerdir.

Önerilen çalışmanın önemli katkıları şunlardır:

1. Günlük hayatta en pratik kullanılan beş parmak hareketinin sınıflandırılmasında CNN ve LSTM yöntemleri kullanılmıştır.
2. EMG sinyallerinin özellik çıkarımı yerine ham EMG sinyalleri değerlendirilmiştir.
3. Sınıflandırma başarısının değerlendirilmesi için farklı yöntemler kullanılarak karşılaştırılmıştır.
4. Elde edilen sonuçlar ile önerilen derin öğrenme yöntemlerinin EMG sinyallerinin sınıflandırma performansının başarısını göstermektedir.

METERYAL VE YÖNTEMLER

Bu çalışmada, NinaPRO DB1 veri setinde günlük hayatta çok kullanılan beş parmak hareketi seçilerek el/parmak hareketleri sınıflandırma mimarisi geliştirildi. 500 ms uzunluğundaki veriler, kayan pencere yöntemi ile %70 oranında (150 ms uzunluğunda) örtüştürerek özellikler elde edildi. Derin öğrenme algoritmalarından CNN ve LSTM modelleri kullanılarak sınıflandırma işlemi yapıldı. Geliştirilen modelin eğitim mimarisi Şekil 1’de gösterilmektedir.



Şekil 1. Geliştirilen Model Mimarisi

Veri Seti (Dataset)

Bu çalışmada kullanılan el hareketlerinin sEMG sinyalleri, ücretsiz olarak temin edilebilen halka açık NinaPRO DB1 veri setinden alınmıştır. Veriler 10 tane Otto Bock MyBock 13E200 sEMG elektrotları kullanarak kaydedilmiştir. sEMG sinyalleri, Radyohumeral eklem yüksekliğinde ön kol çevresinde eşit aralıklarla yerleştirilmiş 8 elektrot ve felsor ve ekstansör kaslarına yerleştirilen 2 elektrot ile kaydedilmiştir. NinaPRO DB1 veri seti 27 denek tarafından gerçekleştirilen 52 farklı el hareketinden oluşmaktadır. Her hareket 10 defa tekrar içermektedir (Atzori et al., 2014).

NinaPRO DB1 veri setinden, günlük hayatta en pratik kullanılan beş parmak hareketini seçtik (Şekil 2). Bu hareketleri yapan 10 kişinin sEMG sinyallerini analiz ettik. Seçilen grup, boyları 169 cm – 187 cm, ağırlıkları 58 kg – 75 kg ve yaşları 23 – 32 arasında değişen 3 kadın ve 7 erkek gönüllüden oluşmaktadır. Gönüllülerin yapılması istenen parmak hareketleri Şekil 2’de gösterilmektedir.

10 gönüllüden alınan veriler, %70 eğitim, %20 doğrulama ve %10 test oranında ayrıldı. Her bir gönüllünün verileri ayrı ayrı analiz edildi.




Şekil 2. Çalışmada Kullanılan El Hareketleri

Evrişimli Sinir Ağları (Convolutional Neural Network – CNN)

Evrişimli Sinir Ağları (CNN), verilerde özellik çıkarma için etkili bir araçtır. CNN örüntü sınıflandırması, görüntü işleme, ses işleme ve model tanıma gibi birçok alanda yaygın olarak kullanılmaktadır (H. Wang et al., 2017). CNN öğrenme yoluyla kendini optimize eden nöronlardan oluşmaları bakımından geleneksel ANN benzerler. ANN temelinde olduğu gibi her nöron bir girdi değeri olarak işlemler gerçekleştirmektedir. CNN en büyük farklılıklarından biri, içindeki katmanların üç boyutta (height, width and depth) organize edilmiş nöronlardan oluşmasıdır (Gursoy, 2024; O’Shea & Nash, 2015). Bir CNN modeli genel olarak evrişim katmanı (Convolution Layer), havuzlama katmanı (Pooling Layer) ve tam bağlantılı katman (Fully Connected Layer) olmak üzere üç ana katmandan meydana

gelmektedir. (i) Evrişim Katmanı: CNN modelinin çekirdeğini oluşturmaktadır. Ana hesaplama işlemleri bu bölümde gerçekleşmektedir. Evrişim katmanının temel görevi giriş verilerinden öznitelikleri belirlemektir. Evrişim katmanında nöronlar arasında bir bağlantı yoktur. Farklı katmanlardaki nöronlar, ağırlık paylaşımı tekniği ile lokal olarak birbirlerine bağlanır. (ii) Havuzlama Katmanı: Model oluşturulurken genellikle evrişim katmanından sonra havuzlama katmanı kullanılır. Bu katmanın ana amacı hesaplama maliyetini azaltmak ve evrişim katmanının özellik vektörünün boyutunu azaltmaktır. (iii) Tam Bağlantılı katman: Bu katman nöronlar ile birlikte ağırlıklardan oluşur. Nöronları farklı iki katmana bağlamak için kullanılır. Genellikle oluşturulan modelin son katmanları Tam Bağlantılı katmanlardan oluşur (Y. Chen et al., 2023; Gürsoy & Alkan, 2022).

Bu çalışmada NinaPRO DB1 veri seti ile CNN mimarisi geliştirilmiştir. Bu mimaride giriş verileri 500 ms (50 veri) boyutunda belirlenmiştir. 4 tane evrişim katmanı ve 3 tam bağlantılı katmandan oluşan bir mimari geliştirilmiştir. Çıkış katmanında 5 parmak hareketini sınıflandıran katman oluşturulmuştur. CNN mimarisi Şekil 3'de gösterilmektedir.




Şekil 3. CNN Mimarisi

Uzun Kısa-Dönem Hafıza (Long Short-Term Memory – LSTM)

Uzun Kısa Süreli Hafıza (LSTM) Hochreiter ve Schmidhuber tarafından 1990 yıllarının sonunda geliştirilen sıralı verilerin modellenmesi için uygulanan Tekrarlayan Sinir Ağları (Recurrent Neural Network -RNN) yaklaşımının özel bir türüdür (Hochreiter & Schmidhuber, 1997). Genellikle uzun vadeli bağımlılık gerektiren öğrenme için kullanılır. LSTM modeli hemen önceki veriler ile değil aynı zamanda geçmiş verileri de dikkate alarak gelecekteki verileri tahmin etmeye olanak tanır. Literatürde, son zamanlarda karmaşık veri kümelerinde LSTM birimlerinin daha iyi performans sergilediği görülmektedir (Abdelaziz et al., 2024; Toro-Ossaba et al., 2022; L. Wang et al., 2023; Zhang et al., 2024). Sürekli insan hareketlerinden elde edilen verilerin işlenmesinde zamansal sıra önemlidir (Garcia-Vellisca et al., 2021). Bu zamansal sırayı göz önünde bulundurarak veri sınıflandırma ve tahmin için LSTM çeşitli çalışmalarda iyi sonuçlar göstermiştir (Li et al., 2020).

LSTM mimarisi ile geliştirilen model Şekil 4'de gösterilmektedir. Bu mimaride giriş katmanı 50 örnek (500 ms) uzunluğunda verileri 10 tekrar ile (50 x 10) şeklinde belirlendi. Modelde ilk olarak 400 nörondan oluşan tam bağlantılı katman belirlendi. Sonradan iki tane 1000 LSTM bloğundan oluşan LSTM – 1 ve 2 katmanları oluşturuldu. Çıkış katmanı ise softmax fonksiyonunu kullanarak 5 parmak hareketini sınıflandıran birimden meydana geldi.



Şekil 4. LSTM Mimarisi

Performans Kriterleri

Sınıflandırma problemlerinde geliştirilen modelin başarısı, doğru olarak belirlenen sınıf verileri ile yanlış olarak belirlenen sınıf verilerinin sayıları karşılaştırılarak belirlenmektedir. Karışıklık matrisi (Confusion Matrix) (Tablo-1) kullanılarak geliştirilen modelin doğruluk, hassasiyet, duyarlılık ve F1 skor değerleri ile hesaplanabilir.

Tablo 1. Karışıklık Matrisi

	Doğru	Yanlış
Doğru	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
Yanlış	Yanlış Negatif (YN)	Doğru Negatif (DN)

Doğruluk, doğru sınıflandırılan örnek sayısının toplam örnek sayısına oranı şeklinde hesaplanmaktadır (Denklem-1). (Icel et al., 2019) Kesinlik, doğru pozitif değerlerin, sınıflandırılan pozitif değerlere oranıdır (Denklem-2). Duyarlılık, geliştirilen model sonucunda elde edilen doğru sınıflandırılmış örnek sayısının, pozitif örnek sayısına oranıdır (Denklem -3). F-Skor, duyarlılık ve kesinlik değerlerinin harmonik ortalamasıdır (Denklem -4). Bazen modellerin başarımı değerlendirilirken tek başına Kesinlik veya Duyarlılık değerlendirilmesi eksik olabilmektedir. Bunun için F-skor parametresi literatürde sıklıkla kullanılmaktadır (Gursoy, 2024).

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (1)$$

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (2)$$

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3)$$

$$F - \text{skor} = 2 \times \frac{\text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (4)$$


BULGULAR VE SONUÇLAR

Bu bölümde önerilen sınıflandırma modellerinin değerlendirilmesinde elde edilen sonuçlar sunulmaktadır. Analizler derin öğrenme algoritmalarından CNN ve LSTM modelleri ile analiz edilmiştir. Bu çalışmada geliştirilen modeller Python programlama dili kullanılarak gerçekleştirilmiştir. Derin öğrenme araçları olarak TensorFlow ve Keras kütüphaneleri kullanılmıştır. Önerilen modeller Windows 11 işletim sistemi ile IntelCore i7 2,2 GHz mikroişlemci ve 32 GB RAM özellikli bilgisayarda geliştirilmiştir.

Sinyal Ön İşleme

NinaPRO DB1 veri setinde veriler kaydedilirken elektrotların amplifikasyon kazancı yaklaşık 14.000 olarak ayarlandı. sEMG sinyalleri bant geçiren filtre ve Kök Ortalama Kare (RMS) ile düzeltilmiş versiyonunu sağlayan 10 tane MyoBock elektrot kullanılarak kaydedildi (Atzori et al., 2014). Veri kümesindeki kişilerin her bir hareketine ilişkin veriler %70 eğitim, %20 doğrulama ve %10 test olarak bölündü (Dobbin & Simon, 2011). Veri kümesinde her bir hareketin 10 tekrarı vardı, dolayısıyla 1.,3.,5.,6.,8.,9. ve 10. tekrarları eğitim için, 2. ve 4. tekrarları doğrulama için ve 7. Tekrarı ise test için kullanıldı.

EMG sinyallerinin sınıflandırma algoritmasından önce, verilerin boyutlarının düzenlenmesi gerekir. Kayan pencere tekniği, bir veri kümesi üzerinde yineleme yapılmasına yönelik bir yöntemdir. Verileri sabit boyuttaki örtüşen pencerelere bölmeyi ve her pencereyi bağımsız olarak işlemeyi içerir. Bu çalışmada sEMG sinyalleri 50 veri (500 ms) uzunluğunda pencerelere ayrıldı. Örtüşme değeri %70 (15 örnek – 150 ms) olarak seçildi (Şekil 5).



Şekil 5. sEMG Sinyallerinin Kayan Pencere


Sınıflandırma

NinaPRO DB1 veri seti kullanılarak 10 kişiden 5 parmak hareketi yapılması sonucunda elde edilen sEMG sinyalleri kullanılarak derin öğrenme algoritmalarından CNN ve LSTM yöntemleri ile sınıflandırma modeli geliştirilmiştir. Kişiler, her parmak hareketini 10 tekrar yaparak elde edilen sonuçlar kaydedilmiştir. Beş farklı sınıfa ait parmak hareketleri modellerde sınıflandırma sonucunda doğruluk, kesinlik, duyarlılık ve F-skör değerleri ile her iki modelin performansı belirlenmiştir. Geliştirilen CNN ve LSTM modellerinde karakteristik parametreleri Tablo 2 de gösterilmektedir.

Tablo 2. CNN - LSTM Modellerinin Karakteristik Parametreleri

Parametreler	Değer	
	CNN	LSTM
Input size	50 x 1	50 x 10
Epoc	200	100
Batch Size	72	32
Optimizer Function	Adam	Adam
Activation Function	Softmax	Softmax
Class	5	5

10 farklı kişinin 5 parmak hareketi ve 10 tekrardan oluşan veri seti geliştirilen CNN ve LSTM algoritmaları kullanılarak sınıflandırılmıştır. Sınıflandırma aşamasında, her bir algoritma 40 defa tekrar edilmiştir. CNN algoritması ile geliştirilen modelde giriş olarak 500 ms uzunluğunda 50 veriden oluşan vektör kullanılmıştır. Algoritma 200 epoc ile eğitilmiştir. CNN algoritmasının eğitim doğruluk (Accuracy) ve kayıp (Loss) fonksiyon grafiği Şekil 6(a)' da gösterilmektedir. LSTM algoritması ile geliştirilen modelde 100 epoc kullanılarak model eğitilmiştir. Modele ait eğitim ve kayıp fonksiyonu Şekil 6(b) de gösterilmektedir. Şekil 6(a) ve (b) görüldüğü gibi model eğitim performansında uygun epoc değeri ile yaklaşık %100 başarı oranına ulaşmıştır.



Şekil 6. Eğitim Doğruluk (Accuracy) ve Kayıp (Loss) Fonksiyonları (a) CNN Model, (b) LSTM Model


CNN ve LSTM modelleri eğitim ve test işlemlerinden sonra elde edilen Doğruluk, Kesinlik, Duyarlılık ve F-skör istatistik parametreleri Tablo 3 de gösterilmektedir. Geliştirilen modellerde 10 kişiye ait istatistik parametreler kişilerin sEMG sinyal özelliklerinden dolayı bazı kişilerde CNN daha üstün sonuç verirken bazı kişilerde LSTM yöntemi daha üstün sonuç verdiği görülmektedir. Örneğin S7 kişinin CNN algoritması ile Ortalama %99 doğru

sınıflandırma elde ediliyorken aynı kişinin LSTM ile ortalama %95 doğru sınıflandırdığı görülmektedir. S10 kişisi için de LSTM yöntemi ortalama %96 doğru sınıflandırırken CNN yöntemi ortalama %94 doğru sınıflandırdığı görülmektedir. Genel olarak ortalama başarı oranları arasında büyük fark olmadığı görülmektedir. Derin öğrenme mimarisinin el/parmak hareketi sınıflandırma problemlerinde yüksek başarı elde ettiği görülmektedir.

CNN ve LSTM modelleri ile geliştirilen algoritmalarda 10 gönüllünün yaptığı 5 parmak hareketi sınıflandırmasında yüksek doğruluk elde edildiği görülmektedir. Her iki algoritma ile yapılan 40 tekrarlı uygulama sonucunda modellerin doğruluk değerleri Şekil 7’de grafikte gösterilmektedir.

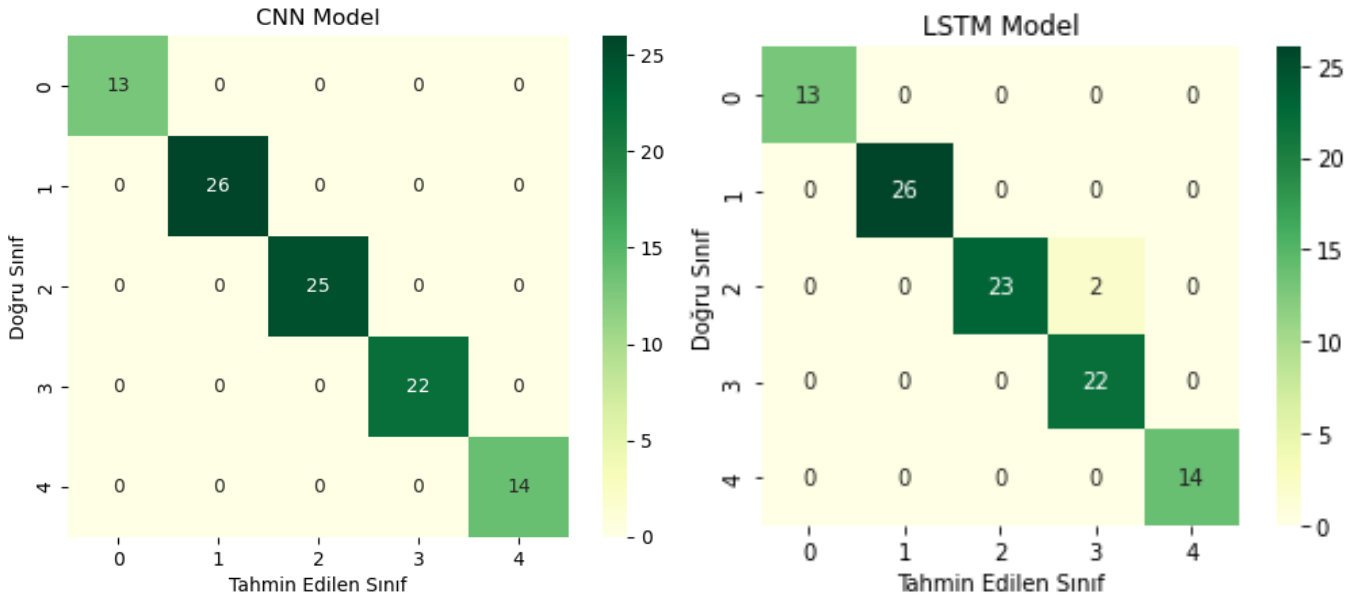
Tablo 3. CNN ve LSTM Modellerinin İstatistiksel Sonuçları

Yöntem	Kişi	Doğruluk (Accuracy)			Kesinlik (Precision)			Duyarlılık (Recall)			F- Skor (F – Score)		
		Min	Max	Ort.	Min	Max	Ort.	Min	Max	Ort.	Min	Max	Ort.
CNN	S1	0,88	0,95	0,92	0,86	0,96	0,92	0,87	0,94	0,91	0,86	0,94	0,91
	S2	0,85	0,95	0,92	0,86	0,95	0,91	0,84	0,94	0,91	0,84	0,94	0,91
	S3	0,90	0,99	0,94	0,90	0,98	0,94	0,89	0,98	0,93	0,89	0,98	0,93
	S4	0,74	0,89	0,83	0,76	0,90	0,85	0,73	0,88	0,82	0,73	0,88	0,82
	S5	0,86	0,97	0,92	0,86	0,96	0,91	0,85	0,96	0,91	0,85	0,96	0,91
	S6	0,92	0,98	0,94	0,92	0,97	0,94	0,91	0,97	0,93	0,91	0,97	0,93
	S7	0,95	1,00	0,99	0,94	1,00	0,98	0,94	1,00	0,98	0,94	1,00	0,98
	S8	0,80	0,89	0,83	0,80	0,90	0,87	0,79	0,88	0,82	0,75	0,87	0,80
	S9	0,86	0,96	0,90	0,86	0,95	0,90	0,85	0,95	0,89	0,84	0,95	0,89
	S10	0,90	0,97	0,94	0,92	0,97	0,95	0,89	0,96	0,93	0,89	0,96	0,93
LSTM	S1	0,88	0,96	0,94	0,90	0,96	0,94	0,87	0,95	0,93	0,87	0,95	0,93
	S2	0,93	0,98	0,95	0,92	0,98	0,95	0,92	0,97	0,94	0,92	0,97	0,94
	S3	0,81	0,96	0,91	0,84	0,95	0,91	0,80	0,95	0,90	0,80	0,95	0,89
	S4	0,80	0,91	0,86	0,81	0,91	0,87	0,79	0,90	0,85	0,79	0,90	0,86
	S5	0,79	0,97	0,91	0,80	0,96	0,91	0,78	0,96	0,90	0,78	0,96	0,90
	S6	0,91	0,97	0,94	0,90	0,96	0,94	0,90	0,96	0,93	0,89	0,96	0,93
	S7	0,91	0,97	0,95	0,97	0,98	0,98	0,97	0,98	0,98	0,97	0,98	0,98
	S8	0,76	0,85	0,81	0,76	0,88	0,83	0,74	0,83	0,79	0,72	0,81	0,77
	S9	0,76	0,88	0,83	0,77	0,88	0,83	0,75	0,87	0,82	0,73	0,87	0,82
	S10	0,93	0,99	0,96	0,94	0,98	0,96	0,92	0,98	0,95	0,92	0,98	0,95



Şekil 7. Geliştirilen Modellerin Doğruluk Oranları (a) CNN Model (b) LSTM Model

Geliştirilen modellerin karışıklık matrisi Şekil 8(a) ve (b)’de gösterilmektedir. CNN ve LSTM modeller ile geliştirilen algoritmalarda sınıflandırma başarısı en yüksek modellerin karışıklık matrisi gösterilmiştir. Bu matriste CNN yöntemi ile test işleminde %100 başarı elde edilirken, LSTM yöntemi ile %99 başarı elde edildiği görülmektedir.



Şekil 8. Sınıflandırma Karışıklık Matrisleri (a) CNN Model (b) LSTM Model

TARTIŞMA

İnsan – bilgisayar etkileşimi çalışmalarında el/parmak hareketi tanıma/sınıflandırma çalışmaları literatürde yoğun bir şekilde yapılmaktadır. Video oyunu, işaret dili tanıma gibi uygulamalarda önemli katkı sağlayacaktır. Bu çalışmada, halka açık NinaPRO DB1 veriseti kullanılarak beş farklı parmak hareketlerinin sınıflandırılması amaçlanmıştır. Derin öğrenme algoritmalarından CNN ve LSTM sinir ağı modelleri geliştirilerek performansları değerlendirilmiş ve karşılaştırılmıştır. Her bir kişi için ayrı ayrı sınıflandırma işlemi yapılmıştır. Geliştirilen modeller 40 defa tekrar ederek doğruluk sonuçları bulunmuştur. CNN modeli ile ortalama doğruluk %83 - %99 arasında elde edilmiştir. LSTM yönteminde ise %81 - %96 arasında ortalama doğruluk değerleri elde edilmiştir. Geliştirilen mimarilerde her iki derin öğrenme algoritmasında da yüksek sonuçlar elde edilmiştir. Ayrıca model geliştirilirken maksimum başarı oranlarında %99-100 değerine ulaşabildiği görülmüştür. Modelin 40 defa tekrarı sonucu ortalama doğruluk oranları elde edilmiştir. Genel olarak ortalama doğruluk oranının yükseltilebilmesi için modelin tekrar sayısı artırılabilir.

Genel olarak elde edilen sonuçlar ile insan – bilgisayar etkileşimi sisteminin geliştirilmesine katkı sağlayacağını göstermektedir. Bu çalışmada kullanılan 5 parmak hareketi tanıma sistemi yeteneği daha fazla el/parmak hareketi tanıyabilecek modellere öncülük edeceği düşünülmektedir. Önerilen çalışma 5 parmak hareketini kapsadığı için veri miktarı kısıtlıdır. EMG sinyallerinin incelenmesinde genelleme yapabilmek için daha büyük verilere ihtiyaç duyulmaktadır.

Bu çalışmada, EMG tabanlı ampute çözümlerin sağlamlığını ve güvenilirliğini belirlemek için, sınıflandırıcıların farklı el/parmak hareketlerinin genelleştirilmesine ilişkin daha ileri analizler geliştirilmesine omurga görevi görebilir. Ayrıca çözümlerin güvenilirliği açısından gerçek zamanlı sınıflandırmanın sağlanması amacıyla ayrıntılı bir çalışma yapılabilir.

KAYNAKLAR

Abdelaziz, M. H., Mohamed, W. A., & Selmy, A. S. (2024). Hand Gesture Recognition Based on Electromyography Signals and Deep Learning Techniques. *Journal of Advances in Information Technology*, 15(2), 255–263. <https://doi.org/10.12720/jait.15.2.255-263>

Atzori, M., Gijbets, A., Castellini, C., Caputo, B., Hager, A. G. M., Elsig, S., Giatsidis, G., Bassetto, F., & Müller, H. (2014). Electromyography data for non-invasive naturally-controlled robotic hand prostheses. *Scientific Data*, 1, 1–13. <https://doi.org/10.1038/sdata.2014.53>

- Bargellesi, N., Carletti, M., Cenedese, A., Susto, G. A., & Terzi, M. (2019). A Random Forest-based Approach for Hand Gesture Recognition with Wireless Wearable Motion Capture Sensors. *IFAC-PapersOnLine*, 52(11), 128–133. <https://doi.org/10.1016/j.ifacol.2019.09.129>
- Barona López, L. I., Ferri, F. M., Zea, J., Valdivieso Caraguay, Á. L., & Benalcázar, M. E. (2024). CNN-LSTM and post-processing for EMG-based hand gesture recognition. *Intelligent Systems with Applications*, 22(February), 200352. <https://doi.org/10.1016/j.iswa.2024.200352>
- Benalcázar, M. E., Caraguay, Á. L. V., & López, L. I. B. (2020). A user-specific hand gesture recognition model based on feed-forward neural networks, emgs, and correction of sensor orientation. *Applied Sciences (Switzerland)*, 10(23), 1–21. <https://doi.org/10.3390/app10238604>
- Benalcázar, M. E., Motoche, C., Zea, J. A., Jaramillo, A. G., Anchundia, C. E., Zambrano, P., Segura, M., Benalcázar Palacios, F., & Perez, M. (2018). Real-time hand gesture recognition using the Myo armband and muscle activity detection. 2017 IEEE 2nd Ecuador Technical Chapters Meeting, ETCM 2017, 2017-Janua, 1–6. <https://doi.org/10.1109/ETCM.2017.8247458>
- Chen, X., Li, Y., Hu, R., Zhang, X., & Chen, X. (2021). Hand Gesture Recognition based on Surface Electromyography using Convolutional Neural Network with Transfer Learning Method. *IEEE Journal of Biomedical and Health Informatics*, 25(4), 1292–1304. <https://doi.org/10.1109/JBHI.2020.3009383>
- Chen, Y., Wang, H., Zhang, D., Zhang, L., & Tao, L. (2023). Multi-feature fusion learning for Alzheimer's disease prediction using EEG signals in resting state. *Frontiers in Neuroscience*, 17. <https://doi.org/10.3389/fnins.2023.1272834>
- Dobbin, K. K., & Simon, R. M. (2011). Optimally splitting cases for training and testing high dimensional classifiers. *BMC Medical Genomics*, 4. <https://doi.org/10.1186/1755-8794-4-31>
- Elsayed, R. A., Sayed, M. S., & Abdalla, M. I. (2017). Hand gesture recognition based on dimensionality reduction of histogram of oriented gradients. 2017 Proceedings of the Japan-Africa Conference on Electronics, Communications and Computers, JAC-ECC 2017, 2018-Janua, 119–122. <https://doi.org/10.1109/JEC-ECC.2017.8305792>
- Garcia-Vellisca, M. A., Matran-Fernandez, A., Poli, R., & Citi, L. (2021). Hand-movement Prediction from EMG with LSTM-Recurrent Neural Networks. *Pan American Health Care Exchanges, PAHCE*, 2021-May. <https://doi.org/10.1109/GMEPE/PAHCE50215.2021.9434840>
- Günay, M., & Alkan, A. (2010). Spektral Yöntemler ve DVM Sınıflandırıcı ile EMG İşaretlerinin Tasnifi Classification of EMG Signals by Spectral Methods and SVM Classifier. *KSU Journal of Engineering Sciences*, 13(2), 63–69.
- Gursoy, M. I. (2024). Biometric Authentication Based on EMG Hand Gestures Signals Using CNN. *Elektronika Ir Elektrotehnika*, 30(2), 54–62. <https://doi.org/10.5755/j02.eie.33777>
- Gürsoy, M. İ., & Alkan, A. (2022). Investigation Of Diabetes Data with Permutation Feature Importance Based Deep Learning Methods. *Karadeniz Fen Bilimleri Dergisi*, 12(2), 916–930. <https://doi.org/10.31466/kfbd.1174591>
- Hahne, J. M., Farina, D., Jiang, N., & Liebetanz, D. (2016). A novel percutaneous electrode implant for improving robustness in advanced myoelectric control. *Frontiers in Neuroscience*, 10(MAR), 1–10. <https://doi.org/10.3389/fnins.2016.00114>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1–32.
- Icel, Y., Mamis, M. S., Bugutekin, A., & Gursoy, M. I. (2019). Photovoltaic Panel Efficiency Estimation with Artificial Neural Networks: Samples of Adiyaman, Malatya, and Sanliurfa. *International Journal of Photoenergy*, 2019, 1–12. <https://doi.org/10.1155/2019/6289021>
- Karnam, N. K., Dubey, S. R., Turlapaty, A. C., & Gokaraju, B. (2022). EMGHandNet: A hybrid CNN and Bi-LSTM architecture for hand activity classification using surface EMG signals. *Biocybernetics and Biomedical Engineering*, 42(1), 325–340. <https://doi.org/10.1016/j.bbe.2022.02.005>
- Li, Z., Zuo, J., Han, Z., Han, X., Sun, C., & Wang, Z. (2020). Intelligent classification of multi-gesture EMG signals based on LSTM. *International Conference on Artificial Intelligence and Electromechanical Automation, AIEA 2020*, 2020, 62–65. <https://doi.org/10.1109/AIEA51086.2020.00020>

- Lin, Y., Palaniappan, R., De Wilde, P., & Li, L. (2022). Reliability Analysis for Finger Movement Recognition With Raw Electromyographic Signal by Evidential Convolutional Networks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 30, 96–107. <https://doi.org/10.1109/TNSRE.2022.3141593>
- Miron, C., Pasarica, A., Costin, H., Manta, V., Timofte, R., & Ciucu, R. (2019). Hand gesture recognition based on SVM classification. 7th E-Health and Bioengineering Conference, EHB 2019, 2–7. <https://doi.org/10.1109/EHB47216.2019.8969921>
- O’Shea, K., & Nash, R. (2015). An Introduction to Convolutional Neural Networks. <http://arxiv.org/abs/1511.08458>
- Ozdemir, M. A., Kisa, D. H., Guren, O., Onan, A., & Akan, A. (2020). EMG based Hand Gesture Recognition using Deep Learning. 2020 Medical Technologies Congress, TIPTEKNO 2020, 1919, 1–4. <https://doi.org/10.1109/TIPTEKNO50054.2020.9299264>
- Özerdem, M. S., & Bamwenda, J. (2019). Recognition of static hand gesture with using ANN and SVM. *DÜMF Mühendislik Dergisi*, 10(2), 561–568. <https://doi.org/10.24012/dumf.569357>
- Pallotti, A., Orenco, G., & Saggio, G. (2021). Measurements comparison of finger joint angles in hand postures between an sEMG armband and a sensory glove. *Biocybernetics and Biomedical Engineering*, 41(2), 605–616. <https://doi.org/10.1016/j.bbe.2021.03.003>
- Saggio, G., Cavallo, P., Ricci, M., Errico, V., Zea, J., & Benalcázar, M. E. (2020). Sign language recognition using wearable electronics: Implementing K-nearest neighbors with dynamic time warping and convolutional neural network algorithms. *Sensors (Switzerland)*, 20(14), 1–14. <https://doi.org/10.3390/s20143879>
- Shanmuganathan, V., Yesudhas, H. R., Khan, M. S., Khari, M., & Gandomi, A. H. (2020). R-CNN and wavelet feature extraction for hand gesture recognition with EMG signals. *Neural Computing and Applications*, 32(21), 16723–16736. <https://doi.org/10.1007/s00521-020-05349-w>
- Shi, H., Jiang, X., Dai, C., & Chen, W. (2024). EMG-based Multi-User Hand Gesture Classification via Unsupervised Transfer Learning Using Unknown Calibration Gestures. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 32, 1119–1131. <https://doi.org/10.1109/TNSRE.2024.3372002>
- Shi, W. T., Lyu, Z. J., Tang, S. T., Chia, T. L., & Yang, C. Y. (2018). A bionic hand controlled by hand gesture recognition based on surface EMG signals: A preliminary study. *Biocybernetics and Biomedical Engineering*, 38(1), 126–135. <https://doi.org/10.1016/j.bbe.2017.11.001>
- Toro-Ossaba, A., Jaramillo-Tigueros, J., Tejada, J. C., Peña, A., López-González, A., & Castanho, R. A. (2022). LSTM Recurrent Neural Network for Hand Gesture Recognition Using EMG Signals. *Applied Sciences (Switzerland)*, 12(19). <https://doi.org/10.3390/app12199700>
- Tuncer, S. A., & Alkan, A. (2022). Classification of EMG signals taken from arm with hybrid CNN-SVM architecture. *Concurrency and Computation: Practice and Experience*, 34(5), 16723–16736. <https://doi.org/10.1002/cpe.6746>
- Wang, H., Yi, H., Peng, J., Wang, G., Liu, Y., Jiang, H., & Liu, W. (2017). Deterministic and probabilistic forecasting of photovoltaic power based on deep convolutional neural network. *Energy Conversion and Management*, 153, 409–422. <https://doi.org/10.1016/j.enconman.2017.10.008>
- Wang, L., Fu, J., Chen, H., & Zheng, B. (2023). Hand gesture recognition using smooth wavelet packet transformation and hybrid CNN based on surface EMG and accelerometer signal. *Biomedical Signal Processing and Control*, 86(PB), 105141. <https://doi.org/10.1016/j.bspc.2023.105141>
- Zhang, K., Badesa, F. J., Liu, Y., & Ferre Pérez, M. (2024). Dual Stream Long Short-Term Memory Feature Fusion Classifier for Surface Electromyography Gesture Recognition. *Sensors*, 24(11), 1–18. <https://doi.org/10.3390/s24113631>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 15.08.2024
Kabul Tarihi : 31.12.2024

Received Date : 15.08.2024
Accepted Date : 31.12.2024

KIRŞEHİR'İN RÜZGAR ENERJİSİ POTANSİYELİ VE İÇ ANADOLU BÖLGESİ KURULU RÜZGAR ENERJİSİ SANTRALLERİNİN GÜÇ ANALİZİ

WIND ENERGY POTENTIAL OF KIRŞEHİR AND POWER ANALYSIS OF WIND ENERGY PLANTS INSTALLED IN CENTRAL ANATOLIA REGION

Müjdat ÖZTÜRK^{1*} (ORCID: 0000-0003-1800-2234)
Ramazan KAYABAŞI² (ORCID: 0000-0001-6195-7445)
Oğuz TAŞDEMİR³ (ORCID: 0000-0003-1782-0024)

¹ Kırşehir Ahi Evran Üniversitesi, Kaman Meslek Yüksekokulu, Kırşehir, Türkiye
² Kayseri Üniversitesi, Tomarza Mustafa Akıncıoğlu Meslek Yüksekokulu, Kayseri, Türkiye
³ Kırşehir Ahi Evran Üniversitesi, Kaman Meslek Yüksekokulu, Kırşehir, Türkiye

* Sorumlu Yazar / Corresponding Author: Müjdat ÖZTÜRK, mujdat.ozturk@ahievran.edu.tr

ÖZET

Türkiye'nin zengin ve çeşitlilik içeren yenilenebilir enerji potansiyeli, son yıllarda hızla değerlendirilmeye başlanmıştır. Özellikle rüzgar enerjisi, elektrik üretiminde önemli bir rol oynamakta ve kurulu güç içerisindeki payını sürekli artırmaktadır. Çevre dostu bir enerji kaynağı olan rüzgar enerjisi, kırsal bölgelerde de yüksek üretim kapasitesine sahiptir. Bu çalışmada, İç Anadolu Bölgesi illerinin rüzgar potansiyeli ve kurulu santral kapasiteleri; nüfus ve gelişmişlik düzeyleriyle ilişkilendirilerek incelenmiştir. Özel olarak Kırşehir bölgesi ele alınmış ve 2024-2028 yılları arasında bölgedeki rüzgar enerjisi üretim kapasitesi Yapay Sinir Ağları (YSA) tabanlı bir model ile tahmin edilmiştir. Analiz sonuçlarına göre, 2024 yılında rüzgar potansiyelinde yaklaşık %1'lik bir düşüş yaşanması öngörülmüş, ancak 2025-2028 yılları arasında her yıl %1'lik bir artış kaydedilmiştir. 2023 yılındaki üretime kıyasla, 2026 yılında tahmini enerji üretimi %3,5 oranında artış göstermiştir. Aynı şekilde, 2027 ve 2028 yıllarında da enerji üretiminde yükseliş devam etmiştir. Çalışma, İç Anadolu Bölgesi'nin rüzgar enerji potansiyelini detaylı bir şekilde değerlendirirken, Kırşehir ilinde yer alan rüzgar santrali özelinde 2024-2028 yılları arasındaki enerji üretim tahminini ortaya koymuştur. Sonuç olarak, bölgenin mevcut kapasitesi ile potansiyel enerji üretimi ve yıllara göre değişimi kapsamlı bir şekilde analiz edilmiştir.

Anahtar Kelimeler: Yenilenebilir enerji kaynakları, rüzgar enerji santrali, rüzgar enerji potansiyeli, YSA, Güç

ABSTRACT

Turkey's rich and diverse renewable energy potential has been rapidly utilized in recent years. Among these resources, wind energy plays a critical role in electricity generation, steadily increasing its share in installed capacity. As an environmentally friendly energy source, wind energy demonstrates high production capacity, particularly in rural areas. This study examines the wind potential and installed power plant capacities of provinces in the Central Anatolia Region, considering parameters such as population and development levels. Specifically, the Kırşehir region was analyzed, and the wind energy production capacity for 2024–2028 was estimated using an Artificial Neural Network (ANN)-based model. The analysis predicted a slight decrease of approximately 1% in wind potential for 2024, followed by an annual increase of 1% from 2025 to 2028. Compared to 2023, energy production in 2026 is projected to rise by 3.5%, with further increases anticipated in 2027 and 2028. This study provides a detailed evaluation of the wind energy potential in the Central Anatolia Region and offers energy production forecasts for the Kırşehir wind farm during 2024–2028 using an ANN-based predictive model. As a result, the study comprehensively analyzes the current capacity, potential energy production, and annual variations in the region.

Keywords: Renewable energy sources, wind power plant, wind energy potential, ANN, power prediction

ToCite: ÖZTÜRK, M., KAYABAŞI, R & TAŞDEMİR, O., (2025). KIRŞEHİR'İN RÜZGAR ENERJİSİ POTANSİYELİ VE İÇ ANADOLU BÖLGESİ KURULU RÜZGAR ENERJİSİ SANTRALLERİNİN GÜÇ ANALİZİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 189-201.

GİRİŞ

Nüfus artışı, şehirleşme ve sanayileşme ile enerji kullanımını giderek artmaktadır. İnsanoğlu ihtiyaç duyduğu enerjiyi karşılamak için araştırmalarını sürdürmekte ve verimli enerji dönüşümü için çalışmalar yapmaktadır (Yang vd., 2020). Bu araştırma ve geliştirme süreçlerinde insanoğlunun doğaya verdiği zararlar zamanla ortaya çıkmaktadır. Nüfus artışı, sanayileşme ve enerji kaynaklarının geri dönüştürülemez olarak kullanımı atmosferin ortalama sıcaklığını artırmakta ve bu artış birçok canlı türünün yok olmasına, orman yangınlarının artmasına, bitki örtüsünde değişimlere, yeraltı ve yerüstü temiz su kaynaklarının kirlenmesine neden olmaktadır. Geri dönülmez bir aşamaya geçmeden insanoğlu bu gidişe çareler aramaktadır. Bu olumsuz etkilerin ortaya çıkmasında ve etkilerin küresel felakete dönüşmesinde CO₂ salınımının artışı yatmaktadır. Bu nedenle CO₂ salınımını artıran fosil yakıtlara alternatif olacak yeni kaynakların keşfi ve var olan kaynakların verimli bir şekilde yaygın olarak kullanılmasının önemi tüm dünya tarafından kabul görmektedir (Wang, 2021). YEK ve teknolojileri kullanılarak fosil yakıt tüketiminin azaltılması hız kazanmasına rağmen henüz yeterli seviyelere ulaşmamıştır.


Dünyada hızla artan enerji ihtiyacını karşılamak için akademik araştırmalar ve ticari geliştirmeler devam etmekte ve ülkeler enerji ihtiyaçlarını karşılamaya yönelik eğilimler ile kalkınma planlarını güncellemektedir. Son yıllarda giderek artan enerji kullanımından dolayı atmosferdeki CO₂ oranı önemli artışlar göstermiştir (IEA, 2024). Uluslararası Enerji Ajansı'na göre CO₂ emisyonlarının %50 azaltılmasını sağlamak amacıyla bir enerji devrimine ihtiyaç bulunmaktadır. Burada enerji verimliliği, enerji depolama, yeni ulaşım teknolojileri, nükleer enerji ve CO₂ yakalama ve depolama çok önemli bir rol oynamaktadır (Bilgili vd., 2015). Nüfus artışına bağlı olarak CO₂ üretimi artmakta bu durum sera etkisine dolayısıyla küresel ısınmaya sebep olmakta ve küresel ısınma sebebiyle de çevre felaketleri sık sık görülmektedir (Arslan vd., 2020). Dünyada enerji üretimi fosil kaynaklar, YEK veya nükleer enerji teknolojisiyle üretilmektedir. Bu kapsamda mevcut yapı ve teknolojilerin kullanılmasıyla var olan fosil yakıtlar kullanılmaya devam ederse dünya geri dönüşü mümkün olmayan çevre felaketlerine sürüklenmesi mümkündür. Bu nedenle çevre dostu ve yenilenebilir kaynakların geliştirilmesi ve yaygınlaştırılması önemlidir. Rüzgar enerjisi karbon salınımı yapmayan, temiz ve sürdürülebilir bir enerji kaynağıdır (Burton vd., 2001). Rüzgar enerjisinden 1 kWh'lık elektrik enerjisi üreterek 2,114 gr CO₂, 0,9 gr CO, 7,1 gr SO₂, 2,8 gr NOX, ve 0,18 gr külün atmosferimize karışması engellenerek küresel ısınma ile mücadele edilmektedir (Uğurel, 2000).

İlhan ve ark. yaptığı çalışmada Türkiye'nin toplam rüzgar enerjisi potansiyeli 115.329 MW olarak hesaplanmıştır. Toplam potansiyelin sadece %13'ü elektrik üretimine yönelik rüzgar enerjisi dönüşüm sistemlerinde değerlendirilmektedir (İlhan vd., 2020). Literatür de yapılan çalışmalar incelendiğinde uygun saha seçimi için Coğrafi Bilgi Sistemi (CBS) ve farklı kaynaklardan elde edilen verilerin değerlendirilmesi için kullanılan Çok Kriterli Karar Verme (ÇKKV) yöntemlerinden en çok kullanılan Analitik Hiyerarşi Süreci (AHS) kullanılarak Rüzgar Enerji Santrali (RES) kurulumu için gerekli alanlar belirlenmektedir (Sedici, 2016; Artun, 2020; Urfalı & Eymen, 2021). Rüzgar santrallerinde güç üretimi, arazinin topografyası, nem seviyesi, rüzgarın hızı ve yönü gibi bir dizi faktöre bağlıdır. Rüzgar enerjisi tahminlerinin uygulanması, enerji sektöründe sürdürülebilirliği ve verimliliği artırmaya hizmet ederken, aynı zamanda rüzgar santrallerinde enerji üretimiyle ilişkili belirsizlikleri azaltmaktadır (Çelik vd., 2024). Günümüzde yapılan çalışmalarda rüzgar enerjisi tahmini için yapay sinir ağları (YSA) ve bazı yapay zeka tabanlı modeller kullanılmaktadır. Ancak geleneksel yöntemler tahmin yeteneği ve doğruluk için daha sık kullanılmaktadır (Lagos vd., 2022). (Bilal vd., 2023) yapmış oldukları çalışmada Moritanya'nın Nouakchott bölgesindeki 30 MW'lık bir rüzgar santralinin verilerini uyarlanabilir nöro-bulanık çıkarım sistemi (ANFIS) ile hesaplamalı analizde kullanmışlardır. Farklı rüzgar türbinlerinden elde edilen çok az veri kullanılarak yüksek doğrulukta tahminler yapmışlardır.

Özşahin ve Kaymaz yapmış oldukları çalışmada Hatay ilindeki rüzgar santrallerinin yapım yeri seçiminin coğrafi faktörler kapsamında ve CBS metotlarını kullanarak incelemiştir. Hatay'ın RES yapımı için orta (% 45,19) ve iyi (25,64) duyarlılık düzeyinde bir yer olduğu tespit edilmiştir. Çalışma sonucunda elde edilen bulguların "Türkiye Rüzgar Enerji Potansiyeli Atlası (REPA)" ile önemli derecede örtüştüğü ifade edilmiştir (Özşahin & Kaymaz, 2013). (Yıldırım vd., 2016) yapmış oldukları çalışmada Niğde bölgesi rüzgar enerjisi potansiyelini Weibull dağılımı fonksiyonunu kullanarak istatistiksel olarak incelemiştir. Bu bağlamda rüzgar hızı ve rüzgar güç yoğunluğu aylık, mevsimsel ve yıllık olarak hesaplanmıştır. Rüzgar gücü yoğunluğunun kış ve ilk bahar aylarında en yüksek değerlere ulaşıldığı belirlenmiştir. (Korkmaz vd., 2024) Kırşehir ilinin RES kurulumu için uygun sahaların tespit edilmesi için 15 kriter belirleyerek inceleme yapmışlardır. Analitik Hiyerarşi Süreci (AHS) yöntemini kullanarak kriterlerin önem derecelerini belirlemiştir. Belirlenen önem derecelerine göre ilin RES uygunluk haritasını çıkarmışlardır. Haritaya göre kurulu olan GEYCEK-RES'in kurulumunun "çok uygun" sınıftaki sahada olduğunu ifade etmişlerdir. (Taşkın


vd., 2020) yapmış oldukları çalışmada Kırşehir ilinde kurul olan GEYCEK RES'in ekonomik faaliyetler ile yerel topluluğun tesisi kabul etme ilişkisini incelemişlerdir. Elde edilen anket ve görüşme sonuçlarına göre santralin ekonomik etkilerinin sınırlı olduğu ve bölge için bir kalkınma enstrümanı olmaktan uzak olduğu ifade edilmiştir. Ayrıca ekonomik etkinin genişletilebilmesi için Kırşehir ilinde bulunan yüksekokul ve teknik liselerde rüzgar enerjisi teknolojisi ile alakalı bölümlerin kurulması ve kalifiye insanların yetiştirilmesi gerekliliği ifade edilmiştir.

Dünyada enerji ihtiyacını karşılamak için kullanılan geleneksel ve çevreci yakıtların yıllara göre değişim senaryoları Exajoule (EJ) olarak Şekil 1'de verilmiştir. Geleneksel yakıtlar zaman içinde azalırken YEK'lerin kullanımı artmaktadır. Enerji ihtiyacını karşılamak ve dünyayı yaşanılabilir olarak tutmak için bu durum yüzyılıımızda zorunluluk haline dönüşmüştür.



Şekil 1. Dünyada Enerji Kaynakları Senaryoları (Solar Heat Europe, 2021)

Türkiye'nin 2023 yılındaki elektrik üretiminin kaynaklara göre dağılımı Şekil 2'de verilmiştir. YEK kullanılarak elde edilen elektrik enerjisi üretimi kaynaklara göre değişiklik göstermekte olup YEK kullanılarak üretilen elektrik enerjisinin yüzdesi fosil yakıtlar kullanılarak üretilen elektrik enerjisi yüzdesinin altında bulunmaktadır.



Şekil 2. Türkiye'de 2023 Yılında Elektrik Üretiminin Kaynaklara Göre Dağılımı

Dünyada ve Türkiye'de yenilenebilir enerji kaynaklarına yönelim hızla artarken birçok bölgede ve şehirde YEK yatırımları yapılmaktadır. Önemli bir rüzgar potansiyeline sahip olan İç Anadolu Bölgesi ve bünyesinde RES bulunan Kırşehir ili bu çalışmanın konusunu oluşturmaktadır. Bu çalışmanın amacı İç Anadolu Bölgesinin rüzgar potansiyeli ve kurulu gücünün nüfus ve gelişmişlik bakımından değerlendirilmesi ve özelinde Kırşehir Bölgesi RES'lerin yapay sinir ağları ile ileriye dönük üretim tahmininin yapılmasıdır.

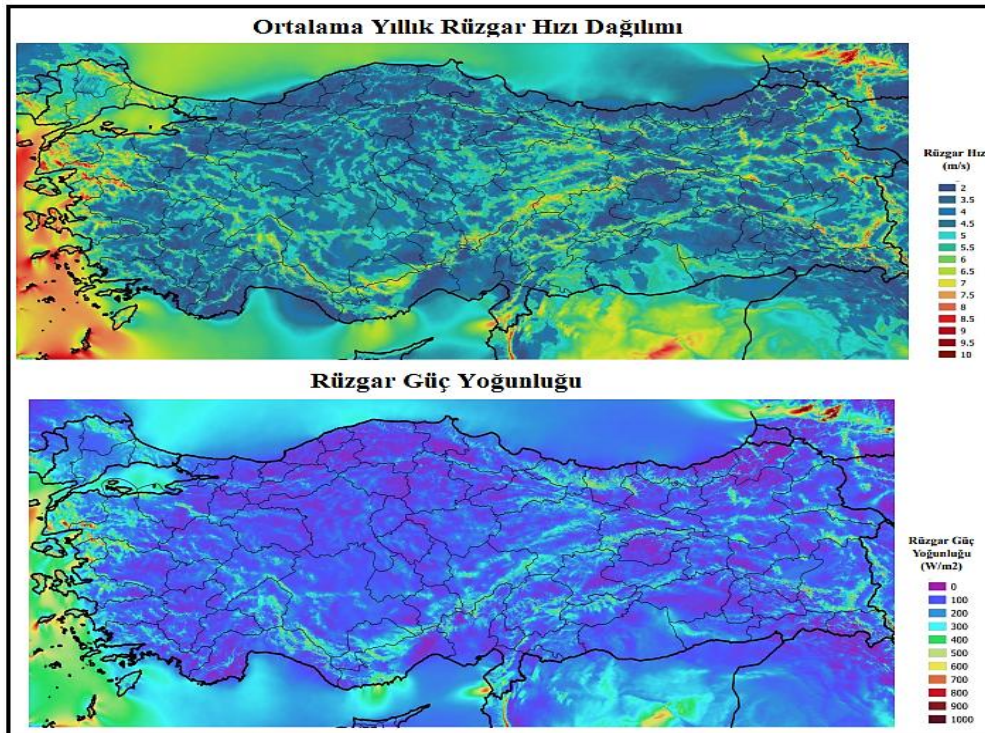
MATERYAL VE YÖNTEM

Yapılan çalışmada İç Anadolu Bölgesi illeri rüzgar potansiyeli ve kurulu santral güçleri incelenmiştir. İç Anadolu Bölgesi'nde bulunan Kırşehir ilinin rüzgar enerjisi potansiyeli hakkında detaylı bilgi verilmiştir. Ancak mevcut

kapasitenin, rüzgar enerjisi potansiyeline göre durumunun ileriye yönelik değerlendirilebilmesi için 2024 ve 2028 yılları arasında üretilebilecek rüzgar enerjisi tahmini yapılmıştır. Tahmin çalışmasında YSA tabanlı tahmin modeli kullanılmış olup çalışmada kullanılan veri seti, Kırşehir'deki 168 MW'e kurulu güce sahip RES tesisinin geçmiş çıkış gücü ölçümlerini kapsamaktadır. Tüm deneyler MATLAB 2018a altında 8 GB RAM'e sahip 2.1 GHz Intel (R) Core (TM) kişisel bilgisayarda gerçekleştirilmiştir.


Türkiye'nin Rüzgar Enerjisi Potansiyeli

Türkiye coğrafi konumu ve topoğrafyası nedeniyle önemli bir rüzgar enerjisi potansiyeline sahiptir. Türkiye Avrupa ülkeleri ile kıyaslandığında rüzgar enerjisi potansiyeli bakımından oldukça iyidir ve rüzgar teknik potansiyeli bakımından kurulu gücün üç katı potansiyeli bulunmaktadır (Bayrakçı & Delikanlı, 2007). Türkiye teorik rüzgar enerji potansiyeli denizlerde 17.393,20 MW iken karalarda 131.756,40 MW olarak hesaplanmıştır (Türkiye Rüzgar Enerjisi Birliği, 2016). Türkiye özellikle batı ve güney kıyı bölgeleri olmak üzere rüzgar enerjisi kaynaklarının yüksek olduğu bir bölgede yer almaktadır. Türkiye'nin coğrafi konumu rüzgar enerjisi potansiyeline katkıda bulunmaktadır. Türkiye stratejik olarak Avrupa ve Asya'nın kavşağında yer almaktadır ve bu da onu Avrupa ve Orta Doğu elektrik şebekeleri arasında bir köprü haline getirmektedir. Türkiye'nin batı ve güney kıyı bölgeleri, rüzgar enerjisi üretimi için ideal olan yüksek ve sürekli rüzgar enerjisine sahiptir. Türkiye'nin özellikle kuzey ve doğu bölgelerindeki dağlık arazisi, rüzgarların vadiler boyunca yönlendirilmesi ve rüzgar koridorlarının oluşturulması da dâhil olmak üzere rüzgar düzenekleri için uygun koşullar oluşturmaktadır. Bu topoğrafik özellikler ülkenin çeşitli yerlerinde rüzgar enerjisi potansiyelini artırmaktadır. Türkiye aynı zamanda Ege ve Akdeniz'de de önemli bir açık deniz rüzgar enerjisi potansiyeline sahiptir. Açık deniz rüzgar çiftlikleri, daha yüksek ve daha tutarlı rüzgar hızlarının yanı sıra açık deniz rüzgar kaynaklarından faydalanma avantajına da sahiptir. Türkiye rüzgar enerjisi potansiyelleri, rüzgar enerjisi uygulamalarını etkileyen tüm parametrelerin çıkarılmasıyla elde edilmiş değerlerdir Şekil 3. Potansiyel hesaplamaları, Türkiye çapında 200 m çözünürlükte rüzgar verilerinden ve bu verilerden oluşturulmuş haritalar üzerinden yapılmaktadır. Bu kapsamda rüzgar potansiyeli hesaplamaları için kullanılan varsayımlarda hesaba katılmayan alanlar çıkarılarak oluşturulmuş harita Şekil 3'te verilmiştir.




Şekil 3. Türkiye Rüzgar Enerjisi Potansiyel Atlası (Enerji ve Tabii Kaynaklar Bakanlığı, 2024).

Türkiye'nin kurulu gücü 2023 yılı aralık ayı sonu itibarıyla 106.668 MW'a ulaşmıştır. Kurulu gücün kaynaklara göre dağılımı %29,97 hidroelektrik, %24,13 doğal gaz, %20,08 kömür, %11,07 rüzgar, %10,61 güneş, %1,59 jeotermal ve %2,55 ise diğer kaynaklar şeklindedir. Ayrıca 2024 yılı itibarıyla Türkiye genelinde kurulu olan elektrik enerjisi üretim santrali sayısı toplamda 25.948 adet olup bunların 369 adeti rüzgar santrallerinden oluşmaktadır. Rüzgar enerjisine dayalı kurulu güç değişimi Şekil 4'te verilmiştir (Enerji ve Tabii Kaynaklar Bakanlığı, 2024).



Şekil 4. Rüzgar Enerjisine Dayalı 2011-2023 Yılları Kurulu Güç Değişimi (Enerji ve Tabii Kaynaklar Bakanlığı, 2024)

Mevcut kurulu güç içerisinde, rüzgar enerjisinin oranı da yıllara göre artış göstermektedir. Rüzgar enerjisinin kurulu güç içerisindeki dağılımını gösteren değişim Şekil 5'te verilmiştir. 2011 yılından itibaren her yıl rüzgar enerjisi kurulu gücün kurulu güç içerisindeki istikrarlı olarak %4 ile %11 arasında artış göstermiştir.



Şekil 5. Kurulu Güç İçerisindeki Rüzgar Enerjisi Dağılımı (Enerji ve Tabii Kaynaklar Bakanlığı, 2024)

Tüm dünyada olduğu gibi Türkiye'de de rüzgar enerjisine dayalı elektrik enerjisi üretimi her geçen gün artmaktadır. Dolayısıyla bu artışın nerelere kadar ulaşabileceğini tahmin etmek için Türkiye genelinde rüzgar enerjisi potansiyelinin çok iyi analiz edilmesi gerekir. Türkiye Rüzgar Enerjisi Potansiyeli Atlası (REPA-V1) verilerine göre 50 m yer seviyesinden yükseklikte ve yıllık ortalama 7,5 m/s rüzgar hızına sahip kullanılabilir alanlarda km² başına 5 MW gücünde RES kurulabileceği tahmin edilmektedir. Bu bağlamda Türkiye'de toplam 47.849,44 MW gücünde RES kurulabileceği belirlenmiştir. Bu potansiyel için gerekli olan toplam alan ise Türkiye yüz ölçümünün yaklaşık %1,30'una eşittir (Enerji ve Tabii Kaynaklar Bakanlığı, 2024). Rüzgar enerjisi potansiyeli kurulu güç bulunan Kırşehir Mucur gibi küçük yerleşim yerlerinde sanayi kollarını geliştirme potansiyeli olmasına rağmen bölgede rüzgar enerjisi teknolojileri teknik bilgi potansiyelinin sınırlı olması sektörün gelişimini yavaşlatmaktadır (Taşkın vd., 2020).

Türkiye'nin enerji talebi istikrarlı bir şekilde artmaktadır ve rüzgar enerjisi, ülkenin fosil yakıtlara olan bağımlılığını azaltırken ve sera gazı emisyonlarını düşürürken bu talebin karşılanmasında çok önemli bir rol oynayabilir. Türkiye, rüzgar türbini imalat ve kurulumunda atılımlar yaparak rüzgar enerjisi sektörünün büyümesine katkıda bulunmaktadır. Yerli rüzgar türbini imalat sanayi gelişmektedir. Türkiye, enerji karışımında yenilenebilir enerjinin payını artırmayı amaçlayan iddialı yenilenebilir enerji hedefleri belirlemiştir. Rüzgar enerjisinin bu hedeflere ulaşmada önemli bir rol oynaması beklenmektedir. Türkiye, önemli rüzgar enerjisi potansiyeline rağmen, bu

potansiyelin tam olarak hayata geçirilmesinde düzenleme ve finansman engelleri, şebeke altyapısı sınırlamaları ve çevresel kaygılar dahil olmak üzere zorluklarla karşı karşıyadır. Ancak ülkenin yenilenebilir enerjiye olan bağlılığı ve sektörde devam eden gelişmeler, rüzgar enerjisinin Türkiye'nin enerji ihtiyacını karşılamada hayati bir rol oynamaya devam edeceğini göstermektedir.

İç Anadolu Bölgesi'nin Rüzgar Enerjisi Potansiyeli

İç Anadolu Bölgesi'ndeki mevsimsel şartlar dikkate alınarak yıllık bazda rüzgar enerjisi potansiyelini etkileyen rüzgar hızı, rüzgar güç yoğunluğu ve kapasite faktörü değişimleri Tablo 1'de verilmiştir. Minimum rüzgar hızı 1,96 m/s iken maksimum rüzgar hızı 9,80 m/s'dir. Minimum kapasite faktörü %1,7 iken maksimum kapasite faktörü %60,1'dir. İç Anadolu Bölgesi'nin arazi çeşitliliği nedeniyle rüzgar enerjisi potansiyelinin farklılık gösterebileceğini unutmamak gerekir. Bazı alanlar diğerlerinden daha uygun koşullara sahip olabilir ve rüzgar enerjisi projeleri için en uygun yerlerin belirlenmesi için kapsamlı bir rüzgar kaynağı değerlendirmesi yapılması gerekmektedir. İç Anadolu Bölgesi önemli bir rüzgar enerjisi potansiyeli sunarken, aynı zamanda şebeke altyapısının geliştirilmesi, çevresel hususlar ve arazi kullanım planlaması gibi zorluklarla da karşı karşıyadır. Dikkatli yer seçimi, çevresel etki değerlendirmeleri ve topluluk katılımı, bölgedeki sürdürülebilir rüzgar enerjisi gelişiminin temel bileşenleridir.

Tablo 1. İç Anadolu Bölgesi Yıllık Rüzgar Hızı, Güç Yoğunluğu ve Kapasite Faktörü (Enerji ve Tabii Kaynaklar Bakanlığı, 2024)

Minimum rüzgar hızı (m/s)	1,96
Maksimum rüzgar hızı (m/s)	9,80
Ortalama rüzgar hızı (m/s)	4,53
Varyans	0,55
Standart sapma	0,74
Minimum güç yoğunluğu (W/m ²)	13,55
Maksimum güç yoğunluğu (W/m ²)	860,019
Ortalama güç yoğunluğu (W/m ²)	128,537
Varyans	3602,881
Standart sapma	60,024
Minimum kapasite faktörü (%)	1,7
Maksimum kapasite faktörü (%)	60,1
Ortalama kapasite faktörü (%)	17,3
Varyans	32,490
Standart sapma	5,7

İç Anadolu Bölgesi, Türkiye'nin önemli rüzgar enerjisi potansiyeline sahip bölgelerinden biridir ve burada aktif olarak rüzgar enerjisi projeleri geliştirilmektedir. Türkiye'nin merkezinde yer alan bu bölge, farklı rüzgar modellerine maruz kalan benzersiz bir coğrafi konuma sahiptir. İç Anadolu'da karasal ve Akdeniz ikliminin etkileri görülmekte, bu da rüzgar hızları ve yönlerinde dalgalanmalara yol açmaktadır. Bölge, platolar, vadiler ve dağlar gibi çeşitli topografik özelliklere sahip olup, bu değişiklikler rüzgar hızlarını artırarak enerjinin verimli bir şekilde üretilebileceği koşullar yaratmaktadır. Özellikle tepeler ve vadiler, rüzgarı yönlendirip yoğunlaştırarak türbinlerin kurulumu için uygun alanlar oluşturur. Ayrıca, bazı bölgelerde doğal rüzgar koridorları bulunmakta, bu koridorlar rüzgar hızlarını artırarak rüzgar türbinlerinin kurulumu için ideal koşullar sağlamaktadır.

İç Anadolu Bölgesi'nin zengin arazi çeşitliliği, rüzgar enerjisi potansiyelinin farklılık göstermesine neden olmaktadır. Bu nedenle, bölgedeki en uygun alanların belirlenmesi için kapsamlı bir rüzgar kaynağı değerlendirmesi yapılması önemlidir. Ancak, bu yüksek potansiyeli değerlendirirken bazı zorluklarla karşılaşmaktadır; örneğin, şebeke altyapısının güçlendirilmesi, çevresel etkiler ve arazi kullanım planlaması gibi unsurlar dikkatle ele alınmalıdır. Sürdürülebilir rüzgar enerjisi gelişimi için yer seçimi, çevresel etki değerlendirmeleri ve topluluk katılımı gibi faktörler büyük önem taşımaktadır.

Rüzgardan Enerjinin Elde Edilmesi

Havanın kütlesi olduğu gibi bir de ağırlığı bulunmaktadır. Atmosferi oluşturan havanın %78'i azot, %21'i oksijen ve kalan %1'i hidrojen, argon, metan ve helyum gibi gazlardır. Metreküp kuru havanın kütlesi 1 bar 20°C sıcaklıkta 1.204 kg iken 1 litre hava yaklaşık 1.2 gram gelmektedir (Smith, 2024).

Havanın ağırlığı nedeniyle hız kazandırılması ile kinetik enerjiye sahip olur. Bu durum kinetik enerji eşitliği ile Eşitlik 1 ile hesaplanır (İstanbul Teknik Üniversitesi, 2024).

$$E = \frac{1}{2}mv^2 \quad (1)$$

Rüzgar düşey bileşeni yatay bileşenine nispetle küçüktür ve ihmal edilirse Eşitlik 2 halini alır. Kütle (m) ve yatay rüzgar şiddeti (u) kullanılmaktadır.

$$E = \frac{1}{2}mu^2 \quad (2)$$

Eşitlik 3'te ise kütle (m) ve ρ havanın özgül kütle ve H ise hacmini göstermektedir.

$$m = \rho \times H \quad (3)$$

Rüzgarın yönüne dik gelen alan (A), rüzgar yönündeki uzunlukta (L) olur ve hacim Eşitlik 4 ile elde edilir.

$$H = A \times L \quad (4)$$

Ayrıca L mesafesini rüzgar şiddetine ve zamana göre düzenlenirse Eşitlik 5 ve L yerine konarak kütle Eşitlik 6 halini alır.

$$L = u \times t \quad (5)$$

$$m = \rho \times A \times u \times t \quad (6)$$

Enerji eşitliğinde ifadeler yerine konulduğunda Eşitlik 7 elde edilir.

$$E = \frac{1}{2} \times \rho \times A \times t \times u^3 \quad (7)$$

Birim alandan birim zamanda ne kadar rüzgar enerjisi elde edilebileceği Eşitlik 7 ile hesaplanır. Eşitlik 7'de (ρ) değeri $1,223 \text{ kg/m}^3$ standart atmosfer şartlarında deniz seviyesindeki yoğunluk kabul değeridir. Yatay rüzgar şiddeti ise 10 metre yükseklikte ölçülen (U) değeridir.


Yapay Sinir Ağları ile Rüzgar Güç Tahmin Uygulaması

YSA, yaygın olarak paralel dağıtılmış ve nöron adı verilen basit işlem birimlerinden oluşan bir işlemcidir. Deneysel bilgiyi kullanım için geçerli olacak şekilde depolamak ve anlamak için doğal bir yeteneğe sahiptir. YSA, yüksek hızlı bilgi işleme, eşleme yetenekleri, hata toleransı, genelleme ve sağlamlık gibi mükemmel özellikler sergiler. Bu özellikler YSA'yı farklı mühendislik sistemlerinin performansının modellenmesi, tahmini ve optimizasyonu için güçlü ve akıllı bir araç haline getirmektedir. Bu nedenle, farklı uygulamalarındaki karmaşık, doğrusal olmayan mühendislik problemlerinde çok fazla kullanılmaktadır (Jani vd., 2017; Siami-Irdemoosa & Dindarloo, 2015).

Genel olarak, birçok YSA modelinin tasarımında kullanılan nöron modeli, sinaps adı verilen ve her birinin kendi ağırlığı w_{kj} olan bir grup bağlantıdan oluşur. Bu ağırlık, tüm ağırlıklı girdileri toplamadan önce kendi girdisi x_j ile çarpılır ve toplamın çıktısı v_k 'yi düşürmekten veya artırmaktan sorumlu olan harici bir önyargı b_k ile toplanır. Daha sonra, çıkış sinyali y_k 'nin genlik aralığını sonlu bir değere düşürmek için bu çıkışa bir aktivasyon fonksiyonu $\phi(\cdot)$ uygulanır. Şekil 6'da doğrusal olmayan nöron modeli verilmiştir.

Çıkış ifadesinin matematiksel ifadesi ise Eşitlik 8'de verilmiş olup, eşitlikteki k ve j sırasıyla nöron ve sinaps sayılarını ifade etmektedir.

$$y_k = \phi\left(\sum_{j=1}^m (w_{kj}) + b_k\right) \quad (8)$$



Şekil 6. Doğrusal Olmayan Nöron Modeli

Yapılan çalışmada, YSA kullanılarak rüzgar gücü tahmini yapılmıştır. Tahmin çalışması yapılırken aşağıdaki adımlar kullanılmıştır.

- Veri toplama

Rüzgar gücü tahmininde, giriş verisi olarak geçmiş rüzgar gücü, rüzgar hızı, sıcaklık ve bağıl nem parametreleri kullanılarak veriler gruplandırılmıştır.

- Sinir ağı modeli tasarımı


Tahmin modeli için çok katmanlı YSA modeli kullanılmış ve girdi verileri kullanılarak çıkış verileri elde edilmiştir.

- Modelin eğitimi ve test edilmesi

Modelin eğitiminde, geçmiş rüzgar gücü verileri ve meteorolojik veriler kullanılmıştır. Eğitim süreci boyunca, modelin tahminleri ile gerçek veriler arasındaki hata oranı minimize edilmeye çalışılmıştır. Model eğitildikten sonra, doğruluğunun değerlendirilmesi için ortalama mutlak yüzdesel hata fonksiyonu kullanılmıştır.

BULGULAR

Bu çalışma ile İç Anadolu Bölgesinde bulunan 13 ilin rüzgar enerji potansiyeli ve devrede olan elektrik santral güç dağılımı incelenmiştir. Kırşehir Bölgesi'nin 2021 ve 2023 yılları arasında üretmiş olduğu rüzgar gücü değişimi Şekil 7'de gösterilmiştir. Kurulu rüzgar gücü artışı ile birlikte yıllara bağlı rüzgar potansiyelinde büyük bir değişim olmasa bile üretimde artış gözlemlenmektedir.



Şekil 7. Gerçekleşen Rüzgar Gücü Üretimi

Bölgenin gelecek 5 yıl için rüzgar enerjisi potansiyeline göre potansiyel değişimini hesaplayabilmek için yıllık bazda günlük geçmiş rüzgar güç verileri kullanılarak ileriye dönük güç tahmini yapılmıştır. Ancak ileriye yönelik yapılan


güç tahmininin başarılı bir performans göstermesi için kullanılan YSA tahmin modeli performansının önceden değerlendirilmesi gerekir. Bunun için 2023 yılında gerçekleşen rüzgar gücü üretimi YSA modeliyle tahmin edilmiştir. Tahmin modelinin performansını değerlendirmek için ise ortalama mutlak yüzdesel hata (OMYH) fonksiyonu kullanılmıştır (Irmak vd., 2024). OMYH fonksiyonunun ifadesi Eşitlik 9'da verilmiş olup, eşitlikteki p_i , t_i , n sırasıyla tahmin edilen değer, ölçülen gerçek değer ve toplam veri noktası sayısını temsil etmektedir. Ayrıca tahminde kullanılan veri seti Tablo 2'de verilmiştir.

$$OMYH = \frac{1}{n} \sum_{i=1}^n \left(\frac{t_i - p_i}{t_i} \right) \times 100 \quad (9)$$

Tablo 2. Tahminde Kullanılan Veri Seti


Girişler	Çıkış
Geçmiş rüzgar gücü	Rüzgar çıkış gücü
Rüzgar hızı	
Sıcaklık	
Bağıl nem	

Önerilen tahmin model performansının değerlendirilmesi için 2023 yılı için yapılan rüzgar gücü tahmininde OMYH değeri %6,46 olarak gerçekleşmiştir. Ayrıca veri setinin tamamı için gerçekleşen ve tahmin edilen rüzgar gücü değişimi Şekil 8'de gösterilmiştir.



Şekil 8. 2023 Yılı Verileri İçin Tahmin Sonuçları

Tahmin modeli 2023 yılı için yapılan tahminde başarılı sonuçlar vermiştir. Tahmin modelinin başarısı gözlemlendikten sonra geçmiş güç verileri kullanılarak 2024, 2025, 2026, 2027 ve 2028 yılları için rüzgar gücü tahmini yapılmıştır. Şekil 9'da tahmin sonuçlarına göre tahmin edilen rüzgar gücü üretim tahmin sonuçlarının değişimi verilmiştir. Tahmin edilen rüzgar gücü potansiyeli bazı yıllarda artış gösterdiği gibi bazı yıllarda azalma göstermektedir.




Şekil 9. Tahmin Edilen Rüzgar Gücü Üretimi

2021-2023 yılları arasında gerçekleşen rüzgar gücü ve 2024-2028 yılları arasında üretilmesi tahmin edilen rüzgar gücü değerleri Tablo 3'te verilmiş olup, 2021-2028 yılları arasındaki rüzgar gücü değişimi ise Şekil 10'da gösterilmiştir. 2023 yılında gerçekleşen enerji üretimine oranla 2026 yılında tahmin edilen enerji üretimi %3,5 artmıştır. 2027 ve 2028 yıllarında tahmin edilen enerji üretimi sürekli artış göstermiştir.


Tablo 3. Yıllara Göre Rüzgar Gücü (MW)

Yıllar	Rüzgar gücü (MW)
2021	393650,92
2022	371894,02
2023	391477,18
2024 (tahmin)	389881,35
2025 (tahmin)	397169,23
2026 (tahmin)	405501,40
2027 (tahmin)	403515,15
2028 (tahmin)	411632,42




Şekil 10. Rüzgar Gücünün Yıllara Göre Değişimi

İç Anadolu Bölgesinde bulunan 13 il içerisinde rüzgar enerjisinden elektrik üretimi yapan 8 il bulunmaktadır. Bu sekiz il içerisinde kurulu güç 338 MW ile Kayseri birinci sıradadır Şekil 11. Kurulu güç bakımından ilk üç il içinde yüksekten aza doğru Kayseri, Konya ve Kırşehir bulunmaktadır.




Şekil 11. İç Anadolu Bölgesinde Devredeki Rüzgar Santralleri (Enerji ve Tabii Kaynaklar Bakanlığı, 2024)

İç Anadolu Bölgesinde bulunan illerde ortalama sıcaklık ve ortalama yağışlı gün sayıları dağılımı Şekil 12’de verilmiştir. İç Anadolu Bölgesinde Sivas ve Yozgat yağışlı gün bakımında yüksek yıllık ortalama sıcaklık bakımından düşüktür. Kırıkkale, Aksaray ve Karaman ise yıllık ortalama sıcaklık bakımından yüksek değerlere sahiptir. Atmosferik koşullar rüzgar enerjisinin potansiyelini ve üretim sürecini doğrudan etkileyen önemli bir unsurdur. Bu nedenle kurulum yapılacak alanın meteorolojik koşullarının ve rüzgar potansiyelinin incelenmesi gerekmektedir.



Şekil 12. İç Anadolu İllerinin Yıllık Ortalama Sıcaklık ve Yağışlı Gün Dağılımı (Meteoroloji Genel Müdürlüğü, 2024)

İç Anadolu Bölgesin ’de kurulu güç ile nüfus dağılımı incelendiğinde Ankara ilinin nüfus yoğunluğu yüksek olmasına rağmen rüzgar enerjisi kurulu gücünün henüz bulunmadığı Konya’nın nüfus yoğunluğu bakımından bölgenin ikinci ili iken kurulu güç olarak yine ikinci sırada olduğu görülmektedir. Kırşehir ise nüfus yoğunluğu bakımından düşük olmasına rağmen kurulu rüzgar gücü bakımından 13 il içerisinde üçüncü sırada yer almaktadır. Şekil 13 incelendiğinde illerin nüfusu ile kurulu güç oranlarının orantılı olmadığı görülmektedir.



Şekil 13. İç Anadolu Bölgesi İlleri Rüzgar Enerjisi Santralleri Kurulu Güç Ve Nüfus Dağılımı

SONUÇ

Yapılan bu çalışmada İç Anadolu Bölgesi illeri rüzgar potansiyeli ve kurulu santral güçleri incelenmiştir. İç Anadolu Bölgesi Kırşehir bölgesinde 2024 ve 2028 yılları arasında üretilebilecek rüzgar enerjisi tahmini yapılmıştır. Tahmin çalışmasında ise literatürde rüzgar gücü tahmini için yaygın olarak kullanılan YSA modeli kullanılmıştır.

Çalışmada aşağıdaki sonuçlara varılmıştır.

- Tahmin edilen rüzgar potansiyeli 2024 yılında % 1'e yakın düşmüş 2025-2028 yılları arasında her yıl bir önceki yıla göre %1 artış göstermiştir. Potansiyel değişimi ve kurulu güç artışına bağlı olarak elektrik enerjisi üretimi artacaktır.
- 2023 yılında gerçekleşen enerji üretimine oranla 2026 yılında tahmin edilen enerji üretimi %3,5 artmıştır. 2027 ve 2028 yıllarında tahmin edilen enerji üretimi sürekli artış göstermiştir.
- Rüzgar enerjisi potansiyeli İç Anadolu Bölgesinde yüksek olmasına rağmen henüz yeterli kurulu güç oranına ulaşmamıştır.
- Kurulu rüzgar gücü nüfus ile bağlantısı bulunamamış olup kurulu güç rüzgar potansiyeli ile bağlantılı olarak illerde artmaktadır.
- Kurulacak rüzgar santrallerinin rüzgar potansiyelinin yanı sıra bölgesel tüketim ihtiyacının da göz önünde bulundurularak değerlendirilmesi gerekmektedir.
- Kurulu rüzgar santrallerinin bölgesel kalkınmaya hizmet etmesi için il ve ilçelerde bulunan teknik programların yenilenebilir enerji alanlarına uygun alanlarda yoğunlaşması önem arz etmektedir.

Rüzgar enerjisi potansiyeli bulunan illerin lokasyonlarında kurulacak santraller ülke genelinde enterkonnekte sistemin yükünü azaltacak böylece enerji nakil maliyetlerinin artmasına engel olacaktır ve enerji nakil hatları kapasite artımı ihtiyacını erteleyecektir. Enerji kaynağı çeşitliliği sağlayacak olup yerinde üret ve yerinde tüket ile elektrik enerjisinin uzun mesafelerden tedarikine gerek duymadan daha küçük dağıtım hatlarıyla enterkonnekte sisteme bağlanarak dağıtımını sağlayacaktır. Ayrıca bölgenin rüzgar potansiyelini kullanmamıza fırsat verecek olup bölge insanının çevre duyarlılığı kazanmasına fırsat sunacaktır.

KAYNAKLAR

Arslan, H., Baltacı, H., Akkoyunlu, B.O., Karanfil, S., & Tayanc, M. (2020). Wind speed variability and wind power potential over Turkey: Case studies for Çanakkale and İstanbul. *Renewable Energy*, 145, 1020-1032. <https://doi.org/10.1016/j.renene.2019.06.128>.

Artun, O. (2020). Determination of the suitable areas for the investment of the wind energy plants (WEP) in Osmaniye using Analytical Hierarchy Process (AHP) and Geographic Information Systems (GIS). *Avrupa Bilim ve Teknoloji Dergisi*, (20), 196-205. <https://doi.org/10.31590/ejosat.763866>

Bayrakçı, C.H., & Delikanlı, K. (2007). Türkiye'de rüzgar enerjisi ve potansiyel belirleme çalışmaları. *Mühendis ve Makina Dergisi*, 48(569), 78-80.

Bilal, B., Adjallah, K. H., Sava, A., Yetilmezsoy, K., & Ouassaid, M. (2023). Wind turbine output power prediction and optimization based on a novel adaptive neuro-fuzzy inference system with the moving window. *Energy*, 263, 126159.

Bilgili, M., Özbek, A., Şahin, B., & Kahraman, A. (2015). An overview of renewable electric power capacity and progress in new technologies in the world. *Renewable and Sustainable Energy Reviews*, 49, 323-334. <https://doi.org/10.1016/j.rser.2015.04.148>

Burton, T., Sharpe, D., Jenkins, N., & Bossanyi, E. (2001) *Wind energy handbook*. Baffins Lane, Chichester West Sussex PO19 1UD: John Wiley & Sons Ltd.

Çelik, E., Bal, G., Öztürk, N., Bekiroglu, E., Houssein, E. H., Ocak, C., & Sharma, G. (2024). Improving speed control characteristics of PMDC motor drives using nonlinear PI control. *Neural Computing and Applications*, 1-12.

Enerji ve Tabii Kaynaklar Bakanlığı, www.enerji.gov.tr, Son Erişim: 15.01.2024

International Energy Agency. (2024). *World Energy Outlook 2024*. Paris: IEA Publications.

Irmak, E., Yeşilbudak, M., & Taşdemir, O. (2024). Enhanced PV power prediction considering PM10 parameter by hybrid JAYA-ANN Model. *Electric Power Components and Systems*, 1-10. <https://doi.org/10.1080/15325008.2024.2322668>

İlhan, A., Bilgili, M., & Şahin, B. (2020). Analyses of current wind energy status of Turkey and its future prospect. *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 35 (4), 1059-1072. <https://doi.org/10.21605/cukurovaummfd.869175>

İstanbul Teknik Üniversitesi, <https://web.itu.edu.tr/~kaymak/images/windpower.html>, Son Erişim: 20.01.2024

- Jani, D.B., Mishra, M., & Sahoo, P.K. (2017). Application of artificial neural network for predicting performance of solid desiccant cooling systems—a review. *Renew. Sustain. Energy Rev.*, 80, 352–366. <https://doi.org/10.1016/j.rser.2017.05.169>
- Korkmaz, M., Öztürk, N., & Harnuboğlu, S. (2024). Kırşehir il sınırları içerisinde Rüzgâr Enerjisi Santrali (RES) kurulumu için uygun sahaların mekânsal olarak belirlenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 12(1), 463-495. <https://doi.org/10.29130/dubited.1181883>
- Lagos, A., Caicedo, J. E., Coria, G., Quete, A. R., Martínez, M., Suvire, G., & Riquelme, J. (2022). State-of-the-Art using bibliometric analysis of Wind-Speed and-Power forecasting methods applied in power systems. *Energies*, 15(18), 6545.
- Meteoroloji Genel Müdürlüğü, <https://www.mgm.gov.tr/>, Son Erişim: 20.01.2024
- Özşahin, E., & Kaymaz, Ç.K. (2013). Rüzgar enerji santrallerinin yapım yeri seçimi üzerine bir CBS analizi: Hatay Örneği. *Türk Bilim Dergisi*, 6(2), 1-18.
- Siami-Irdemoosa, E., & Dindarloo, S.R. (2015). Prediction of fuel consumption of mining dump trucks: a neural networks approach. *Appl. Energy*, 151, 77–84. <https://doi.org/10.1016/j.apenergy.2015.04.064>
- Smith, J. (2024). Chemical composition of air and its applications in energy engineering. *Journal of Energy Engineering*, 150(3), 34-45.
- Sediqi, K.J. (2016). Gis-based multi-criteria approach for land-use suitability analysis of wind farms: the case study of Karaburun Peninsula, Izmir,-Turkey. MSc, Izmir Institute of Technology, İzmir.
- Solar Heat Europe, <https://solarheateurope.eu/2021/06/18/ieas-net-zero-by-2050-a-roadmap-for-the-global-energy-sector/iea-2050-pic-3/>, Son Erişim: 20.02.2024
- Uğurel, A. (2000). Rüzgar ve güneş enerjisinden elektrik üretimi ve türkiye için önemi, III. Ulusal Temiz Enerji Sempozyumu, UTES'2000, İstanbul.
- Urfali, T., & Eymen, A. (2021). CBS ve AHP yöntemi yardımıyla Kayseri ili örneğinde rüzgâr enerji santrallerinin yer seçimi. *Geomatik*, 6(3), 227-237. <https://doi.org/10.29128/geomatik.772453>
- Taşkın, E., Yılmaz, M., & Kılıç, Ç. (2020). Rüzgâr enerji santrallerinin ekonomik etkileri ve sosyal kabul: Mucur örneği. *Coğrafi Bilimler Dergisi*, 18(2), 296-319.
- Türkiye Rüzgar Enerjisi Birliği, www.tureb.com.tr, Türkiye’de rüzgar enerji santralleri illere göre kurulu gücü, Türkiye Rüzgar Enerjisi İstatistik Raporu, Son Erişim: 10.02.2024
- Yang, J., Cai, W., Ma, M., Li, L., Liu, C., Ma, X., & Chen, X. (2020). Driving forces of China’s CO2 emissions from energy consumption based on Kaya-LMDI methods. *Science of the Total Environment*, 711, 134569. <https://doi.org/10.1016/j.scitotenv.2019.134569>
- Yıldırım, U., Gazibey, Y., & Güngör, A. (2016). Niğde ili rüzgar enerjisi potansiyeli. Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi, 1(1), 37-47. <https://doi.org/10.28948/ngumuh.239392>
- Wang, F., Harindintwali, J. D., Yuan, Z., Wang, M., Wang, F., Li, S., ... & Chen, J. M. (2021). Technologies and perspectives for achieving carbon neutrality. *The Innovation*, 2(4), 1-22. <https://doi.org/10.1016/j.xinn.2021.100180>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 19.08.2024
Kabul Tarihi : 13.09.2024

Received Date : 19.08.2024
Accepted Date : 13.09.2024

RÜZGÂR GÜCÜ TAHMİNİNDE UZUN KISA-SÜRELİ BELLEK: VERİ ÖRNEKLEME VE KÜMELEMENİN ETKİSİ

LONG SHORT-TERM MEMORY FOR WIND POWER ESTIMATION: THE EFFECT OF DATA SAMPLING AND CLUSTERING

Volkan YAMAÇLI¹ (ORCID: 0000-0003-0331-8818)

¹ Mersin Üniversitesi, Bilgisayar Mühendisliği Bölümü, Mersin, Türkiye

*Sorumlu Yazar / Corresponding Author: Volkan YAMAÇLI, vyamacli@mersin.edu.tr

ÖZET

Rüzgâr enerjisi, temiz, yenilenebilir ve çevre dostu olarak geleneksel güç kaynaklarının en verimli alternatiflerinden biridir. Bununla birlikte, rüzgâr hızının ve dolayısıyla güç kalitesinin değişken doğasından dolayı, elektrik şebekesinin güvenliği ve güvenilirliğinin önünde bazı engeller oluşabilmektedir. Rüzgâr hızı ve gücü tahmini aracılığı ile güç planlaması sorununu çözebilmek için, en popüler yinelemeli sinir ağlarından (YNSA) biri olan uzun kısa-sürelî bellek (UKSB) tabanlı bir tahmin modeli önerilmektedir. Bu çalışmada Türkiye’de mevcut olan bir rüzgâr türbininden elde edilen ve yayımlanan bir veri seti kullanılmıştır. İlk olarak UKSB ağı, rüzgâr hızı ve rüzgâr gücü zaman-dizilerine ilişkin farklı pencere boyutundaki veriler için eğitilmiştir. Daha sonra bu iki UKSB ağının çıktıları başka bir UKSB ağı için girdi olarak kullanılarak daha yüksek aralıklarla daha az miktarda veri için sağlam bir yaklaşım sağlanması hedeflenmiştir. Nihai rüzgâr gücü tahmin verileri, her bir dizinin sonuçları kullanılarak elde edilir. 30-dakikalık, 1-saatlik, 6-saatlik ve 1-günlük aralıklarla 4 farklı durum çalışması yapılarak önerilen algoritmanın etkinliği gösterilmiştir.

Anahtar Kelimeler: Rüzgâr enerjisi, uzun kısa-sürelî bellek, yinelemeli sinir ağları, rüzgâr güç tahmini.

ABSTRACT

Wind energy is one of the most efficient substitutes for traditional power sources, which is clean, renewable and friendly to the environment. Nonetheless, there are some of obstacles to the security and dependability of power grid functioning due to the erratic nature of wind speed and power quality. In order to address scheduling problem through wind speed and power prediction, a long short-term memory (LSTM)-based prediction model, one of the most popular recurrent neural networks (RNN), is proposed. In this study, the dataset obtained from a wind turbine placed in Turkey is used. At first, the LSTM network is trained for different window size of data for wind speed and power sequences. Then, the outputs of these two LSTM networks are used as an input for another LSTM network ensuring a robust approach for lower amount of data with higher intervals. The final wind power forecasting data are obtained by using each sequences’ results. Four different case studies are carried out based on intervals of 30-minutes, 1-hour, 6-hours, and 1-day in order to the efficiency of the proposed algorithm is shown.

Keywords: Wind energy, long short-term memory, recurrent neural networks, wind power forecasting.

GİRİŞ

Enerji, modern toplumun hızlı ilerlemesinin ve dünya ekonomisinin başarılı gelişiminin önemli bir bileşenidir ve insanın enerjiye olan ihtiyacı her zaman artmaktadır (Shi vd., 2020). Bununla birlikte; kömür, petrol ve doğal gaz gibi geleneksel fosil yakıt kaynaklarının aşırı kullanımı ile enerji kaynaklarının tükenmesi ve çevreye verilen zarar arasında önemli bir ilişki vardır. Dolayısıyla son zamanlarda rüzgâr, güneş, dalga gibi yenilenebilir enerji santrallerine olan ihtiyaç önemli ölçüde artmakla birlikte, bu santrallerin en verimli biçimde kullanılabilmesi de ToCite: YAMAÇLI, V., (2025). RÜZGÂR GÜCÜ TAHMİNİNDE UZUN KISA-SÜRELİ BELLEK: VERİ ÖRNEKLEME VE KÜMELEMENİN ETKİSİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 202-215.

çalışma konusu haline gelmiştir. Dünya genelinde rüzgâr enerjisinin toplam kurulu kapasitesi son yıllarda 743 GW değerine ulaşmıştır ve 2019 yılından bu yana yeni kurulan rüzgâr enerjisi kapasitesi 93 GW olup %53'lük bir büyümeyi temsil etmektedir (Ai vd., 2022). Rüzgâr enerjisi, yeşil yenilenebilir bir enerji kaynağı olarak ekonomik kalkınma için muazzam bir potansiyele sahiptir ve ilgili tahmin teknolojisi araştırmaları giderek daha önemli hale gelmektedir. Rüzgâr gücü tahmini için rüzgâr hızının tahmin edilmesi gereklidir. Rüzgâr enerjisinin günlük ritmi, yüksek stokastik öngörülemezliği ve döngüsel doğası, güvenilir rüzgâr enerjisi tahminini imkânsız hale getirebilmektedir. Yerel ve bölgesel iklimler, arazi koşulları ve binalar gibi engeller rüzgâr enerjisini etkilediğinden, rüzgâr enerjisi kaynaklarının optimum dönüşümü ve uygulanması için bölgenin rüzgâr özelliklerine ilişkin doğru ve kapsamlı bilginin gerekli olduğu açıktır. Ancak rüzgâr kaynaklarının öngörülemeyen, istikrarsız ve düzensiz doğası, güç sisteminin istikrarlı bir şekilde çalışabilmesi için önemli sorunlar ve engeller yaratmıştır. Kısaca, rüzgâr enerjisi kaynaklarının optimum şekilde dönüştürülmesi ve uygulanması için bölgenin rüzgâr özellikleri hakkında doğru ve kapsamlı veriler gerekmektedir. Bilim adamları son zamanlarda, tarihsel rüzgâr hızı zaman serilerine dayanarak çeşitli tahmin yaklaşımları geliştirmişlerdir. Bunların arasında en popüler olan son zamanlarda daha aktif kullanılan derin öğrenme metodlarına dayanmaktadır. Rüzgâr hızı tahminleri, farklı zaman dilimlerine göre ultra kısa vadeli birkaç saniye ile 30 dakika arası; kısa vadeli 30 dakika ile 6 saat arası, orta vadeli 6 ile 24 saat arası ve uzun vadeli 1 ila 7 gün arası olarak sınıflandırılabilir (Jung & Broadwater, 2014). Yukarıda belirtilen sorunları çözmek için geleneksel rüzgâr enerjisi tahmin araçları tam anlamıyla yeterli değildir. Bu nedenle son yıllarda ortaya atılan yapay zekâ teknolojilerinin uygulanması zorunlu bir hal almıştır. İnsan zekasını taklit etmek, genişletmek ve geliştirmek için fikirlerin, tekniklerin, teknolojilerin ve uygulama sistemlerinin incelenmesi, bilgisayar bilimi yapay zekâ alanının odak noktasıdır.

Son yıllarda literatürde rüzgâr hızı tahmini ile ilgili birçok yeni çalışma mevcuttur. Rüzgâr hızı verilerini eğitirken ve tahmin ederken, regresörler, Çok Değişkenli Doğrusal Regresyon (ÇDDR) ve Yapay Sinir Ağı (YSA) dahil olmak üzere akıllı öğrenme teknikleri, rüzgâr hızındaki doğrusal olmayan değişimleri ayarlarken daha iyi performans gösterir (Bokde vd., 2019). Ayrıca rüzgâr hızı ve dolayısıyla rüzgâr gücü tahmininde YSA'lar sıklıkla kullanılabilir. YSA'ların avantajları güçlü, kendi kendine öğrenme yeteneklerini ve iyi doğrusal olmayan uyumu içerir. Bununla birlikte, gizli katmanların sayısı da dahil olmak üzere ağ yapısının oluşturulması zordur ve yavaş yakınsama oranı, yerel optimum değere kaymayı kolaylaştırır. Ultra kısa vadede rüzgâr hızının mekânsal dağılımını tahmin etmek için, evrişimli sinir ağlarına (ESA) dayanan bir rüzgâr hızı tahmin modeli, rüzgâr hızının zamansal ve mekânsal korelasyonunu hesaba katabilir. Ayrıca, geri yayımlı sinir ağları (GYSA), destek vektör makineleri (DVM), aşırı öğrenme makineleri (AÖM), bulanık mantık yöntemleri ve Kalman filtre yöntemleri gibi yapay zekâ tabanlı teknikler, rüzgâr alanında önemli ölçüde artmıştır (Shao vd., 2021). Bilgisayar biliminin hızla ilerlemesiyle hız tahmini, doğrusal olmayan özellikleri çıkarma ve genelleme yeteneği ile bu yapay zekâ tabanlı modeller, rüzgâr hızı eğilimlerinin doğrusal olmayan ilişkisini yakalamada çok başarılı olabilmektedir (Sun & Wang, 2018), rüzgâr hızı tahmini için GYSA'nın bileşik yapısını önermiş ve uygulamıştır, bununla birlikte modelin doğruluğunu ve dayanıklılığını arttırmak için (J. Wang vd., 2013), rüzgâr enerjisi tahmini için geliştirilmiş model arama algoritmasına dayalı bir DVM önermiştir. Çok sayıda faktör rüzgâr hızını etkilemektedir ki ve hiçbir tahmin modeli sayısal fonksiyonlara bağlı olarak bu durumu ifade edememektedir. Tek bir model, özellikle aşırı değişken koşullarında yeterli öğrenmeye sahip değildir ve bu da tahminden önemli ölçüde sapmaya neden olabilir. Çeşitli tekli modelleri uygun şekilde birleştirerek ve her modelin faydalarını vurgulayarak, birleşik tahmin yaklaşımı, aynı anda birkaç modelin avantajlarını hesaba katar ve tahmin doğruluğunu büyük ölçüde artırabilir (J. Wang vd., 2020). Rüzgâr hızı verileri, dalgacık ayrıştırması (Gan vd., 2021; Lopez vd., 2020) ve değişken mod ayrıştırması (DMA) (Li vd., 2020; Xie vd., 2021) kullanılarak da iyileştirilmiş ve doğru sonuçlar tahmin edilebilmiştir. Ayrıca, kısa vadeli rüzgâr hızı tahmin modelini ek tahmin teknikleri ile birlikte geliştirerek, Hilbert-Huang dönüşümü (HHD) (Chen vd., 2024) ve diğer teknikler rüzgâr hızı verilerinin girdi özelliklerini çıkarmayı ve iyi tahmin sonuçları üretmeyi başarabilmektedir.

Bir YNSA versiyonu olarak, uzun kısa-süreli bellek (UKSB), uzun vadeli bağımlılık sorunlarını ele alabilir ve doğuştan gelen gizli özellikleri ortaya çıkarabilir. Bir çalışmada, (Memarzadeh & Keynia, 2021) tarafından elektriğin fiyatını ve yükünü tahmin etmek için UKSB 'ye dayalı bir derin öğrenme tekniği geliştirilmiştir. (Lawal vd., 2021), kısa vadede rüzgâr hızını etkili bir şekilde tahmin etmek için çift yönlü UKSB ve 1-boyutlu ESA kombinasyonunu kullanmıştır. Bununla birlikte, bir optimizasyon algoritması olan parçacık sürüsü optimizasyonu (PSO), (Al-Shaikhi vd., 2022) tarafından hibrit bir UKSB modelinde kullanarak iyi bir sonuç elde etmiştir. Bununla birlikte, özellikle son yıllarda, rüzgâr enerjisine dair çalışmaları içeren birçok çalışma mevcuttur. Bu çalışmalar rüzgâr enerjisinin genel ve geniş güç sistemlerinde kullanımına yönelik veya rüzgâr enerjisi tahminine yönelik olabilmektedir. Rüzgâr enerjisi içeren güç sistemlerine dair farklı optimizasyon çalışmaları gerçekleştirilmiştir (Abaci vd., 2024). Bazı çalışmalarda

ise farklı olarak hem rüzgâr hem de güneş enerjisi sistemlerinin elektriksel açıdan optimizasyonu sağlanmıştır (Yamaçlı vd., 2024). Ek olarak, (Guan vd., 2023) tarafından ultra-kısa-sürelili rüzgâr gücü tahminine yönelik çalışmalar gerçekleştirilmiştir.

Rüzgâr enerjisi, son yıllarda dünyada kullanılan en yüksek yenilenebilir enerji potansiyeline sahiptir (Hou vd., 2024). Bu potansiyel ve profil güneş enerjisine nazaran çok daha yüksektir. Bununla beraber, literatürde mevcut olan çalışmalar genellikle rüzgârla ilgili verilerin herhangi bir ön veri işlemesi veya gruplandırılması yapılmadan UKSB veya benzer metotlar ile tahminine yöneliktir. Dolayısıyla, sadece rüzgâr hızı veya gücü değil, rüzgâr kaynaklı üretime etki eden birçok faktörün göz önüne alınması ve tahmine yönelik çalışmalarda kullanılması gereklidir. Bu sebeple, bu çalışmada rüzgâr enerjisi tahminine yönelik YNSA tabanlı bir zaman serisi analizine dayalı olarak Türkiye veri setinde ölçülen rüzgâr hızı verileri üzerinde farklı gruplandırma ve UKSB girdi kombinasyonları ile rüzgâr gücü tahminine odaklanılmaktadır. İlk olarak UKSB tabanlı rüzgâr hızı tahmin modeli oluşturulmuştur. UKSB ağı, rüzgâr hızı ve rüzgâr gücü dizilerine ilişkin farklı pencere boyutundaki veriler için eğitilmiştir. Bununla birlikte farklı pencere boyutlarında 4 farklı durum çalışması yapılarak önerilen algoritmanın etkinliği gösterilmiştir. Daha sonra, önerilen UKSB modeli için verilerin örnekleme ve kümeleme parametrelerine odaklanılarak rüzgâr tahmininin başarı oranının artışı gözlenmiş ve takip edilmiştir.

Bu makale verilen şekilde organize edilmiştir: Bölüm 2'de veri seti ile ilgili bilgiler sunularak veri setinin grafiksel örneklerine yer verilmiştir. Bölüm 3'te uzun kısa-sürelili bellek ve verilerin ön işlenmesi, örneklenmesi ve kümelemesine dair bilgiler ve açıklamalar sunulmuştur. Diğer bir bölümde, Bölüm 4'te, elde edilen sonuçların sunulması, nicel veriler olarak verilmesi ve teknik açıdan analizlerinin yapılması sağlanmış, ve son olarak Bölüm 5'te yapılan çalışmadan elde edilen ana çıkarımlar, genel katkılar ile sunulmuş ve yorumlanmıştır.

VERİ SETİ


Bu çalışmada, Kaggle web sayfası üzerinden yayınlanmış ve bazı çalışmalarda kullanılmış 2018 yılına ait verileri içeren *Wind Turbine Scada Dataset* (Erisen, 2018) veri seti hem Türkiye'de olması hem de rüzgâr hızı dışında rüzgâr gücü ve sıcaklık gibi parametreleri içermesi sebebiyle seçilmiştir. Veri setindeki verilere ait bazı örnek değerler Tablo 1 ile verilmiştir.

Bu veri setinde 10 dakika aralıklarla verilen verilere ait olmak üzere; zaman, üretilen aktif güç değeri, rüzgâr hızı, teorik güç değerleri ve rüzgâr geliş açısı mevcuttur. Veri seti toplamda 50.530 adet satır içermektedir ve bu da 1 yıllık süre içinde %96'lık bir oranda verilerin kaydedildiği sonucu ortaya çıkmaktadır. Veriler detaylı biçimde incelediğinde bazı hücrelerin değerleri 0 olarak atanmıştır, bu da rüzgâr hızının sınır değerden düşük olması gibi sebeplerle güç üretilmediği veya veri alınmadığını ifade etmektedir. Fakat bu durumda olan veri oranı çok düşük sayıdadır.

Tablo 1. Veri Setinde Mevcut Olan Bazı Örnek Değerler

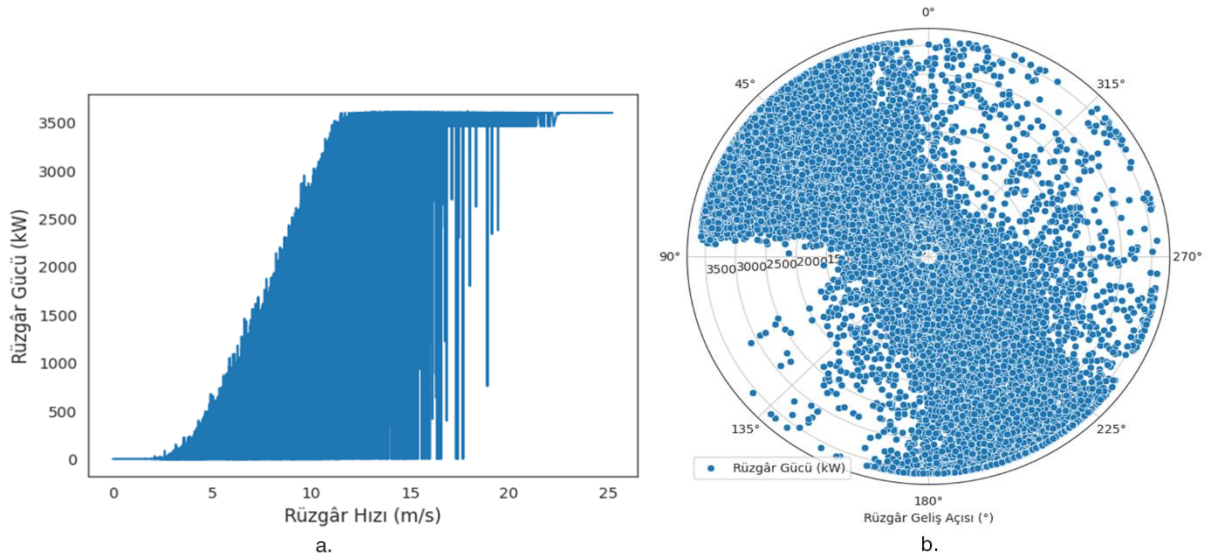
Tarih	Aktif Güç (kW)	Rüzgâr Hızı (m/sn)	Teorik Güç (kW)	Rüzgâr Açısı (derece)
01.01.2018 00:00	380.047790527343	5.311336	416.328907824861	259.994904
01.01.2018 00:10	453.769195556640	5.672167	519.917511061494	268.641113
01.01.2018 00:20	306.376586914062	5.216037	390.900015810951	272.564789
01.01.2018 00:30	419.645904541015	5.659674	516.127568975674	271.258087
01.01.2018 00:40	380.650695800781	5.577941	491.702971953588	265.674286
...
...
24.05.2018 01:30	24.9452304840087	3.394524	41.0767121951976	217.449493
24.05.2018 01:40	44.0470390319824	3.686321	75.6453312993517	215.859100
24.05.2018 01:50	0	2.141613	0	251.522094
24.05.2018 02:00	0	2.824742	0	302.344604
...
...
31.12.2018 23:20	1684.35302734375	7.332648	1173.05577118814	84.062599
31.12.2018 23:30	2201.10693359375	8.435358	1788.28475526396	84.742500
31.12.2018 23:40	2515.69409179687	9.421366	2418.38250336009	84.297913
31.12.2018 23:50	2820.46606445312	9.979332	2779.18409628274	82.274620

Veri setinde verilen rüzgâr hızı ve rüzgâr gücüne dair grafikler ise Şekil 1 ile sunulmuştur. Şekilden de anlaşılacağı üzere, türbinlerin güç üretim karakteristiklerine bağlı olarak, rüzgâr hızının rüzgâr gücü üzerinde direkt olarak etkili olduğu söylenememektedir fakat rüzgâr hızı yine de tahmini bir fikir verebilmektedir. Bu veri setinde özellikle rüzgâr gücünün zamana dayalı tahmini ve rüzgâr gücünün rüzgâr hızına tahminine yönelik çalışmalar gerçekleştirilebilmektedir. Bu makalede de farklı durumlar için rüzgâr gücü, rüzgâr hızı ve rüzgâr açısına dair çalışma, analiz ve tahminlere dair çalışmalara yer verilmiştir.



Şekil 1. a. Zamana Göre Rüzgâr Hızı b. Zamana Göre Üretilen Rüzgâr Gücü

Bununla birlikte rüzgâr gücünün, rüzgâr hızı ve yönüne bağlı değişimi de Şekil 2’de verilmiştir. Şekil 2.a’dan görüleceği üzere rüzgâr hızının 12 m/s’nin üzerinde olduğu zamanlarda verim en iyidir fakat bazı durumlarda rüzgâr hızının yüksek olmasına rağmen beklenenden düşük bir güç üretimi de belirlenmiştir. Bununla birlikte, Şekil 2.b incelendiğinde, yaklaşık 45° ile 200° derece dağılımında rüzgâr gücünün en yüksek değerlere ulaştığı da görülebilmektedir.



Şekil 2. a. Rüzgâr Hızına Göre Rüzgâr Gücü b. Gücün Rüzgâr Geliş Açısına Göre Değişimi


METODOLOJİ

Uzun Kısa-Süreli Bellek

Popüler bir YNSA sınıfı olan UKSB (Hochreiter & Schmidhuber, 1997), zaman serisiyle ilgili sorunları ele almak için literatürde sıklıkla kullanılan ve başarı gösteren yöntemlerden biridir. Birçok zaman serisi tahmin metodundan UKSB gibi dikkate değer performans sergileme kabiliyetine sahiptir; ancak birçok YNSA, eğitim sırasında gradyan kaybolmasına eğilimli olduğundan, uzun vadeli bağımlılıkların öğretilmesi ve tahmini kolay olmamaktadır (Jun

Zhang & Man, 1998). UKSB ağları için üç farklı türde belirgin kapı yapısı ve belirli bir yapısal birim tasarlanmıştır. Birim üzerinden geçen verilere seçici eklemeler ve çıkarmalar yapılır. Kapı yapısını oluşturmak için sigmoid fonksiyonu kullanılmaktadır. İçerisinden akabilen maksimum bilgi miktarını temsil eden sigmoid katsayısı 0 ile 1 arasında değişmektedir.

Önceki bellek durumundan hangi bilginin unutulacağına karar vermek için, LSTM birimi önce verileri unutma kapısı aracılığıyla işler. Bellekte tutulan bilgi daha sonra LSTM birimi tarafından belirlenir ve aynı zamanda giriş kapısı bir yandan hangi verilerin güncelleneceğini seçer. Diğer bir taraftan da tanh katmanı aday vektörü güncellenir. Yukarıdaki iki bileşen daha sonra UKSB birimi tarafından bellek durumunu güncellemek için birleştirilir. Son olarak, çıkış kapısı UKSB birimi tarafından çıkış yapılması gereken bellek durumunu düzenlemek için kullanılır (C. Wang vd., 2019). UKSB'nin genel mimarisi Şekil 3 ile verilmiştir.



Şekil 3. Uzun Kısa-Süreli Bellek Genel Mimarisi

C_{t-1} , H_{t-1} ve O_t mevcut bellek durumu, gizli durum ve çıkış durumu olmak üzere, F_t , I_t ve \hat{C}_t ise sırasıyla unutulacak bellek bilgisi, giriş bilgisi ve aday vektörü olarak ifade edilmektedir. Bu değişkenlere ait denklemler (1)-(3) ile verilmiştir. Denklemlerde W , ilgili kapının ağırlığı ve b ise ilgili kapının yanlılık değişkenidir.

$$F_t = \sigma\{W_F \times (H, X_t) + b_F\} \quad (1)$$

$$I_t = \sigma\{W_I \times (H_{t-1}, X_t) + b_I\} \quad (2)$$

$$\hat{C}_t = \tanh\{W_C \times (H_{t-1}, X_t) + b_C\} \quad (3)$$

Verilen bu denklemler kullanılarak, C_t , O_t ve H_t 'nin eldesi de aşağıdaki biçimde, (4)-(6) ile ifade edilebilir. Denklemlerdeki \odot simgesi eleman-eleman çarpım işlemi ifade etmektedir (Gers vd., 2000).

$$C_t = F_t \odot C_{t-1} + I_t \odot \hat{C}_t \quad (4)$$

$$O_t = \sigma\{W_O \times (H_{t-1}, X_t) + b_O\} \quad (5)$$

$$H_t = \sigma \odot \tanh(C_t) \quad (6)$$

Verilerin Ön-İşlemesi

Veri setinde direkt olarak rüzgâr gücünü etkileyen en temel veri rüzgâr hızıdır, fakat bununla birlikte Şekil 2.b'den de anlaşılacağı üzere rüzgârın yönü de üretilen aktif gücün dağılımını etkilemektedir. Veriler üzerinde yapılan incelemelerde, özellikle, yaklaşık 18 m/s değerinden yüksek hızlarda, rüzgâr yönünün çoğunlukla 200° civarında olduğu gözlenmiştir. Tabii ki bu durum rüzgâr türbinlerinin yönü ile ilgili olabilmektedir dolayısıyla bu çalışmada hem rüzgâr hızı hem de rüzgârın yönünün etkisinin üretilen güce etkisi ve tahmin edilmesine dair çalışmalar için


kullanılan veri setindeki veriler Tablo 2 ile sunulan biçimde örneklenerek her durum için farklı bir UKSB eğitim, validasyon ve test çalışması sağlanmıştır.

Tablo 2. Uzun Kısa-Sürelili Bellek Eğitimde Kullanılan Parametreler

Durum Çalışması	Örnekleme Aralığı	Veri Sayıları*			Kullanılan Girdi(ler)			Çıktı
		Eğitim	Validasyon	Test	Rüzgâr Gücü (RG)	Rüzgâr Hızı (RH)	Rüzgâr Yönü (RY)	
Durum 1.1	30 Dk.	6738	5053	5053	-	✓	-	RH
Durum 1.2	6 saat	559	420	420	-	✓	-	RH
Durum 2.1	30 Dk.	6738	5053	5053	✓	-	-	RG
Durum 2.2	1 Gün	141	105	105	✓	-	-	RG
Durum 3.1	30 Dk.	6738	5053	5053	✓	✓	-	RG
Durum 3.2	1 Gün	141	105	105	✓	✓	-	RG
Durum 3.3	30 Dk.	6738	5053	5053	✓	✓	✓	RG
Durum 3.4	6 Saat	559	420	420	✓	✓	✓	RG
Durum 3.5	1 Gün	20	16	16	✓	✓	✓	RG

*Tabloda verilen veri sayıları tek bir parametreye aittir. Kullanılan girdi sayısı arttıkça kullan veri sayısı oransal biçimde artmaktadır.

Bununla birlikte kullanılan parametreler her durum çalışması için 3, 5 ve 10'luk zaman serileri halinde eğitime sunulmuştur. Örneğin Durum 1.1 için, 6738 adet eğitim verisi mevcuttur ve bu veriler 3'erli, 5'erli ve 10'arlı kümeler halinde çalışılmıştır. Verilerin kümeleneşine dair genel şematik Şekil 4 ile verilmiştir. Bu işlem Tablo 2'de verilen tüm durum çalışmaları için ayrı ayrı gerçekleştirilmiştir.



Şekil 4. Zaman Serisi Verilerinin Kümelere Ayrılması

Hata Metrikleri

Bu çalışmada, elde edilen sonuçların birbiriyle karşılaştırılabilmesi için literatürde yaygın olarak kullanılan bazı hata metrikleri kullanılmıştır. Bu tür zaman serisi tahmine yönelik çalışmalarda, sistem çıktısının girişe nazaran hata oranı ve seviyesini ifade eden bazı göstergeler de mevcuttur. Bunların en çok kullanılanları; ortalama-karesel-hata (OKH) ve kök-ortalama-karesel-hata (KOKH) metrikleridir. OKH (Pavlov-Kagadejev vd., 2024) ve KOKG (Akçay & Yiltas-Kaplan, 2024) genel denklemleri sırasıyla (7) ve (8) ile verilmiştir.

$$OKH = \frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2, \quad n: \text{değişken sayısı}, \quad \hat{x}_i: \text{tahmin değeri}, \quad x_i: \text{gerçek değer} \quad (7)$$

$$KOKH = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2}, \quad n: \text{değişken sayısı}, \quad \hat{x}_i: \text{tahmin değeri}, \quad x_i: \text{gerçek değer} \quad (8)$$

BULGULAR

Önerilen yaklaşımın etkinliğini değerlendirmek; veri örnekleme ve kümeleneşinin etkisini görebilmek amacıyla, kullanılan veri setindeki üretilen rüzgâr gücü, rüzgâr hızı ve rüzgâr yönü parametreleri 1-boyutlu, 2-boyutlu ve 3-boyutlu UKSB ile işlenmiştir. Yapılan çalışmalar, Python yazılımı (versiyon 3.10.1) ve Tensorflow derin öğrenme kütüphanesi (versiyon 2.10.1) kullanılarak Visual Studio Code™ üzerinde Nvidia GeForce RTX™ 3080 donanımına

sahip *Windows 11*TM yüklü bilgisayarda gerçekleştirilmiştir. Sistem versiyonunu gösteren bilgiler Şekil 5 ile verilmiştir.


```
C: > Users > volkn > Desktop > vrsion.py
1 import sys
2 import tensorflow as tf
3 from tensorflow.python.client import device_lib
4
5 print(sys.version)
6 print(tf.__version__)
7 print(device_lib.list_local_devices())
```

```
PS C:\Users\volkn\Desktop\xpception_bend> & C:/Users/volkn/AppData/Local/Programs/Python/Python310-1 (tags/v3.10.1:2cd268a, Dec 6 2021, 19:10:37) [MSC v.1929 64 bit (AMD64)]
2.10.1
2024-08-14 14:19:26.938156: I tensorflow/core/platform/cpu_feature_guard.cc:193]
library (oneDNN) to use the following CPU instructions in performance-critical operations.
To enable them in other operations, rebuild TensorFlow with the appropriate compiler flags.
2024-08-14 14:19:27.442526: I tensorflow/core/common_runtime/gpu/gpu_device.cc:162]
name: NVIDIA GeForce RTX 3080, pci bus id: 0000:01:00:00, compute capability: 8.6
[name: "/device:CPU:0"
device_type: "CPU"
memory_limit: 268435456
```

Şekil 5. Kullanılan Sistem Versiyon ve Özellikleri

Bununla birlikte, UKSB için oluşturulan model kullanılırken, UKSB birim sayısı 10 olarak seçilmiş, ayrıca aktivasyon durumu ise *none* olarak belirlenmiştir. Özellikle aktivasyonun *none* olarak seçilme sebebi, yüksek varyasyona sahip rüzgâr gücü gibi verilerde gerçeğe daha yakın sonuç elde etmektir. Model eğitilirken ise döngü sayısı 10 olarak seçilmiş, öğrenme oranı ise 0.01 olarak belirlenmiştir.

Bu çalışmada, veri örnekleme ve kümeleme gibi sinyal işleme yöntemleri ve literatürde zaman serilerinin tahmini için kullanılan en temel ve efektif ağlardan biri olan uzun kısa-süreli bellek tabanlı rüzgâr gücü tahminini amaçlayan farklı durum çalışmaları gerçekleştirilmiştir. Önerilen yaklaşımı test etmek için, Türkiye sınırları içerisinde olan ve veri seti olarak paylaşılan bir rüzgâr gücü karakteristiği için, farklı örnekleme frekansları ve kümeleme parametreleri kullanılarak, farklı boyutlu UKSB ağları eğitilmiş ve test edilmiştir. Önerilen metodolojinin genel blok diyagramı Şekil 6'da verilmiştir.




Şekil 6. Önerilen Metodun Genel Şematığı


Durum Çalışması-1

Bu durum çalışması rüzgâr geliş hızı ile ilgili iki farklı alt çalışma içermektedir. Bunlardan ilki, 30-dakikalık örneklemeyle, bir diğeri ise 6-saatlik örneklemeyle gerçekleştirilen eğitim ve test sonuçlarıdır. Durum 1.1 ve Durum 1.2'ye ait test değerlerine ait grafikler Şekil 7 ve Şekil 8'de sunulmuştur.

Tablo 3 ile de eğitim, validasyon ve test verilerine dair hata metrikleri de verilmiştir. Hata değerleri hem gerçek değerler hem de normalize değerler olarak sunulmuştur. Test çalışmalarına dair hata değerleri incelendiğinde görülmektedir ki, en iyi sonuç 10'lu kümeleme neticesinde elde edilebilmektedir. Ayrıca, diğer kümeleme değerleri incelendiğinde, Durum 1.1 için 5'li kümeleme daha iyi sonuç verirken, Durum 1.2'de ise 3'lü kümelemede daha iyi sonuç alınabilmektedir. Bunun yanı sıra,



Şekil 7. Durum 1.1 Farklı Kümeleme Değerleri İçin Test ve Gerçek Rüzgâr Hızı Sonuçları **a.** Küme Değeri: 3 **b.** Küme Değeri: 5 **c.** Küme Değeri: 10



Şekil 8. Durum 1.2 Farklı Kümeleme Değerleri İçin Test ve Gerçek Rüzgâr Hızı Sonuçları **a.** Küme Değeri: 3 **b.** Küme Değeri: 5 **c.** Küme Değeri: 10


Tablo 3. Durum Çalışması-1 İçin Elde Edilen Hata Değerleri

Durum Çalışması	Küme Değeri	OKH		KOKH	
		Gerçek	Normalize	Gerçek	Normalize
Durum 1.1 Eğitim	3	0,1931	0,0003	0,4394	0,0191
	5	0,1557	0,0003	0,3946	0,0171
	10	0,0852	0,0004	0,2919	0,0194
Durum 1.1 Validasyon	3	0,1295	0,0009	0,3599	0,0298
	5	0,0926	0,0009	0,3043	0,0310
	10	0,0888	0,0006	0,2980	0,0238
Durum 1.1 Test	3	0,1465	0,0004	0,3827	0,0204
	5	0,1132	0,0002	0,3365	0,0159
	10	0,0533	0,0002	0,2308	0,0165
Durum 1.2 Eğitim	3	3,0050	0,0051	1,7335	0,0714
	5	7,1660	0,0155	2,6769	0,1245
	10	2,0363	0,0045	1,4270	0,0670
Durum 1.2 Validasyon	3	1,4127	0,0072	1,1886	0,0851
	5	1,4782	0,0103	1,2158	0,1014
	10	1,0581	0,0063	1,0286	0,0792
Durum 1.2 Test	3	2,2193	0,0056	1,4897	0,0746
	5	5,5594	0,0164	2,3578	0,1279
	10	1,4437	0,0040	1,2016	0,0629


Durum Çalışması-2

Bu durum çalışması rüzgâr gücüne dair Tablo 2 ile verilen iki farklı durum çalışması içermektedir. Bunlardan ilki, 30-dakikalık örneklemelerle, bir diğeri ise 1-saatlik örneklemelerle gerçekleştirilen rüzgâr gücü tahminine yönelik eğitim ve test sonuçlarıdır.

Durum 2.1 ve Durum 2.2'ye ait test performansını gösterir grafikler Şekil 9 ve Şekil 10 ile sunulmuştur. Bununla birlikte, Tablo 4 ile verilen hata değerleri incelendiğinde, Durum 2.1 için normalize hata değerleri 10'lu kümelemeye en düşük sonucu vermiştir bunlar eğitim, validasyon için sırasıyla; OKH için 0.0005, 0.0004 ve 0.0003; KOKH için ise 0.0228, 0.0204 ve 0.0170'dir. Bunun yanı sıra Durum 2.2 içinse, 5'li kümeleme ile en düşük hata değeri dolayısıyla en yüksek performans elde edildiği görülmektedir ve en yüksek normalize hata değeri, OKH için 0.0698 ve KOKH için ise 0.2643 olarak elde edilmiştir.



Şekil 9. Durum 2.1 Farklı Kümeleme Değerleri İçin Test ve Gerçek Rüzgâr Gücü Sonuçları a. Küme Değeri: 3 b. Küme Değeri: 5 c. Küme Değeri: 10



Şekil 10. Durum 2.2 Farklı Kümeleme Değerleri İçin Test ve Gerçek Rüzgâr Gücü Sonuçları a. Küme Değeri: 3 b. Küme Değeri: 5 c. Küme Değeri: 10

Durum Çalışması-3

Bu alt bölümde, farklı UKSB boyutlarında farklı girişlere sahip durumlar için gerçekleştirilen, 30-dakikalık, 6-saatlik ve 1-günlük örneklemeler kullanılarak çeşitli durum çalışmalarına dair sonuçlar sunulmuştur. Tablo 2 incelendiğinde, hem 1- hem 2- hem de 3-boyutlu UKSB çalışmalarının gerçekleştirildiği görülebilmektedir. Durum çalışmalarına ait test performansları Tablo 5 ile sunulmuş; bununla birlikte tüm alt durum çalışmalarına dair grafikler de Şekil 11 ile verilmiştir.

Durum 3.1 için en optimal normalize hata değerleri OKH ve KOKH için sırasıyla 0.0008 ve 0.0349 olarak 5'li ve 3'lü kümeleme değerleri için elde edilmiştir. Burada özellikle 10'lu kümeleme yaklaşımının hatasının oransal olarak yüksek olduğu tespit edilmiştir. Durum 3.2'de en düşük normalize hata değerleri OKH ve KOKH için 0.0827 ve 0.2875 olarak elde edilmiş; burada da en iyi sonuç kümeleme sayısı 3 olduğu durumda elde edilmiştir. Bununla birlikte, Durum 3.3 ve Durum 3.4'te ise OKH ve KOKH için sırasıyla 5'li ve 3'lü kümeleme yaklaşımında en iyi normalize hata elde edilmiştir; hata oranları sırasıyla OKH ve KOKH için 0.0003 ve 0.0277 ile 0.0192 ve 0.1663'tür.

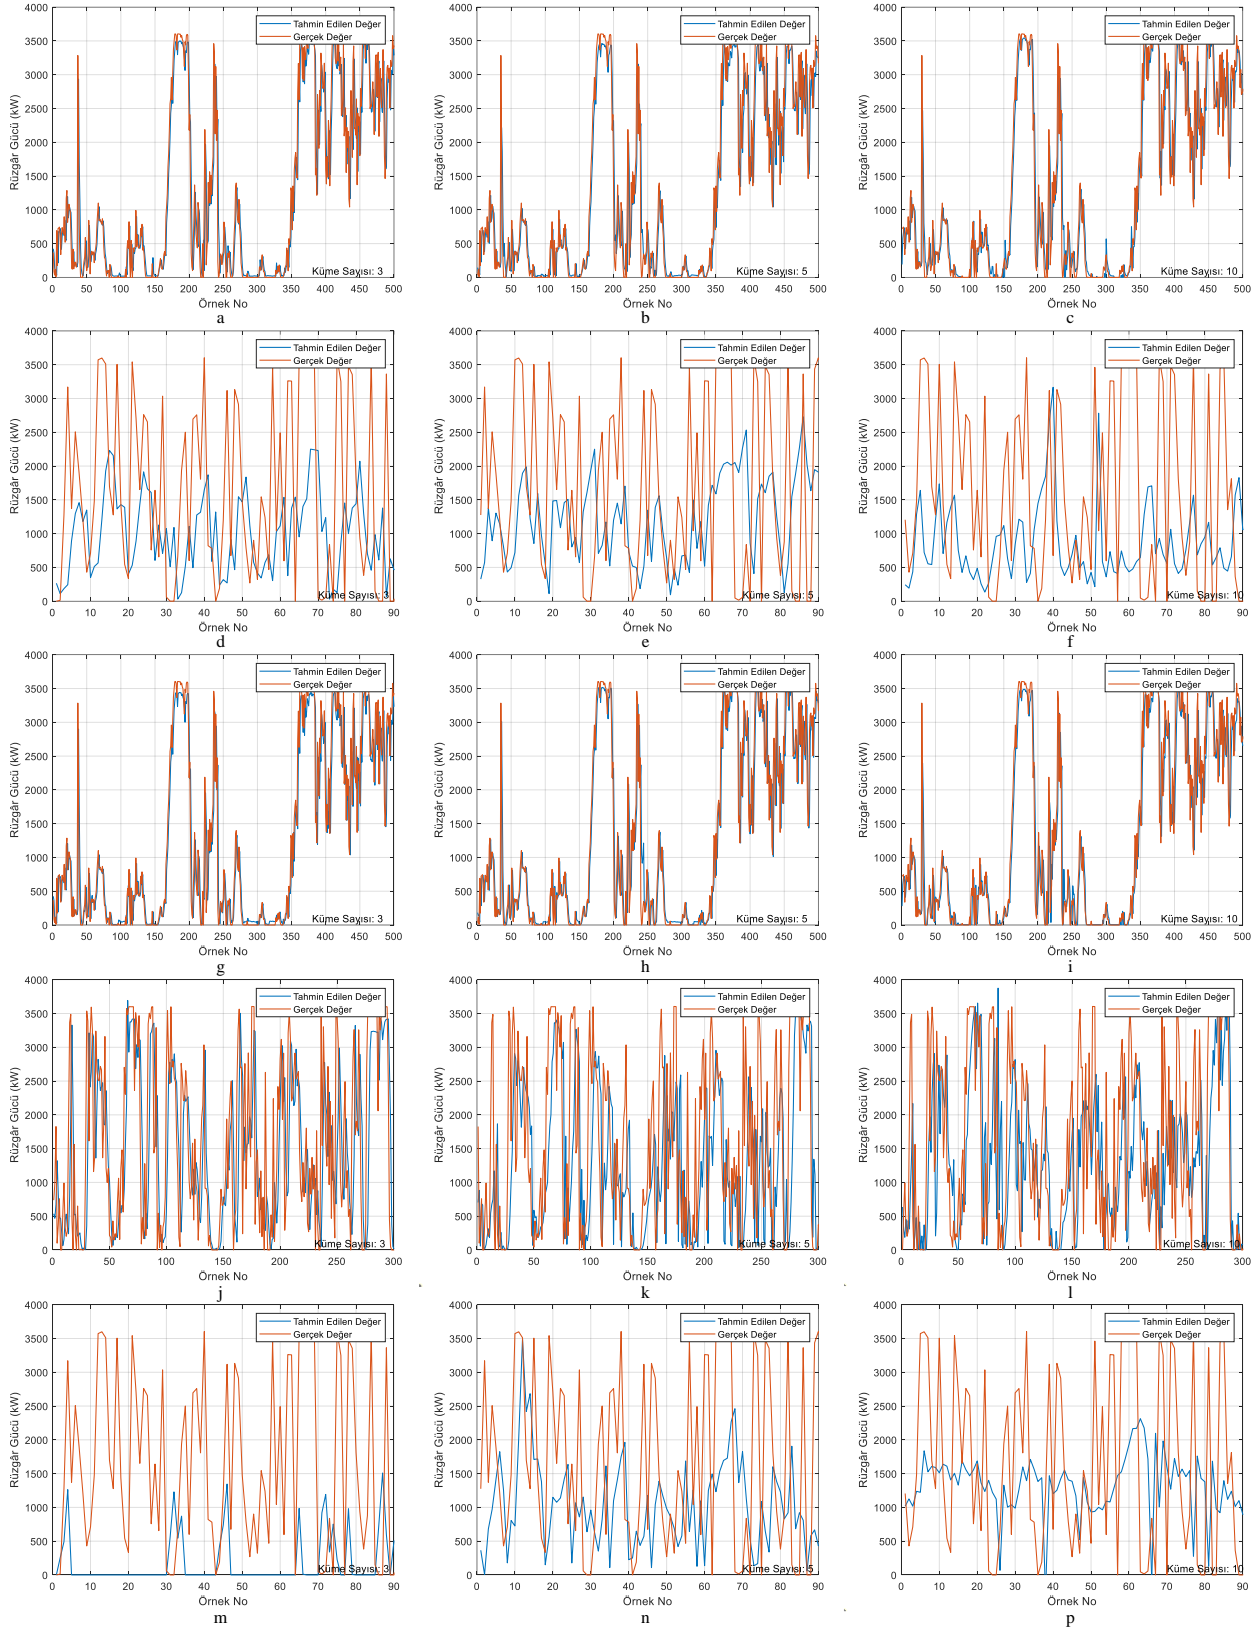
Durum 3.5 incelendiğinde, en düşük normalize hata 10'lu kümeleme durumunda elde edilmiş, fakat 5'lü kümeleme durumundaki hata oranı da optimal sonuca çok yakındır. Tablo 2'de verilen durumların örnekleme parametreleri göz önüne alındığında, örnekleme sıklığı azaldıkça kümeleme sayısının artışının sonuca olumlu etki ettiği; aynı zamanda çok boyutlu UKSB'nin de önceki durumlara nazaran daha iyi sonuçlara imkân sağladığı görülebilmektedir.

Tablo 4. Durum Çalışması-2 İçin Elde Edilen Hata Değerleri

Durum Çalışması	Küme Değeri	OKH		KOKH	
		Gerçek	Normalize	Gerçek	Normalize
Durum 2.1 Eğitim	3	1427,30	0,0125	119,46	0,1116
	5	8061,50	0,0009	89,78	0,0304
	10	9412,90	0,0005	97,02	0,0228
Durum 2.1 Validasyon	3	1289,50	0,0009	113,55	0,0316
	5	7206,20	0,0007	84,88	0,0260
	10	7585,40	0,0004	87,09	0,0204
Durum 2.1 Test	3	1370,70	0,0009	117,07	0,0297
	5	7188,90	0,0007	84,85	0,0256
	10	6628,80	0,0003	81,41	0,0170
Durum 2.2 Eğitim	3	$1587,20 \times 10^3$	0,1201	1259,80	0,3465
	5	$7902,20 \times 10^2$	0,0582	888,94	0,2412
	10	$1417,10 \times 10^3$	0,1082	1190,40	0,3289
Durum 2.2 Validasyon	3	$9843,70 \times 10^2$	0,0759	992,15	0,2754
	5	$4572,40 \times 10^2$	0,0345	676,19	0,1857
	10	$1099,20 \times 10^3$	0,0830	1048,40	0,2881
Durum 2.2 Test	3	$2007,50 \times 10^3$	0,1520	1416,90	0,3899
	5	$9369,00 \times 10^2$	0,0698	967,93	0,2643
	10	$1923,50 \times 10^3$	0,1486	1386,90	0,3854

Tablo 5. Durum Çalışması-3 Test Performansı İçin Elde Edilen Hata Değerleri

Durum Çalışması	Küme Değeri	OKH		KOKH	
		Gerçek	Normalize	Gerçek	Normalize
Durum 3.1	3	8963,80	0,0012	94,67	0,0349
	5	15918,00	0,0008	126,16	0,0291
	10	14853,00	0,0075	121,87	0,0865
Durum 3.2	3	$1489,40 \times 10^3$	0,0827	1220,40	0,2875
	5	$1595,40 \times 10^3$	0,1124	1263,10	0,3353
	10	$3124,40 \times 10^3$	0,2406	1767,60	0,4905
Durum 3.3	3	10470,00	0,0011	102,32	0,0333
	5	6327,50	0,0003	79,54	0,0192
	10	15135,00	0,0008	123,02	0,0293
Durum 3.4	3	$3465,30 \times 10^2$	0,0277	588,67	0,1663
	5	$9040,40 \times 10^2$	0,0688	950,81	0,2623
	10	$6486,40 \times 10^2$	0,0545	805,38	0,2334
Durum 3.5	3	$4406,80 \times 10^3$	0,3923	2099,20	0,6264
	5	$1624,40 \times 10^3$	0,1221	1274,50	0,3494
	10	$1508,50 \times 10^3$	0,1211	1228,20	0,3481



Şekil 11. Durum Çalışması-3: Farklı Kümeleme Değerleri İçin Test ve Gerçek Rüzgâr Gücü Sonuçları **a.** Durum 3.1 Küme Değeri: 3 **b.** Durum 3.1 Küme Değeri: 5 **c.** Durum 3.1 Küme Değeri: 10 **d.** Durum 3.2 Küme Değeri: 3 **e.** Durum 3.2 Küme Değeri: 5 **f.** Durum 3.2 Küme Değeri: 10 **g.** Durum 3.3 Küme Değeri: 3 **h.** Durum 3.3 Küme Değeri: 5 **i.** Durum 3.3 Küme Değeri: 10 **j.** Durum 3.4 Küme Değeri: 3 **k.** Durum 3.4 Küme Değeri: 5 **l.** Durum 3.4 Küme Değeri: 10 **m.** Durum 3.5 Küme Değeri: 3 **n.** Durum 3.5 Küme Değeri: 5 **p.** Durum 3.5 Küme Değeri: 10

Bununla birlikte, tüm durum çalışmalarına ait verilerin en iyi değerleri Tablo 6 ile verilmiştir. Buradan görüleceği üzere, çalışmaların %40'ında 10lu kümeleme en iyi sonucu verirken; %30 oranında 5'li kümeleme ve %20 oranında ise 3'lü kümeleme en iyi sonuçları vermektedir. Buradan görülebilir ki, özellikle girdi boyutunun çok olduğu yani girdi çeşidinin fazla olduğu durumlarda kümeleme sayısının düşük seçilmesi daha iyi sonuçlar elde edilmesini sağlayabilmektedir.

Tablo 6. Tüm Durum Çalışmalarındaki Test Verileri İçin Elde Edilen En İyi Değerler

Durum Çalışması	Küme Değeri	OKH		KOKH	
		Gerçek	Normalize	Gerçek	Normalize
Durum 1.1	10	0,0533	0,0002	0,2308	0,0165
Durum 1.2	10	1,4437	0,0040	1,2016	0,0629
Durum 2.1	10	6628,80	0,0003	81,41	0,0170
Durum 2.2	5	9369,00×10 ²	0,0698	967,93	0,2643
Durum 3.1	3	8963,80	0,0012	94,67	0,0349
Durum 3.2	3	1489,40×10 ³	0,0827	1220,40	0,2875
Durum 3.3	5	6327,50	0,0003	79,54	0,0192
Durum 3.4	3	3465,30×10 ²	0,0277	588,67	0,1663
Durum 3.5	10	1508,50×10 ³	0,1211	1228,20	0,3481

SONUÇLAR

Bu çalışmada, rüzgâr enerji sistemlerinden üretilen güç tahmini problemini ele almak üzere farklı örnekleme ve kümeleme seçenekleri ile uyarlanmış UKSB tabanlı bir zaman serisi tahmin çalışması gerçekleştirilmiştir. Oluşturulan algoritma ile öncelikle rüzgâr hızı tahmini gerçekleştirilmiş ve elde edilen sonuçlar farklı hata metrikleri ile sunulmuştur. Daha sonra çok boyutlu UKSB ağı için girdiler hem rüzgâr hızı hem rüzgâr gücü hem de rüzgâr yönü olacak şekilde belirlenerek farklı boyut sayısına sahip ağlar ile eğitilmiştir. Elde edilen sonuçlar göstermektedir bir yıllık rüzgâr verileri ile yapılan bu çalışmada örnekleme ve kümelemenin sonuca oranda etki ettiği, özellikle yıl içinde değişken karakteristiğe sahip rüzgâr gücünün örnekleme sıklığından yüksek miktarda etkilendiği gözlenmiştir. Normalize hata metrikleri incelendiğinde, örnekleme sıklığının düşük olmasının çıktı olarak elde edilen sinyalin genliğini etkilemekte olmasına rağmen, normalize karakteristiğinin gerçek sinyal karakteristiğine yakın olduğu kolaylıkla görülebilmektedir. Yapılan tüm durum çalışmalarında, en yüksek normalize OKH 0.3923 ve en yüksek normalize KOKH ise 0.6264 olarak elde edilmiştir. Bu durum da rüzgâr gücünün değişkenlik oranı ve skalasını yüksek olması ile açıklanabilir. Sonuçların tamamı incelendiğinde ise, girdilerin karmaşıklığı arttığında kümelemenin etkisinin düştüğü görülebilmektedir. Bu durumun önüne geçebilmek için yapılacak çalışmalarda, farklı UKSB yapıları kullanılabilir veya farklı ağ modelleri ile birlikte hibrit çalışmalar gerçekleştirilebilir. Bunun yanı sıra, rüzgâr gücü gibi değişkenlik oranı yüksek elde edilen verilerin başarı ile işlenebilmesi ve geleceğe yönelik tahmini göstermiştir ki benzer biçimde karakteristiğe sahip olan güneş ve dalga enerjilerinin tahmini için de geçerli olabilecektir. Ayrıca, bir elektrik üretim sistemindeki rüzgâr ve güneş enerji santrallerinin eş zamanlı tahmini ve kısa vadeli enerji planlaması da gerçekleştirilebilir. Bu çalışmanın ana katkıları aşağıdaki gibi ifade edilebilir,

1. Bir, iki ve üç boyutlu UKSB ağlarının kısa ve uzun süreli rüzgâr gücü tahmini için başarı ile kullanılabildiği gösterilmiştir.
2. Rüzgâr hızı ve gücü tahmininde örnekleme sıklığının ve kümeleme parametrelerinin sonuca etkisi ve önemi sayısal nicelikler ile ifade edilebilmiş ve sunulmuştur.
3. Değişkenlik karakteristiği yüksek olan sinyallerde dâhi sinyalin normalize karakteristiğinin başarı ile elde edilebilmesi sağlanmıştır.

KAYNAKLAR

Abaci, K., Yetgin, Z., Yamaçlı, V., & Isiker, H. (2024). Modified effective butterfly optimizer for solving optimal power flow problem. *Heliyon*, 10(12), e32862. <https://doi.org/10.1016/j.heliyon.2024.e32862>

Ai, X., Li, S., & Xu, H. (2022). Short-term wind speed forecasting based on two-stage preprocessing method, sparrow search algorithm and long short-term memory neural network. *Energy Reports*, 8, 14997-15010. <https://doi.org/10.1016/j.egy.2022.11.051>

Akçay, H., & Yılmaz-Kaplan, D. (2024). Zaman serileri tahminleme algoritmaları ile kontör tüketim tahminlemesi ve karşılaştırmalı uygulaması. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 27(1), 166-189. <https://doi.org/10.17780/ksujes.1369811>

- Al-Shaikhi, A., Nuha, H., Mohandes, M., Rehman, S., & Adrian, M. (2022). Vertical wind speed extrapolation model using long short-term memory and particle swarm optimization. *Energy Science & Engineering*, 10(12), 4580-4594. <https://doi.org/10.1002/ese3.1291>
- Bokde, N., Feijóo, A., Villanueva, D., & Kulat, K. (2019). A Review on Hybrid Empirical Mode Decomposition Models for Wind Speed and Wind Power Prediction. *Energies*, 12(2), 254. <https://doi.org/10.3390/en12020254>
- Chen, J., Guo, Z., Zhang, L., & Zhang, S. (2024). Short-term wind speed prediction based on improved Hilbert–Huang transform method coupled with NAR dynamic neural network model. *Scientific Reports*, 14(1), 617. <https://doi.org/10.1038/s41598-024-51252-y>
- Erisen, B. (2018). Wind Turbine Scada Dataset. <https://www.kaggle.com/datasets/berkerisen/wind-turbine-scada-dataset>
- Gan, Z., Li, C., Zhou, J., & Tang, G. (2021). Temporal convolutional networks interval prediction model for wind speed forecasting. *Electric Power Systems Research*, 191, 106865. <https://doi.org/10.1016/j.epsr.2020.106865>
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to Forget: Continual Prediction with LSTM. *Neural Computation*, 12(10), 2451-2471. <https://doi.org/10.1162/089976600300015015>
- Guan, S., Wang, Y., Liu, L., Gao, J., Xu, Z., & Kan, S. (2023). Ultra-short-term wind power prediction method combining financial technology feature engineering and XGBoost algorithm. *Heliyon*, 9(6), e16938. <https://doi.org/10.1016/j.heliyon.2023.e16938>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hou, X., Hu, W., & Luo, M. (2024). Short-term wind farm cluster power point-interval prediction based on graph spatio-temporal features and S-Stacking combined reconstruction. *Heliyon*, 10(14), e33945. <https://doi.org/10.1016/j.heliyon.2024.e33945>
- Jun Zhang, & Man, K. F. (1998). Time series prediction using RNN in multi-dimension embedding phase space. *SMC'98 Conference Proceedings. 1998 IEEE International Conference on Systems, Man, and Cybernetics (Cat. No.98CH36218)*, 1868-1873. <https://doi.org/10.1109/ICSMC.1998.728168>
- Jung, J., & Broadwater, R. P. (2014). Current status and future advances for wind speed and power forecasting. *Renewable and Sustainable Energy Reviews*, 31, 762-777. <https://doi.org/10.1016/j.rser.2013.12.054>
- Lawal, A., Rehman, S., Alhems, L. M., & Alam, Md. M. (2021). Wind Speed Prediction Using Hybrid 1D CNN and BLSTM Network. *IEEE Access*, 9, 156672-156679. <https://doi.org/10.1109/ACCESS.2021.3129883>
- Li, M., Zhang, Z., Ji, T., & Qu, Q. H. (2020). Ultra-short term wind speed prediction using mathematical morphology decomposition and long short-term memory. *CSEE Journal of Power and Energy Systems*. <https://doi.org/10.17775/CSEEJPES.2019.02070>
- Lopez, L., Oliveros, I., Torres, L., Ripoll, L., Soto, J., Salazar, G., & Cantillo, S. (2020). Prediction of Wind Speed Using Hybrid Techniques. *Energies*, 13(23), 6284. <https://doi.org/10.3390/en13236284>
- Memarzadeh, G., & Keynia, F. (2021). Short-term electricity load and price forecasting by a new optimal LSTM-NN based prediction algorithm. *Electric Power Systems Research*, 192, 106995. <https://doi.org/10.1016/j.epsr.2020.106995>
- Pavlov-Kagadejev, M., Jovanovic, L., Bacanin, N., Deveci, M., Zivkovic, M., Tuba, M., Strumberger, I., & Pedrycz, W. (2024). Optimizing long-short-term memory models via metaheuristics for decomposition aided wind energy generation forecasting. *Artificial Intelligence Review*, 57(3), 45. <https://doi.org/10.1007/s10462-023-10678-y>
- Shao, B., Song, D., Bian, G., & Zhao, Y. (2021). Wind Speed Forecast Based on the LSTM Neural Network Optimized by the Firework Algorithm. *Advances in Materials Science and Engineering*, 2021, 1-13. <https://doi.org/10.1155/2021/4874757>
- Shi, Z., Yao, W., Li, Z., Zeng, L., Zhao, Y., Zhang, R., Tang, Y., & Wen, J. (2020). Artificial intelligence techniques for stability analysis and control in smart grids: Methodologies, applications, challenges and future directions. *Applied Energy*, 278, 115733. <https://doi.org/10.1016/j.apenergy.2020.115733>

Sun, W., & Wang, Y. (2018). Short-term wind speed forecasting based on fast ensemble empirical mode decomposition, phase space reconstruction, sample entropy and improved back-propagation neural network. *Energy Conversion and Management*, 157, 1-12. <https://doi.org/10.1016/j.enconman.2017.11.067>

Wang, C., Han, D., Liu, Q., & Luo, S. (2019). A Deep Learning Approach for Credit Scoring of Peer-to-Peer Lending Using Attention Mechanism LSTM. *IEEE Access*, 7, 2161-2168. <https://doi.org/10.1109/ACCESS.2018.2887138>

Wang, J., Sun, J., & Zhang, H. (2013). Short-term wind power forecasting based on support vector machine. 2013 5th International Conference on Power Electronics Systems and Applications(PESA), 1-5. <https://doi.org/10.1109/PESA.2013.6828211>

Wang, J., Wang, Y., Li, Z., Li, H., & Yang, H. (2020). A combined framework based on data preprocessing, neural networks and multi-tracker optimizer for wind speed prediction. *Sustainable Energy Technologies and Assessments*, 40, 100757. <https://doi.org/10.1016/j.seta.2020.100757>

Xie, Y., Li, C., Tang, G., & Liu, F. (2021). A novel deep interval prediction model with adaptive interval construction strategy and automatic hyperparameter tuning for wind speed forecasting. *Energy*, 216, 119179. <https://doi.org/10.1016/j.energy.2020.119179>

Yamaçlı, V., İşiker, H., Yetgín, Z., & Abacı, K. (2024). Solving Optimal Power Flow Control Problem Using Honey Formation Optimization Algorithm. *IEEE Access*, 12, 109293-109322. <https://doi.org/10.1109/ACCESS.2024.3439021>



Kahramanmaraş Sutcu Imam University

Journal of Engineering Sciences



Geliş Tarihi : 22.08.2024
Kabul Tarihi : 06.01.2025

Received Date : 22.08.2024
Accepted Date : 06.01.2025

FINITE ELEMENT ANALYSIS OF EXCAVATOR BUCKET DESIGN WITH BIOMIMETIC APPROACH WITH DIFFERENT STEELS

FARKLI ÇELİKLERLE BİYOMİMETİK YAKLAŞIMLA EKSKAVATÖR KEPÇE TASARIMININ SONLU ELEMANLAR ANALİZİ

Berkay KARAÇOR^{1*} (ORCID: 0000-0001-5208-366X)

Kaan KOÇ¹ (ORCID: 0009-0000-2096-4059)

Mustafa ÖZCANLI¹ (ORCID: 0000-0001-6088-2912)

¹Çukurova University, Faculty of Engineering, Department of Automotive Engineering

*Sorumlu Yazar / Corresponding Author: Berkay KARAÇOR, bkaracor@cu.edu.tr

ABSTRACT

One of the biggest problems of construction machines that make people's lives easier is digging efficiency. In this study, a new excavator teeth model with a biomimetic approach was developed to solve the problem of digging efficiency. This biomimetic digging teeth model is inspired by the front claw of the armadillo, which is naturally a successful digging animal. In the bucket, only the teeth are biomimetic and in the armadillo teeth model, the 5 mm deep thinned parts on the sides of the standard bucket are determined as 25 mm deep in the armadillo teeth model for extra lightness. In addition, a standard digging tooth was designed and finite element analysis of this standard design and the armadillo design was carried out using different steels. The designs were created using the CATIA V5 R21 program. The analyzes were carried out using the Ansys Workbench 18.1 program. Three different steel groups were used for the analysis results. These were St-37, S690QL, and Weldom900 E steels. Total deformation, safety factor, equivalent stress, and cost analysis were carried out. The average stress values were 228.85 MPa for the standard teeth and 162.01 MPa for the armadillo teeth.

Keywords: Excavator bucket, finite element method, biomimetic, armadillo

ÖZET

İnsanların hayatını kolaylaştıran iş makinelerinin en büyük problemlerinden biri kazma verimliliğidir. Bu çalışmada kazma verimliliği problemini çözmek için biyomimetik yaklaşımla yeni bir ekskavatör diş modeli geliştirilmiştir. Bu biyomimetik kazma dişi modeli, doğası gereği başarılı bir kazma hayvanı olan armadillonun ön pençesinden esinlenerek tasarlanmıştır. Kovada sadece dişler biyomimetik olup, armadillo diş modelinde standart kovanın yanlarında bulunan 5 mm derinliğindeki inceltmiş parçalar ekstra hafiflik için armadillo diş modelinde 25 mm derinlikte belirlenmiştir. Ayrıca standart bir kazma dişi tasarlanmış ve bu standart tasarım ile armadillo tasarımının sonlu elemanlar analizi farklı çelikler kullanılarak yapılmıştır. Tasarımlar CATIA V5 R21 programı kullanılarak oluşturulmuştur. Analizler Ansys Workbench 18.1 programı kullanılarak gerçekleştirilmiştir. Analiz sonuçlarında üç farklı çelik grubu kullanılmıştır. Bunlar St-37, S690QL ve Weldom900 E çelikleridir. Toplam deformasyon, güvenlik faktörü, eşdeğer stres ve maliyet analizi yapıldı. Standart dişler için ortalama stres değerleri 228,85 MPa ve armadillo dişleri için 162,01 MPa olarak bulunmuştur.

Anahtar Kelimeler: Ekskavatör kovası, sonlu elemanlar metodu, biyomimetik, armadillo

INTRODUCTION

The development of construction machinery accelerated from the 16th century onwards. Until the 16th century, infrastructural activities were carried out using non-technical work equipment. Construction machinery was used in building work to create modern and orderly cities. In particular, they were often favored in the clean-up and reconstruction of regions that had been destroyed after the Second World War, which is why their importance increased. After that time, the production of construction machinery has gained considerable momentum (Onat, 2013). Construction machines are generally large, powerful machines used in industry or construction. Construction machinery used by government institutions such as agriculture, industry, national defense, and private industry are machines that are equipped with various devices depending on their purpose.

Excavators are construction machines that carry out channel-shaped excavation and loading work. They are often used in the construction of dams and mines. There are two different types: Crawler excavators and wheeled excavators. In general, they replace human power when excavating soil and transporting building materials and do the work more efficiently and quickly (Akpınar, 2010). The concept of biomimetics was first used by Otto H. Schmitt in 1969. The word is of Greek origin and is made up of the words 'bios', meaning life, and 'mimesis', meaning imitation. For designers, it is both difficult to incorporate only biological information into the design process and insufficient if the results in the design are inadequate. Physically, the shape can be mimicked, but to understand the system chemically, scientific work is required. Determining the problem that the designer needs and then implementing the design that results from the scientific work of that problem leads to more efficient results. The abilities of living things in nature, such as digging, swimming, running, and flying, are a source of inspiration for technology, vehicles, mechanisms, and structures. Although the concept of biomimetics was not introduced until 1969, biomimetic studies go back much further. Leonardo Da Vinci, a painter who defined his time with his paintings, designed flying machines by working the structures of flying creatures in nature as they flew. The Crystal Palace in London and the Eiffel Tower in Paris are also examples of biomimetic designs (Yıldız, 2012). Since it is expensive to work on the parts of the excavator, most of the time the work is done in a computer environment. This is because these parts need to be developed.

In this research, Rao et al. studied in detail the effects of vertical cuts of excavator bucket teeth on the tooth. In this instruction, the researchers used 4 different materials (steel, grey cast iron, titanium boride, and titanium carbide) and 3 different cross-sections (round, triangular, and rectangular). Various analyses were carried out on the CAD model they created. These were examined in 4 different analyses, namely static analysis, vibration analysis, fatigue analysis, and impact analysis. The results of the education showed that excavator teeth made of grey cast iron and teeth with a square cross-section were more efficient in static and vibration analyses compared to other materials and cross-sections. These results show that excavator teeth made of grey cast iron and with a square cross-section are more suitable in terms of durability and efficiency (Rao et al., 2016). Lomate et al. investigated the different effects that occur on the excavator's teeth under the digging force with different types of excavators. In these investigations, they first performed the analyses from the Ansys application and also performed mathematical calculations. As a result of the analysis, they determined values such as von Mises stresses, deformation amounts, and shear stresses. They compared the different types of excavators with each other (Lomate et al., 2016). Khedkar et al. investigated the resistance exerted by the excavator bucket on the soil. In the study, various calculations were carried out and the digging force was calculated according to SAE standards.

Outcomes of research concluded that the designed bucket was usable because the digging force of the bucket was higher than the resistance force of the soil (Khedkar et al., 2017). Shaikh and Mulla applied forces and investigated the specific stress values of excavator teeth made of Hardox 400 and Hardox 500 sheets of steel according to SAE standards. In addition, excavator teeth for general purposes such as bolted standard teeth, heavy duty teeth, long teeth, tiger teeth, twin tiger teeth, and wear teeth for smallest batch sizes were analyzed and von Mises stress and total deformation values were observed and necessary optimizations were suggested and tested for reliability (Shaikh & Mulla, 2015). Demircioğlu et al. investigated the effects of bulk materials placed by excavators on the excavator bucket. They created the excavator design using Autodesk inventor software and simulated the bulk material in the EDEM simulation environment. They also used the Ansys mechanic program to investigate the wear, stress, and pressure values that would occur on the bucket. As a result of the analyses, they found that the bucket was subjected to deformation and stresses of 0.5514 mm and 138.75 MPa respectively. At the end of this study, they concluded that the stress and deformation values did not cause serious damage to the blade (Demircioğlu et al., 2021). Tasevski and Christine carried out studies to extend the life and increase the strength of excavator teeth, which are made of cast

iron and do not have the same hardness values at every point. They designed 3 or 4 plates of Hardox steel, one of the most durable steels on the market, as excavator teeth. They tried to develop a design that offered better wear resistance in both the tooth structure and the material. They obtained the wear test values as a result of a DEM analysis. The result of the study was that the service life and wear resistance were at least twice as high as the adapter and teeth made of cast iron (Tasevski & Christine, 2016). Chang et al. designed a biomimetic handle inspired by the ability of the cryptotympana atrata nymph's front claws to cut and dig in the ground. Using reverse engineering and 3D printing, they designed two different corn cutting handles with different heights. They mentioned that the designed biomimetic stalks have lower cutting resistance compared to the stalks with traditional design and that the influence of cutting speed on cutting resistance is determined by the tooth height and digging angle of the cutting edge. They found that the cutting height was 2.5 mm cutting-edge digging angle was 40°, and the cutting resistance did not change significantly with the cutting speed. Results of the analysis, they found that the design of the tooth structure was the main factor in reducing the cutting resistance, and they concluded that the biomimetic design of the handle made by simulating the bottom cutting mechanism of the cryptotympana atrata nymph significantly increased the performance of the handle cutter (Chang et al., 2016). Zhi Jun et al. developed a biomimetic design that resembles a plowshare by modeling it on the nail structure of a field mouse, which has a strong digging ability. First, they studied the curvature and profile analysis of the inner contour line of the claw finger of a field mouse. They fitted the curve obtained to the cutting edge of the blade that first touches the ground. They explained that the part considered in the fit is the ratio of the horizontal length of the digging part in the ground to its vertical length (L/B). They examined the results of the digging process through a finite element analysis. As a result of the instruction, they found that those with an L/B ratio of 0.8 were subject to less soil resistance and less soil adhesion (ZhiJun et al., 2009).

Akter resorted to the biomimetic method to find a solution to one of the common problems of construction machinery, namely digging efficiency. In developing the design using this method, he was inspired by the claws of anteaters and badger excavators. The biomimetic excavator design variants created were compared with each other and with the standard excavators on the market by performing a static analysis in a computer environment. The analysis showed that the designed biomimetic excavator model was more efficient than the standard model in terms of the overall deformation of the excavator claw as well as the deformation and loading of the excavated soil (Akter, 2018). Qingyi et al. designed a biomimetic sawtooth structure on a standard rototiller blade, inspired by the claw structure of the oriental mole cricket, to improve the performance of the rototiller blade. They concluded that the design produced higher torque than standard blades in real and simulated tests and that the field quality was better after work (Qingyi et al., 2017). Hadi Suryo et al. have attempted to determine the stress and wear values to which excavator teeth are subjected. They performed the design, analysis, and maximum stress values using the Abaqus 6.10 Computer Aided Engineering (CAE) application. They determined the stress values of the analysis by applying a force of 8285.06 N at an angle of 32° to the horizontal under static conditions. The result of the analysis shows that the maximum stress to which the excavator's teeth are subjected is 209.3 MPa and this value is below the von Mises value. They therefore concluded that the design is safe (Hadi Suryo et al., 2018). Winter et al. have developed a device inspired by razor clams, sea creatures that dig by liquefying the soil. Using the device, called roboclam, they wanted to investigate how these clams work in different environments and conditions by mimicking their digging methods and transferring them to engineering applications. As a result of the research, they stated that the most efficient digging movements of roboclam mimic the razor clam shell structure and provide high efficiency in terms of energy to depth ratio. In line with these results, they concluded that this inspired design is efficient in terms of energy efficiency and frictional resistance and is therefore viable (Winter et al., 2009).

In this paper, the current standard excavator bucket and teeth were designed in the CATIA V5 R21 computer-aided design program, and a claw model resembling the claw structure of the armadillo, one of the most successful digging animals in nature, was designed using the biomimetic method and mounted on the standard excavator bucket however; to reduce weight in the armadillo bucket, the sides of the armadillo excavator bucket are slightly thinner than the standard bucket. The armadillo claw model was designed to be one piece without the need for an adapter, saving on parts and reducing labor. The resistance of these two different teeth models to the forces applied statically to the ground by 3 different steels was investigated. After the applied loads, the total deformation of the teeth, the values of the equivalent stresses, and the values of the safety factor were analyzed and, at the end of the work, the results of the armadillo-type teeth model created with the biomimetic method and the standard-type teeth model were compared.

MATERIAL AND METHODS

Material

In this study, 3 different steels were preferred to be used in analyzing the excavator bucket in terms of cost, durability, manufacturability, in terms of market availability, performance, and strength. These were determined to be St-37, S690QL, and Weldom900E steel respectively.

St-37 is one of the most preferred steels in industrial organizations and is frequently used in general building materials. It is a type of steel formed as a result of re-processing the steel made by hot production and obtaining it by cold drawing. As a result of these processes, the steel becomes more durable than normal. It is one of the most commonly used steels in the industry due to its affordable cost and easy availability (Maraşlı et al., 2022). Since S690QL steels are tempered steels, they are used in heavy-duty machinery and the construction of high weight structures. Among the areas where the material is preferred are heavy-duty applications such as the truck industry, crane industry, and construction machinery (Efe et al., 2019). The last steel and the most expensive in terms of cost, is Weldom 900 E steel. These steels are known as high-strength and low-alloy steels. Although they are expensive, they are used for the manufacture of heavy objects such as construction and heavy machinery. Although it is structurally low in carbon, it contains elements such as titanium and vanadium. These elements ensure both good weldability and high strength properties. In addition to their high strength, they are steels with a flexible structure (Shi et al., 2022). The values of the material characteristics of the steel used required in the analysis are indicated in Table 1.

Table 1. Material Properties (Karaçor et al 2024; Shi et al 2022)

Material	Density (kg/m ³)	Elastic modulus (GPa)	Poisson ratio	Tensile strength (MPa)	Tensile ultimate strength (MPa)
St-37	7850	200	0.3	250	460
S690 QL	7860	210	0.29	770	810
Weldom 900 E	7800	206	0.3	947.48	1100

Methods

In this investigation, CATIA V5 R21, a Computer Aided Design (CAD) program, was used for the design and Ansys programs for the finite element analysis. While performing the analysis, static analysis was used in the finite element method. Computer Aided Design (CAD) is the use of computer systems that assist with creating and modifying designs. Currently, specific CAD programs also possess the capability to analyze these designs through the analytical modules they have developed. Examples of these analysis are deformation analysis of parts, dynamic analysis, and heat transfer calculations. With this analysis programs, the designer knows how her design will react mechanically and thermodynamically to the stresses to be applied and how to resolve possible errors by analyzing the design before production. This saves time and costs (Çınar, 2014). CATIA is a design program for creating and modifying objects. This design program has design and modeling functions. Designing means creating a new object or modifying an existing object. Drawing, on the other hand, means making the object visually understandable (Prasad et al., 2014). The design of the excavator housing was created in the CATIA V5 R21 program. The finite element method (FEM) is a calculation method used in engineering to obtain approximate solutions to boundary value problems. In short, a boundary value problem is the solution of differential equations that apply at each point of a region and whose boundaries must fulfill certain conditions. This method allows the design of complex shapes. The solution region can be divided into different regions and different finite elements can be used in the different regions (Yılmaz, 2023). The analysis was performed using the finite element method in the Ansys program. Ansys offers the possibility of obtaining analysis results with various characteristics in a computer environment without the need for physical production of the designs. Creating the design is both more costly and more time consuming than the analysis method.

In addition, Ansys increases the life and quality of the parts by identifying and improving the defective parts of the designs owing to the 3D simulations (Kibar & Öztürk, 2012).

While Figure 1a is the view of the excavator bucket designed in CATIA in the Ansys Workbench program; Figure 1b represents the designed armadillo claw excavator bucket. The view of the mesh distribution after the meshing is displayed in Figure 2a. Whilst, Figure 2b indicates which parts are fixed supported during the analysis; Figure 3a displays the view of the forces applied to the teeth and the value of the force. The points on the scale for poor quality are shown in Figure 3b.

While Figure 4 to Figure 6 reflect the analysis results of the standard excavator bucket, Figure 7 to Figure 9 show the analysis results of the armadillo excavator bucket.




Figure 1. a) Standard Excavator Bucket General View b) General View of Armadillo Claw Design Excavator Bucket




Figure 2. a) General Mesh View b) Fixed Support Section of the Excavator Bucket

During the analysis, not only generated mesh was used when creating the mesh. In terms of being more detailed and having fewer elements, a more efficient result was obtained with examinations such as face sizing, face meshing, and body sizing on the parts. As a result, mesh optimization was obtained.

A correct analysis can be solved by defining the number of meshes for each structure. This mesh number can vary according to the dimensions of the design. The bucket used in the study has a width of 1870 mm and therefore the number of meshes should be defined in a range close to the optimal values. The points we pay attention to in the mesh metrics are the skewness and element quality values. Skewness expresses the skewness value of the mesh group in a structure, and the closer this value is to 0, the lower the skewness in the mesh structure in that direction. The optimum skewness range for analysis is assumed to be 0.20-0.25. Element quality expresses the quality value of each element of the same mesh structure. This value is expected to be as close as possible to 1. The optimal range is 0.80-0.90. Considering these parameters, since the structure we analyzed consists of curved surfaces, the triangular mesh structure was preferred, and a mesh size of 4-8 mm was chosen for the nails. The triangular mesh structure provides a more consistent connection between points called nodes that form the corner joints of triangular structures on curved surfaces.

Face meshing is used in the automatic settings. When using the face sizing method, only the element size value was changed. Different element size values were used in different areas. The reason for this is that the accuracy margin at critical points is high. The values for the element size are as follows: Sides of the bucket: 10mm, top, back, and inside of the bucket: 20mm, bottom of the bucket: 15mm. In the method for determining body sizing method, only the values for the element size were changed. For the nails: 4 and 8 mm, for the bucket: 20 mm.

The excavator boom connection pin area was selected as the fixed support. Because the excavator can move thanks to that area while digging the soil. The connection point between the bucket and arm is supported by the pin slots on the arm and the hydraulic system on the arm, as can be seen in the picture. Since the movement of the bucket depends on the user's input, the hydraulic system restricts its movement in case of influences other than the user's input. For this reason, the support points have been chosen so that they are supported by both the hydraulic system and the pins.




Figure 3. a) View of Forces Applied to Teeth b) Elements that can be counted in the Bad range

The force exerted on the teeth was taken from previous studies and determined to be 8285 N (Gurbet et al., 2021). The force was applied to each of the teeth in the negative Z direction. The reason why the force is given to the nails is that they are the most affected and most important part during excavation.

The qualities of the mesh values can be found in Table 2. There are 1001964 elements in the mesh process performed in the analysis. Only 124 of these elements are in the bad range. The closest value is in the bad and fair range. The

124 elements in the bad area are located on the sides of the bucket, which is in the area that is not damaged by the analysis.

Table 3 gives the result values for skewness and element quality that were applied to the other shell combinations using the same mesh methods.

Table 2 Optimum Mesh Properties (ANSYS, 2016)

Value of Skewness	Cell Quality
1	Degenerate
0.9-<1	Bad
0.75 — 0.9	Poor
0.5 — 0.75	Fair
0.25 — 0.5	Good
>0 — 0.25	Excellent
0	equilateral

Table 3. Mesh Values

	Maximum	Minimum	Average
Skewness	0.99951	1.3057e-010	0.26567
Element quality	0.99998	4.0974e-002	0.81329

The excavator bucket design was designed by taking the dimensions of the model of the company that produces the excavator bucket from previous studies as 1870mm in length and 1400mm in width (Akter, 2018).

RESULT AND DISCUSSION

Table 4 indicates the total deformation, equivalent stress, and safety factor values of the standard excavator bucket with different steels as a result of the analysis.

Table 4. Standard Excavator Bucket Results

	St-37	S690QL	Weldox900 E
Total deformation (mm) (Max)	6.8584	6.5166	6.6597
Equivalent stress (MPa) (Max)	180.44	245.26	260.86
Safety factor	1.3855	3.1024	3.6321

Table 5 displays the total deformation, equivalent stress, and safety factor values of the armadillo excavator bucket with different steels as a result of the analysis.

Table 5. Armadillo Excavator Bucket Results

	St-37	S690QL	Weldox900 E
Total deformation (mm) (Max)	7.3546	6.9957	7.1409
Equivalent stress (MPa) (Max)	156.6	164.85	164.6
Safety factor	1.5965	4.6157	5.7563

Table 4 and Table 5 values are given above, if these values are compared;

- The lowest value of total deformation was obtained with the standard S690QL design with a value of 6.5166 mm, while the highest value was obtained with the armadillo St-37 design with a value of 7.3546 mm.

- The lowest equivalent stress value was obtained in the armadillo S690QL design with a value of 156.6 MPa, while the highest value was obtained in the standard Weldox900 E design with a value of 260.86 MPa.
- While the lowest safety factor value was obtained in the Standard St-37 design with a value of 1.3855, the highest value was obtained in the armadillo Weldox900 E design with a value of 5.7563.
- Dontha applied values between 1000000 N and 1200000 N to the excavator bucket tooth in the education and as a result, found the highest equivalent stress value as 332.69 MPa (Dontha, 2017). In this paper, the highest equivalent stress value was found as 245.26 MPa.

Standard Excavator Bucket




Figure 4. a) Total Deformation b) Equivalent Stress Analysis c) Safety Factor Analysis Result of Standard ST-37 Model

The maximum total deformation value with St-37 steel in the excavator bucket of the standard type was determined to be 6.8584 mm. It can be seen that the part that is deformed the most is the tooth at the middle point.

Since the efficiency of the bucket teeth during the lifting, tilting, and pulling motions of the bucket is important and inadequate performance in these areas directly affects the efficiency, Gurbet et al. attempted to determine the deformation, equivalent stress distribution, and safety factor values of the teeth at the front end of the bucket using the finite element method. They created the bucket design using the CATIA V5 design program and carried out the finite element analysis with different materials using the Ansys program. They determined the value applied to each claw as 8285 N. As a result of the research, they observed that the equivalent stress value of the excavator bucket made of St-37 steel was found to be 179.7 MPa (Gurbet et al., 2021). The equivalent stress value of the standard excavator bucket applied with St-37 steel was found to be 180.44 MPa and it was observed that the stress distribution was spread over a larger area.

The safety factor of the excavator bucket type Standard St-37 was determined with a minimum of 1.3855. It has been observed that the parts where the safety factor is minimum are generally the parts where the teeth and the adapter are connected.




Figure 5. a) Total Deformation b) Equivalent Stress Analysis c) Safety Factor Analysis Result of Standard S690QL Model

The maximum total deformation value with S690QL steel in the excavator bucket of the standard type was determined to be 6.5166 mm. The equivalent stress of the excavator bucket type standard S690QL was determined with a maximum of 245.26 MPa. The safety factor of the excavator bucket type standard S690QL was determined with a minimum of 3.1024.

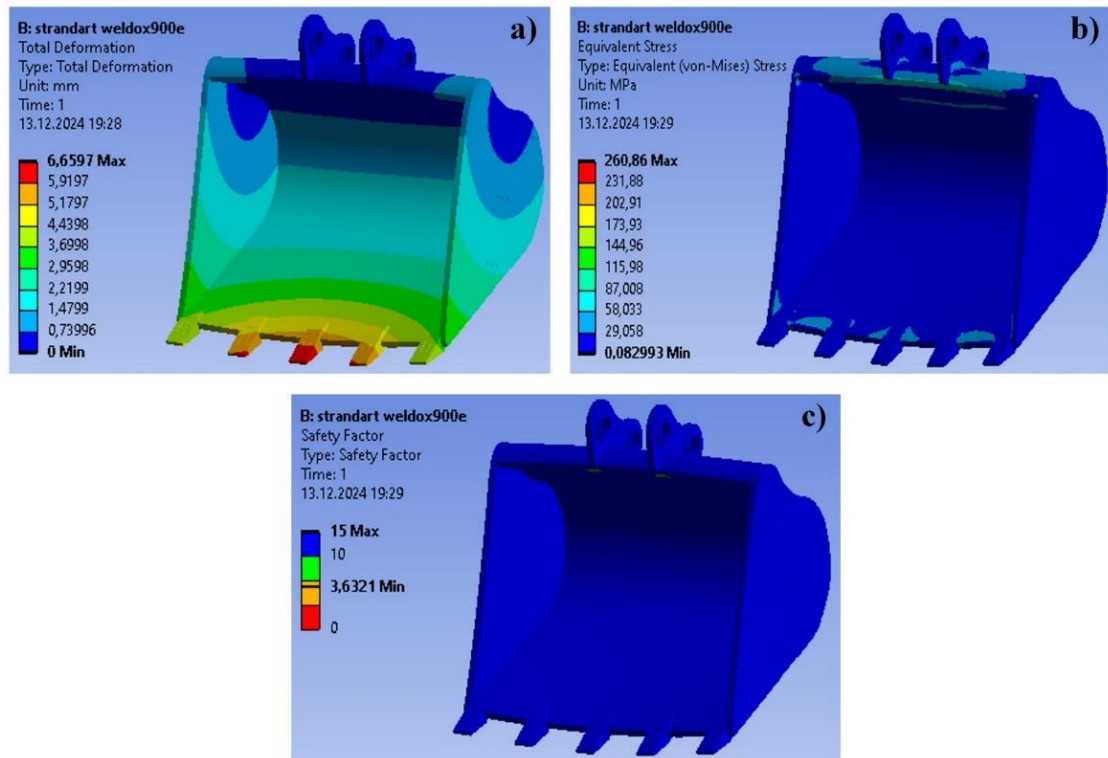


Figure 6. a) Total Deformation b) Equivalent Stress Analysis c) Safety Factor Analysis Result of Standard Weldox900 E Model

In their research, Sarkar et al. carried out a static analysis of the Tata JD 315SJ model excavator bucket made of Hardox 400 alloy, as the failures of the excavator bucket led to production losses. They designed the bucket with the CATIA V5 R18 design program using real dimensions. The material assignment and analysis were carried out using the Ansys Workbench 14.0 program. In the static analysis of the bucket, the bushing was considered a fixed component and the load was applied to the teeth. They determined the equivalent von Mises stress and deformation values formed in the blade using finite element analysis. It has been stated that the total deformation value is a maximum of 17.167 mm when the total force applied to the teeth is 53352 N (Sarkar et al., 2015). In this exploration, the total deformation value of the standard Weldox900 E excavator bucket was found as 6.6597 mm. In Sarkar's study with Hardox400 steel, a barrel with a digging depth of 4.42 m was used and a load of 53.352 kN was applied. In the study with Weldox900E steel, a load of 8.285 kN was applied to each tooth, for a total of 41.425 kN with five teeth. Although the Hardox400 structural steel is more brittle and has a higher yield strength than the Weldox900E steel, the main reason for the difference between the two studies is how the applied force is transferred to the buckets, the bucket design, and the dimensions of the bucket.

The equivalent stress of the excavator bucket type standard Weldox900 E was determined with a maximum of 260.86 MPa. The safety factor of the excavator bucket type standard Weldox900 E was determined with a minimum of 3.6321.

Armadillo Excavator Bucket




Figure 7. a) Total Deformation b) Equivalent Stress Analysis c) Safety Factor Analysis Result of Armadillo St-37 Model

The maximum total deformation value with St-37 steel in the excavator bucket of the armadillo type was determined to be 7.3546 mm. It can be seen that the part that is deformed the most is the tooth at the middle point. In this study, for comparison with Hadi Suryo's study, it was found that the value of the equivalent stress of the armadillo excavator bucket made of St-37 steel is 156.6 MPa and the stress is distributed over a larger area. The safety factor of the excavator bucket type armadillo St-37 was determined with a minimum of 1.5965.

The maximum total deformation value with S690QL steel in the excavator bucket of the Armadillo type was determined to be 6.9957 mm. The equivalent stress of the excavator bucket type armadillo S690QL was determined with a maximum of 164.85 MPa. The safety factor of the excavator bucket type armadillo S690QL was determined with a minimum of 4.6157.

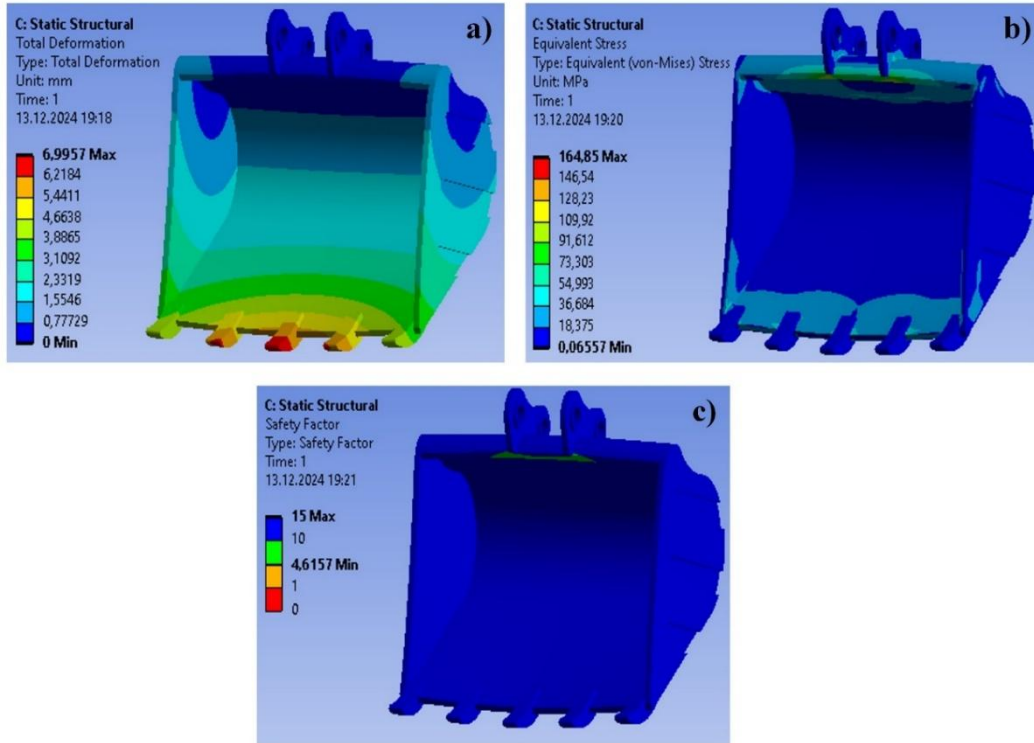


Figure 8. a) Total Deformation b) Equivalent Stress Analysis c) Safety Factor Analysis Result of Armadillo S690QL Model




Figure 9. a) Total Deformation b) Equivalent Stress Analysis c) Safety Factor Analysis Result of Armadillo Weldom900 E Model

The maximum total deformation value with Weldom900 E steel in the excavator bucket of the armadillo type was determined to be 7.1409 mm. In this study, for comparison with Akter's study, it was found that the value of the equivalent stress of the armadillo dredging bucket designed by the same method was 164.6 MPa in Weldom900 E steel. Not only were the values found to be close to each other, but the stress distribution was also found to be close

to each other. The safety factor of the excavator bucket type armadillo Weldom900 E was determined with a minimum of 5.7563.

Since the deformation values in the static analysis will remain below the yield strength of the material, the comparisons should only be evaluated in themselves. Since there will be no fracture, the performances should only be compared within themselves. It was found that the equivalent stress values determined for St-37 were below the yield strength of St-37 (235 MPa). The same results were found for the steels S690ql (690 MPa) and Weldom900 E (900 MPa). If the yield strengths of the materials are taken into account, the results are therefore within the acceptable value range. According to Şekercioğlu, the specified values of the safety factor for machines in the range of 1.2-2 are considered safe. The results are within the acceptable range of values (Şekercioğlu., 2021). Table 6 indicates the costs per ton of materials used.

Table 6. Costs of Steels Used (SSAB Swedish Steel Foreign Trade)

	St-37	S690QL	Weldom900 E
Prices (price (\$) /ton)	682.21	1784.24	2099.11

Table 7 shows the weight of the standard excavator bucket with the steel used and the production cost as a result of this weight.

Table 7. Standard Excavator Bucket Weight and Production Cost Values

Standard	St-37	S690QL	Weldom900 E
Mass (Kg)	2648.9	2652.3	2632
Production cost (\$)	1807.1	4723.33	5524.85

Table 8 shows the weight of the armadillo excavator bucket with the steels used and the production cost as a result of this weight.

Table 8. Armadillo Excavator Bucket Weight and Production Cost Values

Armadillo	St-37	S690QL	Weldom900 E
Mass (Kg)	2611.7	2615	2595.1
Production cost (\$)	1781.7	4665.78	5447.4

According to the obtained values from Tables 6 to 8, the following conclusions have been made;

- The designed armadillo excavator bucket design has less weight than the standard excavator bucket. Because more weight reduction has been made on the sides of the armadillo bucket. As a result of this weight reduction, the armadillo excavator bucket is 1.40% lighter than the standard excavator bucket.

- This weight reduction also resulted in savings in manufacturing costs: \$25.4 for St-37 steel, \$57.55 for S690QL steel, and \$77.45 for Weldom900 E steel.

CONCLUSION

In this research, the excavator bucket was designed, and the reactions resulting from the force exerted by the teeth on the ground were analyzed using the finite element method. The analyses were carried out on two different teeth models. First, a standard tooth and an adapter were designed and their values were analyzed and investigated. Then, a one-piece teeth model inspired by the structure of the armadillo claw was designed using biomimetic methods, and the analysis results were examined. The results of this education are as follows.

-The manufacturer wishing to benefit from the results of the analysis and design should determine the design of the armadillo himself, taking into account the costs and the user's requirements (area of use of the machine, workloads, operating conditions, etc.). Different types of steel have different advantages and disadvantages as well as advantages and disadvantages in terms of design. The optimum design and steel combination should be designed according to the manufacturer's field of application. In the study, the current excavator shells perform the digging process using adapters welded to the shell and teeth attached to the adapters with a pin connection. With this new design, the additional fastening requirements have been eliminated and the same function is achieved using only the adapter. In this way, manufacturers can save additional costs for attachments (tooth, pin, etc.).

- It has been observed that the equivalent stresses of the armadillo excavator bucket design in the steels used are spread over a larger area compared to the equivalent stresses of the standard excavator bucket. This is a desired situation.

- It has been observed that the total deformation values of the standard excavator bucket in the steels used are lower than the total deformation values of the armadillo excavator bucket.

- It has been observed that the safety factor values are higher in the armadillo excavator bucket design than in the standard excavator bucket design. The high safety factor value explains that the design is usable.

- Since the designed armadillo excavator bucket design is more efficient at equivalent stress and safety factor values compared to the standard excavator bucket, the armadillo excavator bucket has been determined as a usable design.

In the future, biomimetic methods are thought to be widely used in all areas of technology. Equipment used by humans can be improved by imitating living things in nature. When it comes to construction machines, designs can be made on excavator booms using elephants and giraffes as examples in future studies.

REFERENCES

- Akpınar, M. V. (2010). *İş makineleri ders notları*. Karadeniz Teknik Üniversitesi, Trabzon.
- Akter, A. Y. (2018). Excavator bucket design biomimetic approach. Master thesis. Gazi University, Industrial Design, Ankara.
- Ansys (2016) Skewness in Ansys Meshing. Ansys documentation Canonsburg PA, USA.
- Chang, Z., Liu, W., Tong, J., Guo, L., Xie, H., Yang, X, Mu, H. & Chen, D. (2016). Design and experiments of biomimetic stubble cutter. *Journal of Bionic Engineering*, 13(2), 335-343. DOI: 10.1016/S1672-6529(16)60306-2
- Çınar, R. (2014). Parametric design and size optimization of external spur gear pump housing. PhD thesis. Kocaeli University. Mechanical engineering. Kocaeli.
- Demircioğlu, P., Böğrekcı, İ., & Hamısu, S. (2021). Analysis of interactive effects of bulk material on excavator bucket. *Uluborlu Mesleki Bilimler Dergisi*, 4(1), 1-12.
- Dontha, S. (2017). Study on loader bucket using finite element analysis. *International Journal of Engineering and Technology*, 4(4), 2856-2858.
- Efe, H., Onar, V., & Çınar, M. G. (2019). The effect of welding currents on microstructures in welding of s690ql series steels in used heavy duty machines. *Journal on Mathematic, Engineering and Natural Sciences (EJONS)*, 3(7), 123-130.
- Gurbet, Z., Karacor, B., & Ozcanli, M. (2021, October). Investigation of bucket teeth stress-deformation distribution by using ultra high strength material. In *6th International Mediterranean Science and Engineering Congress (IMSEC 2021)*, (pp.590-594).
- Guo, Z., Zhou, Z., Zhang, Y., & Li, Z. (2009). Bionic optimization research of soil cultivating component design. *Science in China Series E: Technological Sciences*, 52, 955-965. DOI: 10.1007/s11431-008-0208-4
- Jun, G., Qingyi, Z., Memon, M. S., Changying, J., & Zheng, Z. (2017). Design and experiment of bionic mole's toe arrangement serrated blade for soil-rototilling and straw-shattering. *Transactions of the Chinese Society of Agricultural Engineering*, 33(6), 43-50. DOI: 10.11975/j.issn.1002-6819.2017.06.006
- Karaçor, B., Aslan, A., Özcanlı, M., & Kılınç, Ö. (2024, April). An optimization study: Examining different materials usage in the truck chassis. In *2024 6th International Conference on Global Practice of Multidisciplinary Scientific Studies* (pp.2006-2033).
- Khedkar, Y., Dey, T., & Padasalagi, Y. (2017). Study of forces acting on excavator bucket while digging. *Journal of Applied Mechanical Engineering*, 6(5), 1-6. DOI: 10.4172/2168-9873.1000282

- Kibar, H., & Öztürk, T. (2012). Ansys sonlu eleman yazılımının tarımdaki uygulamaları. *Journal of the Institute of Science and Technology*, 2(2), 65-74.
- Lomate, S., Biradar, S., Dhumal, K., & Waychal, A. (2016). Design and shape optimization of excavator bucket. *International Research Journal of Engineering and Technology (IRJET)*, 3(08), 1423-1429.
- Maraşlı, M., Akmaz, V., Kam, M., & Dikmen, K. (2022). Elektro galvaniz işleminin St37 ankraj elemanının korozyon mekanizmasına etkisinin araştırılması. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 10(1), 367-378. DOI: 10.29130/dubited.938836
- Onat, A. (2013). İş makinaları. In *Makina ve teçhizat* (pp. 200-223). Erzurum: Atatürk Üniversitesi Yayınları.
- Prasad, T. S., Krishnaiah, T., Iliyas, J. M., & Reddy, M. J. (2014). A review on modeling and analysis of car wheel rim using CATIA & Ansys. *International Journal of Innovative Science and Modern Engineering (IJISME)*, 2(6), 1-5
- Rao, A. S., & Ananth, S. (2016). Design, analysis and material optimization of excavator bucket teeth with different cross sections. *Open Journal of Technology and Engineering Disciplines*, 2(4), 410-428.
- Sarkar, M., Shaw, R. K., & Ghosh, S. K. (2015). Numerical analysis of stresses in mine excavator bucket. *Journal of Mining Science*, 51, 309-313. DOI: 10.1134/S1062739115020131
- Shaikh, B. P., & Mulla, A. M. (2015). Analysis of bucket teeth of backhoe excavator loader and its weight optimization. *International Journal of Engineering Research & Technology*, 4(5), 289-295.
- Shi, Y., Hu, A., Du, T., Xiao, X., & Jia, B. (2022). Experimental and numerical study on the protective behavior of Weldox 900 E steel plates impacted by blunt-nosed projectiles. *Metals*, 12, 141. DOI:10.3390/met12010141
- SSAB Swedish Steel Foreign Trade Co. Ltd., S690QL Steel properties Accessed: <https://www.ssab.com/tr-tr/markalar-ve-urunler/strenx/urun-teklifi/700/e-f>
- SSAB Swedish Steel Foreign Trade Co. Ltd., St-37 Steel properties Accessed: <https://www.ssab.com/en/brands-and-products/steel-categories/structural-steels>.
- SSAB Swedish Steel Foreign Trade Co. Ltd., Weldox900E Steel properties Accessed: <https://www.ssab.com/tr-tr/markalar-ve-urunler/strenx/urun-teklifi/900/e-f>.
- Suryo, S. H., Bayuseno, A. P., Jamari, J., & Ramadhan, G. (2018). Simulation of excavator bucket pressuring through finite element method. *Civil Engineering Journal*, 4(3), 478-487. DOI:10.28991/cej-0309107
- Şekercioğlu, T., Makine Elemanları Hesap Şekillendirme, 5. Baskı, Birsen Yayınevi, İstanbul, 2021.
- Tasevski, A., & Hedlund, C. (2016). Design of bucket teeth (Master Thesis). Eskilstuna: Mälardalen University. Design and Engineering. Västerås.
- Winter, A. G., Hosoi, A. E., Slocum, A. H., & Deits, R. L. (2009, January). The design and testing of roboclam: A machine used to investigate and optimize razor clam-inspired burrowing mechanisms for engineering applications. In *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference* (Vol. 49040, pp. 721-726). DOI:10.1115/DETC2009-86808
- Yılmaz, U. (2023). *Crystal plasticity-based analysis of crack propagation at microscale by extended finite element method* Master's thesis. Middle East Technical University. Mechanical Engineering. Ankara
- Yıldız, H. (2012). Biomimetic design and methodology in the content of industrial product design. Master's thesis. İstanbul Technical University. Industrial Design. İstanbul.



Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences



Geliş Tarihi : 27.08.2024
Kabul Tarihi : 20.12.2024

Received Date : 27.08.2024
Accepted Date : 20.12.2024

YÖNETİM ARAÇLARI SEÇİMİNDE SEKTÖR ANALİZİ VE ÇOK KRİTERLİ KARAR VERME TEKNİKLERİ KULLANIMI: HİBRİT ENTROPİ-TOPSIS METODU İLE SAĞLIK TURİZMİ ARACI İŞLETMELERİNE YÖNELİK BİR UYGULAMA

SECTOR ANALYSIS AND USE OF MULTI-CRITERIA DECISION-MAKING TECHNIQUES IN THE SELECTION OF MANAGEMENT TOOLS: AN APPLICATION FOR HEALTH TOURISM INTERMEDIARY BUSINESSES WITH HYBRID ENTROPY-TOPSIS METHOD

Serkan ETİ¹ (ORCID: 0000-0002-4791-4091)
Halil YORULMAZ^{1*} (ORCID: 0000-0002-4497-323X)

¹ İstanbul Medipol Üniversitesi, Meslek Yüksekokulu, İstanbul, Türkiye

*Sorumlu Yazar / Corresponding Author: Halil YORULMAZ, hyorulmaz59@gmail.com

ÖZET

Yönetim araçları, temelde işletmelerin performanslarını artırmalarına yardımcı olan araçlardır. Çeşitli çevre koşullarında faaliyet gösteren işletmelerin her yöne aynı anda geliştirilmesi mümkün değildir. İşletmenin gelişiminde, öncelikli yönlerin belirlenerek hangi yönetim araçlarının uygulanması gerektiği yöneticiler için kritik bir karar problemidir. Bu çalışmada, Porter beş güç çerçevesi temelli çevre analizi ile gelişme yönlerinin tespiti ve buna dayanarak en doğru yönetim araçlarının seçimine yönelik bir çerçeve ortaya koyularak, bu karar problemine destek olunması amaçlanmaktadır. Bu doğrultuda çok kriterli karar verme (ÇKKV) yöntemlerinden Entropi ve TOPSIS kullanılmaktadır. Beş güç çerçevesinin önem ağırlıklarının belirlenmesi için Entropi yöntemi, en uygun yönetim aracının belirlenmesi için TOPSIS yöntemi kullanılmaktadır. Çalışma, beş güç çerçevesini ve modern yönetim araçlarını aynı bağlamda birleştirmesi bakımından güçlü ve özgün bir yaklaşıma sahiptir. Amaca yönelik uygulama, sağlık turizmi sektöründe sağlık aracı işletmelerine yönelik yapılmıştır. Araştırmada, işletmelere yönelik yol gösterici bulguların yanı sıra, bu algoritmanın uygulanmasına ilişkin ayrıntılı bir açıklama sunularak araştırmacıların bu metodolojiyi başka senaryolarda da yeniden üretmesine olanak tanınmaktadır. Sektör analizine yönelik sonuçlar, sektöre yeni girebilecek işletmelerin varlığının oluşturduğu tehdidin en güçlü kriter olduğuna işaret etmektedir. Yönetim aracı tercihiye yönelik sonuçlar sırasıyla, çevik yönetim, toplam kalite yönetimi, dijital dönüşüm ve değişim yönetimi araçlarının sektör özelliklerine göre yüksek uygunluk değerine sahip olduğuna işaret etmektedir.

Anahtar Kelimeler: Sektör analizi, yönetim aracı, stratejik yönetim, sağlık turizmi, ÇKKV

ABSTRACT

Management tools help companies to improve their performance. It's not possible for businesses operating in environmental conditions to develop in all directions simultaneously. It's a critical decision problem to determine which tools should be applied by selecting the priority directions. This research aims to provide a framework for selecting the most appropriate management tools based on Porter's five forces framework-based environmental analysis. Multi-criteria decision-making (MCDM) methods are used in this direction. The entropy method is used to determine the importance weights of Porter's five forces framework, and the TOPSIS method is used to determine the most appropriate management tool. The study has an original approach in that it combines Porter's five forces framework and management tools in the same context. The application was made for health intermediary businesses. In addition to guiding findings for healthcare intermediary businesses, it provides a detailed explanation of the

ToCite: ETİ, S., & YORULMAZ, H., (2025). YÖNETİM ARAÇLARI SEÇİMİNDE SEKTÖR ANALİZİ VE ÇOK KRİTERLİ KARAR VERME TEKNİKLERİ KULLANIMI: HİBRİT ENTROPİ-TOPSIS METODU İLE SAĞLIK TURİZMİ ARACI İŞLETMELERİNE YÖNELİK BİR UYGULAMA. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 230-244.

implementation of this algorithm, allowing researchers to reproduce this methodology in other scenarios. The results indicate that the threat posed by the presence of new entrants is the strongest criterion. Agile management, total quality management, digital transformation, and change management tools have high suitability values according to the sector's characteristics.

Keywords: Sector analysis, management tool, strategic management, health tourism, MCDM

GİRİŞ

Küreselleşme dünya genelinde tüm sektörleri az ya da çok etkilemektedir. Günden güne gelişim hızı artan teknoloji ise küreselleşme sürecini hızlandırmaktadır. Küreselleşme ve teknolojik gelişmeler insan davranışlarını, müşteri tercihlerini ve bununla birlikte iş yapış şekillerini de değiştiren olgulardır. Bunların getirisi olarak iş çevreleri değişmiş, yeni oyuncular sektörlere dahil olmuş, rekabet şiddetlenmiştir. Değişim, işletmelerin günlük gerçekliğinin bir parçası haline gelmiştir. İşletmelerin, hedefledikleri karlılığa ulaşabilmek ve bunu devam ettirebilmek, bunun da ötesinde birçok zaman hayatta kalabilmek için değişen çevre koşullarına, rekabete ve sürekli değişime uyum sağlaması gerekmektedir. Bunun için de işletme yöneticilerinin stratejik yönetim sürecinin bir parçası olarak çevreyi iyi okuması ve doğru yönetim araçlarını tercih ederek performanslarını arttırmaları ve işletmelerinin rekabet ortamındaki varlıklarını sürdürmeleri gerekmektedir (Lesnikova vd., 2023).

Yönetim araçları, stratejik düşünmeyi, stratejik karar almayı ve strateji uygulama faaliyetlerini yapılandıran veya etkileyen tüm kavram, fikir, teknik ve yaklaşımların tamamı olarak tanımlanabilir (Knott, 2006). Literatürde yönetim aracı kavramının tanımı üzerinde bir uzlaşıdan söz etmek mümkün değildir fakat temelde şirketlerin performanslarını radikal bir şekilde arttırmalarına yardımcı olan araçlar olduğu söylenebilir (Rigby, 2001). Çoğu zaman birbirinin yerine kullanılan, karar araçları, karar verme araçları, strateji araçları, stratejik yönetim araçları, yönetim araçları ve stratejik planlama araçları gibi çeşitli kavramlarla ifade edilmektedirler (Lesnikova vd., 2023). Stratejik karar vericiler arasında en popüler yönetim araçları ise dengeli puan kartı, kıyaslama, PEST analizi, Porter beş güç çerçevesi ve SWOT analizidir (Koseoglu vd., 2019). Bununla birlikte küresel danışmanlık kuruluşu Bain & Company, 1993 yılından bu yana her yıl yürüttüğü araştırmalar ile dünyanın her yerindeki işletme yöneticileri tarafından tercih edilen en popüler 25 yönetim aracını raporlamaktadır.

Yönetim araçları, işletmelerin rekabet ettikleri pazar gereksinimlerine uyum sağlamalarına yardımcı olarak, iş verimliliğinin ve karlılığının sağlanmasında ve rekabet gücünün artırılmasında önemli rol oynamaktadırlar (Cambalikova, 2021). Dolayısıyla işletmelerin, küreselleşme ve teknolojinin getirdiği değişime uyum sağlayabilmeleri, müşteri gereksinimlerini ortaya çıkartabilmeleri, rekabetçi bir konum elde edebilmeleri ve pazar paylarını arttırabilmeleri için dış ve iç çevre faktörlerine yönelik en doğru hamleleri yapabilmeleri; bunun için de stratejik karar vericiler tarafından doğru yönetim araçlarının tercih edilmesi gerekmektedir. Bununla birlikte işletmeler çoğunlukla işgücü ve ekonomik kısıtlardan ötürü kendilerini etkileyen iç ve dış çevre faktörlerinin hepsine aynı anda müdahale edemezler (Lesnikova vd., 2023). Son yıllarda yöneticiler geçmişteki uygulamalara kıyasla daha az araç benimserken, iyi bir yönetim için doğru araçları, doğru yerlerde, doğru şekillerde, doğru zamanda kullanmaya odaklandıkları görülmektedir (Rigby vd., 2023). Yönetim araçlarının hangilerinin hangi öncelikte ve ne ölçüde uygulanması gerektiği işletme yöneticilerinin vermesi gereken kritik kararlardandır.

Çeşitli çevre koşullarında faaliyet gösteren işletmelerin her yöne aynı anda geliştirilmesi mümkün değildir ve en öncelikli yönün belirlenmesi gerekmektedir. İşletmenin gelişme yönünün belirlenerek ne ölçüde ve hangi yönetim araçlarını uygulaması gerektiği yöneticiler için kritik bir karar problemine dönüşmektedir. Bu araştırmada, Porter beş güç çerçevesi temelli çevre analizi ile geliştirme yönlerinin tespiti ve buna dayanarak en doğru yönetim araçlarının seçimine yönelik bir çerçeve ortaya koyularak, bu karar problemine destek olunması amaçlanmaktadır. Bunun için de rekabet ortamına dayalı karmaşık ve belirsiz sorunların çözümünde en elverişli yöntem olan çok kriterli karar verme temelli bir yaklaşım sunulmaktadır (Dağdeviren ve Yüksel, 2010).

Beş güç çerçevesi karmaşık bir stratejik ortamda bir endüstrinin konumunu açıklamak için Porter tarafından 1979 yılında geliştirilmiştir. Geliştirildiği tarihten günümüze kadar da strateji öğrencileri, akademisyenler ve uygulayıcılar tarafından en sık kullanılan analitik araçlardan biridir (Pangarkar ve Prabhudesai, 2024). Müşteriler, mevcut rakipler, pazara yeni rakip giriş tehdidi, tedarikçiler ve ikame mallar üzerinden yürütülen beş güç analizi ile sektörün durumu tespit edilerek işletmenin stratejik kararlarına yol gösterici olunmaktadır (Porter, 1979). Bu çerçeve geliştirildiği tarihten itibaren her sektör için geçerli kabul edilmiştir (Porter, 2008).

Rigby ve diğerlerinin (2023) araştırması, yöneticilerin geçmişteki uygulamaların aksine, yönetim aracı kullanımında giderek daha sofistike hale gelmekte, yönetim araçları konusundaki modaya daha az itibar etmekte ve kullandıkları araçları dikkatli bir şekilde seçmeye çalıştıklarını göstermektedir. Buradan hareketle doğru yönetim araçları seçimine ilişkin ortaya koyulacak matematiksel modelleme, uygulamacılar için önem arz etmektedir. Bu çalışmada, yönetim araçları seçimi bir karar problemi olarak ele alınmakta, bu problemin çözümü ise, iş çevresinin Porter beş güç çerçevesi ile analizine dayandırılmaktadır. Çalışma kapsamında yönetim araçları havuzunun oluşturulmasında Bain & Company tarafından raporlanan en popüler 25 yönetim aracı ve trendi (Rigby vd., 2023) çerçevesinden de yararlanarak 10 alternatif yönetim aracı belirlenmiştir.

Bu araçlardan müşteri deneyimi yönetimi, işletmenin müşterilerle olan etkileşimlerine yönelik geri bildirim sistemleri ve ölçümlenmelere yöneliktir. Kıyaslama (benchmarking) aynı ya da farklı endüstrideki en iyi firmaları analiz ederek onlardan öğrenmek, bilgi ve deneyimlerini kullanmak ile ilgilidir. Değişim yönetimi, işletmelerin üstün performans elde etmek için sistemlerini, süreçlerini ve stratejilerini değiştirmeye yönelik değişim girişimleri planlanmasını ifade eder. Çevik yönetim, değişime hızlı uyum sağlanması için organizasyonların yatay olarak yapılandırılması, tüm süreçlere müşteri katılımı, iş birliği, çalışan gelişimi ve tüm yeteneklerinden faydalanılmasını içermektedir. Stratejik ortaklık, ortak hareket edilerek avantajlar elde edilmesi ve birlikteliğin dışında kalan taraflara karşı rekabet anlayışının devam ettirilmesi üzerinedir.

Esnek çalışma düzenlemeleri, çalışma zamanı ve mekânı konusunda çeşitli alternatifler geliştirilerek uygulanmasını içermektedir. Toplam kalite yönetimi, müşteri odaklı bir yaklaşımı temsil etmekte olup, hataları önlemek veya azaltmaya yönelik kuruluş çapındaki faaliyetleri ifade etmektedir. Yeşil yönetim, işletmenin tüm faaliyetlerinin sürdürülebilirliğe entegre ve sürdürülebilirliği hedefleyen yapıda düzenlenmesi ile ilgilidir. İş süreçlerinin yeniden yapılandırılması, üretkenlik, döngü süreleri, kalite, çalışan ve müşteri memnuniyetinde iyileştirmeler sağlamak için süreçlerin izlenmesi, işin nasıl yapılacağına veya yapılması gerekip gerekmediğine karar verilmesi ve sürece dahil olan tüm tarafların rollerinin yeniden değerlendirilmesi ile ilgilidir. Dijital dönüşüm ise üstün müşteri deneyimleri oluşturabilmek ve asıl işi güçlendirebilmek için dijital teknolojileri işletmenin operasyonlarına entegre etmekle ilgilidir.

Bu araştırma kapsamında oluşturulan, Porter beş güç çerçevesi analizine dayalı olarak yönetim aracı seçimini içeren model, sağlık turizmi sektöründe faaliyet gösteren sağlık aracı firmalarına yönelik uygulanmıştır. Sağlık aracı firmaları, küresel düzeyde hacmi artmakta olan ve ülke ekonomileri için dinamo görevi gören stratejik bir sektör haline gelen sağlık turizmi sektöründe faaliyet göstermektedirler (Drinkert ve Singh, 2017; Öğüt vd., 2018). Sektörün Türkiye ekonomisi içerisindeki payı istikrarlı bir artış içerisindedir (Aydın ve Karamehmet, 2017). İstatistiklere göre Türkiye sağlık turizminde son yıllarda en çok ziyaret edilen ülkeler arasında yer almaktadır (Sevim ve Kurtaran, 2023). Sektördeki bu hareketlilik ve gerçekleştirdikleri faaliyetlerin dinamik ve düzensiz taleplere gebe olan yapısı, bu firmaların başarılı olabilmeleri için doğru yönetim araçlarını tercih ederek iyi yönetilmelerini zorunlu kılmaktadır. Hatalı yönetim araçlarının tercih edilmesi, Kanada gibi yüksek ekonomik gelişmişlik düzeyine sahip ve sektörde payı yüksek olan ülkelerde bile sağlık turizm şirketlerinin önemli bir kısmının bu dinamizme ayak uyduramayarak başarısızlık yaşamalarına ve faaliyetlerini sonlandırmalarına neden olmuştur (Sarantopoulos vd., 2014; Turner, 2012).

Bu çalışmanın amacı uygun ve doğru yönetim araçları seçimi problemine yönelik, iş çevresi analizine dayalı çözüm sunmaktır. Ayrıca, literatürde bu alandaki boşluğa ve ihtiyaca yönelik katkı sunulmaktadır. Uygulamanın yapıldığı sağlık turizmi sektörünün Türkiye açısından artan önemi araştırmanın önemini de arttırmaktadır. Çalışmada çok kriterli karar verme yöntemlerinden Entropi ve TOPSIS kullanılmaktadır. Porter'ın beş güç çerçevesinin önem ağırlıklarının belirlenmesi için Entropi yöntemi, sonrasında en uygun yönetim aracının belirlenmesi için de TOPSIS yöntemi kullanılmaktadır. Çalışma, Porter beş güç çerçevesini ve modern yönetim araçlarını matematiksel modelleme bağlamında birleştirmesi bakımından güçlü ve özgün bir yaklaşıma sahiptir. Sağlık turizmi sektöründe faaliyet gösteren sağlık aracı işletme yöneticilerine yönelik yol gösterici bulguların yanı sıra, bu algoritmanın uygulanmasına ilişkin ayrıntılı bir açıklama sunarak araştırmacıların bu metodolojiyi başka senaryolarda da yeniden üretmesine olanak tanımaktadır.

Literatürde geniş çerçevede turizm sektörüne odaklanan çalışmalar (Gallo vd., 2021; Jana, 2021), alt sektör olarak sağlık turizminin kendine has özelliklerinden doğabilecek farklılıklara cevap verememektedir. Çalışmalar çeşitli ülke bağlamlarında yürütülmekte olup (Tsekouropoulos vd., 2023; Dobrovič vd., 2019), bağlamsal farklılıklar da sonuçları etkileyebilmektedir. Sektörler farklı ülkeler içerisinde farklı dinamiklere sahip olabilmektedirler. Bu

çalışma yürütüldüğü bağlam ve alt sektör bakımından önemli sonuçlar sunmaktadır. Literatürde yer alan çalışmalarda hipotez testleri ve çeşitli nicel metotların yanı sıra nitel metotlar da kullanılmaktadır (Alfonso vd., 2022; Chongthanavanit, 2020). Çok kriterli karar verme yöntemlerinin sağlık turizminde kullanımı ise çoğunlukla destinasyon seçimi üzerinedir ve ayrıca çalışmaların çoğunda yöntem tekil olarak kullanılmaktadır (Arslan ve Sevim, 2022). Bu çalışma hibrit yöntem kullanımı ve odaklandığı konu ile literatüre katkı sunmanın yanı sıra uygulamacılar için rehber vazifesi görmektedir. Yönetim araçlarına ilişkin literatürdeki çalışmalar genellikle tek yönetim aracına odaklanmış, ya da çeşitli bulgulardan yapılan çıkarımlar sonucunda bir yönetim aracı önerisinde bulunmaktadır (Rudnichenko vd., 2021). Konuyu bir karar problemi olarak ele alarak çok kriterli karar verme yöntemleri ile yönetim araçları havuzu içerisinde seçim yapılmasına yönelik bu çalışma, beş güç analizi ile hem sektör özelliklerine uygun sonuçlar hem de metodolojik bir ufuk sunmaktadır.

Bu araştırma altı ana başlıktan oluşmaktadır. Bundan sonraki ana başlıklarda sırasıyla literatür özeti, materyal ve metot, bulgular, tartışma ve sonuç yer almaktadır.

LİTERATÜR ÖZETİ

Bilimsel literatürde Porter beş güç çerçevesine yönelik geçerliliği ve güvenilirliği kanıtlanmış bir ölçeğe rastlanmamaktadır. Bununla birlikte Porter beş güç çerçevesi veya çeşitli yönetim araçlarını konu edinen, çok kriterli karar verme yöntemlerini kullanan çalışmalar bulunmaktadır. Literatürde, çok kriterli karar verme yöntemlerini kullanan çalışmalardan; Tanrıverdi ve Lezki (2021) çalışması hava kargoculuğu sektöründe beş güç analizi kriterlerine dayalı olarak, Porter (1980) jenerik stratejileri içerisinde alternatif strateji seçimi önermektedir. Benzer bir çalışma Aydın ve Özbek (2024) tarafından iş ve inşaat makineleri sektöründe tekrarlanmıştır. Biswas ve Niyogi (2024) çalışması beş güç çerçevesi aracılığıyla Hindistan'da çelik sektöründeki iş yeterliliğini ortaya çıkarmaya yöneliktir. Paksoy ve diğerleri (2023) hidrolik pres endüstrisi şirketinde yürüttükleri örnek olay çalışması ile beş güç analizine dayalı olarak bir şirketin rekabetçiliğini nesnel göstergeler ve ölçütlere dayalı olarak ölçen bir teknik önermektedir. Görece eski tarihli çalışmalardan Dağdeviren ve Yüksel (2010) beş güç analizi çerçevesinde bir organizasyonun sektörel rekabetçilik düzeyini belirlemek amacıyla örnek olay çalışması gerçekleştirmişlerdir.

Literatürde yönetim araçlarına ilişkin çeşitli yöntemler kullanan çalışmalardan; Köninger ve Gouthier (2024) bir strateji olarak müşteri deneyimi yönetiminin başarılı olarak uygulanabilmesine yönelik faktörleri ele alarak, uygulanması durumunda firma içi ve dışı etkilerini araştırmaktadırlar. Gareta ve diğerleri (2020) küçük ve orta büyüklükteki işletmeleri ele aldıkları araştırmada bir yönetim aracı olarak kıyaslanmanın (benchmarking) hangi alanlarda kullanıldığını ve iş etkinliğine olan etkisine odaklanmaktadırlar. Phillips ve Klein (2023) değişim yönetimini ele aldıkları çalışmada, uygulamadaki türleri ve kullanım sıklıklarını araştırmaktadırlar. Çevik yönetime odaklanan araştırmalarında Rudnichenko ve diğerleri (2021), işletmelerde çevik yönetim araçlarının uygulama maliyetlerini en aza indirecek şekilde seçimi için matematiksel model önermektedirler. Stratejik ortaklıkları ele alan araştırmalardan Olutimehin ve diğerleri (2024) stratejik ortaklık ve performans arasındaki ilişkiyi incelerken, Ochuba ve diğerleri (2024) çalışması veri analitiğinden faydalanarak stratejik ortaklar arasındaki sinerjinin artırılmasına odaklanmaktadır.

Yönetim aracı olarak esnek çalışma düzenlemelerini ele alan Yorulmaz ve diğerleri (2023) örgütsel dayanıklılık ile ilişkisine yönelik ipuçları aramaktadırlar. Abbas (2020) çalışması işletmelerin kurumsal sürdürülebilirlik hedefine ulaşmasında toplam kalite yönetiminin rolünü araştırmaktadır. Kaçamak ve Uygun (2022) çalışmalarında yeşil yönetim modeli önerisi sunmaktadırlar. Harika ve diğerlerinin (2021) çalışması, operasyona yönelik bir yönetim aracı olan iş süreçlerinin yeniden yapılandırılmasında, ortak sorunları ve zorlukları değerlendirmeye yöneliktir. Dijital dönüşüme ilişkin çalışmalardan Vaska ve diğerleri (2021) dijital dönüşüm alanının gelişimini analiz etmek ve dijital teknolojilerin iş modeli yeniliği üzerindeki etkisini anlamaya yönelik literatür taraması temelli bir çalışma yürütürken, Bican ve Brem (2020) konuyu sürdürülebilirlik bağlamında ele alarak dijital dönüşümün sürdürülebilirlik ile ilişkilendirmesine yönelik kavramsal bir çerçeve önermektedirler.

Sağlık turizmi sektörüne yönelik literatürde ise Porter beş güç çerçevesini kullanan kimi çalışmalar mevcuttur. Bu çalışmalardan Tsekouropoulos ve diğerleri (2023), Yunanistan bağlamında yürüttükleri araştırmada, sistematik literatür taraması ve oluşturdukları yapılandırılmış anket aracılığı ile topladıkları nicel veriler üzerinden yaptıkları analiz neticesinde sektörde Porter beş güç çerçevesine yönelik çıkarımlarda bulunmuşlardır. Metodolojik olarak değerlendirildiğinde Tsekouropoulos ve diğerlerinin (2023) çalışması ikincil nitel ve birincil nicel verilerin analizine dayandırılan çıkarımlardan oluşmaktadır. Bu araştırmada kullanılan yöntemin aksine, Porter beş güç çerçevesine yönelik matematiksel modelleme yapılmamıştır.

Chongthanavanit (2020) araştırması Tayland'da dental turizm sektörüne yönelik pazarlama iletişimi stratejileri geliştirilmesine yöneliktir. Metodolojik olarak karma yöntem tercih edilen çalışmada elde edilen verilerden hareketle, sektörün Porter beş güç çerçevesine göre analizi yapılmaktadır. Chongthanavanit (2020) araştırması metodolojik olarak ele alındığında, bu çalışmadaki matematiksel modellemenin aksine, karma yöntem metodolojisini uygulayarak Porter beş güç çerçevesine yönelik tespitlerde bulunmaktadır. Alfonso ve diğerleri (2022) benzer şekilde Kolombiya sağlık turizmi sektörüne yönelik Porter beş güç çerçevesi uyarınca analiz yapmaktadırlar. Yazarlar, 60 sağlık kuruluşuna uygulanan anket ve ikincil nitel verilerden oluşan bir metodoloji takip etmektedirler. Metodolojik olarak değerlendirildiğinde ise Alfonso ve diğerleri (2022) çalışması da Porter beş güç çerçevesine yönelik nitel analizler ortaya koymaktadır.

Literatürde sağlık turizmi sektörü özelinde çok kriterli karar verme yöntemlerini kullanan çalışmalar da mevcuttur. Sektör özelinde çok kriterli karar verme yöntemlerini kullanan çalışmalardan, Aykın ve diğerlerinin (2024) çalışması sağlık turizmi pazarlamasında sosyal medya araçlarının değerlendirilmesine yöneliktir. Yazarlar kriter ağırlıklarını belirlemede güçlü-zayıf yöntemini ve alternatiflerin sıralanmasında birleştirilebilir uzaklık tabanlı değerlendirme yöntemini kullanmışlardır. Bulanık analitik hiyerarşi prosesi yöntemini kullanan Guru ve diğerleri (2023) ve bulanık önem performans analizi yöntemini kullanan Heidary Dahooie ve diğerleri (2024) çalışmaları, hastaların destinasyon seçimine odaklanmaktadır. Yılmaz ve Güneren (2023) sağlık turizmi destinasyonunun rekabet gücünü etkileyen faktörlere odaklanırken, analitik hiyerarşi prosesi, önem performans analizi ve kalite fonksiyon yayılımı yöntemlerini kullanmaktadır. Gökalp (2024) ise sağlık turizmi yatırımlarını etkileyen kriterleri ele alarak sektöre yönelik stratejiler üretmeye odaklanmaktadır. Yazar çalışmada küresel bulanık TOP-DEMATEL yöntemini kullanmaktadır. Sağlık turizminde çok kriterli karar verme tekniklerinin kullanıldığı çalışmaları bibliyometrik yöntemlerle inceleyen Arslan ve Sevim (2022), her ne kadar literatürde hibrit yöntem kullanımları görülebilse de yayımlanan makalelerin büyük çoğunluğunun çok kriterli karar verme yöntemlerini tekil olarak kullandığını ve hibrit kullanımların düşük olduğu bulgularını elde etmişlerdir. Ayrıca yazarlar sağlık turizminde çok kriterli karar verme tekniklerinin kullanıldığı çalışmalarda odaklanılan konuların ise destinasyon seçimi ve sektör gelişimine yönelik strateji seçimine yönelik olduğunu ortaya koymaktadırlar.

Literatür genel hatları ile değerlendirildiğinde, çok kriterli karar verme yöntemlerini kullanan Porter beş güç çerçevesine ilişkin çalışmaların çoğunlukla rekabet stratejisi seçimlerine yönelik olduğu görülmektedir. Sağlık turizmine yönelik Porter beş güç çerçevesini kullanan çalışmaların da nitel analizler ortaya koyduğu görülmektedir. Sağlık turizmi sektöründe Porter beş güç çerçevesini ve çok kriterli karar verme yöntemlerini kullanan çalışma eksikliği bulunmaktadır. Sağlık turizmi sektörü özelinde çok kriterli karar verme tekniklerinin kullanıldığı çalışmaların, daha çok destinasyon seçimine odaklanması ve çok kriterli karar verme yöntemlerini tekil olarak kullanmaları göz önünde bulundurulduğunda, sektördeki işletmelerin yönetimine ilişkin çalışmalara ve çok kriterli karar verme yöntemlerinin hibrit kullanımlarına yönelik boşluk dikkat çekmektedir. Ayrıca literatürde, yönetim araçlarına yönelik çalışmalar da bu araçları tek tek ele almaktadırlar. Spesifik olarak sağlık turizminde yönetim araçlarına odaklanan çalışmalara rastlanmamaktadır. Bununla birlikte yönetim araçlarının grup halinde ele alınarak işletmelerin bu araçlar arasından yapacakları seçimlere yönelik onlara bir alet çantası sunma niteliğine sahip çalışma eksikliği ve ihtiyacı bulunmaktadır.

MATERYAL VE METOT

Bu çalışmanın temel amacı, Porter beş güç çerçevesi analizine dayanarak, işletmeler için en uygun yönetim aracının belirlenmesidir. Bu amaç doğrultusunda, ilk olarak sektörde Porter beş güç çerçevesinin önem ağırlıkları Entropi yöntemi ile belirlenmektedir. Daha sonrasında, güç prensiplerinin ağırlıkları altında, en uygun yönetim aracının belirlenmesi için TOPSIS yöntemi kullanılmaktadır. Söz konusu bu iki yöntem, çok kriterli karar verme teknikleri olup, sayısal ve sayısal olmayan veriler ile analiz sunmasından dolayı tercih edilmektedir.

İşletme yöneticileri için en uygun yönetim aracının seçimi gibi alacakları kararlarda objektif bir yaklaşım sergilenmesi önemlidir. Objektif olmayan yaklaşım ile yapılacak tercihler, uygun olmayan tercihlere yatırım yapılmasına ve dolayısıyla işletmelerde ek maliyetlere ya da kimi zaman zarara neden olabilir. Bu nedenle bu tip kritik kararlarda veriye dayalı analitik bir model tercih edilmelidir. Ancak kriterlerin ya da alternatiflerin seçiminde dikkate alınacak hususların ölçülemediği veya sayısal olarak ifade edilemediği durumlarda istatistik yöntemleri tercih etmek mümkün olmamaktadır. Bu gibi durumlarda en uygun tercihin yapılabilmesi için çok kriterli karar verme yöntemlerine başvurulur. Başka bir ifade ile, çevre analizinden hareketle yönetim araçlarının ağırlıklandırılmasında kullanılan Porter beş güç çerçevesi parametrelerinin sayısal olarak ölçülmesi veya zamana bağlı değerlendirilmesi mümkün olmadığından, çok kriterli karar verme tekniklerine ihtiyaç duyulmaktadır. Yöntemin

uygulanmasıyla elde edilen sonuçlar göz önüne alındığında, sayısal olmayan verilerin kullanılması daha gerçekçi sonuçların elde edilmesine ve uygulamada da karşılık bulabilecek alternatiflerin belirlenmesine olanak sağlamaktadır.

Çok kriterli karar verme tekniklerinin ekonometrik veya istatistik modellere göre üstünlüğü, sayısal olmayan veriler ile de analiz gerçekleştirebilmesidir. Karmaşık problemlerin ele alınabilmesi, modeli diğer modellerden üstün kılmaktadır. Ayrıca, çok kriterli karar verme teknikleri içerisinde Entropi yöntemi, AHP, DEMATEL yöntemleri gibi subjektif değerlendirmeye dayanan modellere göre daha objektif değerlendirme imkânı sunar. Başka bir ifade ile, Entropi yönteminin veriye dayalı bir ağırlıklandırma modeli olması sebebiyle bu yöntemde daha doğru sonuçlar elde edilebilmektedir. Ayrıca, alternatiflerin sıralanması için kullanılan TOPSIS yönteminin diğer sıralama yöntemlerine göre hem pozitif hem de negatif ideallere göre değerlendirme sunması bu yöntemin üstünlüğünü oluşturur. Bir başka yöntem olan VIKOR, sadece tek ideali dikkate alırken, TOPSIS hem pozitif hem negatif ideali dikkate almaktadır.

Bu başlık altında bundan sonraki alt başlıklar ile, Entropi ve TOPSIS yöntemleri detaylandırılmıştır.

Entropi Yöntemi

Entropi, rassal bir değişkenin belirsizliğini ölçmek için kullanılan ve Shannon ile bilgi entropisi ile adlandırılan bir kavramdır. Mühendislik, ver bilimi, fizik, matematik gibi alanlarda sıkça kullanılan Entropi kavramı, çok kriterli karar verme yöntemi olarak da kullanılmaktadır. Söz konusu yöntem, AHP ve DEMATEL gibi yöntemlere göre daha objektif bir yöntem olarak ele alınmaktadır. Bundan dolayı, Entropi yöntemi verileri dikkate alarak kriter ağırlıklarını hesaplaması bakımından diğer yöntemlerden ayrışır (Wang vd., 2022). Entropi yönteminin basamakları aşağıdaki şekilde özetlenebilir.

İlk olarak, karar matrisi normalize edilir. Normalize değerler (p) üzerinden Denklem (1)'deki entropi değeri (E) hesaplanır.

$$E_j = \left(-\frac{1}{\ln(m)} \right) \sum_{i=1}^m (p_{ij} \ln p_{ij}) \quad (1)$$

Burada m, alternatif sayısını ifade eder. P_{ij} , i. alternatifin j. kriterin normalize değeridir. Daha sonra, çeşitlilik derecesi (d) Denklem (2) ile hesaplanır.

$$d_j = 1 - E_j \quad (2)$$

Son olarak, Denklem (3) kullanılarak kriter ağırlıkları (w) belirlenir (Yüksel vd., 2024).

$$w_j = \frac{d_j}{\sum_{j=1}^n d_j} \quad (3)$$

Burada n kriter sayısını gösterir.

TOPSIS Yöntemi

TOPSIS yöntemi, alternatiflerin negatif ve pozitif ideal çözümlere olan Öklid uzaklıklarını dikkate alan çok kriterli karar vermede sıralama yöntemlerindedir. Söz konusu yöntem, negatif idealden uzak, pozitif ideale yakın olan alternatifin belirlenmesinde tercih edilir (Opricovic ve Tzeng, 2004). TOPSIS yönteminin aşamaları aşağıda paylaşılmıştır.

İlk olarak karar matrisi oluşturulur ve normalize edilir. Daha sonra, normalize değerler (r), kriter ağırlıkları (w) ile Denklem (4) yardımıyla çarpılır ve ağırlıklı normalize matris (V) elde edilir.

$$V = W * R \quad (4)$$

Daha sonra pozitif (V^*) ve negatif (V^-) ideal çözümler belirlenir. Burada, fayda kriterleri için en büyük değer pozitif ideal çözüm olurken, en küçük değer negatif ideal olarak dikkate alınır. Ancak, kriter maliyet kriteri ise, kriterin en küçük değeri pozitif ideal çözüm kabul edilirken, en büyük değeri negatif ideal olarak seçilir. İdeal çözümler belirlendikten sonra, her bir alternatifin ideal çözümlere uzaklıkları Denklem (5) ve (6) ile hesaplanır.

$$S_i^* = \sqrt{\sum_{j=1}^m (v_{ij} - v_j^*)^2}, \quad i = 1, 2, \dots, n \quad (5)$$

$$S_i^- = \sqrt{\sum_{j=1}^m (v_{ij} - v_j^-)^2}, \quad i = 1, 2, \dots, n \quad (6)$$

Burada S_i^- , i-inci alternatifin negatif ideale Öklid uzaklığını gösterirken, S_i^* i-inci alternatifin pozitif ideale olan uzaklığını ifade eder. Son olarak, ideal çözüme göreli yakınlık katsayısı (C) Denklem (7) yardımıyla elde edilir.

$$C_i^* = \frac{S_i^-}{S_i^* + S_i^-}, \quad i = 1, 2, \dots, n \quad (7)$$

C değeri büyük olan alternatif en uygun seçim olarak belirlenir (Eti ve Baş, 2023).

BULGULAR

Porter beş güç çerçevesine göre en uygun yönetim stratejisinin belirlenmesine ilişkin analiz sonuçları ve bulgulara yönelik tartışma bu başlık altında sunulmaktadır.

Porter Beş Güç Çerçevesinin Ağırlıklandırılması

Porter beş güç çerçevesi kapsamında önerdiği güçler çalışmada kriter olarak ele alınmıştır. Bunlar, sektördeki rakipler arasındaki rekabetin şiddeti, müşterilerin pazarlık gücü, tedarikçilerin pazarlık gücü, sektöre yeni girebilecek işletmelerin oluşturduğu tehdit ve ikame ürünlerin oluşturduğu tehdit olarak literatürde yer almaktadır. Buna karşın belirlenen alternatif yönetim araçları ise analizde kullanılacak kodlamalar ile birlikte Tablo 1'de sunulmaktadır.

Tablo 1. Yönetim Araçları ve Porter Beş Güç Çerçevesi

Tanımı	Kod
Müşteri deneyimi yönetimi	A1
Kıyaslama (benchmarking)	A2
Değişim yönetimi	A3
Çevik yönetim	A4
Stratejik ortaklık	A5
Esnek çalışma düzenlemeleri	A6
Toplam kalite yönetimi	A7
Yeşil yönetim	A8
İş süreçlerinin yeniden yapılandırılması	A9
Dijital dönüşüm	A10
Sektördeki rakipler arasındaki rekabetin şiddeti	Güç 1
Müşterilerin pazarlık gücü	Güç 2
Tedarikçilerin pazarlık gücü	Güç 3
Sektöre yeni girebilecek işletmelerin oluşturduğu tehdit	Güç 4
İkame ürünlerin oluşturduğu tehdit	Güç 5

Araştırma kapsamında sektör uzmanlarından yönetim araçlarını Porter beş güç çerçevesi açısından değerlendirmeleri istenmiştir. Literatürde, uzman sayısının fazla olmasının karar vericilerin güvenilirliğini düşürdüğü yönünde eleştiriler ve alanda uzman kişiler ile az sayıda görüş elde edilerek kapsayıcı analiz yapılmasına yönelik öneriler yer almaktadır (Bhuiyan vd., 2022; Yüksel ve Dinçer, 2023). Bu doğrultuda üç uzmandan görüş alınmıştır. Görüş alınan uzmanlar için en az 10 yıl sağlık turizmi sektörü deneyimi ve halen devam etmekte bulunan, sağlık aracı firmalarında sahiplik/ortaklık/yöneticilik yapma kriterleri aranmıştır. Görüş alınan ilk uzman, son 14 yılı sağlık turizmi sektöründe olmak üzere 20 yılı aşkın yöneticilik deneyimine sahiptir ve aynı zamanda sektörde faaliyet gösteren orta ölçekli bir firmanın hem %50 ortağı hem genel müdürüdür. Görüş alınan ikinci uzman son 10 yılı sağlık

turizm sektöründe olmak üzere 30 yıllık yöneticilik deneyimine sahip olup, sektörde faaliyet gösteren orta ölçekli ve çok ortaklı bir firmada hisse sahibi ve aynı zamanda yöneticidir. Görüş alınan üçüncü uzman ise sektörde faaliyet gösteren büyük ölçekli ve prestijli bir firmada 10 yılı aşkın süredir üst düzey yöneticilik yapmaktadır.

Uzman değerlendirmeleri 1 en düşük, 9 en yüksek olacak şekilde gerçekleştirilmiştir. Değerlendirme sonuçları Tablo 2’de paylaşılmaktadır.

Tablo 2. Uzman Değerlendirmeleri

Uzman 1					
	Güç 1	Güç 2	Güç 3	Güç 4	Güç 5
A1	9	6	9	9	2
A2	9	9	9	9	2
A3	8	7	7	7	1
A4	2	2	2	2	2
A5	9	9	9	9	2
A6	9	9	8	9	2
A7	8	2	2	9	2
A8	9	9	9	9	2
A9	9	8	4	9	2
A10	9	9	6	9	2

Uzman 2					
	Güç 1	Güç 2	Güç 3	Güç 4	Güç 5
A1	5	8	8	9	4
A2	9	7	7	9	2
A3	7	9	4	8	3
A4	6	5	4	6	2
A5	6	9	4	7	3
A6	9	8	7	9	3
A7	9	8	8	7	4
A8	9	8	7	9	4
A9	9	9	9	8	5
A10	7	5	4	9	3

Uzman 3					
	Güç 1	Güç 2	Güç 3	Güç 4	Güç 5
A1	7	7	8	9	3
A2	9	8	8	9	2
A3	8	8	6	7	2
A4	4	3	4	4	2
A5	8	9	6	8	2
A6	9	8	8	9	2
A7	8	4	3	8	3
A8	9	8	8	9	3
A9	9	8	7	8	3
A10	8	7	5	9	2

Sonraki adımda üç farklı uzmanın değerlendirme sonuçlarının ortalaması alınarak, karar matrisi oluşturulur. Oluşturulan karar matrisi Tablo 3’te paylaşılmıştır.

Daha sonra değerler normalize edilir. Normalize değerlerler üzerinden Denklem (1) yardımıyla kriterlerin entropi değerleri hesaplanır. Daha sonrasında Denklem (2) yardımıyla çeşitlilik dereceleri bulunur. Son olarak, Denklem (3) ile kriterlerin ağırlıkları elde edilir. Entropi, çeşitlilik derecesi ve ağırlık değerleri Tablo 4’te özetlenmiştir.

Tablo 4 incelendiğinde Porter beş güç çerçevesine göre, ağırlık değeri 0,216 ile en büyük olan, sektöre yeni girebilecek işletmelerin oluşturduğu tehdit kriterinin Türkiye bağlamında sağlık turizmi sektöründe en önemli kriter olduğu görülmektedir. Bu kriterin ardından sektördeki rakipler arasındaki rekabetin şiddeti ve müşterilerin pazarlık gücü kriterleri görece yüksek öneme sahiptir. İkame ürünlerin oluşturduğu tehdit ise görece en düşük öneme sahip kriterdir.

Tablo 3. Karar Matrisi

	Güç 1	Güç 2	Güç 3	Güç 4	Güç 5
A1	7,000	7,000	8,333	9,000	3,000
A2	9,000	8,000	8,000	9,000	2,000
A3	7,667	8,000	5,667	7,333	2,000
A4	4,000	3,333	3,333	4,000	2,000
A5	7,667	9,000	6,333	8,000	2,333
A6	9,000	8,333	7,667	9,000	2,333
A7	8,333	4,667	4,333	8,000	3,000
A8	9,000	8,333	8,000	9,000	3,000
A9	9,000	8,333	6,667	8,333	3,333
A10	8,000	7,000	5,000	9,000	2,333

Tablo 4. Kriterlerin Entropi, Çeşitlilik Ve Ağırlık Değerleri

Kriterler	E	d	w
Güç 1	-1,36	2,363	0,214
Güç 2	-1,365	2,3654	0,214
Güç 3	-1,27	2,271	0,206
Güç 4	-1,38	2,380	0,216
Güç 5	-0,66	1,657	0,150

Yönetim Araçlarının Sıralanması

Araştırma modelinin ikinci aşamasında Tablo 1’de yer alan yönetim araçları TOPSIS yöntemi ile sıralanır. Uzmanlardan elde edilen değerlendirmelerin ortalaması ile oluşturulan ve Tablo 3’te verilen karar matrisi ilk olarak normalize edilir ve Tablo 4’teki kriter ağırlıkları ile Denklem (4) yardımıyla çarpılır. Ağırlıklı normalize karar matrisi Tablo 5’te sunulmuştur.

Tablo 5. Ağırlıklı Normalize Karar Matrisi

	Güç 1	Güç 2	Güç 3	Güç 4	Güç 5
A1	0,0592	0,0641	0,0829	0,0749	0,0553
A2	0,0762	0,0732	0,0796	0,0749	0,0368
A3	0,0649	0,0732	0,0564	0,0610	0,0368
A4	0,0339	0,0305	0,0332	0,0333	0,0368
A5	0,0649	0,0824	0,0630	0,0665	0,0430
A6	0,0762	0,0763	0,0763	0,0749	0,0430
A7	0,0705	0,0427	0,0431	0,0665	0,0553
A8	0,0762	0,0763	0,0796	0,0749	0,0553
A9	0,0762	0,0763	0,0663	0,0693	0,0614
A10	0,0677	0,0641	0,0497	0,0749	0,0430

Ağırlıklı normalize karar matrisi oluşturulduktan sonra, her bir Porter çerçevesi güç değeri için pozitif ve negatif ideal çözüm değerleri belirlenir. Daha sonrasında Denklem (5) ve (6) kullanılarak, S* ve S- değerleri hesaplanır. Son olarak, Denklem (7) ile, ideal çözüme göreli yakınlık katsayısı elde edilir. Tüm sonuçlar Tablo 6’da raporlanmıştır.

Tablo 6. S*, S- ve C Değerleri

Yönetim Araçları	S*	S-	C
A1	0,0795	0,0257	0,2442
A2	0,0866	0,0264	0,2338
A3	0,0640	0,0414	0,3926
A4	0,0000	0,0964	1,0000
A5	0,0754	0,0305	0,2881
A6	0,0867	0,0205	0,1914
A7	0,0551	0,0574	0,5101
A8	0,0901	0,0093	0,0933
A9	0,0830	0,0185	0,1824
A10	0,0657	0,0430	0,3954

Tablo 6 incelendiğinde, sektörde Porter beş güç çerçevesi baz alındığında en uygun yönetim aracı, C değerinin en büyük olduğu çevik yönetimdir. Bunu sırasıyla toplam kalite yönetimi, dijital dönüşüm ve değişim yönetimi takip etmektedir. Yeşil yönetim ise uygulamadaki en düşük gerekliliğe sahip yönetim aracı olarak öne çıkmaktadır. Yeşil yönetim ise iş süreçlerinin yeniden yapılandırılması takip etmektedir.

TARTIŞMA

Araştırma bulguları sırasıyla sektöre yeni girebilecek işletmelerin oluşturduğu tehdit, rakipler arasındaki rekabetin şiddeti ve müşterilerin pazarlık gücü kriterlerinin yüksek öneme sahip olduğunu ortaya koymaktadır. Sağlık turizmi sektörüne yönelik, Yunanistan bağlamında yürütülen ve Porter beş güç çerçevesini kullanan Tsekouropoulos ve diğerlerinin (2023) çalışması, sağlık turizminin Yunanistan için henüz yeni bir sektör olduğuna da vurgu yaparak, sektöre yeni girebilecek işletmelerin oluşturduğu tehdidinin öne çıktığı çıkarımında bulunmaktadır. Yazarlar Yunanistan özelinde henüz sektöre yönelik standartları ve sertifikasyon kriterlerini belirleyen kapsamlı bir yasal düzenleyici çerçevenin bulunmamasının sektöre girişler için fırsat oluşturduğunu belirtmektedirler. Ayrıca çevrimiçi pazarlama kanallarına erişimin kolaylığı nedeniyle rakipler arasındaki rekabetin şiddetinin de yüksek olduğu çıkarımlarında bulunmaktadır. Bu yönleriyle değerlendirildiğinde, Türkiye ve Yunanistan bağlamında sektörün benzerlik gösterdiği söylenebilir.

Tayland'da dental turizm sektörüne yönelik yürütülen bir başka araştırmada, Porter beş güç çerçevesini kullanılarak yapılan analizlere göre sektörde rakipler arasındaki rekabet ve yeni girenlerin oluşturduğu tehdit güçlüdür (Chongthanavanit, 2020). Tedarikçi sayısı ve tedarikçilerin verimliliği nedeniyle tedarikçilerin gücü düşüktür. Farklı ülkede hizmet alımına yönelik ilk tedavi planının değiştirme maliyetlerinin yüksek olması nedeniyle müşterilerin pazarlık gücü düşüktür. İkame hizmet tehdidi de düşüktür. Chongthanavanit (2020) araştırması sonuçları bu araştırma sonuçları ile birlikte değerlendirildiğinde Tayland ve Türkiye bağlamında sektörlerin benzerlik gösterdiği fakat müşterilerin pazarlık gücünün Türkiye'de görece daha yüksek olduğu çıkarımında bulunulabilir.

Alfonso ve diğerleri (2022) tarafından Kolombiya sağlık turizmi sektörüne yönelik Porter beş güç çerçevesi kullanılarak yapılan analiz sonuçları, Türkiye bağlamında yürütülen bu araştırma sonuçlarından farklı olarak Kolombiya'da uluslararası sertifikasyon süreci gerekliliği ve bunun getirdiği ek mali külfet nedeniyle sektöre giriş engellerinin yüksek olduğuna ve bu nedenle yeni girebilecek işletmelerin oluşturduğu tehdidin yanı sıra rekabet şiddetinin de düşük olduğuna işaret etmektedir. Literatür sağlık turizmi sektörü açısından değerlendirildiğinde, ikame ürünlerin oluşturduğu tehdidin ve tedarikçilerin pazarlık güçlerinin düşük olduğu söylenebilir. Porter beş güç çerçevesinde yer alan, sektöre yeni girenlerin oluşturduğu tehdit ve rekabetin şiddetinin gücünün ise ülkelerin sektöre girişlerdeki mevzuatsal düzenlemelerinin katılığına bağlı olarak ülkeler bazında değişken olduğu çıkarımında bulunulabilir.

Yönetim araçlarına ilişkin çalışmalardan ise, Hırvatistan bağlamında halk sağlığı sistemi üzerine yapılan bir araştırma sonucunda çevik yönetim modeli önerilmesi (Sipina, 2016) bu araştırma sonuçları ile benzerlik göstermektedir. Kostadinova ve Katsarova (2019) çalışması ise sağlık turizmi sektörüne yönelik olup, bu araştırmadaki görece düşük öneme sahip olmasından farklı olarak, değer zincirinde yer alan farklı paydaşlar arasındaki iş birliği ve ortaklıkların önemine vurgu yapmaktadır. Aynı araştırmadaki dijital stratejilerin tasarımına önem verilmesi ve böylelikle teknoloji bağımlısı kuşağa yönelik pazarlama girişimleri vurgusu (Kostadinova ve Katsarova, 2019) ise bu araştırmadaki dijital dönüşüm yönetim aracının yüksek önemi ile benzeşmektedir.

Slovakya bağlamında geniş çerçevede turizm sektörü üzerine yürütülen araştırmalardan Gallo ve diğerleri (2021), sektörde faaliyet gösteren işletmelerde modern yönetim yöntem ve araçları kullanılarak işletme yönetiminin etkinliğinin artırılması konusunu ele aldıkları çalışmada, bu araştırmadaki görece düşük tercih gücüne sahip bir yönetim aracı olan kıyaslamanın (benchmarking), zorlu ve çalkantılı iş ortamında başarılı olma olasılığını arttırdığını öne sürmektedirler. Yazarlar, bu araştırmanın bakışına paralel olarak, işletmelerin yönetiminde sadece finansal göstergeler değil, finansal olmayan teknikler olarak modern yönetim araçlarının önemine dikkat çekmektedirler. Benzer bir diğer araştırmada ise toplam kalite yönetiminin bu araştırmadaki yüksek uygunluk derecesini doğrulayan sonuçlar elde edilmiştir (Dobrovič vd., 2019). Dobrovič ve diğerleri (2019), sektörde toplam kalite yönetimi uygulamalarının az ve yetersiz kullanıldığına dikkat çekerek, araştırma bulgusu olarak bu yönetim aracını, kurumsal performansın yalnızca finansal değil aynı zamanda finansal olmayan yönlerini de değerlendiren modern, yenilikçi bir yönetim aracı olarak sunmaktadır. Geniş çerçevede turizm sektörüne odaklanan ve bu araştırma sonuçlarına paralel bulgular elde eden bir başka çalışmada, Çekya bağlamında işletmelerde yönetim aracı olarak kalite yönetim

sistemi uygulamalarının, müşterilere yönelik olumlu ve duyarlı bir adım olduğu kadar rekabet gücünü artırmada da etkili bir araç olarak değerlendirilebileceği sonuçları elde edilmiştir (Jana, 2021).

Turizm sektörüne odaklanan Klein ve Dodds (2018) ise Kanada'nın Ontario şehri bağlamında çevresel sürdürülebilirliğe yönelik mavi bayrak uygulaması ve sertifikasyon sisteminin turizm firmaları arasında, bir çevre yönetimi veya koruma aracı olmaktan çok, turizm tanıtım aracı olarak algılandığını göstermektedir. Bu araştırma sonuçlarında da yeşil yönetim aracının görece olarak uygunluk derecesi en düşüktür. Çok kriterli karar verme yöntemleri metodolojisine sahip bu çalışmada elde edilen bu sonuç, Porter beş güç çerçevesinde ele alınan sektörde, yeşil yönetim modelinin bir farklılık oluşturmayacağı ya da işletmelere bir avantaj sağlamayacağı şeklinde yorumlanabilir. Bu da sektörde çevresel sürdürülebilirliğe yönelik mevzuatların azlığına ya da yokluğuna, bununla birlikte çevresel sürdürülebilirliğe ilişkin bilincin oluşmamış olmasına işaret etmektedir. Türkiye bağlamında tekstil sektörü üzerine yapılan bir çalışmada Yorulmaz (2023) tarafından çok kriterli karar verme yöntemleri kullanılarak işletmelerin yeşil yönetim araçlarına yönelik motivasyonları ölçülmüş ve işletme yöneticilerinin çevre bilincinin en güçlü motivasyon olduğu bulguları elde edilmiştir. Tüm bu değerlendirmeler ışığında, işletmeleri çevresel sürdürülebilirlik tabanlı yeşil yönetim aracı gibi uygulamaları tercih etmelerinde, işletmelere avantaj sağlayacak faktörlerin varlığı, mevzuatsal zorunluluklar ya da bunların olmadığı durumlarda işletme yöneticilerinin çevresel sürdürülebilirliğe yönelik bilinç ve farkındalığının gerektiği çıkarımında bulunulabilir.

SONUÇLAR

Küreselleşmenin yapılandığı modern dünyada işletmelerin rekabet avantajı elde etmesine yardımcı olmak için uygulanan rekabet stratejilerine ek olarak bir dizi yönetim aracı da kullanılmaktadır. Yönetim araçları organizasyonel performansı iyileştirmeye yöneliktir. Yönetim araçlarındaki trendler ise kimi zaman yöneticilerin modaya kapılarak hatalı araçları kullanmasına ve şüpheli ya da olumsuz sonuçlarla karşılaşmalarına neden olabilmektedir. Bu çalışma ile bu araçları denemek için zamanları ve kaynakları yetersiz olan işletmeler için araç seçimi konusunda yol gösterici olacak bir dizi ampirik yöntem önerilmektedir. Araştırma özgün bir yaklaşımla sektör analizi ile doğru yönetim aracı seçimi problemini birleştirmektedir. Araştırmada çok kriterli karar verme yöntemleri ile Porter beş güç çerçevesine dayanan sektör analizi yapılmakta ve ardından yönetim araçları havuzu içerisinde araçlar uygunluklarına göre sıralanmaktadır. Bu yöntemin uygulanması ile işletmeler, kısıtlı zaman ve kaynaklarını sektör özelliklerine en uygun araçları tercih ederek verimli kullanabilirler. Çoğunlukla birden fazla yönetim aracı seçimi yapan işletmeler de uygunluk seviyeleri belirlenen yöntemler arasından tercihler yapabilirler.

Araştırma modeli sağlık turizmi sektöründe faaliyet gösteren sağlık aracı işletmeleri özelinde uygulanmıştır. Sektör analizine yönelik sonuçlar, sektöre yeni girebilecek işletmelerin varlığının oluşturduğu tehdidin en güçlü kriter olduğuna işaret etmektedir. Sektördeki rakipler arasındaki rekabetin şiddeti ve müşterilerin pazarlık gücü kriterlerinin de önem dereceleri yüksekken, sektörde ikame ürünlerin oluşturduğu tehdit görece en düşük güce sahip kriterdir. Sektöre girişlerin kolay olması değerlendirildiğinde, alandaki mevzuatların yumuşak olması, denetimin zayıf olması ve buna dayanarak yetkisiz işletmelerin sektördeki varlıkları ve sektöre rahatlıkla girebilmeleri çıkarımında bulunulabilir. Sektöre yönelik araştırmalarla bu çıkarımlara yönelik ampirik kanıtlar sunulması sektöre yönelik düzenlemeler için faydalı olabilir. Ayrıca sektöre girişlerin kolay olması sektördeki işletme sayılarında artışı beraberinde getirmekte olduğu ve işletme sayılarının artmasının da müşterilerin pazarlık gücünü arttırdığı çıkarımında bulunulabilir.

Yönetim araç tercihine yönelik sonuçlar sırasıyla çevik yönetim, toplam kalite yönetimi, dijital dönüşüm ve değişim yönetimi araçlarının sektör özelliklerine göre yüksek uygunluk değerine sahip olduğuna işaret etmektedir. Bulgular rekabetin şiddetli olduğu ve müşterilerin pazarlık güçlerinin yüksek olduğu bir ortamla uyumlu olup, şiddetli rekabetin üstesinden gelinmesine ve müşteri değeri oluşturulmasına yönelik araçlardır. Sektörün, müşteri taleplerine anında cevap verilmesini gerektiren, kalitenin ön planda olduğu, dijital teknolojilerin yoğun kullanıldığı ve değişime hızlı yanıt gerektiren yapıda olduğu çıkarımında bulunulabilir. Çevik yönetim, sektörün özelliği olan hızlı değişen müşteri beklentileri, talepleri ve şiddetli rekabet karşısında, aynı hızla aksiyon alınabilmesi ve uyum sağlanabilmesi için, organizasyonun yatay kurgulanarak kendi kendini yöneten küçük çapraz-fonksiyonel takımlar, sık aralıklarla toplantılar ve geriye dönük değerlendirmeler, takım üyelerinin tüm süreçlere katılımı, müşterilerle iş birliği yapılması ve planlarda ısrarcı olmak yerine değişime hızlı biçimde yanıt verilebilmesi gibi uygulamaları içermektedir. Toplam kalite yönetimi müşteri ihtiyaçlarının karşılanabilmesi için tüm çalışanların katkı sunarak, insan, iş ve hizmet kalite gereksinimlerinin sistematik biçimde karşılanmasına yöneliktir. Dijital dönüşüm, üstün müşteri deneyimleri yaratabilecek ve temel işi güçlendirebilecek dijital teknolojilerin kuruluşun stratejisine ve operasyonlarına entegre edilmesi ile ilgilidir. Değişim yönetimi ise dış çevrede meydana gelen sosyal, politik, hukuki, ekonomik, teknolojik

ve kültürel alanlardaki ani değişimlere uyum sağlayabilmek için içsel değişiklikler ve düzenlemeler yapılmasına yöneliktir.

Önerilen model her ne kadar sağlık turizmi sektöründe faaliyet gösteren sağlık aracı işletmeleri özelinde uygulanmış olsa da bulgular beş güç analizi bağlamında benzerlik gösteren sağlık turizmi dışındaki diğer sektörlerde de uygulanabilir. Bunun için işletme yöneticileri tarafından bu araştırmada önerilen matematiksel model haricinde nitel ya da nicel yöntemlerle yapılan beş güç analizleri kullanılabilir. Ayrıca optimum yönetim araçlarına ilişkin sıralama, sağlık turizmi sektöründen farklı dinamiklere sahip olan kimi sektörler için de geçerli olabilir. Bunun için detaylı adımları sunulan matematiksel model farklı sektörler için uygulanabilir. Porter beş güç analizi tüm sektörler için geçerlidir, uygulanabilir ve yönetim araçları da dünya genelinde teorik ve pratik anlamda geniş çevrelerce kabul görmektedir. Sonuçlar, çevre analizi uyarınca mevcut araç seti içerisindeki optimum araçların sıralamasını göstermekte olup, düşük sıralamaya sahip yönetim araçlarının uygunsuz olduğu anlamını taşımayabilir. Örneğin, düşük sıralamaya sahip yeşil yönetim günün koşullarında sektördeki işletmeler için optimum seçenek olmamakta fakat bu konuda uygulamaya koyulacak bir mevzuat ile en optimum seçenek haline gelebilir. Dolayısıyla bu durumda bugünün koşullarında optimum olmayan bu yönetim aracını uygulamakta olan işletmeler avantajlı konuma gelebilir.

Araştırma modelinin uygulanmasında belirli bir sektörün seçimi araştırmanın sınırlılıkları arasında sayılabilir. Yönetim araçları, işletmelerin performansını arttırabilecek, işletmelere ve tüm paydaşlara iyileştirmeler getirebilecek güce sahiptir. Araştırma modelinin diğer sektörlerde de uygulanması ve yaygınlaştırılmasını önermekteyiz. Sonraki çalışmalar için yönetim araçları havuzunun genişletilerek uygulanması, tercih yapacak işletmeler için alternatiflerin değerlendirilmesinde yararlı olabilir. Ayrıca çevresel sürdürülebilirliğin önemini arttırdığı günümüzde, yeşil yönetim modelinin sektöre uygunluk derecesinin düşük olmasına ilişkin bulgulara dayanan, sektörde çevresel sürdürülebilirliğe ilişkin mevzuatların ya da yöneticilerdeki bilincin muhtemel eksikliğine dair çıkarımlar, bu konudaki ileri araştırmalar için ipuçları sunmaktadır.

KAYNAKLAR

- Abbas, J. (2020). Impact of total quality management on corporate sustainability through the mediating effect of knowledge management. *Journal of Cleaner Production*, 244, 118806. <https://doi.org/10.1016/j.jclepro.2019.118806>
- Alfonso, G. M. J., Jorge, S. M., and Orlando, G. M. J. (2022). Health Tourism: An Economic Alternative For Norte De Santander. *Journal of Language and Linguistic Studies*, 18(2).
- Arslan, D., & Sevim, E. (2022). Multi-Criteria Decision-Making Techniques in Medical Tourism Studies: A Systematic Review. *Süleyman Demirel Üniversitesi Vizyoner Dergisi*, 13(36), 1305-1317.
- Aydın, Ş. N. ve Özbek, A. (2024). Porter'ın beş güç modeli'ne göre jenerik rekabet stratejisi seçimi: AHP, WASPAS ve EDAS yöntemleri ile bir uygulama. *International Journal of Engineering Research and Development*, 16(1), 74-92. <https://doi.org/10.29137/umagd.1299126>
- Aydin, G., and Karamehmet, B. (2017). Factors affecting health tourism and international health-care facility choice. *International Journal of Pharmaceutical and Healthcare Marketing*, 11(1), 16-36. <https://doi.org/10.1108/IJPHM-05-2015-0018>
- Aykın, Ö., Karaman, D., & Aydoğmuş, H. Y. (2024). Evaluation of social media tools in health tourism marketing with multi criteria decision making methods. *Uluslararası Yönetim Akademisi Dergisi*, 7(1), 183-202.
- Bhuiyan, M. A., Dinçer, H., Yüksel, S., Mikhaylov, A., Danish, M. S. S., Pinter, G., ... and Stepanova, D. (2022). Economic indicators and bioenergy supply in developed economies: QROF-DEMATEL and random forest models. *Energy Reports*, 8, 561-570. <https://doi.org/10.1016/j.egy.2021.11.278>
- Bican, P. M., and Brem, A. (2020). Digital business model, digital transformation, digital entrepreneurship: Is there a sustainable "digital"? *Sustainability*, 12(13), 5239. <https://doi.org/10.3390/su12135239>
- Biswas, P., and Niyogi, J. G. (2024). Analysing the competitiveness of industries using the Analytical Hierarchy Process and Porter's model: A case of Durgapur city. *Upravlenets / The Manager*, 15(1), 55-69. <https://doi.org/10.29141/2218-5003-2024-15-1-4>
- Cambalikova, A. (2021). Modern trends in business management in the light of globalization. In SHS Web of Conferences, 92, 02009, *EDP Sciences*. <https://doi.org/10.1051/shsconf/20219202009>

- Chongthanavanit, P. (2020). *Development of marketing communication strategy for branding in the dental tourism industry in Thailand*. Ph.D. Thesis, University of the Thai Chamber of Commerce, Thailand.
- Dağdeviren, M., Yüksel, İ. (2010). A fuzzy analytic network process (ANP) model for measurement of the sectoral competitiveness level (SCL). *Expert Systems with Applications*, 37(2), 1005-1014. <https://doi.org/10.1016/j.eswa.2009.05.074>
- Dobrovič, J., Kmeco, L., Gallo, P., and Gallo Jr, P. (2019). Implications of the Model EFQM as a strategic management tool in practice: a case of Slovak tourism sector. *Journal of Tourism and Services*, 10(18), 47-62. <https://doi.org/10.29036/jots.v10i18.91>
- Drinkert, A., and Singh, N. (2017). An investigation of American medical tourists' posttravel experience. *Journal of Hospitality Marketing & Management*, 26(3):335-346. <https://doi.org/10.1080/19368623.2017.1241199>
- Eti, S., and Baş, H. (2023). Determining the social exclusion levels of international students from different regions using the MAIRCA and TOPSIS method. *Globalisation, Societies and Education*, 1-20. <https://doi.org/10.1080/14767724.2023.2272168>
- Gallo, P., Dobrovič, J., Čabinová, V., Pártlová, P., Straková, J., and Mihalčová, B. (2021). Increasing the efficiency of enterprises in tourism sector using innovative management methods and tools. *Social Sciences*, 10(4), 132. <https://doi.org/10.3390/socsci10040132>
- Gareta, S., Bakama, E. M., Mukwakungu, C. M., and Sukdeo, N. (2020). The use of benchmarking as a management tool for organisational effectiveness in South Africa: A focus on small to medium enterprises. In *2020 IEEE International Conference on Technology Management, Operations and Decisions (ICTMOD)* (pp.1-6).IEEE. <https://doi.org/10.1109/ICTMOD49425.2020.9380620>
- Gökalp, Y. (2024). Sağlık turizmi yatırımlarının etkinliğinin artırılmasına yönelik öncelikli stratejilerin küresel bulanık top-dematel yöntemiyle belirlenmesi. *Dokuz Eylül Üniversitesi İşletme Fakültesi Dergisi*, 25(1), 1-15.
- Guru, S., Sinha, A., & Kautish, P. (2023). Determinants of medical tourism: Application of fuzzy analytical hierarchical process. *International Journal of Emerging Markets*, 18(11), 4819-4842.
- Harika, A., Sunil Kumar, M., Anantha Natarajan, V., and Kallam, S. (2021). Business process reengineering: issues and challenges. In *Proceedings of Second International Conference on Smart Energy and Communication: ICSEC 2020* (pp. 363-382). Springer Singapore. https://doi.org/10.1007/978-981-15-6707-0_35
- Heidary Dahooie, J., Estiri, M., & Shahinpour, S. (2024). Policy framework for selecting medical tourism destinations: fuzzy-IPA approach. *Anatolia*, 35(3), 439-456.
- Jana, N. (2021). Quality Management as a Tool to Ensure the Competitiveness of Tourism Service Providers. *Economics Working Papers*, 5(4), 5-59.
- Kaçamak, H. ve Uygun, Ö. (2022). Yeşil yönetim modeli önerisi. *Sürdürülebilir Çevre Dergisi*, 2(2), 12-17.
- Klein, L., and Dodds, R. (2018). Blue Flag beach certification: an environmental management tool or tourism promotional tool?. *Tourism Recreation Research*, 43(1), 39-51. <https://doi.org/10.1080/02508281.2017.1356984>
- Knott, P. J. (2006). A typology of strategy tool applications. *Management Decision*, 44(8), 1090-1105. <https://doi.org/10.1108/00251740610690630>
- Koseoglu, M. A., Tetteh, I. L., and King, B. (2019). Decision tools: A systematic literature review, co-citation analysis and future research directions. *Nankai Business Review International*, 10(4), 591-617. <https://doi.org/10.1108/NBRI-07-2018-0045>
- Kostadinova, T., and Katsarova, S. (2019). The importance of the European health tourism for the development of economy of wellbeing. In *4th International Thematic Monograph: Modern Management Tools and Economy of Tourism Sector in Present Era*, Belgrade. <https://doi.org/10.31410/tmt.2019.527>
- Königer, J. K., and Gouthier, M. H. (2024). Successful implementation of customer experience strategy: determinants and results. *Journal of Service Management*, Vol. ahead-of-print No. ahead-of-print. <https://doi.org/10.1108/JOSM-10-2023-0431>

- Lesnikova, P. Schmidtova, J., and Cichocka, I. (2023). Strategy formulation activities with emphasis on strategic management tools and techniques in Slovak companies. *Problems and Perspectives in Management*, 21(3), 54-68. [http://dx.doi.org/10.21511/ppm.21\(3\).2023.05](http://dx.doi.org/10.21511/ppm.21(3).2023.05)
- Ochuba, N. A., Okafor, E. S., Akinrinola, O., Usman, F. O., and Amoo, O. O. (2024). Strategic partnerships in the satellite and telecommunications sectors: a conceptual review of data analytics-enabled identification and capitalization of synergies. *Engineering Science & Technology Journal*, 5(3), 716-727. <https://doi.org/10.51594/estj.v5i3.867>
- Olutimehin, D. O., Ofodile, O. C., Ejibe, I., and Oyewole, A. (2024). Developing a strategic partnership model for enhanced performance in emerging markets. *International Journal of Management & Entrepreneurship Research*, 6(3), 806-814. <https://doi.org/10.51594/ijmer.v6i3.937>
- Opricovic, S. and Tzeng, G. H. (2004). Compromise solution by MCDM methods: A comparative analysis of VIKOR and TOPSIS. *European Journal of Operational Research*, 156(2), 445-455. [https://doi.org/10.1016/S0377-2217\(03\)00020-1](https://doi.org/10.1016/S0377-2217(03)00020-1)
- Öğüt, K., Yeşilyurt, S. ve Yurtseven, Ç. (2018). Kazakistan-Türkiye Sağlık Turizmi: Sağlık Sektörlerine Bakış ve Potansiyeller 1, 2 [Health Tourism between Kazakhstan and Turkey: Outlook on Health Sectors and Potentials]. *Business and Economics Research Journal*, 9(1):57-74. <https://doi.org/10.20409/berj.2018.93>
- Özdemirci, F., Yüksel, S., Dinçer, H., and Eti, S. (2023). An assessment of alternative social banking systems using T-Spherical fuzzy TOP-DEMATEL approach. *Decision Analytics Journal*, 6, 100184, 2023. <https://doi.org/10.1016/j.dajour.2023.100184>
- Paksoy, T., Gunduz, M. A., and Demir, S. (2023). Overall competitiveness efficiency: A quantitative approach to the five forces model. *Computers & Industrial Engineering*, 182, 109422. <https://doi.org/10.1016/j.cie.2023.109422>
- Pangarkar, N., and Prabhudesai, R. (2024). Using Porter's Five Forces analysis to drive strategy. *Global Business and Organizational Excellence*, 43(5), 24-34. <https://doi.org/10.1002/joe.22250>
- Phillips, J., and Klein, J. D. (2023). Change management: from theory to practice. *TechTrends*, 67(1), 189-197. <https://doi.org/10.1007/s11528-022-00775-0>
- Porter, M. E. (1979). How Competitive forces shape strategy. *Harvard Business Review*, 2 (March-April).
- Porter, M. E. (1980). *Competitive Strategy: Techniques for Analyzing Industries and Competitors*. New York, NY, USA: The Free Press.
- Porter, M. E. (2008). The five competitive forces that shape strategy. *Harvard Business Review*, 86(1): 25-40.
- Rigby, D. K. (2001). Putting tools to the test: senior executives rate 25 top management tools. *Strategy & Leadership*, 29(3), 4-12. <https://doi.org/10.1108/10878570110396086>
- Rigby, D. K., Bilodeau, B., and Ronan, K. (2023). Management tools & trends 2023, Bain & Company. <https://www.bain.com/insights/management-tools-and-trends-2023/> Erişim: 15 Ağustos 2024.
- Rudnichenko, Y., Liubokhynets, L., Havlovska, N., Illiashenko, O., and Avanesova, N. (2021). Qualitative justification of strategic management decisions in choosing agile management methodologies. *International Journal for Quality Research*, 15(1), 209. <https://doi.org/10.24874/IJQR15.01-12>
- Sarantopoulos, I., Katsoni, V., and Geitona, M. (2014). Medical tourism and the role of e-medical tourism intermediaries in Greece. *Tourismos*, 9(2), 129-145. <https://doi.org/10.26215/tourismos.v9i2.412>
- Sevim, F., and Kurtaran, A. T. (2023). Evaluation of Turkey's Health Tourism Performance with the MOORA Method. *Gümüşhane Üniversitesi Sosyal Bilimler Dergisi*, 14(1), 99-109. <https://doi.org/10.36362/gumus.1128042>
- Sipina, N. (2016). Croatian Public Health Governance Model Improvement. *ENTRENOVA-ENTERPRISE RESEARCH INNOVATION*, 2(1), 177-184.
- Tanrıverdi, G., and Lezki, Ş. (2021). Istanbul Airport (IGA) and quest of best competitive strategy for air cargo carriers in new competition environment: A fuzzy multi-criteria approach. *Journal of Air Transport Management*, 95, 102088. <https://doi.org/10.1016/j.jairtraman.2021.102088>

- Tsekouropoulos, G., Vasileiou, A., Hoxha, H., Dimitriadis, A., and Zervas, I. (2023). Sustainable Approaches to Medical Tourism: Strategies for Central Macedonia/Greece. *Sustainability*, 16(1), 121. <https://doi.org/10.3390/su16010121>
- Turner, L. (2012). Canada's turbulent medical tourism industry. *Canadian Family Physicians*, 58(2), 371-373.
- Vaska, S., Massaro, M., Bagarotto, E. M., and Dal Mas, F. (2021). The digital transformation of business model innovation: A structured literature review. *Frontiers in Psychology*, 11, 539363. <https://doi.org/10.3389/fpsyg.2020.539363>
- Wang, C. N., Le, T. Q., Chang, K. H., and Dang, T. T. (2022). Measuring road transport sustainability using MCDM-based entropy objective weighting method. *Symmetry*, 14(5), 1033. <https://doi.org/10.3390/sym14051033>
- Yilmaz, V., & Güneren, E. (2023). Determining destination competitiveness in medical tourism: A study based on AHP-QFD framework. *Journal of multidisciplinary academic tourism*, 8(2), 141-157.
- Yorulmaz, H. (2023). Tekstil KOBİ'leri Bağlamında Yeşil İşletme Stratejisi Motivasyonlarının AHP Yöntemiyle Önceliklendirilmesi. *Sosyal Mucit Academic Review*, 4(4), 477-502. <https://doi.org/10.54733/smar.1370063>
- Yorulmaz, H., Baykal, E., and Eti, S. (2023). Effects of teleworking and strategic orientations on resilience in the post-pandemic period. *OPUS Journal of Society Research*, 20(51), 30-42. <https://doi.org/10.26466/opusjsr.1207071>
- Yüksel, S. and Dinçer, H. (2023). Sustainability analysis of digital transformation and circular industrialization with quantum spherical fuzzy modeling and golden cuts. *Applied Soft Computing*, 138, 110192. <https://doi.org/10.1016/j.asoc.2023.110192>
- Yüksel, S., Eti, S., Dinçer, H., and Gökalp, Y. (2024). Comprehensive risk analysis and decision-making model for hydroelectricity energy investments. *Journal of Soft Computing and Decision Analytics*, 2(1), 28-38. <https://doi.org/10.31181/jsdda21202421>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 06.09.2024
Kabul Tarihi : 07.10.2024

Received Date : 06.09.2024
Accepted Date : 07.10.2024

EVALUATION OF THE VESSEL WITH DIFFERENT STENOSIS STRUCTURES USING CFD APPROACH

FARKLI DARLIK YAPILARINA SAHİP DAMARIN HAD YAKLAŞIMI KULLANILARAK DEĞERLENDİRİLMESİ

Arif ÇUTAY^{1*} (ORCID: 0000-0002-0057-9417)
Özdeş ÇERMİK¹ (ORCID: 0000-0001-9308-4589)
Ahmet KAYA¹ (ORCID: 0000-0001-9197-3542)

¹ Kahramanmaraş Sütçü İmam University, Department of Mechanical Engineering, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: Arif ÇUTAY, arif.cutay@gmail.com

ABSTRACT

Stenosis of blood vessels is a common cardiovascular issue, and numerical simulation provides an accessible alternative to experimental studies. This study utilizes computational fluid dynamics (CFD) to simulate blood flow dynamics in stenotic vessels with varying dimensions and viscosity models, offering insights into how blood behaves under different conditions. Validation, conducted by comparing results with experimental data in the post-stenotic region, shows acceptable differences. Nine stenosis models were analyzed by altering stenosis length (from 13.75 mm to 27.5 mm) and height (from 2.2 mm to 4.4 mm) while testing three viscosity models: Newtonian, Power Law, and Carreau Law. Key variables such as wall shear stress (WSS), pressure drop, and maximum throat velocity were determined, and recirculation zones and streamline contours were observed. The results indicate that small changes in stenosis dimensions significantly impact flow dynamics. While Newtonian and Power Law models produce similar outcomes, different viscosity models alter flow results. Carreau Law shows maximum WSS values between 25 Pa and 125 Pa, compared to 1.5 to 10 Pa for the Newtonian and Power Law models under the same conditions.

Key Words: Blood flow dynamics, computational fluid dynamics, CFD non-Newtonian flow, wall shear stress, stenosis

ÖZET

Kan damarlarındaki stenoz, yaygın bir kardiyovasküler sorundur ve sayısal simülasyon, deneysel çalışmalara karşı erişilebilir bir alternatif sunar. Bu çalışma, hesaplamalı akışkanlar dinamiği (HAD) kullanarak farklı boyutlara ve viskozite modellerine sahip stenozlu damarlardaki kan akış dinamiklerini simüle etmektedir ve bu, kanın farklı koşullar altında nasıl davrandığına dair önemli bilgiler sağlamaktadır. Stenoz sonrası bölgedeki deneysel verilerle yapılan karşılaştırmalar sonucunda doğrulama, kabul edilebilir farklılıklar göstermektedir. Stenoz uzunluğu (13.75 mm'den 27.5 mm'ye) ve yüksekliği (2.2 mm'den 4.4 mm'ye) değiştirilerek dokuz farklı stenoz modeli analiz edilmiş ve üç viskozite modeli (Newtonian, Power Law, Carreau Yasası) test edilmiştir. Temel değişkenler olan duvar kayma gerilimi (WSS), basınç düşüşü ve maksimum boğaz hızı belirlendi ve resirkülasyon bölgeleri ile akım çizgileri kontrolü gözlemlendi. Sonuçlar, stenoz boyutlarındaki küçük değişikliklerin akış dinamiklerini önemli ölçüde etkilediğini göstermektedir. Newtonian ve Power Law modelleri benzer sonuçlar üretirken, farklı viskozite modelleri akış sonuçlarını değiştirmektedir. Carreau Law Modeli, maksimum WSS değerlerini 25 Pa ile 125 Pa arasında gösterirken, Newtonian ve Power Law modelleri aynı koşullar altında 1.5 ile 10 Pa arasında değerler göstermektedir.

Anahtar Kelimeler: Kan akış dinamikleri, hesaplamalı akışkanlar dinamiği, HAD, Newtoniyen olmayan akış, duvar kayma gerilimi, stenoz

INTRODUCTION

ToCite: ÇUTAY, A., ÇERMİK, Ö., KAYA, A. (2025). EVALUATION OF THE VESSEL WITH DIFFERENT STENOSIS STRUCTURES USING CFD APPROACH. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 245-257.

The blood vessel is one of the fundamental components of the cardiovascular system, along with the heart and blood. The occlusion of a blood vessel, called “stenosis,” distorts this system, which is a frequent medical issue. It can become a life-threatening condition when the occlusion rate exceeds the cardiovascular system's tolerance. Computational fluid dynamics (CFD) has a broad range of applications, including hemodynamic flows. CFD can provide a powerful contribution to estimating stenosis severity by giving insights into the flow properties of the narrowed vascular area. It is well known that CFD has been utilized by several researchers for simulating blood flow to aid in diagnosing and treating vascular problems. Many studies state that local hemodynamic results can assist in assessing the degree of stenosis (Zarins et al., 1983; Davies et al., 1986; Shaaban and Duerinckx, 2000). Wall shear stress (WSS) is closely related to the assessment of local hemodynamics due to the nature of fluid dynamics. While regions with low shear stress contribute to the formation and progression of stenosis, due to the increased residence time of lipid particles (Malek et al., 1999; Soulis et al., 2006), high WSS is associated with a higher risk of vascular wall rupture, platelet aggregation, or the progression of stenosis (Dolan et al., 2013; Kumar et al., 2021). The velocity profile of stenosis can be an effective tool for understanding the characteristics of stenosis. The recirculation zone in the post-stenotic region is inherently associated with severe stenosis and can also serve as a predictive parameter for the progression of stenosis. Additionally, increased or decreased velocity is a crucial measurement for evaluating the percentage occlusion of stenosis. The pressure drop is another flow dynamic property that is a decisive factor in maintaining flow without varying the flow rate. For this reason, heart function is strongly correlated with pressure drop, as the heart acts as a biological pump to deliver the necessary blood for the body's vital needs.

Numerous studies on hemodynamics utilize the CFD approach. Some of these studies are discussed in the following section. Razavi et al. numerically investigated different stenosis forms under pulsatile flow conditions using various viscosity models (Razavi et al., 2021). Their studies focused on 30-60% occlusion in symmetric stenosis in the carotid artery. It was shown that while viscosity models had similar trends, they differed in magnitude. They concluded that the narrowing of the blood flow area resulted in a larger recirculation zone and disturbed radial velocity profiles (Samady et al., 2011). Chan et al. conducted a numerical study on non-Newtonian blood flow in an axisymmetric stenosis model. They included elastic wall boundary conditions using the fluid-structure interaction module of ANSYS. The Power Law and Carreau non-Newtonian models were used to define blood rheology. It was reported that the Carreau model showed greater stress values compared to the Power Law model. Their results indicated that the elastic wall boundary condition had an insignificant effect on the flow results (Chan et al., 2005). Kumar et al. modeled non-Newtonian blood flow through successive stenoses under pulsatile flow conditions. Two stenosis occlusion rates were used, ranging from 20-80% compression. While their wall boundary condition was rigid, a sinusoidal velocity profile was applied as the pulsatile flow condition at the inlet. They demonstrated that the compression rate was directly proportional to the shear stress rate in the narrowing region for both cases (Kumar et al., 2021). Basavaraja et al. analyzed the WSS and the oscillatory shear index (OSI) distribution at different severities of stenosis in the carotid artery. Multiple CT volumes were used to obtain flow volumes for simulation, and stenosis occlusion rates ranging from 50-99% were measured using CT angiography (Basavaraja et al., 2017). Zun et al. studied the prediction of restenosis in stented geometry by simulating local coronary blood flow. They concluded that small vessel size was an independent risk factor for restenosis in stented vessels (Zun et al., 2021). Foong et al. simulated blood flow behavior in terms of stenosis and artery radius. Blood flow was assigned a uniform velocity profile at the inlet, with a rigid wall condition, and the flow was laminar and steady state. Four different radii and five different stenosis angles were used to compare cases. As a result of this simulation, maximum shear stress values were observed at the minimum radius, while shear stress increased with a larger stenosis angle (Foong et al., 2020). Lopes et al. examined the fluid-structure interaction in carotid blood flow to compare viscosity models. The Newtonian and Carreau viscosity models were used as rheological models in their study. The Womersley flow condition was chosen for the inlet boundary. It was shown that vascular wall displacement was not dependent on blood viscosity. However, it was observed that the Carreau viscosity model produced dramatically higher WSS values (Lopes et al., 2020). Rostami et al. compared the cases of anemic, normal, and hypertensive patients using the Carreau viscosity model in a bypass vein. Blood flow was assumed to have a uniform velocity profile at the inlet. It was shown that hypertensive patients had the highest WSS values at three different sections compared to others. From their simulation results, they concluded that the graft position is critical for the success of bypass surgery, as the point between the host and grafted vessel exhibited the maximum stress (Rostami et al., 2020). Zhao et al. investigated the efficacy of shunt operations for inferior vena cava stenosis using the CFD approach. The wall was modeled with a rigid boundary condition, and pressure was applied at the inlet. Distinctive results were observed pre- and post-operatively in terms of velocity, pressure, and WSS. They demonstrated the validity of CFD analysis for clinical use in monitoring the efficacy of vascular operations (Zhao et al., 2021). Elhanafy et al. computationally investigated the effect of changes in hematocrit levels on blood flow under different degrees of stenosis occlusion. The Newtonian

viscosity model was used for blood, and the vessel model had a diameter of 7 mm. Non-pulsatile flow conditions were applied at the inlet, and the vessel wall was assumed to be rigid. WSS, shear rate, pressure, and velocity were examined to illustrate variations between cases (Elhanafy et al., 2020). Abugattas et al. performed a numerical study on bifurcated vessel geometry using three different non-Newtonian viscosity models. They analyzed the bifurcation angle and 60% stenosis categorically. The study's results were examined in terms of WSS values under the Power Law, Carreau-Yasuda, and Cross viscosity models (Abugattas et al., 2020).

In summary, blood flow simulation has significant potential for defining flow disturbances based on the existing literature. This study aims to simulate blood flow reactions computationally by creating different stenosis dimensions. The stenosis models are designed proportionally to observe the effects of stenosis length and height. Additionally, different viscosity models are adopted in the blood flow simulation to evaluate the response to varying stenosis models.

MATERIAL AND METHOD

In the present work, a laminar, incompressible, and steady 3-D stenosis geometry is utilized. The geometry of the validation model is shown in Figure 1(a), consisting of a cylindrical tube with a diameter of 6 mm and a length of 216 mm. The stenosis has a 2.75 mm occlusion and a length of 21 mm. This validation geometry is directly adapted from the study (Ai et al., 2010). The geometry used in our numerical study is shown in Figure 1(b). The validation geometry features sharper edges compared to the geometry in the present study. Therefore, the geometry in this study has been modified to visualize the effects of stenosis height and length. Nine different stenosis geometries were created with varying stenosis heights and lengths to observe the flow dynamics, as illustrated in Table 1. The stenosis length was kept constant while the heights varied, and vice versa. This approach allows both effects to be examined numerically without influencing each other.




Figure 1. Illustration of Utilized Geometries and Mesh. (a) Validation Geometry (b) Geometry of Present Study (c) Mesh of Stenosis Region

The blood viscosity exhibits non-Newtonian characteristics due to the presence of red blood cells forming a suspension. However, many previous studies have considered blood as a Newtonian fluid (Basavaraja et al., 2017 ; Zun et al., 2021). Blood can only be approximated as Newtonian in larger arteries where the shear rate exceeds 100 s^{-1} (Samad et al., 2017). In this study, three different viscosity models—Newtonian, Power Law, and Carreau have been selected from the literature for comparison (Cho et al., 1991). Blood density is chosen as 1060 kg/m^3 (Hoskins

et al., 1990), and in the Newtonian model, blood viscosity is set at 0.00345 Pa·s. The non-Newtonian Carreau model used is shown below:

$$\mu = \mu_{\infty} + (\mu_0 - \mu_{\infty})[1 + (\lambda\dot{\gamma})^2]^{(n-1)/2} \quad (1)$$

where time is constant $\lambda = 3.313$ s, zero strain viscosity is $\mu_0 = 0.056$ Pa·s, infinite strain viscosity is $\mu_{\infty} = 0.00345$ Pa·s, empirical exponent is $n = 0.3568$; and the Power Law model is shown as;

$$\mu = \mu_0(\dot{\gamma})^{n-1} \quad (2)$$

In the Carreau model, the nominal viscosity is set to $\mu_0 = 0.35$ Pa·s, and the empirical exponent is $n = 0.6$. The governing equations are solved numerically under steady flow conditions using finite volume methods within ANSYS FLUENT. A second-order upwind scheme is used to discretize the Navier-Stokes equations for each control volume in the solution method section. Pressure-velocity coupling is achieved using the SIMPLE algorithm. A second-order upwind scheme is also applied for pressure interpolation, and least-squares cell-based methods are employed for spatial discretization. The simulation is considered converged when the residuals for all equations fall below 10^{-6} to ensure accuracy in comparison with experimental data. The simulations are performed on a personal computer equipped with an Intel i7-6700HQ processor, 16 GB of RAM, and a 64-bit Windows 7 operating system.

Table 1. Characteristics of Stenosis Models

Models	Stenosis Dimension Ratio (SDR)	Length (L)	Height (H)	Reduction Rate (%)	Mesh Number	Maximum Skewness	Minimum Orthogonal Quality
Model 1	5	13.75	2.75	46 %	1.300.749	0.58	0.42
Model 2	6	16.5	2.75	46 %	1.297.809	0.58	0.42
Model 3	7	19.25	2.75	46 %	1.295.671	0.58	0.42
Model 4	8	22	2.75	46 %	1.293.918	0.58	0.42
Model 5	10	27.5	2.75	46 %	1.289.348	0.60	0.40
Model 6	5	22	4.4	73%	1.262.885	0.6	0.4
Model 7	6	22	3.67	61%	1.276.161	0.58	0.42
Model 8	7	22	3.142	52%	1.286.354	0.58	0.42
Model 9	10	22	2.2	37%	1.302.919	0.6	0.4

Validation of Numerical Study

The validation of the numerical results is confirmed against the corresponding experimental and numerical data of Ai et al., as seen in Figure 2, focusing on the post-stenotic region for axial velocity across the radial direction. The post-stenotic region is selected due to the presence of recirculation zones observed in the experimental study, making it suitable for validation. Our results show better agreement with the experimental data of Ai et al. at certain points compared to their numerical study. The discrepancies between the numerical and experimental studies are mainly concentrated near the wall region. These differences can be attributed to two main factors. From the experimental perspective, the nature of the ultrasound measurement technique using probes can disturb the flow field. Additionally, it is challenging to accurately measure flow close to the wall due to the effects of the wall on hydrodynamics. From a numerical perspective, modeling flow near the wall is difficult due to the rapid changes in flow characteristics within this boundary layer. Furthermore, detecting recirculation zones in small flow regions is highly sensitive to both modeling and resolution. Overall, our numerical study shows results within acceptable limits when compared with the experimental data.

Grid Independence

Mesh independency is achieved using 6 different mesh numbers. Finer mesh is utilized at the stenotic region to capture the velocity gradient in detail as shown in Figure 1 (c). The optimum mesh number has been chosen as 1.2 million to save computational effort. Increasing the mesh number above the optimum mesh number does not significantly affect the results of the present study as illustrated in Figure 3.




Figure 2. Validation of Numerical Results with Corresponding Experimental and Numerical Studies




Figure 3. Mesh Independency Study

Boundary Condition

For this study, the non-pulsatile inlet boundary condition which is 0.00265 kg/s taken purely from experimental data (Chan et al., 2005; Elhanafy et al., 2020; Ai et al., 2010) is utilized. Rigid wall boundary condition is selected. Pressure outlet boundary condition is the outlet choice as atmospheric pressure.

RESULTS AND DISCUSSION

The blood flow properties in a stenotic vessel are quantified and visualized for different viscosity models through various flow dynamic parameters, including wall shear stress (WSS), pressure drop, velocity, detection of recirculation zones, and flow streamlines. The simulation of blood flow is conducted to investigate the effects of stenosis dimensions. In this chapter, the results of blood flow dynamics are presented, focusing on the WSS in the throat region, pressure drop across the stenosis, and maximum velocity values for three different viscosity models and nine different stenosis geometries. The simulations reveal distinctive results across the varying stenosis geometries.

Wall Shear Stress

The relationship between the initiation and development of stenosis and wall shear stress (WSS) has been studied extensively by researchers (Marshall et al., 2004; Pandey et al., 2020; Costa et al., 2016). WSS, defined as the dynamic force exerted by blood flow on the vessel wall, is a critical parameter in stenosis research. In this study, different stenosis models revealed varying WSS values, with the throat region consistently exhibiting significantly higher WSS compared to the pre- and post-stenotic regions across all viscosity models. The trends were similar across all viscosity models, though the WSS values differed, particularly at the throat. An exponential increase in WSS was observed as the stenosis dimension increased from Model 9 (2.2 mm) to Model 6 (4.4 mm). However, a sudden jump in WSS occurred between Model 6 (3.67 mm) and Model 7 (4.4 mm). The highest WSS was found at the narrowest height, while the largest stenosis height showed the lowest WSS, validating the use of WSS in assessing stenosis severity. Stenosis length had minimal impact on WSS in the throat and post-stenotic regions, but a slight increase in WSS was observed in the pre-stenotic region for longer stenosis models in the Newtonian and Power Law models. The Carreau model, however, showed a steady increase in WSS with increasing stenosis length for both pre- and post-stenotic regions. Among the viscosity models, the Newtonian and Power Law models exhibited the most distinctive WSS variations in the pre- and post-stenotic regions, while the Carreau model displayed similar characteristics across these regions but had notably higher WSS at the throat. This highlights the Carreau model's sensitivity in detecting differences between stenosis models at the throat. Comparatively, the WSS in the pre- and post-stenotic regions showed little variation across different viscosity models, and the stenosis length did not significantly affect WSS at the throat for models with constant stenosis height. However, pre-stenotic WSS increased consistently with stenosis length across all models. The throat WSS results for the Newtonian model were compared with Elhanafy et al.'s study, where maximum WSS ranged from 1 Pa to 24 Pa for various stenosis occlusion rates, while our study showed a range of 1.5 Pa to 10 Pa. The WSS results for Model 8, with a 52% occlusion rate, closely aligned with the 50% stenosis occlusion geometry in their study. Additionally, the Power Law model's WSS values ranged from 1.5 Pa to 10 Pa at the throat, showing an increasing trend similar to other studies as stenosis occlusion rates rose (Abuguttas et al., 2020). The Carreau model's WSS results, particularly for Model 9 with mild stenosis, were approximately 25 Pa, consistent with Chan et al.'s findings for similar throat region stenosis dimensions (Chan et al., 2005). Overall, these results demonstrate that WSS is a valuable metric for assessing stenosis severity, with sensitivity varying across different viscosity models.

Pressure Drop

Pressure drop is a fluid dynamic parameter that measures the loss of pressure between two points along the flow path, and it is directly related to the power consumption of systems, such as the heart in the circulatory system. Contraction or expansion of the flow area, as occurs in stenosis, is a common cause of pressure drop in blood flow. Figure 5 shows the pressure drop for different stenosis geometries, measured at pre- and post-stenosis points using three viscosity models. While the pressure drop trend follows a similar pattern to that of the wall shear stress (WSS), the effect of increasing stenosis length is more evident for pressure drop. This effect is most pronounced in the Carreau viscosity model compared to the other models. Despite this, the Carreau model shows the lowest overall pressure drop percentage, as it simulates lower viscous forces exerted on the blood flow. The Newtonian and Power Law models display similar trends, but the Newtonian model exhibits higher pressure drop percentages. Both the Newtonian and Power Law models indicate a greater pressure drop compared to the Carreau model. The narrowest stenosis geometry leads to the highest pressure drop, consistent with the WSS results. Conversely, the lowest pressure drop is observed in the longest stenosis length. Changes in stenosis height have a more noticeable effect on pressure drop than variations in stenosis length, indicating that a decrease in stenosis height poses a greater risk to heart function than an increase in stenosis length. Therefore, predicting pressure drop percentages can be an essential tool for estimating stenosis severity and assessing heart function in narrowing situations. Accurate modeling of stenosis geometry, based on medical imaging, is crucial for this process (Perinajová et al., 2021).

Velocity

Figure 6 illustrates the maximum velocity results for all stenosis models across three different viscosity models at the throat region. An increase in velocity in narrowed regions is expected according to the law of continuity.




Figure 4. WSS Results of Nine Different Stenosis Geometries for Three Viscosity Models. Newtonian (b) Power Law (c) Carreau Law

However, it is important to observe how different viscosity models react to changes in stenosis height and length. Additionally, the maximum velocities at the pre- and post-stenotic regions provide valuable insights into blood flow dynamics in stenosis geometries. The narrowing of the region induces disturbances in flow both within and outside the stenosis. Numerical simulations are superior to experimental methods in obtaining sensitive measurements without disrupting the flow, as experimental measurements can be challenging due to the difficulty of placing probes accurately within the vessel. Stenosis length has a decreasing effect on blood velocity in the pre- and post-stenotic regions. However, the throat velocity is only minimally affected by changes in stenosis length. Conversely, the maximum velocity occurs at the minimum stenosis length for all viscosity models when the stenosis height is held constant. The Power Law and Newtonian viscosity models show similar trends, which align with the WSS results. The Carreau model, however, yields the highest velocities for both pre- and post-stenotic regions. Variations in stenosis dimensions not only increase throat velocity but also lead to higher velocities in the pre- and post-stenotic regions. Velocity of this study has congruence with respect to Samad et al. study in terms of magnitude change at pre and post stenotic regions for Newtonian model. However, In the non-Newtonian model, the velocity results have not

been higher, contrary to our study. This may be due to the different input of the subparameters of the non-Newtonian model, specifically the Carreau model (Samad et al., 2017).

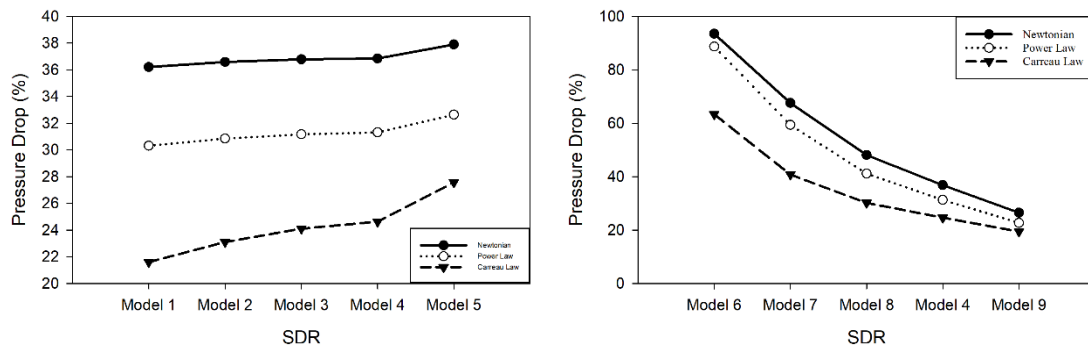


Figure 5. Pressure Drop of Different Stenosis Geometries between Pre- and Post-Stenosis Points for Three Viscosity Models.

Recirculation Zone

Recirculation zones are fluid dynamic phenomena indicating severe stenosis, described as the "reaction of fluid to a sudden change in flow area." This condition is significant in blood flow dynamics, as it can both classify the degree of vessel occlusion in terms of risk and serve as an indicator of clot formation and stenosis progression (Sharifzadeh et al., 2020; Gallo et al., 2014). Figure 7 presents vector plots of stenosis at the post-stenotic region, highlighting recirculation zones near the vessel wall for all viscosity models. In this study, recirculation zone characteristics are observed for the Newtonian and Power Law viscosity models in three cases: Model 6 (4.4 mm height), Model 7 (3.67 mm diameter), and Model 8 (3.142 mm height). Different viscosity models result in varying distributions of the recirculation zone at the same stenosis model. Figure 7 clearly shows a dramatic increase in the magnitude of the recirculation zone with rising stenosis height. Similarly, narrowing the blood flow area enlarges the recirculation zone, and the formation point of the recirculation zone extends longitudinally with increased stenosis height. Model 8 exhibits a prominent recirculation zone for the Newtonian viscosity case, while the Power Law model shows a less distinct recirculation zone confined to a small area near the wall. Compared to Models 6 and 7, Model 8 demonstrates incipient recirculation zone characteristics and represents a turning point with a 52.45% occlusion rate in the stenosis models. Although both the Newtonian and Power Law models reveal recirculation zones at the stenosis wall, the Newtonian model shows more visible and pronounced vector arrows. In contrast, the Carreau model fails to display any recirculation zone vectors for any stenosis models or flow regions, making it unsuitable for detecting recirculation zones as a stenosis flow characteristic. As observed in this study, while the Newtonian model in the literature provides a wider recirculation area, the non-Newtonian model has shown recirculation flows in a narrower region (Rostami et al., 2020; Samad et al., 2017; Cho et al., 1991).

Streamlines

Interaction between fluid and the vein in which it flows is characterized by selected viscosity law. Reaction of fluid can be observed in detail through streamlines against the vein wall. Flow separation is an important parameter that defines the characteristics of flow. It changes with viscosity and flow area. Figure 8 displays the streamline of blood flow for nine different stenosis models and three different viscosity models to observe the zone of flow separation. Streamlines of the Carreau model flow closer to the wall region than other models at the post-stenotic region. It is hard to observe flow separation by utilizing the Carreau model since the flow vector sticks to the vessel wall due to the nature of the Carreau Law as you can see in Figure 7. This characteristic is coherent with the recirculation zone results of the Carreau model. The Newtonian and Power model shows similar streamlines characteristics which are analogous to the results of other flow properties. The recirculation zone of flow at the post-stenotic region shows congruence with streamlines flow behavior for these models in terms of flow characteristics among vessel wall and blood. Arrangements of streamlines are made to observe flow behavior effectively. In the first row, a picture of different stenosis lengths is placed under the same height at the post-stenotic region. The position of flow separation occurs at an earlier distance when the stenosis length is decreased. Besides, the flow has streamlines close to the wall at higher stenosis lengths. In the second row, streamlines are classified with regard to increasing stenosis height for

illustration of the stenosis height effect. Higher stenosis height produces more spaces for flow separation at the wall region. Furthermore, an increment of stenosis height is associated with earlier flow separation.

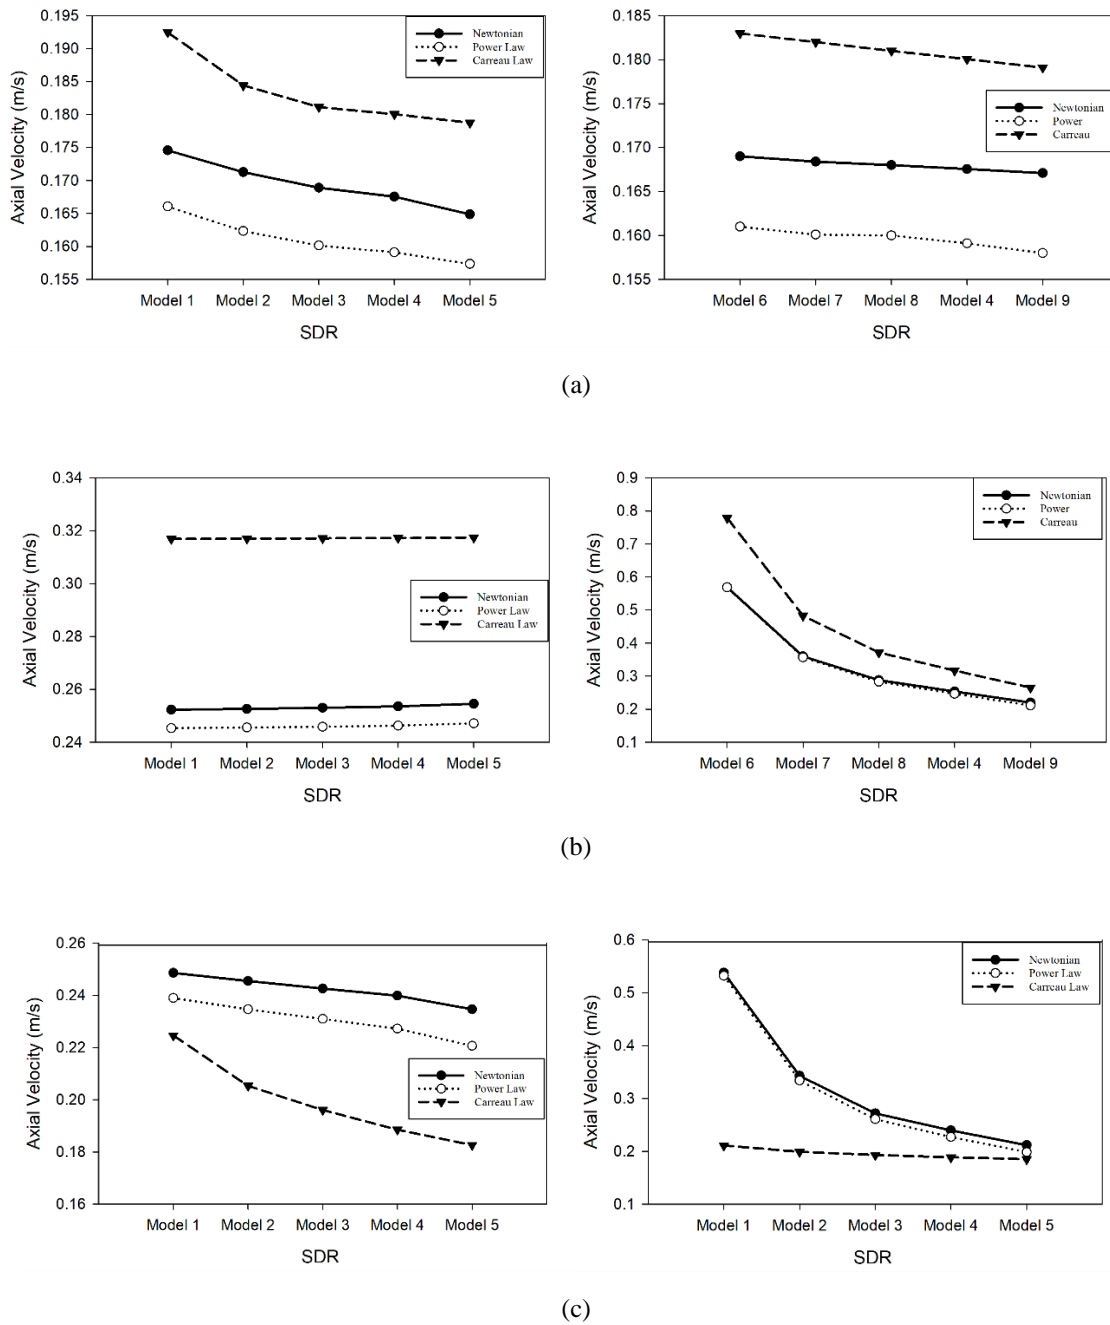




Figure 6. Maximum Velocity Values for Different Stenosis Geometries at Three Regions. Pre-Stenosis (b) Throat (c) Post-Stenosis



(a)



(b)




Figure 7. Velocity Vector Contours for Model 6 (a), Model 7 (b), and Model 8 (c) Post-Stenotic Region




Figure 8. Streamlines of Nine Stenosis Models under Three Viscosity Models.

CONCLUSION

In this study, numerical simulations of nine different geometries are performed under three different viscosity models to observe the effect of both different geometries and viscosity models. Flow dynamic results are analyzed through the selection of appropriate parameters (WSS, pressure drop, velocities) with the help of open literature. Observation of flow characteristics is carried out with the help of analyzing streamlines and detecting recirculation zones. The following results are deduced in the consequences of numerical simulation by comparing different cases.

- The characteristic of the recirculation zone is seen only in four cases and two geometries at the post-stenotic region. These cases are the Model 6 and the Model 7 of the Newtonian and Power Law. The Carreau model cannot show any recirculation zone characteristic.
- The characteristic of flow separation is analyzed with the help of streamlines. Higher stenosis height and shorter stenosis length cause bigger flow separation areas at post-stenotic regions. The Carreau model is not convenient for observing flow separation while the Power and Newtonian give illustrations of flow separation.

- The WSS results show high rate of escalation at increasing height while stenosis length has a slight effect on the WSS results in the direction of rising.
- The stenosis height and length are highly correlated with pressure drop percentage. An increase in stenosis dimensions results in elevated pressure drop for all viscosity models. Pressure drop percentage results have been ordered in number as Newtonian>Power>Carreau with regard to viscosity models.
- The most affected area by the change in stenosis height is the throat area. At the same time, the stenosis model dimensions have a considerable effect on pre- and post-stenotic flow velocities. Therefore, pre- and post-stenosis regions should be taken into account for the correct examination of stenosis.
- The selected viscosity model has a significant impact on the sensitivity of the properties being studied. For this reason, the utilization of different viscosity models could be considered to obtain better sensitivity of viewed flow properties, especially for comparative studies.

REFERENCES

- Abugattas, C., Aguirre, A., Castillo, E., & Cruchaga, M. (2020). Numerical study of bifurcation blood flows using three different non-Newtonian constitutive models. *Applied Mathematical Modelling*, 88, 529-549.
- Ai, L., Zhang, L., Dai, W., Hu, C., Shung, K. K., & Hsiai, T. K. (2010). Real-time assessment of flow reversal in an eccentric arterial stenotic model. *Journal of Biomechanics*, 43(14), 2678-2683.
- Basavaraja, P., Surendran, A., Gupta, A., Saba, L., Laird, J. R., Nicolaides, A., ... & Suri, J. S. (2017). Wall shear stress and oscillatory shear index distribution in carotid artery with varying degree of stenosis: a hemodynamic study. *Journal of Mechanics in Medicine and Biology*, 17(02), 1750037.
- Chan, W. Y., Ding, Y., & Tu, J. Y. (2005). Modeling of non-Newtonian blood flow through a stenosed artery incorporating fluid-structure interaction. *Anziam Journal*, 47, C507-C523.
- Cho, Y. I., & Kensey, K. R. (1991). Effects of the non-Newtonian viscosity of blood on flows in a diseased arterial vessel. Part 1: Steady flows. *Biorheology*, 28(3-4), 241-262.
- Costa, E. D. (2016). Hemodynamics in the Left Coronary Artery-numerical and in vitro approaches (Doctoral dissertation, Universidade do Porto (Portugal)).
- Davies, P. F., Remuzzi, A., Gordon, E. J., Dewey, C. F., & Gimbrone, M. A. (1986). Turbulent fluid shear stress induces vascular endothelial cell turnover in vitro. *Proceedings of the National Academy of Sciences*, 83(7), 2114-2117.
- Dolan, J. M., Kolega, J., & Meng, H. (2013). High wall shear stress and spatial gradients in vascular pathology. Kumar, G., Kumar, H., Mandia, K., Zunaid, M., Ansari, N. A., & Husain, A. (2021). Non-Newtonian pulsatile flow through an artery with two stenosis. *Materials Today: Proceedings*.
- Elhanafy, A., Elsaid, A., & Guaily, A. (2020). Numerical investigation of hematocrit variation effect on blood flow in an arterial segment with variable stenosis degree. *Journal of Molecular Liquids*, 313, 113550.
- Foong, L. K., Shirani, N., Toghraie, D., Zarringhalam, M., & Afrand, M. (2020). Numerical simulation of blood flow inside an artery under applying constant heat flux using Newtonian and non-Newtonian approaches for biomedical engineering. *Computer Methods and Programs in Biomedicine*, 190, 105375.
- Gallo, D., Gülan, U., Di Stefano, A., Ponzini, R., Lüthi, B., Holzner, M., & Morbiducci, U. (2014). Analysis of thoracic aorta hemodynamics using 3D particle tracking velocimetry and computational fluid dynamics. *Journal of Biomechanics*, 47(12), 3149-3155.
- Hoskins, P. R., Loupas, T., & McDicken, W. N. (1990). A comparison of the Doppler spectra from human blood and artificial blood used in a flow phantom. *Ultrasound in Medicine & Biology*, 16(2), 141-147.
- Kumar, G., Kumar, H., Mandia, K., Zunaid, M., Ansari, N. A., & Husain, A. (2021). Non-Newtonian pulsatile flow through an artery with two stenosis. *Materials Today: Proceedings*.
- Lopes, D., Puga, H., Teixeira, J., & Lima, R. (2020). Blood flow simulations in patient-specific geometries of the carotid artery: a systematic review. *Journal of Biomechanics*, 110019.
- Malek, A. M., Alper, S. L., & Izumo, S. (1999). Hemodynamic shear stress and its role in atherosclerosis. *Jama*, 282(21), 2035-2042.

- Marshall, I., Zhao, S., Papathanasopoulou, P., Hoskins, P., & Xu, X. Y. (2004). MRI and CFD studies of pulsatile flow in healthy and stenosed carotid bifurcation models. *Journal of Biomechanics*, 37(5), 679-687.
- Pandey, R., Kumar, M., & Srivastav, V. K. (2020). Numerical computation of blood hemodynamic through constricted human left coronary artery: Pulsatile simulations. *Computer Methods and Programs in Biomedicine*, 197, 105661.
- Perinajová, R., Juffermans, J. F., Westenberg, J. J., van der Palen, R. L., van den Boogaard, P. J., Lamb, H. J., & Kenjereš, S. (2021). Geometrically induced wall shear stress variability in CFD-MRI coupled simulations of blood flow in the thoracic aortas. *Computers in Biology and Medicine*, 133, 104385.
- Razavi, A., Shirani, E., & Sadeghi, M. R. (2011). Numerical simulation of blood pulsatile flow in a stenosed carotid artery using different rheological models. *Journal of Biomechanics*, 44(11), 2021-2030.
- Rostami, S., Mozoun, M. A., Toghraie, D., Zarringhalam, M., & Goldanlou, A. S. (2020). Insight into the significance of blood flow inside stenosis coronary jointed with bypass vein: The case of anemic, normal, and hypertensive individuals. *Computer Methods and Programs in Biomedicine*, 196, 105560.
- Samad, A., Husain, A., Zunaid, M., & Samad, A. (2017). Newtonian and Non-Newtonian Pulsatile Flows through an Artery with Stenosis. *The Journal of Engineering Research [TJER]*, 14(2), 191-205.
- Samady, H., Eshtehardi, P., McDaniel, M. C., Suo, J., Dhawan, S. S., Maynard, C., ... & Giddens, D. P. (2011). Coronary artery wall shear stress is associated with progression and transformation of atherosclerotic plaque and arterial remodeling in patients with coronary artery disease. *Circulation*, 124(7), 779-788.
- Shaaban, A. M., & Duerinckx, A. J. (2000). Wall shear stress and early atherosclerosis: a review. *American Journal of Roentgenology*, 174(6), 1657-1665.
- Sharifzadeh, B., Kalbasi, R., Jahangiri, M., Toghraie, D., & Karimipour, A. (2020). Computer modeling of pulsatile blood flow in elastic artery using a software program for application in biomedical engineering. *Computer Methods and Programs in Biomedicine*, 192, 105442.
- Soulis, J. V., Giannoglou, G. D., Chatzizisis, Y. S., Farmakis, T. M., Giannakoulas, G. A., Parcharidis, G. E., & Louridas, G. E. (2006). Spatial and phasic oscillation of non-Newtonian wall shear stress in human left coronary artery bifurcation: an insight to atherogenesis. *Coronary Artery Disease*, 17(4), 351-358.
- Zarins, C. K., Giddens, D. P., Bharadvaj, B. K., Sottiurai, V. S., Mabon, R. F., & Glagov, S. (1983). Carotid bifurcation atherosclerosis. Quantitative correlation of plaque localization with flow velocity profiles and wall shear stress. *Circulation Research*, 53(4), 502-514.
- Zhao, Y., Ping, J., Yu, X., Cui, Y., Yin, J., Sun, C., ... & Tang, L. (2021). Computational fluid dynamics simulation of time-resolved blood flow in Budd-Chiari syndrome with inferior vena cava stenosis and its implication for postoperative efficacy assessment. *Clinical Biomechanics*, 82, 105256.
- Zun, P., Svitenkov, A., & Hoekstra, A. (2021). Effects of local coronary blood flow dynamics on the predictions of a model of in-stent restenosis. *Journal of Biomechanics*, 120, 110361.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 16.09.2024
Kabul Tarihi : 27.12.2024

Received Date : 16.09.2024
Accepted Date : 27.12.2024

ZEOLİT-BENTONİT KARIŞIMLARININ TERMAL İLETKENLİK DAVRANIŞI

THERMAL CONDUCTIVITY BEHAVIOR OF ZEOLITE-BENTONITE MIXTURES

Esra GÜNERİ^{1*} (ORCID: 0000-0002-1840-2118)

¹ İzmir Demokrasi Üniversitesi, İnşaat Mühendisliği Bölümü, İzmir, Türkiye

*Sorumlu Yazar / Corresponding Author: Esra GÜNERİ, esra_cetinorgu@hotmail.com

ÖZET

Killi zeminlerin mühendislik davranışlarının diğer zemin tiplerine göre oldukça önem taşıdığı bilinmektedir. Kil miktarının artması ile birlikte kayma dayanımı, sıkışabilirlik ve daha birçok parametrenin genel olarak olumsuz etkilendiği yapılan çalışmalarla görülmüştür. Ancak bunun yanında kil yüzdesi arttıkça geçirimsizliğin azaldığı ve bu nedenle kilin, özellikle de "bentonitin" tampon malzeme olarak sıklıkla kullanıldığı bilinmektedir. Katı atık veya nükleer atık depolama alanları gibi sıcaklığın yükseldiği ve atıkların sızdırmazlığının sağlanması amacıyla bir tampon malzemeye ihtiyaç duyulan bu ve benzeri alanlarda kullanılacak tampon malzemenin, oluşan yüksek sıcaklık varlığında göstereceği termal davranış büyük önem arz etmektedir. Hali hazırda tampon malzeme olarak sadece bentonit (yüksek sızdırmazlık özelliği sebebi ile) ya da kum-bentonit (kumun, bentonitin büzülme miktarını azaltıcı etkisinden yararlanması sebebi ile) kullanılmaktadır. Bu çalışmada, zeolit-bentonit karışımlarının kullanımının yüksek sıcaklık varlığında test edilerek ve kullanımına elverişli sonuçlar elde edilmesi halinde yaygınlaştırılması amaçlanmaktadır. Çalışma kapsamında, farklı bentonit oranları kullanılarak oluşturulan zeolit-bentonit karışımlarının oda sıcaklığı ve yüksek sıcaklık altında (55°C) termal iletkenlik ölçümleri gerçekleştirilmiştir. Deney sonuçları, bentonit oranının ve sıcaklığın karışımların termal özelliklerini nasıl değiştirdiğini ortaya koymuştur.

Anahtar Kelimeler: Bentonit, sıcaklık, termal iletkenlik, zeolit

ABSTRACT

It is known that the engineering behavior of clayey soils is quite important compared to other soil types. It was observed in studies that shear strength, compressibility and many other parameters are generally negatively affected with the increase in the amount of clay. However, in addition, as the clay percentage increases, permeability decreases and therefore clay, especially "bentonite", is frequently used as a buffer material. In areas such as solid waste or nuclear waste storage areas where the temperature increases and a buffer material is needed to ensure the sealing of the waste, the thermal behavior of the buffer material to be used in the presence of high temperatures is of great importance. Currently, only bentonite (due to its high sealing properties) or sand-bentonite (due to the use of the effect of sand and bentonite in reducing the shrinkage amount) is used as a buffer material. In this study, it is aimed to test the use of zeolite-bentonite mixtures in the presence of temperature and to popularize them if suitable results are obtained. Within the scope of the study, thermal conductivity measurements of zeolite-bentonite mixtures formed using different bentonite ratios were carried out at room temperature and high temperature (55°C). The experimental results revealed how the bentonite ratio and temperature changed the thermal properties of the mixtures.

Keywords: Bentonite, temperature, thermal conductivity, zeolite

GİRİŞ

Enerji insan nüfusunun kaçınılmaz ihtiyaçlarından biridir ve her geçen gün nüfus artışına bağlı olarak enerji ihtiyacı artmaktadır. Var olan enerji kaynaklarına alternatif olarak yeni kaynakların ortaya çıkarılması ya da var olan sistemlerden enerji üretecek şekilde yararlanması araştırılan konular arasındadır. Gömülü güç kabloları, ısı

ToCite: GÜNERİ, E., (2025). ZEOLİT-BENTONİT KARIŞIMLARININ TERMAL İLETKENLİK DAVRANIŞI. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 258-265.

kazıkları, katı atık depolama alanları, nükleer atık depolama alanları ve jeotermal tesisler gibi yapılar ve elemanlar enerji yapılarının başında gelmektedir. Örnek verilen bu enerji yapılarının her birinin çalışma prensibi kendine has olmakla beraber, zeminlerin sıcaklıkla olan ilişkisi bakidir. Zeminlerin mühendislik özelliklerini etkileyen birçok parametre mevcut olup, bunlardan en temel olanları boşluk oranı, zemin cinsi, doygunluk derecesi, su içeriği, sıcaklık olarak sayılmaktadır. Zeminlerin sıcaklık varlığında mühendislik parametrelerinin değişerek başlangıç aşamasında yani tasarım sırasında hesaplanan parametrelerden farklılaştığı yapılan çalışmalarda görülmüştür (Gray, 1936; Youssef vd., 1961; Paaswell, 1967). Sıcaklık arttıkça zeminlerin genellikle hidrolik iletkenlik değerinin viskozitenin azalmasına bağlı olarak arttığı, sıkışabilirlik özelliğinin artış gösterdiği, kayma dayanımının genellikle azalarak olumsuz etkilendiğine dair araştırmacılar tarafından birçok sonuç ortaya konmuştur (Fleureau, 1979; Robinet vd., 1996; Laloui, 2001). Daha önceki çalışmalarında, bor katkılı (kolemanit, üleksit ve tinkal) kum-bentonit karışımları, enerji geo-yapıları etrafındaki yüksek sıcaklık ve sıcaklık döngülerinin varlığında kullanımı için test edilmiştir (Alpaydın, 2019) ve ayrıca cam elyafı, perlit, pomza (Çirkin ve Yükselen Aksoy, 2022) katkı malzemeleri de kum-kaolin karışımlarında kullanılmıştır. Bu çalışmalarda kullanılan alternatif katkı malzemelerinin bir kısmı hidrolik iletkenlik davranışı açısından yeterli bulunurken, bir kısmı da sıkıştırılabilirlik, şişme ve kesme dayanımı davranışları gibi farklı mühendislik parametreleri açısından yeterli bulunmuştur.

Katı atık depolama alanları, kullanım ömürleri boyunca birçok atığı depolamaktadır. Bu atıkların miktarı zamanla değişmekle birlikte istifleme yoğunlukla gıda atığı, sentetik tekstiller, ahşap, kağıt ve plastik gibi biyomalzemelerden oluşmaktadır. Atıklar ayrıştırıldığında %50 CH₄, %50 CO₂ ve sıcaklık ortaya çıkmaktadır. Katı atıkların bakteriler tarafından ayrıştırılması için gereken optimum sıcaklık, bakteri türüne bağlı olarak 35-40 °C ile 50-60 °C arasında olmalıdır (Tchobanoglous vd., 1993). Çoklu katı atık depolama alanları için belirtilen genel sıcaklık değeri ise 55 °C civarındadır (Hanson vd., 2010).

Nükleer atık depolama alanlarında radyoaktif atıkların, zemin yüzeyinden ülkelerin belirledikleri konseptler dahilinde yaklaşık 500 metre aşağıda ana kayanın içerisine istiflendikleri bilinmektedir (Sellin ve Leupin, 2013). Radyoaktif atıkların bozunması sonucunda 100°C'yi bulan hatta geçebilen sıcaklık değerlerinin oluştuğu bilinmektedir (Sellin ve Leupin, 2013). Atıkların gömüldükten sonra etrafını saracak, oluşacak radyoaktivitenin yeraltı suyuna sızmasını engellemek ve yine oluşacak yüksek sıcaklık değerinin atıkların depolandığı bakır kaptan (canister) ana kayaya doğru uzaklaştıracak bir tampon malzeme kullanılmaktadır. Burada kullanılan bariyer sistemi tekli ya da çoklu olabilmektedir; tekli kullanılan sistemlerde tampon malzeme oluşan yüksek sıcaklığı nükleer atıktan ana kayaya doğru hızla uzaklaştırılmalıdır. Bunun için gerekli olan tampon malzemenin gereken termal özelliklere sahip olması önemlidir. Bunlara ilaveten, tampon malzemenin birincil özelliğinin sızdırmazlığının düşük olması ve kullanım ömrü boyunca sızdırmazlığını muhafaza edebilmesi çok önemlidir.

Tampon malzeme olarak halihazırda bentonit ya da kum-bentonit karışımları sıklıkla kullanılmaktadır. Bentonitin, su tutma kapasitesinin oldukça yüksek bir kil grubu ve bu alanlarda gereken seviyede şişme basıncını sağlayabilecek potansiyele sahip olması gibi nedenler kullanımını desteklemektedir (Smith vd., 1980; Cho vd., 1999). Kum-bentonit karışımlarında ise bentonitin bünyesindeki su miktarının azalmasına bağlı olarak gerçekleşebilecek bir büzülme durumunda kumun, davranışı dengeleyici davranarak çatlakları önleyebilmesi, ayrıca dayanımı artırıcı bir etkiye sahip olması kullanımında ön plana çıkan özellikler arasındadır (Dixon vd., 1985; Pakbaz ve Khayat, 2004; Akgün vd., 2015). Sıcaklık arttıkça, termal iletkenliğin artarak ısı iletimini artırması ve ısı kaynağında oluşan yüksek sıcaklığı aslında birincil tampon görevini üstlenen ana kayaya doğru iletmesi aday tampon malzemenin beklenen en temel özellikler arasındadır. Yoon ve diğerleri (2021), oda sıcaklığından 80-90 °C'ye kadar değişen sıcaklıklarda bentonitin termal iletkenliğini ölçerek, termal iletkenliğin sıcaklıkla arttığını ortaya koymuşlardır. Ancak, bir başka çalışma termal iletkenlik katsayısının 100-150 °C sıcaklık değerlerine ulaşıldığında, 100 °C'nin üzerindeki sıcaklıklarda bentonit katmanları arasına adsorbe olan suyun uzaklaştırılmasına bağlı olarak ihmal edilebilir ölçüde azaldığını göstermiştir (Yoon vd., 2022).

Bu çalışma kapsamında zeolit-bentonit karışımlarının, tampon malzeme olarak kullanımının yaygınlaştırılması amaçlanmıştır. Bu bağlamda en temel parametrelerden biri olan termal iletkenlik katsayısının (λ), sıcaklık varlığında kullanıma uygun olup olmadığının incelenmesi amacı ile oda sıcaklığı ve yüksek sıcaklık altında (55 °C) Termal iletkenlik değerleri ölçülmüştür. Deneyler kapsamında ilk olarak kompaksiyon deneyi gerçekleştirilmiş olup, buradan elde edilen parametrelerde termal iletkenlik ölçüm numuneleri hazırlanmıştır. Dört farklı bentonit oranı kullanılarak, bentonit değişiminin de ısıl iletkenliği nasıl etkilendiği incelenmiştir.


MALZEME VE YÖNTEM

Malzeme Karakterizasyonu

Bu çalışma kapsamında zeolit-bentonit karışımları kullanılmıştır. Zeolit ve bentonit yerel firmalardan temin edilmiştir (Şekil 1). Zeolit ve bentonit No. 40 elekten elenerek kullanılmıştır. %90 zeolit-%10 bentonit karışımlarının bentonit oranı %10 arttırılarak dört farklı karışım oluşturulmuştur. Karışımlara isim verilirken kısaltmalar kullanılmıştır. Örneğin; 80Z-20B, %80 zeolit ve %20 bentoniti temsil etmektedir. Malzemelere ait fiziko-kimyasal özellikler Tablo 1’de verilmiştir.



Şekil 1. Deneylerde Kullanılan a. Zeolit b. Zeolit-Bentonit Karışımı



Şekil 2. a. Bentonitin ve b. Zeolitin Atomik Yapısının Şematik Gösterimi (Zendelska vd.; 2015, Pourhakkak vd., 2021)

Bentonit, genellikle silika katmanları arasına yerleştirilmiş bir gibsit tabakası ve montmorillonit içeren saf olmayan önemli bir kil, aynı zamanda alüminyum fillosilikat adsorbandır (Pourhakkak vd., 2021). Yer değiştirmeler özellikle oktahedral katman içinde ve az derecede silikat katmanı arasındadır (Şekil 2.a). Kilin yapısı esas olarak hidroksil-alüminosilikat yapısıyla ilişkilidir. Silika ve alümino oktahedral levhaların tetrahedral katmanları arasındaki ilişki, killerin kristal çerçevesini oluşturmaktadır. Yapılarında, Mg^{2+} veya Fe^{2+} kısmen Al^{3+} kationlarını değiştirir ve bu yer

değiştirmeyi yük dengesi sağlayan Na, K, Mg veya Ca gibi metallerin dahil edilmesi izlemektedir (Pourhakkak vd., 2021).


Tablo 1. Kullanılan Malzemelerin Fiziko-Kimyasal Özellikleri

Özellik	Zeolit	Bentonit
Özgül ağırlık	2.50	2.40
Likit limit (%)	50.0	476.0
Plastik limit (%)	N.P.	70.1
pH	7.6	9.5

Gözenekli malzemelerin özellikleri hem malzemenin kimyasına hem de gözenek yapılarına bağlıdır (Şekil 2.b). Zeolitler gibi son derece spesifik fiziksel ve kimyasal özelliklere sahip malzemelerin, (yüksek gözenekliliğe ve benzersiz yapıya sahip) çoğu doğal mineral olarak bulunmaktadır ancak sentetik olarak da üretilmektedir. Kullanım amaçları ticari olabilirken, kimyalarını incelemek için bilim insanları tarafından da kullanılabilir. Mevcut durumda, tanımlanmış 191 benzersiz zeolit çeşidi bulunmaktadır (Baerlocher vd., 2007) ve zeolitlerin tanınan üyelerinden bazıları analsim, şabazit, gismondin, harmotom, heulandit, natrolit ailesi ve stilbit ailesidir (Zendelska vd., 2015).

Deneysel Yöntemler

Bu çalışma kapsamında, zeolit-bentonit karışımlarının kompaksiyon deneyleri ve termal iletkenlik ölçümleri gerçekleştirilmiştir. Termal iletkenlik ölçümleri hem oda hem de 55°C altında yapılmıştır. 10B-90Z, 20B-80Z, 30B-70Z ve 40B-60Z olmak üzere dört farklı bentonit oranına sahip karışım oluşturulmuştur. Kompaksiyon deneyleri ASTM: D698'e göre yapılmıştır (ASTM: D698). Kompaksiyon zeminin mevcut boşluk oranını azaltmak ve böylece zeminin geçirimsizliğini azaltmak, zeminin taşıma gücünü artırmak ve zeminin sıkışabilirliğini minimuma indirmek gibi birçok mühendislik parametresini optimize etmektedir. Numuneler önce kuru halde tartılıp, bir kaba alındıktan sonra dört farklı su içeriğinde hazırlanarak 24 saat boyunca ağzı kapalı bir şekilde bekletilmiştir. Bu sürenin sonunda suyun karışım içerisindeki homojen dağılımı sağlanmıştır. Deney sonunda optimum su içeriği (w_{opt}) ve maksimum kuru birim hacim ağırlık ($\gamma_{dry,max}$) değerlerine ulaşılmıştır.



Şekil 3. Kompaksiyon Deneyi Öncesi ve Sonrası Şematik Zemin Görşelleri (Shutterstock, 2024)

Termal iletkenlik ölçümleri "Tempos" cihazı ile yapılmıştır. Ölçümleri gerçekleştirilecek numuneler Standard Proctor kompaksiyon deneyinden elde edilen optimum su içeriği ve maksimum kuru birim hacim ağırlık değerlerine göre hazırlanarak ölçüm kabında sıkıştırılmıştır. Termal iletkenlik ölçümü için kullanılan yaklaşık 7 cm uzunluğunda bir probdan yararlanılmıştır (Şekil 4). Özgül ısı gibi farklı termal parametreler için kullanılacak probsa ayrı olarak tasarlanmış ancak bu çalışma kapsamında kullanılmamıştır.


Ölçümler oda sıcaklığı ve 55 °C'de bekletilen numuneler üzerinde gerçekleştirilmiştir. Oda sıcaklığında gerçekleşen deneylerde, numuneler hazırlanıp sıkıştırıldıktan sonra ölçümler her numunede üç kez gerçekleştirilmiş olup, ortalama değerler kullanılmıştır. Yüksek sıcaklığa maruz kalmış ve termal iletkenlik değerleri elde edilmek istenen numuneler, kalıpta sıkıştırıldıktan sonra etrafı hava almayacak şekilde sarılarak 55 °C sıcaklığa sahip etüvde yaklaşık 48 saat bekletilmiştir. Bu sürenin sonunda numuneler etüvden çıkartılarak, prob yardımıyla termal iletkenlik değerleri ölçülmüştür.



Şekil 4. Termal İletkenlik Ölçüm Ekipmanları

SONUÇLAR VE TARTIŞMA

Bu çalışmada zeolit-bentonit karışımlarının kompaksiyon deneyleri ve termal iletkenlik ölçümleri gerçekleştirilmiştir. Termal iletkenlik deneyleri oda sıcaklığı ve 55 °C altında yürütülmüştür. Şekil 5'de karışımlara ait kompaksiyon eğrileri verilmiştir. Deney sonuçları, beklendiği üzere bentonit miktarının artması ve zeolit miktarının azalmasına bağlı olarak maksimum kuru birim hacim ağırlığın azaldığını ve optimum su içeriğinin arttığını göstermektedir. %10 bentonitli karışımın sırasıyla w_{opt} ve $V_{dry,max}$ değerleri %42 ve 11.5 kN/m³ iken bu değerler %40 bentonitli karışımında %53 su içeriği değerine yükselirken, kuru birim hacim ağırlık değeri azalarak 9.9 kN/m³ değerine düşmüştür. Bentonitin özgül ağırlığının zeolitinkine göre daha düşük olması, karışımdaki bentonit miktarının artması sonucu birim hacim ağırlık değerinin azalışının nedenini oluştururken, bentonitin yüksek su tutma kapasitesine sahip olması ise karışımların artan su içeriği değerlerinin dayandığı esası açıklamaktadır.



Şekil 5. Karışımlara ait Kompaksiyon Eğrileri


Bentonitin termal iletkenliği sıcaklık, su içeriği ve kuru yoğunluktan önemli ölçüde etkilenmektedir (DeVries, 1963; Nikolaev vd., 2013). Sıcaklığın, boşluk yapısına olan etkisi ve boşluk yapısının boyut dağılımına olan etkisi sonucunda termal iletkenlik yani ısı transferi etkilenmektedir (Ye vd., 2010; Xu vd., 2022). Daha önce yüksek sıcaklık varlığında bentonitle yapılan çalışmalar termal iletkenliğin arttığı ancak 100-150°C gibi çok yüksek sıcaklık değerlerine ulaşıldığında artışta önemli ölçüde azalış olduğu gözlenmiştir (Yoon vd., 2022, Ye vd., 2010, Xu vd., 2021). Tablo 2'de karışımların farklı sıcaklıklar altında termal iletkenlik değerleri verilmiştir. Deney sonuçları oda sıcaklığı altında bentonit miktarı arttıkça termal iletkenliğin azaldığını göstermiştir. Oda sıcaklığından yüksek sıcaklığa geçildiğinde ise literatüre paralellik gösteren sonuçlar elde edilmiş ve termal iletkenliğin karışım bazında arttığı görülmüştür. Daha önce bentonit kullanılarak, üç farklı sıcaklık altında gerçekleştirilen bir çalışmada, bentonitin termal iletkenlik değerinin 25 °C, 60 °C ve 80 °C altında sırasıyla 0.658 W/mK, 0.808 W/mK ve 1.077 W/mK olarak arttığı gözlenmiştir. Aynı çalışmada, ferrokrom, çelik çürüf gibi katkıları varlığında da bentonitin artan sıcaklıkla birlikte termal iletkenlik katsayısının (λ) artış gösterdiği belirlenmiştir (Aşçı, 2023).

Bentonit içerikli tampon malzemelerin yüksek sıcaklık varlığında termal, hidrolik ve mekanik özelliklerinin nasıl etkilendiğini değerlendirilmelidir. Bu amaçla, Kore ve diğer ülkelerde çok sayıda çalışma yürütülmüştür; ancak çoğu,

100 °C veya daha düşük sıcaklıklarda incelemiştir. Araştırmacılar, sabit doygunluk koşullarıyla hazırlanan sistemlerde termal iletkenliğin sıcaklıkla arttığını ortaya koymuşlardır (Yoon vd., 2022). Bentonitin, termal iletkenliğinin katı, su ve hava fazlarındaki maddelerin termal iletkenliklerinin bir kombinasyonu olduğu varsayılmaktadır. Bentonit, sıkıştırılmış hale geçtiğinde daneler arası temas artacağından oda sıcaklığı altında termal iletkenlik artmaktadır. (Şekil 6).


Tablo 2. Farklı Sıcaklıklar Altında Karışımlara ait “ λ ” Katsayıları

Karışım	Oda Sıcaklığı (22~25° C)	55° C
	Termal İletkenlik (λ , W/mK)	Termal İletkenlik (λ , W/mK)
10B-90Z	0.958	1.049
20B-80Z	0.821	0.975
30B-70Z	0.803	0.971
40B-60Z	0.784	0.952



Şekil 6. Karışımların Termal İletkenlik Değerlerinin Karşılaştırılması

Deney sonuçları, bentonit yüzdesi arttıkça termal iletkenliğin azaldığını göstermiştir (Şekil 7). Oda sıcaklığından yüksek sıcaklığa geçirdiğinde, bu trend devamlılık göstermiş ve bentonit miktarının artması ile birlikte termal iletkenliğin azaldığı görülmüştür.



Şekil 7. Sıcaklık-Termal İletkenlik İlişkisi

Bu çalışma kapsamında, zeolit-bentonit karışımlarının oda sıcaklığı ve yüksek sıcaklık altında termal iletkenlik ölçümleri yapılmıştır. Deney sonuçları, sıcaklık artışı ile birlikte karışımların termal iletkenliğinin arttığını

göstermiştir. Termal iletkenlik ölçümlerinde temas yüzeyi ve su içeriği büyük önem taşımaktadır. Karışımların su içeriği düşüken, termal iletkenlik davranışını danelerin temas yüzeyleri kontrol etmektedir. Su miktarının artması ile birlikte kontrol su yüzdesine bağlı olarak değişmektedir (Tien vd., 2005). Belirli bir seviyeden sonra ise bu etki ihmal edilebilir düzeye gelmektedir. Buna ek olarak, artan sıcaklıkla birlikte zeminlerin sıkışma miktarının içerisindeki suyun atılması ile birlikte artmasından dolayı (Laloui, 2001), yine daneler birbiri ile yakınlaşmakta ve termal iletkenlik artmaktadır. Bu sonuçlar doğrultusunda, deneye tabi tutulan karışımların, gerekli diğer mühendislik parametrelerini de sağlaması koşulu ile yüksek sıcaklığın ısı kaynağından uzaklaştırılması hedeflenen alanlarda kullanımının uygun olacağı görülmüştür.

KAYNAKLAR

- Akgün, H., Ada, M. & Koçkar, M.K. (2015). Performance assessment of a bentonite–sand mixture for nuclear waste isolation at the potential akkuyu nuclear waste disposal site, southern Turkey, *Environ. Earth Sci.* 73(10) 6101-6116.).
- Alpaydm, Ş. G. (2019). An investigation of effects of boron additives on the permeability and shear strength behavior of sand-bentonite mixtures under high temperatures. Master thesis, Dokuz Eylül University, Supervisor: Yükselen Aksoy, Y., 161 p., 2019.
- ASTM:D698-12. (2012). Standard test methods for laboratory compaction characteristics of soil using standard effort (12 400 ft-lbf/ft³ (600 kN-m/m³)). ASTM International, West Conshohocken, PA, USA, 1–13.
- Aşçı, C. (2023). Developing thermally conductive and resistive soil mixtures for energy geo-structures. Master thesis, Dokuz Eylül University, Supervisor: Yükselen Aksoy, Y., 208 p., 2023.
- Baerlocher C., Meier W. H., Olson D. H., Atlas of Zeolite Framework Types, 6th Edition, Elsevier, 2007.
- Cho, W. J., Lee, J. O., & Kang, C. H. (1999). Influence of salinity on the hydraulic conductivity of compacted bentonite. *MRS Proceedings*, 713.
- Çirkin, İ., Yükselen Aksoy, Y. (2022). Pomza, Perlit ve Cam Elyaf Katkılarının Yüksek Sıcaklık Altında Kum-Kaolin Karışımlarının Kayma Dayanımı Davranışına Etkisi. *DEUFMD*, 24(71), 657-663.
- DeVries D.A. (1963). Thermal Properties of Soils. In W.R. van Wijk (ed.) *Physics of Plant Environment*. North-Holland Publishing Company, Amsterdam.
- Dixon, D.A., Gray, M.N., & Thomas, A.W. (1985). A study of the compaction properties of potential clay–sand mixtures for use in nuclear fuel waste. *Engineering Geology*, 21: 247–255.
- Fleureau, J. M. (1979). Influence d'un champ thermique ou électrique sur les phénomènes d'interaction solide-liquide dans les milieux poreux, Doctoral thesis. Ecole Centrale de Paris.
- Gray, H. (1936). Progress Report on Research on the Consolidation of Fine-Grained Soils. *Proc. Internat. Conf. on Soil Mech. and Found. Eng.*, Harvard University, Vol. 2, p. 138-141.
- Hanson, J.L., Yeşiller, N., & Oettle, N.K. (2010). Spatial and temporal Temperature distributions in municipal solid waste landfills. *Journal of Environmental Engineering*, 136(8), 804-814.
- Laloui, L. (2001). Thermo-mechanical behavior of soils. *Revue Française de Genie Civil.*, 5 (6), 809-843.
- Nikolaev, I.V.; Leong, W.H.; Rosen, M.A. (2013). Experimental investigation of soil thermal conductivity over a wide temperature range. *Int. J. Thermophys.* 34, 1110–1129.
- Paaswell, R. (1967). Temperature effects on clay soil consolidation. *Journal of the Soil Mechanics and Foundations Division*, 93, 9-22.
- Pakbaz, M.C. and Khayat, N. (2004). The effect of sand on strength of mixtures of bentonite sand. *Engineering Geological Methods: Modelling of soil and rock behaviour. Engineering Geology for Infrastructure Planning in Europe*, 104: 316 - 320.
- Pourhakkak, Poursan & Taghizadeh, Ali & Taghizadeh, Mohsen & Ghaedi, Mehrorang & Haghdoost, Sepahdar. (2021). Fundamentals of adsorption technology. 10.1016/B978-0-12-818805-7.00001-1.
- Robinet, J. C., Rahbaoui, A., Plas, F. & Lebon, P. (1996). A constitutive thermomechanical model for saturated clays. *Eng Geol.* [https://doi.org/10.1016/0013-7952\(95\)00049-6](https://doi.org/10.1016/0013-7952(95)00049-6)

- Sellin, P. & Leupin, O. X. (2013). The use of clay as an engineered barrier in radioactive-waste management - A review. *Clays and Clay Minerals*, 61(6), 477–498.
- Shutterstock, 2024. <https://www.shutterstock.com/tr/search/soil-compaction/> Accessed 16.09.2024.
- Smith, M. J. et al. (1980). Engineered barrier development for a nuclear waste repository in basalt: an integration of current knowledge. In: RHO-BWI-ST-7, Rockwell Hanford Operations, WA.
- Tchobanoglous, G., Theisen, H., & Vigil, S. A. (1993). Integrated solid waste management: Engineering principles and management issues, McGraw-Hill, New York.
- Tien, Y. M., Chu, C. A., & Chuang, W. S. (2005). The prediction model of thermal conductivity of sand-bentonite based buffer material. *France Clays in Natural & Engineered Barriers for Radioactive Waste Confinement*, 657.
- Yoon, S., Kim, M.J., Park, S., Kim, G.Y. (2021). Thermal conductivity prediction model for compacted bentonites considering temperature variations, *Nucl. Eng. Technol.* 53, 3359–3366.
- Yoon, S., Lee, G., Park, T., Lee, C., Cho, D. (2022). Thermal conductivity evaluation for bentonite buffer materials under elevated temperature conditions, *Case Studies in Thermal Engineering*, Volume 30, 101792, ISSN 2214-157X, <https://doi.org/10.1016/j.csite.2022.101792>.
- Xu, Y.S., Zeng, Z.T., Lv, H.B. (2019). Temperature dependence of apparent thermal conductivity of compacted bentonites as buffer material for high-level radioactive waste repository. *Appl. Clay Sci.* 174, 10–14.
- Xu, Y., Zhou, X., Sun, D., Zeng, Z.T. (2022). Thermal properties of GMZ bentonite pellet mixtures subjected to different temperatures for high-level radioactive waste repository. *Acta Geotech.*, 17, 981–992.
- Ye, W.M., Chen, Y.G., Chen, B., Wang, Q., Wang, J. (2010). Advances on the knowledge of the buffer/backfill properties of heavily-compacted GMZ bentonite. *Eng. Geol.* 2010, 116, 12–20.
- Youssef, M.S., Sabry, A. & El Ramli A.H. (1961). Temperature changes and their effects on some physical properties of soils. *Proceedings of the Fifth International Conference on Soil Mechanics and Foundation Engineering 2* : 419-421, Paris.
- Zendelska A., Golomeova M., Blažev K., Boev B., Krstev B., Golomeov B., A, Krstev. (2015). Kinetic studies of manganese removal from aqueous solution by adsorption on natural 46 Microporous and Mesoporous Materials zeolite. *Macedonian Journal of Chemistry and Chemical Engineering*, 34(1), 1857–5625.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 19.09.2024
Kabul Tarihi : 03.12.2024

Received Date : 19.09.2024
Accepted Date : 03.12.2024

ÜRETİMDE DİJİTAL DÖNÜŞÜMÜN BAŞARISINI DEĞERLENDİRMEK İÇİN PERFORMANS ÖLÇMEYE YÖNELİK BİR YAKLAŞIM

A PERFORMANCE MEASUREMENT APPROACH FOR EVALUATING THE SUCCESS OF DIGITAL TRANSFORMATION IN MANUFACTURING

Gökçen SARAY¹ (ORCID: 0009-0000-7185-9910)
Bilal ERVURAL^{1*} (ORCID: 0000-0002-5206-7632)

¹ Necmettin Erbakan Üniversitesi, Endüstri Mühendisliği Bölümü, Konya, Türkiye

*Sorumlu Yazar / Corresponding Author: Bilal ERVURAL, bervural@erbakan.edu.tr

ÖZET

Dijital Dönüşüm, dijital teknolojilerin kullanımıyla yeni iş modelleri ve stratejiler geliştirme sürecini ifade eder. İşletmelerin rekabet avantajı elde etmeleri ve kurumsal verimliliklerini artırmaları için dijitalleşme süreçlerine uyum sağlamaları kritik bir öneme sahiptir. Bu dönüşüme yanıt verebilmek için, işletmelerin dijital dönüşüm etkinliklerini ölçmeleri ve dijital dönüşüm yol haritalarını çizmeleri gerekmektedir. Bu çalışma, üretim sektöründeki işletmelerin dijital dönüşüm performanslarını belirlemeye yönelik bir performans ölçüm sistemi geliştirmeyi amaçlamaktadır. Bu bağlamda, dijital dönüşüm ve Endüstri 4.0 uygulamaları için gerekli kriterler, nesnelar, insanlar ve sistemler arasındaki etkileşimler göz önünde bulundurularak belirlenmiştir. Belirlenen kriterler, yalnızca otomasyon, robotik, nesneların interneti, yapay zekâ ve büyük veri analitiği gibi ileri teknolojilerden değil; aynı zamanda organizasyonel faktörler ve değişime olan istek gibi insan odaklı unsurlardan da yararlanarak tanımlanmıştır. Kriterler kapsamlı bir literatür taraması sonucunda oluşturulmuş ve açıklanmıştır. Uzman görüşleri alınarak, bu kriterlerin önem derecelerini gösteren ağırlıklar hesaplanmış ve SWARA yöntemi ile ağırlıklandırılmıştır. Dijital dönüşüm performansının ölçümünde ise Gri İlişkisel Analiz (GİA) yöntemi kullanılmıştır. Geliştirilen model, örnek bir vaka üzerinde test edilmiş ve firma performansları karşılaştırılmıştır.

Anahtar Kelimeler: Performans ölçüm, dijital dönüşüm, endüstri 4.0, akıllı fabrikalar, otomasyon.

ABSTRACT

Digital Transformation refers to the process of developing new business models and strategies through the use of digital technologies. For businesses to gain a competitive advantage and enhance corporate efficiency, it is crucial to adapt to digitalization processes. Companies must measure their digital transformation activities and chart their digital transformation roadmaps to respond to this transformation. This study aims to develop a performance measurement system for identifying the digital transformation performance of companies in the manufacturing sector. In this context, the necessary criteria for implementing digital transformation and Industry 4.0 applications have been determined by considering the interactions between objects, people, and systems. The identified criteria are defined not only by utilizing advanced technologies such as automation, robotics, the Internet of Things, artificial intelligence, and big data analytics but also by incorporating human-centered factors such as organizational aspects and the willingness to change. The criteria were established and explained through a comprehensive literature review. By obtaining expert opinions, the importance weights of these criteria were calculated and weighted using the SWARA method. Grey Relational Analysis (GRA) was used to measure digital transformation performance. The developed model was tested on a case study, and company performances were compared.

Keywords: Performance measurement, digital transformation, industry 4.0, smart factories, automation.

ToCite: SARAY, G., & ERVURAL, B., (2025). ÜRETİMDE DİJİTAL DÖNÜŞÜMÜN BAŞARISINI DEĞERLENDİRMEK İÇİN PERFORMANS ÖLÇMEYE YÖNELİK BİR YAKLAŞIM. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 266-284.

GİRİŞ

Günümüzün hızla dijitalleşen dünyasında, işletmelerin sürdürülebilir bir rekabet avantajı elde edebilmesi için dijital dönüşüm süreçlerine uyum sağlamları kritik hale gelmiştir (Kraus vd., 2021). Üretim süreçlerinin daha akıllı, bağımsız ve otomatik hale gelmesi, dijital teknolojilerin iş süreçlerine entegre edilmesini zorunlu kılmaktadır (Adem vd., 2022). Dijital dönüşüm, yalnızca maliyetleri düşürme ve operasyonel verimliliği artırma potansiyeli ile değil, aynı zamanda stratejik değer yaratma ve iş modellerini yeniden yapılandırma kapasitesi ile de öne çıkmaktadır. Bu doğrultuda, üretimdeki dijitalleşme süreçleri, Endüstri 4.0 olarak adlandırılan dördüncü sanayi devriminin bir parçası olarak değerlendirilmektedir (Gülseren ve Sağbaş, 2019).

Endüstri 4.0, işletmelerin üretim süreçlerinde dijitalleşmeyi sağlamak amacıyla siber-fiziksel sistemler, nesnelerin interneti, büyük veri analitiği, yapay zeka ve robotik gibi teknolojilerden yararlanmaktadır. Bu dönüşüm, makineler ve insanlar arasında sürekli bağlantı sağlayarak süreçlerin kesintisiz, otomatik ve daha esnek bir şekilde yönetilmesine olanak tanımaktadır (Ryalat vd., 2023). Ancak dijital dönüşüm süreçleri her işletme için farklı aşamalarda gerçekleşmekte ve işletmelerin dijital olgunluk düzeyine göre değişiklik göstermektedir (Ivancic vd., 2019). Bu nedenle, işletmelerin dijital dönüşüm kapasitelerini belirlemeleri ve uygun stratejiler geliştirmeleri için kapsamlı bir performans ölçüm sistemi geliştirilmesi gerekmektedir.

Bu çalışma, üretim sektöründeki işletmeler için dijital dönüşüm performansını ölçmeye yönelik entegre bir model ortaya koymaktadır. Çalışmanın özgün yönlerinden ilki, dijital dönüşüm süreçlerinin karmaşıklığını daha iyi yansıtabilmek için hem ileri teknolojilere hem de organizasyon ve insan faktörlerine dayalı çok boyutlu bir kriter seti belirlenmesidir. Literatürdeki mevcut çalışmaların büyük çoğunluğu, dijital dönüşüm sürecinde insan faktörünü ve organizasyonel uyum gibi yumuşak unsurları yeterince dikkate almamaktadır. Bu çalışmada, dijital dönüşüm performansını ölçmek için toplamda 3 boyut, 6 ana kriter ve bu ana kriterlerin altında 26 alt kriter belirlenmiş ve bu kapsamda geniş bir çerçeve oluşturulmuştur. Geliştirilen modelin özgünlüğünü oluşturan bir diğer unsur, SWARA (Step-wise Weight Assessment Ratio Analysis) ve Gri İlişkisel Analiz (GİA) yöntemlerinin bir araya getirilmesiyle entegre bir performans ölçüm modeli geliştirilmesidir. SWARA yöntemi, uzman görüşlerine dayalı olarak kriterlerin önem derecelerini belirlemekte, böylece dijital dönüşüm performansının objektif ve çok boyutlu bir perspektifle değerlendirilmesine olanak tanımaktadır. Performans ölçüm aşamasında ise GİA yöntemi kullanılarak işletmelerin dijital dönüşüm performansları karşılaştırılmaktadır. Geliştirilen modelin etkinliği, otomotiv yan sanayi sektöründen elde edilen verilerle test edilmiştir. Bu yaklaşım, dijital dönüşüm sürecinin farklı yönlerini entegre bir çerçevede değerlendirerek stratejik karar alıcılar için kapsamlı bir araç sunmaktadır.

Bu çalışmanın geri kalanı şu şekilde organize edilmiştir: Bölüm 1, dijital dönüşüm kavramı ve Endüstri 4.0 uygulamalarına genel bir bakış sunmaktadır. Bölüm 2'de, dijital dönüşüm ile ilgili literatür özetlenmiştir. Bölüm 3'te ise dijital dönüşüm sürecinde dikkate alınması gereken ana ve alt kriterler ayrıntılı olarak ele alınmıştır. Bölüm 4, çalışmanın metodolojisini açıklamakta olup, SWARA ve GİA yöntemlerinin nasıl uygulandığı anlatılmaktadır. Bölüm 5'te örnek bir uygulama gerçekleştirilmiş ve sonuçlar analiz edilmiştir. Son olarak, Bölüm 6'da, çalışma kapsamında elde edilen sonuçlar değerlendirilmiş ve dijital dönüşüm stratejileri için önerilerde bulunulmuştur.

LİTERATÜR TARAMASI

Dijital dönüşüm ve Endüstri 4.0 kavramları, işletmelerin modern teknolojiye adaptasyonu ve rekabet avantajı elde etme süreçlerinde kritik bir rol oynamaktadır. Bu doğrultuda dijital dönüşüm literatürü, işletmelerin dijitalleşme sürecindeki zorlukları, gerekli yetkinlikleri ve performans değerlendirme metodlarını inceleyen çok sayıda çalışma içermektedir. Dijital dönüşüm performansını ölçme konusunda yapılan çalışmalarda, kriterlerin belirlenmesi ve değerlendirilmesi önemli bir yer tutmaktadır. Özellikle Endüstri 4.0 teknolojilerinin etkili bir şekilde uygulanabilmesi için gerekli olan altyapı, beceri ve organizasyonel değişiklikler, dijital dönüşümün temel boyutları olarak ele alınmaktadır.

Bu alanda yapılan çalışmalar, dijital dönüşümün başarısında teknolojik altyapının yanı sıra, işletme kültürü ve insan kaynaklarının da önemli rol oynadığını vurgulamaktadır. Dijital dönüşüm performansını değerlendirirken işletmelerin süreçlerine, ölçeklerine ve sektörel farklılıklarına göre özelleştirilebilir kriterlerin seçilmesi önerilmektedir. Örneğin, öncelikli olarak ERP yazılımları, veri altyapısı ve IoT gibi teknolojilerin önemi literatürde sıklıkla vurgulanmıştır (Kocaoğlu ve Kırmızı, 2024; Keskinlikç ve İpkin, 2023). Bu teknolojilerin dijital dönüşüm performansı üzerindeki etkileri, performans ölçümünde dikkate alınması gereken kritik faktörler olarak belirlenmiştir.

Çok Kriterli Karar Verme (ÇKKV) yöntemlerinin dijital dönüşüm değerlendirme süreçlerinde kullanımına dair de birçok çalışma bulunmaktadır. Bunun nedeni, dijital dönüşümün işletme ve tedarik zinciri içinde çeşitli düzeylerde karar vermeyi gerektirmesidir (Lo ve Siao, 2023). Bu süreç genellikle maliyet, fayda, sosyal ve çevresel etkiler ve risk gibi çeşitli faktörleri kapsamaktadır. Organizasyonlar, ÇKKV tekniklerini kullanarak bu karmaşık karar verme prosedürlerini daha etkin bir şekilde yönetebilir ve modernize edebilir, böylece kararlarının hem hassasiyetini hem de etkinliğini artırabilir. Örneğin, ÇKKV dijital dönüşüme yönelik farklı stratejileri değerlendirme ve karşılaştırma amacıyla uygulanabilir. Bunun sonucunda işletme, hedeflerine ve gereksinimlerine en uygun stratejiyi seçebilir (Abdallah vd., 2022; Uslu vd., 2019). Ayrıca ÇKKV, dijital dönüşüm yolculuğu boyunca çeşitli paydaşların farklı ihtiyaç ve çıkarlarını uzlaştırma konusunda kuruluşlara yardımcı olabilir (Liu vd., 2024). Dijital dönüşüm risklerinin belirlenmesi ve önceliklendirilmesi amacıyla ÇKKV tekniklerinden yararlanılmaktadır (Hasani vd., 2024).

Endüstri 4.0'a yönelik olgunluk modelleri üzerine yürütülen güncel çalışmalarda, genellikle ağırlıklandırma ve değerlendirme süreçlerine yönelik çeşitli yöntem ve modeller geliştirilmiştir. Angreani vd., (2023), Endüstri 4.0 olgunluk seviyelerinin belirlenmesi için bulanık TOPSIS ve DEMATEL yöntemlerini kullanarak dijital dönüşüm süreçlerini çok boyutlu bir yaklaşımla ele almışlardır. Benzer şekilde, Chang vd., (2021), küçük ve orta ölçekli işletmelerin (KOBİ) dijital dönüşüm kapasitelerini analiz etmek için DEMATEL ve VIKOR yöntemlerinden yararlanarak, teknoloji uygulamalarının işletmeler üzerindeki etkisini değerlendirmişlerdir. Örneğin, Elibal vd. (2024) tarafından geliştirilen ERP tabanlı Endüstri 4.0 olgunluk modeli, KOBİ'lerin dijital dönüşüm sürecine entegrasyonunu kolaylaştırmak amacıyla ERP işlevlerine dayalı bir değerlendirme sunmaktadır. Tuş vd., (2023) dijital dönüşüm endeksinin hesaplanması için Bayesian BWM tekniğinden yararlanmışlardır. Demirel vd., (2024) AHP, TOPSIS ve PROMETHEE yöntemlerini kullanarak Türk savunma sanayiindeki firmaların dijital olgunluk seviyelerini analiz eden bir metodolojik yaklaşım sunmaktadırlar.

Dijital dönüşümün sektörel bazda etkilerini analiz eden araştırmalarda, özellikle tekstil ve beyaz eşya sektörlerinde yapılan çalışmalar dikkat çekmektedir. Çevik Aka (2023), tekstil sektöründe Endüstri 4.0'ın işletmelerin çeviklik özelliklerine etkisini incelemiş ve FUCOM yöntemi ile en etkili çeviklik yeteneklerini belirlemiştir. Dermenci ve Sağbaş (2023) ise beyaz eşya sektöründe faaliyet gösteren bir firmanın dijital olgunluk seviyesini AHP ve TOPSIS yöntemleri ile değerlendirmiştir. Benzer şekilde, Akman ve Kokumer (2023), beyaz eşya sektöründe dijital dönüşüm sürecindeki başlangıç noktalarını belirlemek amacıyla bir model geliştirmiştir. Bu çalışma, firmaların dijital dönüşüm yetkinliklerini başlangıç aşamasında belirleyerek yol haritası oluşturmalarına katkı sağlamaktadır. Dijital dönüşüm stratejilerinin belirlenmesi konusunda Uslu vd., (2019), ÇKKV yöntemlerini kullanarak işletmelerin Endüstri 4.0 strateji seçimlerine yönelik çözümler sunmuşlardır. AHP ve TOPSIS gibi yaygın yöntemlerin kullanıldığı bu çalışma, dijital dönüşüm stratejilerinin çok boyutlu analizinin önemine dikkat çekmektedir. Sektörel bazda geliştirilen modellerden biri olan Görçün vd., (2024) çalışması, otomotiv sektöründe dijital dönüşüm stratejilerini sürdürülebilirlik açısından değerlendirerek sektöre özgü bir yöntem sunmaktadır. Ancak bu model, daha çok teknolojik stratejilere odaklanmakta ve geniş çapta uyarlanabilir bir yapı içermemektedir.

Buna karşılık, Erik ve Kuvvetli (2021) veri zarflama analizi ile işletmelerin Endüstri 4.0 uyum yeteneğini değerlendirmiş ve dijitalleşme süreçlerinde işletmelerin bilgi teknolojileri, ARGE faaliyetleri ve süreç iyileştirme gibi kriterler üzerinden nasıl farklılıklar gösterdiğini ortaya koymuştur. Özdemir (2022) ise KOBİ'lerde Endüstri 4.0 performansını değerlendirmek için bulanık performans ölçüm modeli geliştirmiştir. Bu çalışmalarda kullanılan metodolojiler, dijital dönüşümün farklı sektörlerdeki uygulanabilirliğine dair geniş bir bakış açısı sunmaktadır. Dijital dönüşümün önündeki engelleri inceleyen Sharma vd., (2022), KOBİ'lerde karşılaşılan yaygın engelleri bulanık AHP ve PROMETHEE yöntemleri ile analiz ederek bu engellerin üstesinden gelmek için stratejik çözümler geliştirmiştir. Sriram ve Vinodh (2021) ise COPRAS yöntemi kullanarak KOBİ'lerde Endüstri 4.0 uygulamasına hazırlık faktörlerini analiz etmişlerdir. Bu çalışmalar, dijital dönüşüm sürecinin her işletmede farklı şekillerde ortaya çıkan zorluklara karşı stratejik bir yaklaşımla ele alınması gerektiğini vurgulamaktadır.

Literatürde SWARA-GİA yönteminin dijital dönüşüm alanında sınırlı olsa da diğer sektörlerdeki karar verme süreçlerinde yaygın olarak kullanıldığı görülmektedir (Supçiller ve Bayramoğlu, 2020; Ghoushchi vd., 2020; Muneeb vd., 2024). Enerji sektöründe belirsizlikleri azaltmak amacıyla rüzgar santrali yer seçimi (Supçiller ve Bayramoğlu, 2020), lojistik sektöründe performans düşüşlerini önlemek için finansal analiz (Özbek ve Demirkol, 2018), üretim işletmelerinin finansal performans değerlendirmesi (Özdağoğlu ve Keleş, 2019), dijital platform tercih kriterlerinin değerlendirilmesi (Erdem vd., 2023) ve kara kuşak eğitimi alacak personelin seçiminde (Çakır ve Kacı, 2018) SWARA-GİA'nın kullanımı dikkat çekmektedir.

Bu çalışmada, üretim sektöründe faaliyet gösteren işletmelerin dijital dönüşüm süreçlerini etkin bir şekilde değerlendirmek ve bu süreçte izlenecek kritik faktörlerin belirlenmesi amaçlanmaktadır. Literatürde, dijital dönüşüm performans ölçümünde SWARA ve GİA yöntemlerinin birlikte kullanıldığı herhangi bir çalışmaya rastlanmamaktadır. Bu çalışma ile dijital dönüşümde karşılaşılan belirsizliklerin azaltılması ve dijitalleşme sürecinin çok yönlü bir yaklaşımla değerlendirilmesi hedeflenmiştir. Çalışmada, dijital dönüşüm performansının ölçümünde, kriterlerin ağırlıklandırılmasında SWARA yöntemi ve performans hesaplamasında GİA ilk kez birlikte kullanılmıştır. Bu yöntemlerin tercih edilme nedenleri arasında, SWARA'nın subjektif kararları minimal seviyeye indirerek uzman görüşlerini sistematik bir şekilde değerlendirmesi ve az sayıda karşılaştırma yapması gibi avantajlar bulunmaktadır (Supçiller ve Bayramoğlu, 2020). SWARA yöntemi, n kriter için yalnızca $(n-1)$ adet karşılaştırma gerektirmesi nedeniyle karmaşık yapılar karar verme problemlerine uygun bir çözüm sunmaktadır. Ayrıca, karar vericilere kriterleri daha özgür bir şekilde değerlendirme imkanı sağlamakta, ikili karşılaştırmalar için kullanılacak sabit bir ölçek gerektirmemektedir (Stanujkic vd., 2015). Bu özellikleri sayesinde SWARA, dijital dönüşüm gibi çok boyutlu ve dinamik yapıya sahip alanlara uygulandığında hızlı ve esnek bir çözüm sunmaktadır. GİA yöntemi, performans değerlendirme çalışmalarında yaygın olarak kullanılan ve başarılı sonuçlar vermesiyle bilinen bir analiz tekniğidir. Özellikle ÇKKV süreçlerinde, çeşitli faktörler arasındaki ilişkileri etkili bir şekilde ortaya koyma kapasitesi sayesinde sıklıkla tercih edilmektedir (Ervural, 2023). GİA, alternatiflerin çok boyutlu performanslarını karşılaştırmada güvenilir ve tutarlı sonuçlar sunmakta, karar vericilere uygulama kolaylığı sağlamaktadır. Bu bağlamda, SWARA ve GİA yöntemlerinin dijital dönüşüm alanında sağladığı objektif analizler, işletmelerin dijitalleşme sürecindeki kritik önceliklerini belirlemesine rehberlik edecek niteliktedir. Bu çalışma, dijital dönüşüm performansını analiz etmek için yeni bir uygulama alanı sunarak literatüre özgün bir katkı sağlamaktadır.

DİJİTAL DÖNÜŞÜM DEĞERLENDİRME FAKTÖRLERİNİN BELİRLENMESİ

Dijital teknolojilerin hızla gelişmesi ve dijitalleşmenin üretim süreçlerine entegrasyonu, işletmelerin dijital dönüşüm seviyelerini ölçme gerekliliğini de beraberinde getirmiştir. Dijital dönüşümün etkin bir şekilde yönetilebilmesi için işletmelerin, dijitalleşme süreçlerini doğru bir şekilde değerlendirebilmesi kritik öneme sahiptir. Bu değerlendirmeyi sağlamak amacıyla, literatürde ve uygulamada çeşitli modeller ve çerçeveler geliştirilmiştir. Ancak, her işletmenin kendi sektörel dinamiklerine ve dijitalleşme hedeflerine uygun kriterlerle dijital dönüşümünü değerlendirmesi gerekmektedir.

Bu çalışmada, üretim sektöründeki işletmelerin dijital dönüşüm etkinliklerini ölçmek üzere kullanılacak kriterlerin belirlenmesi için kapsamlı bir literatür taraması gerçekleştirilmiştir. Dijital dönüşüm performansını etkileyen faktörler, mevcut çalışmalardaki öneriler ve uygulamalar dikkate alınarak sınıflandırılmıştır. Literatür taraması sonucunda, dijital dönüşüm süreçlerinde dikkate alınması gereken kriterler üç ana başlık altında toplanmıştır: (i) Teknolojik yetenekler, (ii) İnsan ve organizasyonel faktörler ve (iii) Operasyonel verimlilik ve entegrasyon.

Bu ana başlıklar altında, dijital dönüşüm süreçlerinin farklı yönlerini kapsayan alt başlıklar ve kriterler tanımlanmıştır. Belirlenen kriterler, dijital dönüşümün sadece ileri teknolojilerle değil, aynı zamanda işletme kültürü, çalışanların yetkinliği ve organizasyonel değişime adaptasyon kapasitesi gibi insan ve yönetsel faktörlerle de ilgili olduğunu göstermektedir.

Bu kapsamda, dijital dönüşüm performansını değerlendirmek amacıyla toplamda 6 ana kriter ve bu ana kriterler altında 26 alt kriter tanımlanmıştır. Bu kriterler, işletmelerin dijital dönüşüm süreçlerini kapsamlı bir şekilde değerlendirmelerine olanak tanıyan bir çerçeve sunmaktadır. Çalışmada kullanılan kriterler Tablo 1'de sunulmuştur.

Teknolojik Yetenekler

Dijital dönüşüm sürecinde teknolojik yetenekler, işletmelerin dijitalleşme düzeylerini belirlemede kritik bir rol oynamaktadır. Teknolojinin bu süreçteki katkıları, üretim sistemlerini daha verimli hale getirmek, süreçleri optimize etmek ve yenilikçi çözümler sunmak açısından büyük önem taşır. Bu başlık altında, dijital dönüşümde önemli yere sahip akıllı üretim teknolojileri ve veri ile yazılım altyapısına odaklanılmaktadır.

i. Akıllı Üretim Teknolojileri (K1)

- Gelişmiş Robotik (Otonom ve İşbirlikçi Robotlar) (K1.1): Otonom ve işbirlikçi robotlar, dijital dönüşümün temel taşlarından biridir. Bu robotlar, gömülü bilişim sistemleri ve yapay zekâ tekniklerini kullanarak karar verebilme, bu kararları eyleme dönüştürebilme yeteneklerine sahiptirler. Robotlar,

üretim süreçlerinde veri toplama, analiz etme ve diğer akıllı nesnelere iletişim kurma becerisiyle işletmelerin verimliliğini artırmaktadır (Paksoy vd., 2020).

Tablo 1. Dijital Dönüşüm Etkinlik Değerlendirme Kriterleri

Ana kriterler		Alt Kriterler	Çalışma(lar)
Teknolojik Yetenekler	K1-Akıllı üretim teknolojileri	K1.1-Gelişmiş Robotik (Otonom ve İşbirlikçi Robotlar)	Ayyıldız ve Demir (2022) Biby ve Dehe (2018) Kamble vd., (2019)
		K1.2-Siber Fiziksel Sistemler	Angreani vd., (2023) Kocaoğlu ve Kırmızı (2024) Osterrieder (2020) Yıldızbaşı ve Ünlü (2020)
		K1.3-Dijital İkiz ve Artırılmış Gerçeklik	Dermenci ve Sağbaş (2023) Yıldızbaşı ve Ünlü (2020)
		K1.4-Eklemeli İmalat teknolojisi	Angreani vd., (2023) Chowdhury vd., (2024) Wagire vd., (2020)
	K2-Veri ve yazılım altyapısı	K2.1-Endüstriyel Nesnelere İnterneti	Angreani vd., (2020) Biby ve Dehe (2018) Osterrieder (2020)
		K2.2-Endüstriyel Veri Güvenliği	Dermenci ve Sağbaş (2023) Kökümer (2018) Özdemir (2022)
		K2.3-Büyük Veri ve Analitik	Kocaoğlu ve Kırmızı (2024) Hitham vd., (2023) Yıldızbaşı ve Ünlü (2020)
		K2.4-Bulut Bilişim ve Uç Bilişim (Edge Computing)	Angreani vd., (2020) Biby ve Dehe (2018) Dermenci ve Sağbaş (2023)
		K2.5-Kurumsal Kaynak Planlaması (ERP) Yazılımı	Kasnak ve Özkara (2022) Özdemir (2022)
		K2.6-Blozkinciri Teknolojisi	Kasnak ve Özkara (2022) Wang ve Sao (2024)
İnsan ve Organizasyonel Faktörler:	K3-İşgücü Gelişimi ve Stratejik Bağlılık	K3.1-Dijital beceriler ve yetkinlik geliştirme	Büyüközkan ve Güler (2019). Wagire vd., (2020)
		K3.2-İnsan-robot iş birliği	Osterrieder (2020) Kasnak ve Özkara (2022)
		K3.3-Yatırım ve kaynak tahsisi	Dermenci ve Sağbaş (2023) Keskin vd., (2019) Xu ve Yin (2025)
		K3.4-Dijital dönüşüm stratejisi	Büyüközkan vd., (2020) Hitham vd., (2023) Karadağ vd., (2024)
		K3.5-Liderlik Desteği ve vizyonu	Büyüközkan ve Güler (2019) Hitham vd., (2023) Chen vd., (2024)
Operasyonel verimlilik ve entegrasyon	K4-Üretim Süreci Otomasyonu	K4.1-Süreç Otomasyonu ve Kontrolü	Alkan ve Kahraman (2019) Kalender ve Zilka (2024) Angreani vd., (2023)
		K4.2-Ürün ve Üretim İzlenebilirliği	Wagire vd., (2020)
		K4.3-Kestirimci Bakım ve Arıza Tespiti	Dotoli vd., (2018)
		K4.4-Esneklik ve Yeniden Yapılandırılabilirlik	Sriram ve Vinodh (2020)
	K5-Kesintisiz Mühendislik ve Optimizasyon Uygulamaları	K5.1-Dijital Tasarım ve Prototipleme	Doğan ve Baloğlu (2020)
		K5.2-Üretim Yürütme Sistemleri (MES) Kullanımı	Biby ve Dehe (2018) Kökümer (2018)
		K5.3-Envanter Optimizasyon Uygulamaları	Khan ve Ahmed (2024) Liu ve Nishi (2023)
		K5.4-Enerji Tüketiminin İzlenmesi ve Optimizasyonu	Dotoli vd., (2018) Chen vd., (2024)
		K6-Entegrasyon ve Bağlantı	Godbole (2023) Keskinkılıç ve İpkin (2023)
K6-Entegrasyon ve Bağlantı	K6.2-Elektronik Ticaret Uygulamaları	Ayyıldız ve Demir (2022) Wang ve Sao (2024)	
	K6.3-Dijital Teknolojilerin Entegrasyonu	Angreani vd., (2020) Ayyıldız ve Demir (2022) Büyüközkan vd., (2020)	

- **Siber Fiziksel Sistemler (K1.2):** Bu sistemler, fiziksel işlemleri sanal dünya ile entegre eden yapılardır. Sensörler ve aktüatörlerle fiziksel dünyadaki süreçleri izleyen, koordine eden ve kontrol eden bu sistemler, akıllı üretim süreçlerinde merkezi bir rol oynar. Siber-fiziksel sistemler sayesinde üretim süreçleri daha esnek ve verimli hale gelmektedir (Dökme, 2020).
 - **Dijital İkiz ve Artırılmış Gerçeklik (K1.3):** Dijital ikizler, bir ürün ya da sistemin dijital bir kopyasıdır ve gerçek zamanlı verilerle güncellenerek sanal simülasyonlar yapmayı sağlar. Bu teknoloji, üretim süreçlerini optimize etme ve bakım gereksinimlerini öngörme gibi faydalar sunar. Artırılmış gerçeklik ise, fiziksel dünyaya sanal unsurlar ekleyerek üretim süreçlerini zenginleştirir (Attaran vd., 2024).
 - **Eklemeli İmalat Teknolojisi (K1.4):** Eklemeli imalat, malzemelerin katmanlar halinde üst üste biriktirilerek nesnelerin oluşturulmasını sağlar. 3D baskı teknolojisi sayesinde hızlı ve maliyet etkin üretim süreçleri gerçekleştirilebilir. Bu teknoloji, özellikle özel ve küçük ölçekli üretimlerde önemli avantajlar sunmaktadır (Bhatia ve Sehgal, 2023).
- ii. **Veri ve yazılım altyapısı (K2)**
- **Endüstriyel Nesnelerin İnterneti (K2.1):** Üretim süreçlerindeki cihazların ve makinelerin internet aracılığıyla birbirine bağlanması ve veri alışverişi yapması, üretim ortamının sürekli izlenmesini ve optimize edilmesini sağlar. Bu teknoloji sayesinde fabrikalar, süreçleri gerçek zamanlı olarak izleyip yönetebilir, üretim verimliliğini artırabilir (Kesbiç, 2020).
 - **Endüstriyel Veri Güvenliği (K2.2):** Dijitalleşen dünyada veri güvenliği kritik bir unsur haline gelmiştir. Üretim süreçlerindeki hassas bilgilerin korunması, dijital dönüşümde başarılı olmanın ön koşullarından biridir. Veri güvenliği, sadece verilerin korunmasını değil, aynı zamanda veri alışverişinin güvenli ve kesintisiz olmasını da kapsar (Cheminod vd., 2013).
 - **Büyük Veri ve Analitik (K2.3):** Büyük veri, üretim süreçlerinden elde edilen büyük hacimli verilerin analiz edilmesini sağlayarak işletmelerin stratejik karar alma süreçlerine katkıda bulunur. Büyük veri analitiği, özellikle üretim verimliliğini artırmak ve süreç optimizasyonu sağlamak açısından önemli bir role sahiptir (Sahut vd., 2022).
 - **Bulut Bilişim ve Uç Bilişim (K2.4):** Bulut bilişim, işletmelere büyük miktarda veri depolama ve işleme kapasitesi sunarken, uç bilişim teknolojisi verilerin kaynağa daha yakın bir noktada işlenmesini sağlar. Bu teknolojiler, üretim süreçlerinde esnekliği artırmak ve maliyetleri düşürmek açısından önemli avantajlar sunmaktadır (Singla vd., 2018).
 - **Kurumsal Kaynak Planlaması (ERP) Yazılımı (K2.5):** ERP yazılımları, işletmenin tüm kaynaklarını entegre bir şekilde yönetmesini sağlayan sistemlerdir. Bu yazılımlar, üretim süreçleri, finans, muhasebe ve diğer işletme fonksiyonları arasında veri akışını sağlarken, Endüstri 4.0 ile birlikte akıllı fabrikaların temelini oluşturur (Kökümer, 2018).
 - **Blokszinciri Teknolojisi (K2.6):** Blokszincir, işletmeler arası veri paylaşımında şeffaflık ve güvenlik sağlayan bir teknoloji olarak dijital dönüşümde önemli bir yere sahiptir. İşletmeler arasındaki işlemlerin güvenli bir şekilde kaydedilmesi ve takip edilmesi, blokszincir teknolojisinin sağladığı avantajlardan biridir (Han vd., 2023).

İnsan ve Organizasyonel Faktörler

Dijital dönüşüm süreci sadece teknolojik yeniliklerle sınırlı değildir; aynı zamanda işletmelerin çalışanlarının yetkinlikleri, organizasyonel yapıları ve stratejik yaklaşımları bu süreçte kritik bir rol oynar. İnsan ve organizasyonel faktörler, işletmelerin dijital dönüşüme uyum sağlamasını ve başarıyla sürdürmesini etkileyen önemli unsurlardır. Bu başlık altında iş gücü gelişimi ve stratejik bağlılık, liderlik desteği ve kaynak tahsisi gibi konular ele alınmaktadır.

i. İşgücü Gelişimi ve Stratejik Bağlılık (K3)

- **Dijital Beceriler ve Yetkinlik Geliştirme (K3.1):** İşletmelerin Endüstri 4.0'a uyum sağlaması için çalışanların dijital becerilerini geliştirmesi gerekmektedir. Dijital dönüşüm sürecinde teknolojik gelişmeler, işgücü piyasasında önemli değişikliklere neden olmakta ve bu süreç çalışanların dijital yetkinliklerini geliştirmesini gerektirmektedir. Özellikle robotik teknolojiler ve dijital sistemlerdeki ilerlemeler, mevcut iş gücünün becerilerinin sürekli olarak güncellenmesini zorunlu kılmaktadır (Goulart vd., 2022).

- İnsan-Robot İş Birliği (K3.2): Dijital dönüşümde işçilerin ve robotların birlikte çalışabilmesi, verimlilik artışı ve iş süreçlerinin optimize edilmesi açısından büyük bir öneme sahiptir. İnsan-robot iş birliği, özellikle üretim alanlarında hem verimliliği artırmakta hem de çalışanların robotlarla birlikte daha etkin bir şekilde çalışmasını sağlamaktadır. Bu iş birliği, endüstriyel süreçlerde insan faktörünü güçlendirirken robotların mekanik işlerde etkin rol almasına olanak tanır.
- Yatırım ve Kaynak Tahsisi (K3.3): Dijital dönüşüm sürecinde teknolojilere ve insan kaynağına yapılacak yatırımlar, sürecin başarısında kritik bir rol oynar. İşletmelerin yeni teknolojilere adaptasyon sağlaması ve çalışanlarını dijital beceriler açısından eğitmesi için bilgi teknolojilerine ve insan kaynaklarına yatırım yapması gerekmektedir. Bu yatırımlar, dijital dönüşüm süreçlerinin sürdürülebilirliğini sağlar.
- Dijital Dönüşüm Stratejisi (K3.4): İşletmelerin dijital dönüşüm süreçlerinde belirledikleri strateji, dijital teknolojilerin etkin bir şekilde entegre edilmesi açısından önemlidir. Dijital dönüşüm stratejisi, işletmenin genel iş hedefleriyle uyumlu olmalı ve sürdürülebilir bir dijitalleşme sürecini desteklemelidir. Net bir yol haritası ve kapsamlı bir strateji olmadan, dijital dönüşüm süreçleri başarısız olabilir (Mitroulis ve Kitsios, 2019).
- Liderlik Desteği ve Vizyonu (K3.5): Dijital dönüşümün işletmelerde başarılı olabilmesi için liderlerin sürece kararlılıkla katılımı ve destek vermesi gereklidir. Dijital liderlik, organizasyonun dijital varlıklarını stratejik hedefler doğrultusunda etkin bir şekilde yönetmeyi gerektirir. Liderlik desteği, dijital dönüşümün tüm organizasyon genelinde benimsenmesi ve sürdürülebilirliği açısından kritik öneme sahiptir (Kıyak ve Bozkurt, 2020).

Operasyonel Verimlilik ve Entegrasyon

Dijital dönüşüm sürecinde operasyonel verimliliği artırmak ve işletme süreçlerini entegre etmek, işletmelerin rekabet avantajını sürdürebilmesi için büyük önem taşır. Bu bağlamda, üretim süreci otomasyonu, kesintisiz mühendislik ve optimizasyon uygulamaları, entegrasyon ve bağlantı gibi konular işletmelerin dijital dönüşümünü hızlandıran faktörler olarak öne çıkar.

i. Üretim Süreci Otomasyonu (K4)

- Süreç Otomasyonu Kontrolü (K4.1): Üretim süreçlerinde otomasyon, verimliliği artırmanın ve insan hatalarını en aza indirmenin önemli bir yoludur. Otomasyon teknolojileri, robotlar, sayısal kontrol (NC) makineleri, programlanabilir mantık kontrolörleri (PLC'ler), CNC sistemleri ve endüstriyel sensörler gibi çeşitli araçlarla sağlanabilir. Bu teknolojiler, üretim görevlerinin gerçek zamanlı izlenmesini ve kontrolünü mümkün kılar, böylece kalite, güvenlik ve üretkenlik artışı sağlar (Anonim, 2023).
- Ürün ve Üretim İzlenebilirliği (K4.2): Üretim süreçlerinin her aşamasında izlenebilirlik sağlanması, özellikle tedarik zinciri yönetimi için kritik bir unsurdur. Nesnelerin interneti (IoT), RFID etiketleri, barkodlar ve GPS gibi teknolojiler, ürünlerin tedarik zinciri boyunca her adımda izlenebilmesine olanak tanır. İzlenebilirlik sayesinde ürünlerin nerede, ne zaman ve kim tarafından üretildiği takip edilebilir, bu da kalite kontrol ve geri çağırma süreçlerini iyileştirir (Koç, 2020).
- Kestirimci Bakım ve Arıza Tespiti (K4.3): Kestirimci bakım, makine ve ekipmanlarda oluşabilecek arızaları önceden tahmin ederek, plansız duruşları en aza indiren bir yöntemdir. Makine öğrenmesi algoritmaları ve sensörler aracılığıyla toplanan veriler kullanılarak arıza tahminleri yapılır ve bakım süreçleri optimize edilir. Bu süreç, işletmelerin bakım maliyetlerini düşürmesine ve operasyonel verimliliği artırmasına yardımcı olur (Ceyhan ve Kasapbaşı, 2021; Özkat, 2021).
- Esneklik ve Yeniden Yapılandırılabilirlik (K4.4): Dijital dönüşüm süreçlerinde esneklik, değişen müşteri taleplerine ve piyasa koşullarına hızla adapte olabilmek için kritik bir yetenektir. Yeniden yapılandırılabilir üretim sistemleri, modüler ve isteğe göre uyarlanabilen yapılar sunarak üretim süreçlerinin hızla değiştirilmesine olanak tanır. Bu esneklik, hatalı ürünlerin yeniden işlenebilmesi, stok maliyetlerinin azaltılması ve taleplere hızlı cevap verebilme gibi avantajlar sağlar (Santos vd., 2017).

ii. Kesintisiz Mühendislik ve Optimizasyon Uygulamaları (K5)

- Dijital Tasarım ve Prototipleme (K5.1): Dijital tasarım araçları ve üç boyutlu yazıcılar, ürün geliştirme süreçlerinde prototiplerin hızlı ve düşük maliyetli bir şekilde üretilmesine olanak tanır. Bu yöntemler, mühendislerin daha yenilikçi ve karmaşık tasarımlar geliştirmesini sağlar, aynı zamanda üretim hatalarını

en aza indirir. Dijital prototipleme araçları, geleneksel prototipleme yöntemlerine kıyasla daha hızlı ve esnek çözümler sunar (Nelson vd., 2020).

- Üretim Yürütme Sistemleri (MES) Kullanımı (K5.2): MES, hammaddeden bitmiş ürüne kadar üretim sürecini izleyen ve kontrol eden kapsamlı bir yazılım sistemidir. MES, operatörler için veri yönetimi, süreç izleme ve kalite kontrol işlevleri sağlar. Aynı zamanda, üretim süreçlerinin gerçek zamanlı takibini sağlayarak maliyetleri düşürür, kaliteyi artırır ve üretim süreçlerinin optimizasyonuna katkıda bulunur (Chen ve Voigt, 2020).
- Envanter Optimizasyon Uygulamaları (K5.3): Stokların doğru seviyede tutulması, maliyetleri düşürmek ve müşteri taleplerini karşılamak için önemlidir. Envanter optimizasyonu, lojistik maliyetlerini en aza indirmek ve stok fazlası veya eksikliği gibi sorunları önlemek için kullanılan yazılım ve algoritmaların uygulanmasıdır.
- Enerji Tüketiminin İzlenmesi ve Optimizasyonu (K5.4): Enerji tüketimi, dijital dönüşüm süreçlerinde dikkat edilmesi gereken önemli bir maliyet unsurudur. Sensörler ve enerji yönetim sistemleri kullanarak enerji tüketimi izlenebilir ve optimize edilebilir. Bu süreç, işletmelerin enerji maliyetlerini düşürmesine ve sürdürülebilirlik hedeflerine ulaşmasına yardımcı olur (Dotoli vd., 2016).

iii. Entegrasyon ve Bağlantı (K6)

- ERP Yazılımının Entegrasyonu (K6.1): ERP sistemleri, işletmelerin tüm departmanlarının verilerini ve süreçlerini entegre ederek iş birliği sağlar. ERP, maliyetleri düşürmek, stratejik karar almayı kolaylaştırmak, süreç iyileştirmeleri yapmak ve esnekliği artırmak için önemli bir araçtır. İşletmelerde ERP'nin entegrasyonu, verilerin gerçek zamanlı olarak departmanlar arasında paylaşılmasını sağlar, bu da daha hızlı ve etkili kararlar alınmasına yardımcı olur (Tarigan vd., 2020).
- Elektronik Ticaret Uygulamaları (K6.2): E-ticaret, işletmelerin ticari faaliyetlerini internet üzerinden gerçekleştirmelerini sağlayarak, maliyetlerin azalması ve fiyatların düşmesi gibi avantajlar sunar. E-ticaret, geleneksel ticaret modellerini değiştirerek daha hızlı ve etkin bir müşteri deneyimi sağlar (Güven, 2020).
- Dijital Teknolojilerin Entegrasyonu (K6.3): İşletmelerde dijital teknolojilerin entegrasyonu, süreçlerin verimli bir şekilde yönetilmesi ve optimize edilmesi için kritik öneme sahiptir. API'ler, middleware, SOA ve EDI gibi entegrasyon teknolojileri, işletmelerin farklı sistemler arasında veri alışverişini yapmasını ve süreçlerini sorunsuz bir şekilde yönetmesini sağlar.

METODOLOJİ

Bu bölümde, işletmelerin dijital dönüşüm performanslarını değerlendirmek amacıyla kullanılan yöntemler ve sürecin detayları ele alınmaktadır. Çalışmada, kriter ağırlıklandırma için SWARA yöntemi, performans ölçüm aşamasında ise GİA yöntemi kullanılmıştır.

SWARA Yöntemi

SWARA (Aşamalı Ağırlık Değerlendirme Oran Analizi) yöntemi, kriterlerin ağırlıklandırılması sürecinde karar vericilerin uzmanlıklarına dayanarak daha öznel bir değerlendirme yapmalarına olanak sağlar. SWARA yöntemi, ilk olarak Keršulienė, Zavadskas ve Turskis tarafından önerilmiştir (Keršulienė vd., 2010) ve son yıllarda ağırlık belirleme amacıyla sıklıkla tercih edilen yöntemlerden biri haline gelmiştir. SWARA yöntemi, basit yapısıyla farklı uzmanların veya karar vericilerin aynı anda ortak bir amaç için iş birliği yapmasını kolaylaştırır. Bu durum, özellikle zaman kısıtlaması olan projelerde önemli bir avantaj sunar (Hashemkhani Zolfani vd., 2015). AHP gibi yöntemlere kıyasla, SWARA yönteminde yapılan ikili karşılaştırmaların sayısı daha azdır, bu da işlem maliyetini azaltır. Ayrıca, işlem adımları daha basit ve hızlı olduğundan, karar vericilerin zamandan tasarruf etmesini sağlar (Çakır, 2018). SWARA yöntemi, karar vericilere kendi önceliklerini seçme imkânı tanır. Kriterler arasındaki öncelik sıralamasının uzmanlar tarafından belirlenmesi, sonuçların daha stratejik olmasını sağlar. SWARA yönteminin şu şekildedir:

Adım 1: Uzmanlar, kriterler için önem sıralaması yapar. Örneğin en önemli olan ilk sırada, en önemsiz olan en son sırada olacak şekilde sıralama yapılır.

Adım 2: İkinci kriterden başlanarak, $j-1$. kriter ile j . kriterin kıyaslaması yapılır ve $j-1$. kriterin j . kritere karşı göreceli önemi belirlenir. Bu belirlenen değere (s_j) "ortalama değer karşılaştırmalı önemi" adı verilmiştir. s_j değeri için uzmanlar, 0,05 ve katlarını kullanmışlardır.

Adım 3: Tüm kriterler için katsayı değeri k_j , Denklem (1) kullanılarak hesaplanır.

$$k_j = \begin{cases} 1 & j = 1 \\ s_j + 1 & j > 1 \end{cases} \quad (1)$$

Adım 4: Tüm kriterler için q_j değeri yani düzeltilmiş ağırlıklar Denklem (2) kullanılarak hesaplanır. Birinci sırada yer alan kriterin q_j değeri 1 olarak kabul edilir ve q_j hesaplanırken q_j 'ye göre yapılan sıralama dikkate alınır.

$$q_j = \begin{cases} 1 & j = 1 \\ \frac{k_{j-1}}{k_j} & j > 1 \end{cases} \quad (2)$$

Adım 5: Bütün kriterler için nihai ağırlıkların hesaplaması Denklem (3) kullanılarak yapılır.

$$w_j = \frac{q_j}{\sum_{k=1}^n q_k} \quad \forall j = 1, \dots, n \quad (3)$$

Gri İlişkisel Analiz Yöntemi

Gri İlişkisel Analiz (GİA), 1982 yılında Deng tarafından geliştirilen Gri Sistem Teorisi'nin bir parçası olarak belirsizlik durumlarında karar verme süreçlerinde kullanılan bir yöntemdir. Gri sistem teorisi, özellikle belirsiz, eksik veya kısmen belirlenmiş verilerle çalışırken faydalı bir yaklaşımdır. GİA, ayrı veri setleri arasındaki ilişkileri analiz ederek bu veriler arasında bir bağ kurulmasına olanak sağlar. Yöntemin en büyük avantajları, orijinal verilere dayanması, hesaplamalarının kolay ve anlaşılır olmasıdır. GİA, özellikle ÇKKV süreçlerinde, alternatiflerin performanslarını ölçmek ve en iyi seçimi belirlemek amacıyla kullanılır. Dijital dönüşüm performansını değerlendirme gibi çok sayıda kriterin bulunduğu alanlarda bu yöntem, işletmelere doğru ve güvenilir bir karar verme imkânı sunar.

GİA'da ilk adım, tüm alternatiflerin belirlenerek karşılaştırılabilirlik dizilerine dönüştürülmesidir. Bu diziler, her alternatifin performansını temsil eden kriterlere göre düzenlenir. İkinci adımda, ideal hedef olarak kullanılacak bir referans dizi tanımlanır. Bu referans dizi, tüm kriterler açısından en iyi performansı sergileyen durumu temsil eder. Üçüncü adım, verilerin normalize edilmesidir. Normalize işlemi, farklı ölçeklerdeki kriterlerin karşılaştırılabilir hale getirilmesini sağlar ve veriler 0 ile 1 arasında değerlere dönüştürülür. Bu sayede, tüm kriterler aynı ölçek üzerinden değerlendirilmiş olur. Normalleştirilmiş veriler kullanılarak referans dizi ile diğer karşılaştırılabilirlik dizileri arasındaki Gri İlişkisel katsayı hesaplanır. Bu katsayı, her alternatifin referans dizisine ne kadar yakın olduğunu gösterir. Son adımda, referans dizi ile karşılaştırılabilirlik dizileri arasındaki Gri İlişkisel dereceler hesaplanır. Gri ilişkisel dereceler, alternatiflerin birbirine olan yakınlıklarını belirlemek için kullanılır. En yüksek Gri İlişkisel skora sahip alternatif, en iyi seçenek olarak değerlendirilir. GİA yönteminin adımları şu şekildedir:

Adım 1: Karar Matrisinin Oluşturulması

İlk adımda alternatiflerin kriter değerlerini belirten karar matrisi oluşturulur. Burada n alternatifleri, m kriterleri, $x_i(j)$ i. alternatifin j. kritere göre değerini göstermektedir ve $n \times m$ boyutlu karar matrisi Denklem (4)'deki gibi oluşturulur.

$$x_i = \begin{bmatrix} x_1(1) & x_1(2) & \dots & x_1(n) \\ x_2(1) & x_2(2) & \dots & x_2(n) \\ \vdots & \ddots & \dots & \vdots \\ x_m(1) & x_m(2) & \dots & x_m(n) \end{bmatrix} \quad (4)$$

Adım 2: Referans Serisinin Belirlenmesi

Gri ilişkisel analizin bu aşamasında değerlendirme kriterlerine ilişkin referans serileri belirlenmelidir. Referans seri $x_0 = x_0(1), x_0(2), \dots, x_0(j) \dots \dots x_0(n)$ şeklindedir. $x_0(j) = j, j$. Kriterin değerleri arasındaki en büyük, en küçük ve olması istenen bir değeri belirtmektedir.

Adım 3: Karar Matrisinin Normalize Edilmesi

Normalizasyon işlemi fayda durumu, maliyet durumu ve optimal durum olmak üzere 3 farklı şekilde yapılmaktadır. Seri değerlerinin daha büyük olması amaca olumlu katkı sağlıyorsa normalizasyon işlemi Denklem (5) ile gerçekleştirilir.

$$x_i^* = \frac{x_i(j) - \min x_i(j)}{\max x_i(j) - \min x_i(j)} \quad (5)$$

Seri değerlerinin daha küçük olması amaca olumlu katkı sağlıyorsa normalizasyon işlemi Denklem (6) ile yapılır.

$$x_i^* = \frac{\max x_i(j) - x_i(j)}{\max x_i(j) - \min x_i(j)} \quad (6)$$

Seri değerlerinin belirlenen bir optimal değere göre normalizasyonu gerçekleştirilecekse Denklem (7) kullanılır.

$$x_i^* = \frac{|x_i(j) - x_{ob}(j)|}{\max x_i(j) - x_{ob}(j)} \quad (7)$$

Adım 4: Mutlak Değer (Fark) Matrisinin Oluşturulması

X_0^* ile X_j^* arasındaki mutlak farkın değeri $\Delta_{0i}(j)$ Denklem (8) ile hesaplanır.

$$\Delta_{0i}(j) = |X_0^*(j) - X_j^*(j)| \quad (8)$$

Adım 5: Gri İlişki Katsayılarının Hesaplanması

Gri ilişki katsayıları Denklem (9) kullanılarak hesaplanır.

$$\gamma_{0i}(j) = \frac{\Delta_{\min} + \xi \Delta_{\max}}{\Delta_i(j) + \xi \Delta_{\max}} \quad (9)$$

Formülde yer alan ξ katsayısı 0 ile 1 arasında bir değer almaktadır. Literatürde bu değer genellikle 0,5 olarak kullanılmaktadır.

Adım 6: Gri İlişki Derecesinin Hesaplanması

Gri ilişki derecesinin hesaplanması aşamasında iki farklı formül kullanılır. Kriterlerin önem seviyelerinin eşit olduğu varsayımında Denklem (10), önem seviyelerinin farklı olduğu durumlarda ise Eşitlik (11) kullanılır. w_j değeri kriter ağırlıklarını ifade eder ve ağırlıklar toplamı 1'e eşittir.


$$\Gamma_{0i} = \frac{1}{n} \sum_{j=1}^n \gamma_{0i}(j) \quad (10)$$

$$\Gamma_{0i} = \sum_{j=1}^n w_j \gamma_{0i}(j) \quad (11)$$

Önerilen Yöntem

Bu bölümde, dijital dönüşüm etkinliğinin değerlendirilmesi amacıyla geliştirilen performans ölçüm sisteminin adımları açıklanacaktır. Amaç, işletmelerin dijital dönüşüm süreçlerinin etkinliğini belirleyerek, dijital strateji geliştirmeleri ve gerekli adımları atabilmeleri için bir yol haritası sunmaktır. Önerilen yöntemin ilk adımında, dijital dönüşümün değerlendirilmesine yönelik kriterler belirlenecektir. Bu kriterler, literatür taraması ve uzman görüşlerine dayanarak oluşturulacaktır. Dijital dönüşümle ilgili faktörler hem teknolojik hem de organizasyonel düzeyde incelenecek, işletmelerin dijital dönüşüm süreçlerindeki başarısını etkileyen anahtar performans göstergeleri (KPI'lar) belirlenecektir. Belirlenen kriterlerin önem derecelerini hesaplamak için SWARA yöntemi kullanılacaktır. Uzmanlardan alınan geri bildirimler doğrultusunda, kriterler arasında bir öncelik sıralaması yapılacak ve her bir kriterin ağırlığı hesaplanacaktır.

Kriter ağırlıklarının belirlenmesinden sonra, dijital dönüşüm performansını ölçmek için GİA yöntemi kullanılacaktır. GİA, kriterler ve alternatifler arasındaki ilişkiyi ölçerek dijital dönüşümde en iyi performans gösteren işletmeleri belirlemeye olanak tanır. Bu yöntem sayesinde, her bir işletmenin dijital dönüşüm başarısı skora dayalı olarak değerlendirilecektir. GİA yöntemi ile elde edilen bulgular doğrultusunda, işletmelere yönelik dijital dönüşüm stratejileri ve gelişim yol haritaları oluşturulacaktır. Bu stratejiler, işletmelerin dijital dönüşüm süreçlerinde daha verimli ve etkili olmasını sağlamak amacıyla tasarlanacaktır. İşletmeler, dijital teknolojilere yatırımlarını artırarak operasyonel süreçlerini iyileştirebilir ve dijitalleşme sürecini hızlandırabilir. Bu metodolojinin adımlarını gösteren akış şeması Şekil 1'de sunulmuştur.



Şekil 1. Dijital Dönüşüm Performans Ölçüm Sistemi Aşamaları

UYGULAMA

Bu bölümde, dijital dönüşüm performansının ölçülmesi amacıyla geliştirilen metodolojinin uygulanması detaylandırılacaktır. İlk olarak kriterlerin ağırlıklandırılması SWARA yöntemi ile gerçekleştirilecek, ardından GİA yöntemi ile performans skorları hesaplanacaktır.

Kriterlerin Ağırlıklandırılması

Dijital dönüşüm etkinliğinin değerlendirilmesi için 6 ana kriter ve 26 alt kriter belirlenmiştir. Belirlenen kriterlerin ağırlıklarının SWARA yöntemi ile belirlenebilmesi için dijital dönüşüm alanında çalışan akademisyenlerden ve sektördeki uzmanlardan oluşan 10 kişilik bir uzman paneli oluşturulmuştur. Sektörde çalışan uzmanlar, firmaların planlama, üretim ve kalite departmanlarında çalışmakta olup 5-15 yıl arası tecrübeye sahiptirler.

SWARA yönteminin uygulanması adımlarında uzmanlardan, ana ve alt kriterleri önem sırasına göre sıralamaları istenmiştir. Uzmanlar, ana ve alt kriterleri önem derecelerine göre sıralamışlardır. En önemli kriter 1. sırada, en az önemli olan ise son sırada yer alacak şekilde bir sıralama yapılmıştır. Uzmanlar, ikinci kriterden başlayarak her bir kriterin bir önceki kriterine göre ne kadar daha önemli olduğunu ifade eden s_j değerini belirlemiştir. Bu değerler, yüzdelik farklar halinde belirlenir ve tabloya yansıtılır. Örneğin, K3 kriterinin K2 kriterinden %20 daha önemli olduğu belirtilirse bu, 0.2 değeri ile ifade edilir. Ardından, Denklem (1) kullanılarak her bir k_j değeri, ilgili s_j değerine 1 eklenerek hesaplanır. İlk kriterin q_j değeri 1 olarak kabul edilir. Sonraki q_j değerleri ise önceki kriterin q_j değeri ile ilgili k_j değerinin çarpılmasıyla hesaplanır. Ağırlıklar (w_j), Denklem (3)'te gösterildiği şekilde her bir kriterin q_j değeri, toplam q_j değerlerine bölünerek bulunur. Tablo 2'de, Uzman-1 için ana kriterler ve K1 altındaki alt kriterler

için s_j , k_j , q_j ve w_j değerleri gösterilmiştir. Bu örnek adımlarda SWARA yöntemi ile her bir kriterin ağırlığının nasıl hesaplandığı açıklanmaktadır.

Tablo 2. Uzman 1'e Ait Ana Kriter Değerlendirmesi

Önem sırası	Kriterler	s_j	k_j	q_j	w_j
1	K3-İşgücü Gelişimi ve Stratejik Bağlılık	—	1	1	0,253
2	K2-Veri ve Yazılım Altyapısı	0,2	1,2	0,833	0,211
3	K4-Üretim Süreci Otomasyonu	0,3	1,3	0,641	0,162
4	K6-Entegrasyon ve Bağlantı	0,1	1,1	0,582	0,147
5	K5-Kesintisiz Mühendislik ve Optimizasyon Uygulamaları	0,2	1,2	0,485	0,123
6	K1-Akıllı Üretim Teknolojileri	0,2	1,2	0,404	0,103

Her bir uzman için ana ve alt kriterlere yönelik aynı işlemler yapılmış, her bir uzmanın hesapladığı ağırlıklar toplanarak ortalama ağırlıklar elde edilmiştir. 10 uzmanın değerlendirilmesi sonucu elde edilen ağırlıklar ve ana kriterler ve alt kriterler için Tablo 3'te gösterilmiştir.

Tablo 3'te görüldüğü üzere ana kriterler arasında en yüksek ağırlığa sahip olan K2-Veri ve Yazılım Altyapısı (%21,7), dijital dönüşüm için kritik öneme sahip olduğu görülmektedir. Bu ana kriter altında ERP yazılımı (%5,5), en yüksek ağırlığa sahip alt kriter olarak öne çıkmaktadır. K6-Entegrasyon ve Bağlantı ana kriteri de önemli bir rol oynamakta olup, alt kriterlerden ERP yazılımının entegrasyonu (%6,4) en kritik faktör olarak belirlenmiştir. K1-Akıllı Üretim Teknolojileri ve K5-Kesintisiz Mühendislik ve Optimizasyon ana kriterleri de ağırlıklı olarak dijital üretim süreçlerini destekleyen teknolojilerle ilişkilidir. Genel olarak, ERP yazılımı ve entegrasyonunun dijital dönüşümde en önemli unsurlar olduğu, buna ek olarak akıllı üretim teknolojileri ve veri güvenliğinin de kritik bir rol oynadığı görülmektedir.

Tablo 3. Ana Kriter ve Alt Kriter Ağırlıkları

Ana Kriterler	Ana Kriter Ağırlıkları	Alt kriterler	Alt Kriter Ağırlıkları	Nihai Alt Kriter Ağırlıkları
K1-Akıllı üretim teknolojileri	0,156	K1.1.Gelişmiş Robotik (Otonom ve İşbirlikçi Robotlar)	0,314	0,049
		K1.2.Siber Fiziksel Sistemler (SFS)	0,276	0,043
		K1.3.Dijital İkiz ve Artırılmış Gerçeklik	0,205	0,032
		K1.4.Eklemeli İmalat teknolojisi	0,212	0,033
K2-Veri ve Yazılım Altyapısı	0,217	K2.1.Endüstriyel Nesnelerin İnterneti (IoT)	0,175	0,038
		K2.2.Endüstriyel Veri Güvenliği	0,184	0,040
		K2.3.Büyük Veri ve Analitik	0,171	0,037
		K2.4.Bulut Bilişim ve Uç Bilişim	0,124	0,027
		K2.5.Kurumsal Kaynak Planlaması (ERP) Yazılımı	0,253	0,055
		K2.6.Blokzinciri Teknolojisi	0,097	0,021
K3-İşgücü Gelişimi ve Stratejik Bağlılık	0,176	K3.1.Dijital Beceriler ve Yetkinlik Geliştirme	0,199	0,035
		K3.2.İnsan-Robot İş birliği	0,136	0,024
		K3.3.Yatırım ve Kaynak Tahsisi	0,199	0,035
		K3.4.Dijital Dönüşüm Stratejisi	0,222	0,039
		K3.5.Liderlik Vizyonu ve Desteği	0,227	0,040
K4-Üretim Süreci Otomasyonu	0,140	K4.1.Süreç Otomasyonu ve Kontrolü	0,257	0,036
		K4.2.Ürün ve Üretim İzlenebilirliği	0,279	0,039
		K4.3.Kestirimci Bakım ve Arıza Tespiti	0,200	0,028
		K4.4.Esneklik ve Yeniden Yapılandırılabilirlik	0,257	0,036
K5-Kesintisiz Mühendislik ve Optimizasyon Uygulamaları	0,150	K5.1.Dijital Tasarım ve Prototipleme	0,220	0,033
		K5.2.Üretim Yürütme Sistemleri (MES) Kullanımı	0,267	0,040
		K5.3.Envanter Optimizasyon Uygulamaları	0,320	0,048
K6-Entegrasyon ve Bağlantı	0,162	K5.4.Enerji Tüketiminin İzlenmesi ve Optimizasyonu	0,193	0,029
		K6.1.ERP Yazılımının Entegrasyonu	0,395	0,064
		K6.2.Elektronik Ticaret Uygulamaları	0,259	0,042
		K6.3.Dijital Teknolojilerin Entegrasyonu	0,364	0,059

Performans Analizi

Bu bölümde, dijital dönüşüm etkinliğinin hesaplanması için nihai kriter ağırlıkları ile performans değerleri GİA yöntemiyle birleştirilmiştir. Örnek uygulama olarak, Konya'da faaliyet gösteren 3 otomotiv yan sanayi firması seçilmiştir. Bu firmalardaki dijital dönüşüm performansını ölçmek için 1-5 arasında bir değerlendirme ölçeği

kullanılmıştır. Stratejik planlama ve üretim alanında tecrübeli 3 uzman, belirlenen kriterler üzerinden firmaların performanslarını puanlamış ve her kriter için verilen puanların ortalaması alınarak hesaplamalar gerçekleştirilmiştir.

Tablo 4. Kriter Bazında Uzman Değerlendirmeleri


	Firma 1	Firma 2	Firma 3		Firma 1	Firma 2	Firma 3
K1.1	2,67	5,00	2,67	K3.4	2,00	4,33	2,00
K1.2	2,33	3,67	3,00	K3.5	3,67	3,33	3,00
K1.3	1,33	4,00	2,33	K4.1	3,67	4,00	2,67
K1.4	2,33	4,33	3,00	K4.2	4,00	3,67	3,00
K2.1	2,67	3,33	3,00	K4.3	3,00	3,67	1,67
K2.2	4,33	4,00	2,00	K4.4	4,33	3,00	3,00
K2.3	3,00	4,33	3,00	K5.1	2,33	4,33	2,00
K2.4	2,33	4,00	2,67	K5.2	2,33	5,00	2,33
K2.5	2,67	3,33	3,00	K5.3	3,67	4,00	3,00
K2.6	1,00	4,67	1,00	K5.4	3,67	3,33	3,00
K3.1	3,33	3,67	3,33	K6.1	1,67	4,00	2,00
K3.2	2,33	3,67	2,00	K6.2	3,67	5,00	3,00
K3.3	3,67	4,67	3,00	K6.3	3,67	4,33	2,00

GİA yöntemiyle yapılan analiz sonucunda, firmaların dijital dönüşüm performans skorları Tablo 5'te gösterilmektedir. Sonuçlara göre, Firma 2 %70,21 ile en yüksek dijital dönüşüm etkinlik performansına sahip olurken, Firma 1 %51,72 ve Firma 3 %46,02 performans skorları ile sıralamayı takip etmektedir. Bu sonuçlar, dijital dönüşüm süreçlerinde firmalar arasındaki farklılıkları ve gelişim potansiyellerini ortaya koymaktadır.

Tablo 5. Firmaların Performans Skorları

	Firma 1	Firma 2	Firma 3
Nihai Performans Skoru (%)	51,72	70,21	46,02
Sıra	2	1	3

Şekil 2'de radar grafiği kullanılarak firmaların ana kriter bazındaki performansları karşılaştırılmıştır. Şekil 3 ise alt kriter bazında firmaların performanslarının bar grafiği ile görselleştirilmiştir, bu da firmaların hangi alanlarda güçlü veya zayıf olduğunu net bir şekilde göstermektedir.




Şekil 2. Firma Ekseninde Ana Kriter Skorlarının Karşılaştırılması

SONUÇ VE ÖNERİLER

Günümüz iş dünyasında işletmeler, maliyetleri düşürmek, daha hızlı ve verimli üretim gerçekleştirebilmek için süreçlerini dijital dönüşüme adapte etmek zorundadır. Endüstri 4.0'ın gerektirdiği yenilik ve teknolojilerin benimsenmesi, bu sürecin bir parçasıdır. Ancak, dijital dönüşümü başarıyla gerçekleştirebilmek için işletmelerin,

mevcut durumlarını analiz etmeleri ve dijital dönüşüm yolculuklarında hangi aşamada olduklarını net olarak anlamaları gerekmektedir.



Şekil 3. Firma Ekseninde Alt Kriter Skorlarının Karşılaştırılması

Çalışmamızın bulguları, literatürde Endüstri 4.0 ve dijital dönüşüm süreçlerinde karşılaşılan kritik faktörlerle uyumludur. Özellikle ERP, IoT ve veri altyapısı gibi teknolojik unsurların dönüşüm sürecindeki önemi daha önce birçok çalışmada vurgulanmıştır. Bizim modelimizde de bu unsurlar belirgin olarak öne çıkmıştır; böylece işletmelerin, dijital dönüşümün teknolojik altyapısını güçlendirme gerekliliği doğrulanmıştır. Bu sonuç, teknolojik altyapının işletme performansına katkısı hakkında yapılan önceki araştırmalarla paralellik göstermektedir. Ayrıca, dijital dönüşüm performansının yalnızca teknolojik gelişim değil, aynı zamanda organizasyonel yapı ve insan kaynakları boyutunu da içerdiği literatürde vurgulanan önemli bir çıkarımdır. Çalışmamız, bu faktörlerin dijital dönüşüm sürecindeki etkisini göz önünde bulundurarak, bu kriterlerin ağırlıklandırılmasına yönelik sistematik bir yaklaşım sunmuştur. Böylece, işgücü gelişimi ve stratejik bağlılık yönetiminin, dijital dönüşüm başarısı üzerindeki önemini destekleyecek yeni bulgular elde edilmiştir.

Kriterlerin önem derecelerini belirlemek amacıyla, dijital dönüşüm alanındaki akademisyenler ve sektördeki profesyonellerden oluşan bir uzman paneliyle değerlendirmeler yapılmıştır. Bu değerlendirmeler SWARA yöntemi kullanılarak analiz edilmiş ve dijital dönüşümde öncelik verilmesi gereken ana ve alt kriterlerin ağırlıkları belirlenmiştir. Sonuçlara göre, en yüksek öneme sahip ana kriter K2 (Veri ve Yazılım Altyapısı) olarak belirlenmiştir. Buna karşılık, en düşük ağırlığa sahip ana kriter ise K4 (Üretim Süreci Otomasyonu) olmuştur. Alt kriterler düzeyinde ise en yüksek ağırlık K2.5 (Kurumsal Kaynak Planlaması- ERP Yazılımı) kriterine verilmiştir. Bu durum, dijital dönüşüm için ERP yazılımı ve entegrasyonunun önemini vurgulamaktadır. Bu kriteri K6.1 (ERP Yazılımının Entegrasyonu) ve K6.3 (Dijital Teknolojilerin Entegrasyonu) kriterleri izlemektedir. Buna karşın, K2.6 (Blokzincir Teknolojisi) ve K3.2 (İnsan-Robot İş birliği) gibi kriterler en düşük ağırlığa sahip olarak daha az kritik faktörler olarak değerlendirilmiştir. Bu bulgular, dijital dönüşüm sürecinde ERP yazılımı ve entegrasyonunun öncelikli olarak ele alınması gerektiğini göstermektedir.

Bu çalışmada, dijital dönüşüm performansının değerlendirilmesi amacıyla SWARA ve GİA yöntemlerinin birlikte kullanıldığı özgün bir yaklaşım geliştirilmiştir. Literatürde SWARA ve GİA yöntemlerinin çeşitli sektörlerde karar verme süreçlerinde başarılı sonuçlar sunduğu ancak dijital dönüşüm performans değerlendirme alanında sınırlı çalışmalarda yer aldığı görülmektedir. Uygulama örneğinde, otomotiv yan sanayi firmalarından elde edilen veriler kullanılarak dijital dönüşüm performansı GİA yöntemi ile hesaplanmış ve sonuçlar yorumlanmıştır. Çalışmanın literatüre katkısı, dijital dönüşüm sürecini yalnızca teknoloji odaklı değil, aynı zamanda insan faktörlerini de dikkate alan bütüncül bir yaklaşımla ele almasıdır.

Çalışmamız, dijital dönüşüm performansını ölçmek ve işletmelerin dijitalleşme sürecindeki önceliklerini belirlemek isteyen işletmelere rehber niteliğindedir. Geliştirilen performans ölçüm sistemi, işletmelerin dijital dönüşüm stratejilerini şekillendirmelerine ve dijitalleşme etkinliklerini değerlendirmelerine yardımcı olabilir. Gelecekteki

çalışmalar için öneriler ise şu şekildedir: (i) Çalışmada kullanılan kriter seti genişletilerek dijital dönüşüm performansını daha fazla boyutta inceleyen faktörler eklenebilir. Böylece farklı işletme ihtiyaçlarını karşılayacak esnek bir model geliştirilebilir, (ii) Önerilen sistemin farklı sektörlerde test edilmesi, modelin genel geçerliliğini artırabilir ve dijital dönüşüm performansını değerlendirmek için geniş çapta kullanılabilir hale getirebilir, (iii) SWARA ve GİA yöntemlerinin yanı sıra, dijital dönüşüm performansını ölçmeye yönelik diğer ÇKKV teknikleri ile de bir karşılaştırma yapılabilir. Özellikle kriter sayısının arttığı durumlarda uzman yargılarına dayalı SWARA yöntemi yerine CRITIC, Entropi gibi objektif ağırlıklandırma teknikleri tercih edilebilir. Performans değerlendirme için ise TOPSIS ve VIKOR gibi değer temelli yöntemlerden yararlanılabilir.

NOT

Bu çalışma Gökçen Saray'ın Necmettin Erbakan Üniversitesi Fen Bilimler Enstitüsü, Endüstri Mühendisliği Anabilim dalında Dr. Bilal Ervural danışmanlığında yürüttüğü “Üretimde dijital dönüşüm etkinliğinin değerlendirilmesi için bir performans ölçüm sistemi geliştirilmesi” isimli yüksek lisans tezine dayanmaktadır.

KAYNAKLAR

- Abdallah, Y. O., Shehab, E., & Al-Ashaab, A. (2022). Developing a digital transformation process in the manufacturing sector: Egyptian case study. *Information Systems and e-Business Management*, 20(3), 613-630.
- Adem, A., Kaya, B. Y., Çakıt, E., & Dağdeviren, M. (2022). Üretim sistemlerindeki dijital dönüşümün iş etüdü teknikleri üzerindeki etkisi. *Verimlilik Dergisi*, 110-122.
- Akman, G., & Kokumer, Z. (2023). Endüstri 4.0 kapsamında beyaz eşya sektöründe dijital dönüşüm yetkinliğinin MACBETH ve EDAS yöntemleriyle değerlendirilmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 38(4), 2033-2054.
- Alkan, N., & Kahraman, C. (2023). Prioritization of supply chain digital transformation strategies using multi-expert fermatean fuzzy analytic hierarchy process. *Informatica*, 34(1), 1-33.
- Angreani, L. S., Vijaya, A., & Wicaksono, H. (2020). Systematic literature review of industry 4.0 maturity model for manufacturing and logistics sectors. *Procedia manufacturing*, 52, 337-343.
- Angreani, L. S., Vijaya, A., & Wicaksono, H. (2023). Identifying Essential Driving Factors of Industry 4.0 Maturity Models Using Fuzzy MCDM Methods. *Procedia CIRP*, 120, 1582-1587.
- Attaran, S., Attaran, M., & Celik, B. G. (2024). Digital Twins and Industrial Internet of Things: Uncovering operational intelligence in industry 4.0. *Decision Analytics Journal*, 10, 100398.
- Ayyıldız, M. E., & Demir, A. O. (2022). Dijital Dönüşüm Olgunluk Seviyesinin Ölçülmesine Yönelik Modellerin İncelenmesi. *İstanbul Ticaret Üniversitesi Girişimcilik Dergisi*, 6(12), 61-80.
- Azambuja, A.J., Giese, T. (2023). Digital Twins in Industry 4.0 – Opportunities and challenges related to Cyber Security. *11th CIRP Global Web Conference (CIRPe 2023)*, 25-30.
- Bhatia, A., & Sehgal, A. K. (2023). Additive manufacturing materials, methods and applications: A review. *Materials Today: Proceedings*, 81, 1060-1067.
- Bibby, L., & Dehe, B. (2018). Defining and assessing industry 4.0 maturity levels–case of the defence sector. *Production Planning & Control*, 29(12), 1030-1043.
- Büyüközkan, G., & Güler, M. (2020). Analysis of companies' digital maturity by hesitant fuzzy linguistic MCDM methods. *Journal of Intelligent & Fuzzy Systems*, 38(1), 1119-1132.
- Büyüközkan, G., Feyzioğlu, O., & Havle, C. A. (2020). Analysis of success factors in aviation 4.0 using integrated intuitionistic fuzzy MCDM methods. In *Intelligent and Fuzzy Techniques in Big Data Analytics and Decision Making: Proceedings of the INFUS 2019 Conference, Istanbul, Turkey, July 23-25, 2019* (pp. 598-606).
- Ceyhan, H., Kasapbaşı, M., C. (2021). Üretim Sistemlerinde Makine Öğrenmesi ile Kestirimci Bakım, *Avrupa Bilim ve Teknoloji Dergisi*, 33, 167-175.
- Chang, S.-C.; Chang, H.-H.; Lu, M.-T. 2021, Evaluating Industry 4.0 Technology Application in SMEs: Using a Hybrid MCDM Approach, *Mathematics*, 9, 414.

- Cheminod, M., L. Durante, and A. Valenzano. (2013). "Review of Security Issues in Industrial Networks." *IEEE Transactions on Industrial Informatics* 9 (1): 277–293.
- Chen, X., & Voigt, T. (2020). Implementation of the Manufacturing Execution System in the food and beverage industry. *Journal of Food Engineering*, 278, 109932.
- Chen, Z. S., Wang, Z. R., Devenci, M., Ding, W., Pedrycz, W., & Skibniewski, M. J. (2024). Optimization-based probabilistic decision support for assessing building information modelling (BIM) maturity considering multiple objectives. *Information Fusion*, 102, 102026.
- Çakır, E., & Kacı, Ü. (2018). Altı Sigma kara kuşak eğitimi alacak personelin bütünleşik SWARA ve GİA yöntemleri ile belirlenmesi. *Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü Elektronik Dergisi*, 9(23), 142-166.
- Çakır, E., 2018, Elektronik Belge Yönetim Sistemi (Ebys) Yazılımı Seçiminde Çok Kriterli Karar Verme Yöntemleri: Bir Belediye Örneği, *Business Economics and Management Research Journal*, 1(1), 15-30
- Çevik Aka, D. (2023). Evaluation Of The Effects Of Industry 4.0 On Organizational Agility With Fucom: Implementation In The Textile Industry, *Uluslararası İktisadi Ve İdari İncelemeler Dergisi*(40), 33-48.
- Demircan Keskin, F., Kabasakal, İ., Kaymaz, Y., & Soyuer, H. (2019). An assessment model for organizational adoption of industry 4.0 based on multi-criteria decision techniques. In *Proceedings of the International Symposium for Production Research 2018 18* (pp. 85-100). Springer International Publishing.
- Demirel, B. E., Tınmaz, G., Güven, E., & Eren, T. (2024). Türk Savunma Sanayiinde Dijital Olgunluk Seviyelerinin Karşılaştırılması. *Verimlilik Dergisi*, 58(4), 555-572.
- Dermenci, M.,S., Sağbaş A. (2023). Dijital Dönüşüm Ekseninde Çok Kriterli Karar Verme Yöntemleri ile Endüstri 4.0 Olgunluk Modelinin Değerlendirilmesi, *European Journal of Engineering and Applied Sciences*,6 (2),74-85.
- Doğan, O., & Baloğlu, N. (2020). Endüstri 4.0 kavramsal farkındalık ölçeği. *Karamanoğlu Mehmetbey Üniversitesi Sosyal ve Ekonomik Araştırmalar Dergisi*, 22(38), 58-81.
- Dotoli, M., A. Fay, M. Miśkiewicz, and C. Seatzu. (2016). "Advanced Control in Factory Automation: a Survey." *International Journal of Production Research* 55 (5): 1243–1259
- Dökme, S. (2020). Sakarya'da Dijital Dönüşüme Yönelik Sanayi Kuruluşlarında Karşılaştırmalı Değerlendirme Çalışması. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Sakarya.
- Elibal, K., Özceylan, E., & Çetinkaya, C. (2024). An ERP Based Industry 4.0 Maturity Model Proposal. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 39(2), 535-544.
- Elkadi, Hitham., & El Tazi, N. (2023). Identifying and prioritizing digital transformation elements using fuzzy analytic hierarchy process. *International Journal of Advanced Computer Science and Applications*, 14(9).
- Erdem, A., Kara, M. A., & Dumlu, H. (2023). Dijital platform tercihlerinin SWARA ve gri ilişkisel analiz yöntemleri ile değerlendirilmesi. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, (41), 91-106.
- Erik, A., & Kuvvetli, Y. (2021). Üretim İşletmelerinin Endüstri 4.0 Entegrasyonunun Veri Zarflama Analizi ile Değerlendirilmesi. *Çukurova Üniversitesi Mühendislik Fakültesi Dergisi*, 36(3), 637-647.
- Ervural, B. (2023). Comparative Analysis of E-Government Website Performances of European Countries Using Dynamic Grey Relational Analysis. In *International Conference on Electronic Governance with Emerging Technologies* (pp. 112-124). Cham: Springer Nature Switzerland.
- Godbole, M. V. (2023). Revolutionizing Enterprise Resource Planning (ERP) Systems through Artificial Intelligence. *International Numeric Journal of Machine Learning and Robots*, 7(7), 1-15.
- Goulart, V. G., Liboni, L. B., & Cezarino, L. O. (2022). Balancing skills in the digital transformation era: The future of jobs and the role of higher education. *Industry and Higher Education*, 36(2), 118-127.
- Görçün, Ö. F., Mishra, A. R., Aytakin, A., Simic, V., & Korucuk, S. (2024). Evaluation of Industry 4.0 strategies for digital transformation in the automotive manufacturing industry using an integrated fuzzy decision-making model. *Journal of Manufacturing Systems*, 74, 922-948.
- Guven, H. (2020). Industry 4.0 and marketing 4.0: in perspective of digitalization and E-Commerce. In *Agile Business Leadership Methods for Industry 4.0* (pp. 25-46).

- Gülseren, A., & Sağbaş, A. (2019). Endüstri 4.0 perspektifinde sanayide dijital dönüşüm ve dijital olgunluk seviyesinin değerlendirilmesi. *European Journal of Engineering and Applied Sciences*, 2(2), 1-5.
- Han, H., Shiwakoti, R. K., Jarvis, R., Mordi, C., & Botchie, D. (2023). Accounting and auditing with blockchain technology and artificial intelligence: A literature review. *International Journal of Accounting Information Systems*, 48, 100598.
- Hasani, A., Haseli, G., & Deveci, M. (2024). Analyzing operational risks of digital supply chain transformation using hybrid ISM-MICMAC method. *OPSEARCH*, 1-25.
- Hashemkhani Zolfani, S., Salimi, J., Maknoon, R. ve Simona, K. (2015). Technology foresight about R&D projects selection; application of SWARA method at the policy making level. *Engineering Economics*, 26(5), 571–580. 9571.
- Hashemkhani Zolfani, S., Zavadskas, E. K. ve Turskis, Z. (2013). Design of Products with Both International and Local Perspectives Based on Yin-Yang Balance Theory and SWARA Method. *Economic Research*, 26(2), 153–166.
- Ivančić, L., Vukšić, V. B., & Spremić, M. (2019). Mastering the digital transformation process: Business practices and lessons learned. *Technology Innovation Management Review*, 9(2).
- İpkin, M., & Keskinçalış, M. (2023). İşletmelerde Erp Uygulamalarının Dijital Dönüşüm Sürecine Katkıları. *Aurum Journal Of Social Sciences*, 8(1), 49-74.
- Jafarzadeh Ghouschi, S., Ab Rahman, M. N., Raiesi, D., Osgooei, E., & Jafarzadeh Ghouschi, M. (2020). Integrated decision-making approach based on SWARA and GRA methods for the prioritization of failures in solar panel systems under Z-information. *Symmetry*, 12(2), 310.
- Kaisler S., Armour F., Espinosa J. A., Money, W. (2013). Big data: Issues and Challenges Moving Forward. In 2013. *46th Hawaii International Conference on System Sciences* , 995-1004.
- Kalender, Z. T., & Žilka, M. (2024). A Comparative Analysis of Digital Maturity Models to Determine Future Steps in the Way of Digital Transformation. *Procedia Computer Science*, 232, 903-912.
- Kamble, S., Gunasekaran, A., & Dhong, N. C. (2020). Industry 4.0 and lean manufacturing practices for sustainable organisational performance in Indian manufacturing companies. *International journal of production research*, 58(5), 1319-1337.
- Karadağ, H., Şahin, F., Karamollaoğlu, N., & Saunila, M. (2024). Disentangling the dynamic digital capability, digital transformation, and organizational performance relationships in SMEs: a configurational analysis based on fsQCA. *Information Technology and Management*, 1-17.
- Kasnak, E., & Özkara, B. (2022). Türkiye'deki imalat şirketlerinin endüstri 4.0 olgunluk düzeyinin belirlenmesi. *Verimlilik Dergisi*, (3), 365-380.
- Kesbiç, Ö., (2020), Üretimde Dijital Dönüşüm Ve Etkileri: Türkiye Ekonomisi Açısından Bir Analiz, Manisa Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, Manisa.
- Keskinçalış, M., & İpkin, M. (2023). İşletmelerde ERP uygulamalarının dijital dönüşüm sürecine katkıları. *AURUM Sosyal Bilimler Dergisi*, 8(1), 49-74.
- Khan, A., & Ahmed, A. (2024). Optimizing Retail Operations, Inventory Management and Sales Forecasting with Big Data and AI in China. *Emerging Trends in Machine Intelligence and Big Data*, 16(1), 18-37.
- Kıyak, A., & Bozkurt, G. (2020). A General Overview To Digital Leadership Concept. *Uluslararası Sosyal Ve Ekonomik Çalışmalar Dergisi*, 1(1), 84-95.
- Kocaoglu, B., & Kirmizi, M. (2024). Prescriptive digital transformation maturity model: a development and validation study. *Kybernetes*.
- Koç, E. (2020). Tedarik Zinciri İzlenebilirliği Ve Sürdürülebilirliğinde Yeni Paradigma: Blokzincir. *Bingöl Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 10(20), 417-437.
- Kökümer, Z., Çok Kriterli Karar Verme Yöntemleri İle Beyaz Eşya Sektöründe Endüstri 4.0 Dijital Dönüşüm Yetkinlik Analizi, 2018, Yüksek Lisans Tezi, Kocaeli Üniversitesi Fen Bilimleri Enstitüsü, Kocaeli.
- Kraus, S., Jones, P., Kailer, N., Weinmann, A., Chaparro-Banegas, N., & Roig-Tierno, N. (2021). Digital transformation: An overview of the current state of the art of research. *Sage Open*, 11(3).

- Liu, T., Gao, K., & Rong, Y. (2024). An integrated picture fuzzy operational competitiveness ratings group decision approach for evaluating the enterprise digital transformation capability. *Granular Computing*, 9(2), 32.
- Lo, H. W., & Siao, Z. (2023). Exploring the Role of Multiple Criteria Decision-Making in Enterprise Digital Transformation. *International Journal of Business*, 28(3), 1-17.
- Mitroulis, D., Kitsios, F., & Kitsios, F. (2019, February). Digital transformation strategy: A literature review. In *Proceedings of the 6th National Student Conference of HELORS, Xanthi, Greece* (pp. 59-61).
- Muneeb, F. M., Karbassi Yazdi, A., Hanne, T., & Mironko, A. (2024). Small and medium-sized enterprises in emerging markets and foreign direct investment: an integrated multi-criteria decision-making approach. *Applied Economics*, 1-18.
- Nelson, J., Berlin, A., Menold, J., & Parkinson, M. (2020). The role of digital prototyping tools in learning factories. *Procedia Manufacturing*, 45, 528-533.
- Osterrieder, P., Budde, L., & Friedli, T. (2020). The smart factory as a key construct of industry 4.0: A systematic literature review. *International Journal of Production Economics*, 221, 107476.
- Özbek, A., & Demirkol, İ. (2018). Lojistik sektöründe faaliyet gösteren işletmelerin SWARA ve GİA yöntemleri ile analizi. *Kırıkkale Üniversitesi Sosyal Bilimler Dergisi*, 8(1), 71-86.
- Özdağoğlu, A., & Keleş, M. K. (2019). Bankaların bakış açısından BIST sınai işletmelerinin değerlendirilmesi–SWARA-GİA bütünlük yaklaşımı. *Süleyman Demirel Üniversitesi Vizyoner Dergisi*, 10(24), 229-241.
- Özdemir, Y.S. (2022). A Spherical Fuzzy Multi-Criteria Decision-Making Model For Industry 4.0 Performance Measurement, *Axioms*, 11,325
- Özkat, E. C. (2021). Makine Öğrenmesi Metodolojisi Kullanılarak Yüksek Hızlı Rulmanlarda Sağlık Göstergesinin Belirlenmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (22), 176.
- Paksoy, T., Kochan, C. G., & Ali, S. S. (Eds.). (2020). *Logistics 4.0: Digital transformation of supply chain management*. CRC Press.
- Ryalat, M., El Moaqet, H., & Al Faouri, M. (2023). Design of a smart factory based on cyber-physical systems and Internet of Things towards Industry 4.0. *Applied Sciences*, 13(4), 2156.
- Sahut, J.M., Schweizer, D., Peris-Ortiz, M., (2022), Technological forecasting and social change introduction to the VSI technological innovations to ensure confidence in the digital World, *Technol. Forecast. Soc. Chang*, 179, 121680.
- Santos, C., Mehra, A., Barros, A. C., Araujo, M., & Ares, E. (2017), Towards Industry 4.0: an overview of European strategic roadmaps, *Procedia Manufacturing*, 13, 972-979.
- Sharma, M., Raut, R., Sehrawat, R., Ishizaka, A. (2022), Digitalisation of manufacturing operations: The influential role of organisational, social, environmental, and technological impediments. *Expert Systems With Applications*, 211.
- Singla, C., Kaushal, S., Verma, A., Kumar, H. (2018). Computational Intelligence for Multimedia Big Data on the Cloud with Engineering Applications. *Intelligent Data-Centric Systems*, 147-157.
- Sriram, R. M., & Vinodh, S. (2021). Analysis of readiness factors for Industry 4.0 implementation in SMEs using COPRAS. *International Journal of Quality & Reliability Management*, 38(5), 1178-1192
- Stanujkic, D., Karabasevic, D., & Zavadskas, E. K. (2015). A framework for the selection of a packaging design based on the SWARA method. *Engineering Economics*, 26(2), 181-187.
- Supçiller, A. A., & Bayramoğlu, S. (2020). Aralıklı gri sayı tabanlı A-GİA ve gri EDAS yöntemleriyle rüzgar santrali yer seçimi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 35(4), 1847-1860.
- Tarigan, Z. J. H., Siagian, H., & Jie, F. (2020). The role of top management commitment to enhancing the competitive advantage through ERP integration and purchasing strategy. *International Journal of Enterprise Information Systems (IJEIS)*, 16(1), 53-68.
- Tuş, A., Öztaş, G. Z., Öztaş, T., Özçil, A., & Adalı, E. A. (2023). Türkiye'nin dijital dönüşüm endeksinin hesaplanması için alternatif bir yaklaşım: Bayesian BWM. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 29(8), 842-854.

Uslu, B., Gür, Ş., Eren, T. (2019). Endüstri 4.0 Uygulaması İçin Stratejilerin Aas Ve Topsis Yöntemleri İle Değerlendirilmesi. *Eskişehir Technical University Journal of Science and Technology B- Theoretical Sciences*,7(1), 13-28.

Wagire, A. A., Joshi, R., Rathore, A. P. S., & Jain, R. (2021). Development of maturity model for assessing the implementation of Industry 4.0: learning from theory and practice. *Production Planning & Control*, 32(8), 603-622.

Wang, D., & Shao, X. (2024). Research on the impact of digital transformation on the production efficiency of manufacturing enterprises: Institution-based analysis of the threshold effect. *International Review of Economics & Finance*, 91, 883-897.

Xu, J., & Yin, J. (2024). Digital transformation and ESG performance: The chain mediating role of technological innovation and financing constraints. *Finance Research Letters*, 106387.

Yıldızbaşı, A., & Ünlü, V. (2020). Performance evaluation of SMEs towards Industry 4.0 using fuzzy group decision making methods. *SN Applied Sciences*, 2(3), 355.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 01.10.2024
Kabul Tarihi : 23.10.2024

Received Date : 01.10.2024
Accepted Date : 23.10.2024

THE EFFECT OF PEANUT TAHINI UTILIZATION ON THE MINERAL CONTENT OF HALVA

YER FISTIĞI TAHİNİ KULLANIMININ HELVANIN MİNERAL İÇERİĞİ ÜZERİNE ETKİSİ

Venüs KARAKUŞ¹ (ORCID: 0000-0002-2538-5790)
Kurban YAŞAR^{1*} (ORCID: 0000-0002-6514-2101)

¹ Osmaniye Korkut Ata University, Faculty of Engineering and Natural Sciences, Department of Food Engineering, Osmaniye, Türkiye.

*Sorumlu Yazar / Corresponding Author: Kurban YAŞAR, kurbanyasar@osmaniye.edu.tr

ABSTRACT

Halva is a traditional Turkish dessert with origins in the Seljuk and Ottoman periods. Made from tahini, sugar, soapwort extract, and various additives, it is widely consumed in the Middle East and Mediterranean, particularly in Türkiye. Often enjoyed for breakfast and special occasions, tahini halva can be enriched with ingredients like cocoa, pistachios, and hazelnuts. This study produced halva using different ratios of peanut tahini (50% and 100%), with sesame tahini as the control and analyzed the mineral content of the samples. The halvans were prepared by mixing tahini with other components and kneading until the desired consistency was achieved. Mineral content was analyzed using atomic absorption spectrometry to measure macro-minerals (Ca, K, Na, Mg, P) and micro-minerals (Fe, Zn, Mn). Results indicated that halva made with sesame tahini had higher levels of calcium, sodium, magnesium, phosphorus, and zinc. In contrast, halva made with peanut tahini contained higher levels of potassium, iron, and manganese. Thus, the study concluded that the ratio of peanut tahini significantly affects the mineral content of halva.

Keywords: Halva, sesame, peanut, tahini, mineral content

ÖZET

Helva, Selçuklu ve Osmanlı dönemlerine dayanan geleneksel bir Türk tatlısıdır. Tahin, şeker, çöven otu ekstresi ve çeşitli katkı maddelerinden yapılır ve özellikle Türkiye’de Orta Doğu ve Akdeniz ülkelerinde yaygın olarak tüketilmektedir. Genellikle kahvaltılarda ve özel günlerde tercih edilen tahin helvası, kakao, fıstık ve fındık gibi malzemelerle zenginleştirilebilir. Bu çalışmada, %50 ve %100 oranlarında yer fıstığı tahini kullanılarak helva üretilmiş, kontrol olarak susam tahini kullanılmış ve örneklerin mineral içeriği analiz edilmiştir. Helvalar, tahini diğer bileşenlerle karıştırarak ve istenen kıvama gelene kadar yoğurarak hazırlanmıştır. Mineral içeriği, makro mineraller (Ca, K, Na, Mg, P) ve mikro mineraller (Fe, Zn, Mn) ölçmek için atomik absorpsiyon spektrometresi kullanılarak analiz edilmiştir. Sonuçlar, susam tahini ile yapılan helvanın daha yüksek kalsiyum, sodyum, magnezyum, fosfor ve çinko seviyelerine sahip olduğunu göstermiştir. Buna karşılık, yer fıstığı tahini ile yapılan helvanın daha yüksek potasyum, demir ve manganez seviyeleri içerdiği belirlenmiştir. Böylece, çalışmada yer fıstığı tahininin oranının helvanın mineral içeriğini önemli ölçüde etkilediği sonucuna varılmıştır.

Anahtar Kelimeler: Helva, susam, yer fıstığı, tahin, mineral içeriği

INTRODUCTION

Desserts hold a significant place in Turkish cuisine, which is a continuation of Seljuk and Ottoman culinary traditions, and various types of halva are prominent among these desserts. Today, numerous varieties of halva are produced both locally and on an industrial scale in many regions of Turkey (Badem, 2020). Tahini halva, one of the renowned traditional desserts of Turkish cuisine, is made by combining tahini (sesame paste) with sugar, water, citric acid, tartaric acid, an emulsifier, and soapwort (*Saponaria officinalis*) extract. Tahini halva and similar products are widely produced and consumed in Middle Eastern, Mediterranean, and Balkan countries (Öğütcü et al., 2017). Halva, which is generally consumed for breakfast, can have its flavors enhanced by adding sweeteners such as cocoa, pistachio, almond, and hazelnut, depending on consumer preferences (Var et al., 2007).

Sesame (*Sesamum indicum* L.), belonging to the Pedaliaceae family, is acknowledged as one of the four primary oilseed crops in China and is among the oldest oil crops cultivated for human consumption. Traces of sesame have been discovered in ancient settlements in Pakistan, and today it is widely cultivated in countries such as India, China, Malaysia, Sudan, Myanmar, and Tanzania. In recent years, sesame production has surged, particularly in Africa, with Tanzania surpassing India to become the leading global producer (Wei et al., 2022). Tahini, also known as tehina or tahina, is produced by roasting and grinding sesame seeds. It serves as a vital component in numerous food products, particularly bakery items, confections, and traditional dishes. For instance, tahini is the primary component of halva in the Middle East, Saudi Arabia, and Türkiye, where it is mixed with sweeteners to create spreadable desserts (Lokumcu et al., 2005; Torlak et al., 2013). Sesame seeds considered nutritionally valuable are used in numerous food products such as tahini, halva, hummus, crackers, cakes, cookies, donuts, chips, and margarine due to their high oil and protein content (Bakal, 2022).

Peanuts (*Arachis hypogaea* L.) rank among the most cultivated legumes worldwide cultivated agricultural crops globally, valued for their high nutritional content and distinct flavor. China leads global peanut production, contributing 37.9% of the world's supply, followed by major producers such as India, Nigeria, the USA, and Sudan. Türkiye is the largest producer of peanuts among European countries, and more than 80% of peanut cultivation is carried out in the provinces of Adana and Osmaniye (Sahin et al., 2022).

Peanuts are rich in essential nutrients and bioactive compounds, including proteins, lipids, carbohydrates, vitamins, minerals, stilbenoids, flavonoids, phenolic acids, phytosterols, triterpenes, and alkaloids. Among these, resveratrol is particularly notable for its extensive biological activities, which include anticancer effects, cardiovascular protection, anti-inflammatory properties, antibacterial effects, and its role in regulating intestinal microbiota (Mingrou et al., 2022). Peanuts are utilized across various industries, including oil production, peanut butter, confectionery, roasted peanuts, and snacks, making them the fourth most significant oilseed crop globally. Peanut protein is highly regarded for its nutritional value, offering a balanced amino acid profile that closely resembles animal proteins, making it a valuable source of plant-based nutrition (Boukid, 2022). Moreover, peanut shells which contain 47% fiber are increasingly recognized for their functional food potential due to their significant antioxidant and antimicrobial properties (Toomer, 2020).

Minerals are essential micronutrients that play key roles in maintaining bone structure, regulating muscle and nerve functions, and balancing fluids. They also act as cofactors for enzymes and hormones. Additionally, minerals support the immune system, influencing both innate and adaptive immune responses. Adequate mineral intake is crucial for infection resistance and reducing the risk of chronic diseases (Weyh et al., 2022).

Sesame production in Türkiye is limited and heavily reliant on imports, resulting in increased costs for sesame-based products like halva. Conversely, peanuts are primarily consumed as a snack and contain more protein than sesame, which is available at a lower price. Taking these factors into account, peanuts seem to be a viable alternative to sesame in food production.

In this study, halva was produced using sesame tahini, peanut tahini, and a blend of the two tahini types in equal proportions. The mineral content of the halva samples was analyzed to assess the nutritional impact of using different tahini varieties.

MATERIALS AND METHODS

Halva Production

The control sesame tahini halva was produced following the method described by Karakahya (2006). Initially, wax was prepared for halva production. %45 crystalline sugar powder, water, and %0.01 citric acid was added to the tahini boiler and heated. Once the mixture was cooked, %0.28 Saponaria officinalis extract was introduced to bleach the sugar syrup, and the mixture was heated to 150°C. %53 tahini was then added to the halva kneading bowl, followed by the wax, %0.01 vanillin, and %1.7 emulsifier. The mixture was initially stirred using a wooden paddle and then hand-kneaded until the desired consistency was achieved. The halva was subsequently packaged into 1000 g plastic containers.

Peanut tahini used in this study was commercially sourced from a company in Osmaniye. Two formulations were prepared for the study: 100% peanut tahini and a 50% peanut tahini + 50% sesame tahini blend. These were processed similarly to the control sesame tahini halva. Each halva type was produced in two replicates.

Mineral Content Analysis of Halva

Sample preparation for mineral content analysis was done according to the protocol established by Chapman and Pratt (1961). For mineral analysis, halva samples were subjected to dry ashing in a muffle furnace. Specifically, 0.5 g of halva samples were placed in 50 ml porcelain crucibles and incinerated at 550°C for 5 hours. Once cooled, the ash was dissolved in 5 ml of 2 N HCl solution. The resulting solution was then diluted with purified water to a final volume of 50 ml and filtered using Whatman No. 42 filter paper.

Macro minerals (Ca, K, Na, Mg, and P) and micro minerals (Fe, Zn, and Mn) were analyzed using atomic absorption spectrometry (Agilent 240 FS, UK). The concentrations of these elements were reported in mg/kg (Kıvrık et al., 2022).

Statistical Analysis

One-way analysis of variance was applied to all data belonging to halva samples. Significant differences among groups were assessed using Duncan's multiple comparison test. For this purpose, the SPSS 20.0 Statistical package program was used.

RESULTS AND DISCUSSION

Mineral Content of Halvas

Calcium (Ca) is an essential mineral for human health, comprising approximately 1.5-2.2% of total body weight. Most Ca is stored in bones as calcium phosphate, providing structural strength. In soft tissues, extracellular fluid, and blood, calcium exists in its ionic form, maintaining a delicate balance with the calcium in bones (Lin et al., 2024).

The macro mineral content of the halva samples is presented in Table 1. According to the results, Ca content of the halva ranged from 527 mg/kg to 940 mg/kg. The highest Ca concentration was found in the halva made with 100% sesame tahini (X), while the lowest Ca content was observed in the halva made with 100% peanut tahini (Z). The type of tahini used in halva production had a statistically significant effect on its Ca content ($p < 0.01$).

In a study on conventional and organic sesame tahini production, Kaplan (2022) reported that the Ca content of sesame tahini ranged between 2030 and 2847 ppm. The Ca levels identified in this study were lower than those reported by Kaplan (2022). This discrepancy was likely due to the addition of ingredients such as sugar, citric acid, and emulsifiers in halva production, which could have diluted the Ca concentration derived from tahini.

Potassium (K) is an essential mineral in human nutrition, playing a critical role in regulating blood pressure. Many studies have shown an inverse relationship between K intake and blood pressure, showing that potassium-rich diets contribute to cardiovascular health, independent of their effects on blood pressure (D'Elia et al., 2023).

Table 1. Macro Mineral Content of Halvas (mg/kg)

Halvas	Ca	K	Na	Mg	P
X	940 ^{a#} ±21.21	1525 ^{c#} ±49.50	985 ^{a#} ±35.36	1052 ^{a#} ±53.39	1505 ^{a#} ±50.21
Y	690 ^b ±35.36	2327 ^b ±45.86	725 ^b ±63.66	890 ^b ±11.14	1100 ^b ±13.12
Z	527 ^c ±3.55	2952 ^a ±38.89	270 ^c ±14.15	747 ^c ±16.17	725 ^c ±11.02

X: halva made with 100% sesame tahini, Y: halva made with 50% sesame tahini and 50% groundnut tahini, Z: halva made with 100% groundnut tahini. #: Means with different letters in the same column are statistically different from each other (p<0.05).

K content in the halva samples varied significantly depending on the type of tahini used, with values ranging from 1525 mg/kg in halva made with 100% sesame tahini (X) to 2952 mg/kg in halva made with 100% peanut tahini (Z) (Table 1). The difference in K content was statistically significant (p<0.01), indicating that the type of tahini plays a crucial role in determining the K levels in halva.

In a study by Oduma et al. (2020), peanut paste was produced by adding varying amounts of sesame, and it was found that increasing the proportion of sesame led to a decrease in K content. This finding aligned with the results of the current study, which showed that halva made with peanut tahini had greater K levels compared to halva made with sesame tahini.

Akbulut (2008) reported that the K content of tahini produced using different methods ranged from 4096 mg/kg to 6846 mg/kg. The K levels observed in this study were lower than those reported by Akbulut. This discrepancy may be attributed to the inclusion of other ingredients in halva production, such as sugar and emulsifiers, or variations in production methods.

Sodium (Na) plays a crucial role in maintaining fluid balance and regulating blood pressure in the human body. However, excessive Na intake is associated with an increased risk of health conditions such as cardiovascular disease, kidney disorders, hypertension, and certain cancers (Vidal et al., 2023).

Na content in the halva samples ranged from 270 mg/kg to 985 mg/kg. The highest Na content was detected in halva made with 100% sesame tahini (X), while the lowest was found in halva made with 100% peanut tahini (Z) (Table 1). The type of tahini used in halva production had a statistically significant impact on its N content (p<0.01).

In a study focused on sesame tahini, Akbulut (2008) reported Na levels ranging from 605 mg/kg to 2436 mg/kg. These values are significantly higher than those found in the present study. Additionally, a survey of Na content in 15 varieties of sesame tahini halva sold in the provinces of Balıkesir, Bilecik, Bursa, and Çanakkale revealed sodium levels between 1200 mg/kg and 3500 mg/kg (Kilci and Çetin, 2023). The Na values observed in this study are lower than these reported results.

Magnesium (Mg) is the fourth most abundant cation in the human body and is an essential electrolyte vital for maintaining cellular and organ function. It also plays a significant role in neuronal development and the functioning of the central nervous system by crossing the blood-brain barrier (Chen et al., 2024).

The type of tahini used in halva production was found to significantly affect the Mg content (p<0.05). The highest Mg concentration was observed in halva made with 100% sesame tahini (X), while the lowest was found in halva made with 100% peanut tahini (Z) (Table 1). Akbulut (2008) reported Mg levels in sesame tahini ranging from 2040 mg/kg to 2482 mg/kg, and the Mg values obtained in this study were lower than those reported by Akbulut (2008).

Phosphorus (P) is a vital element in the human body, essential for various processes such as ATP production, signal transduction, and bone mineralization. Around 85% of the body's phosphorus is found in bones and teeth as part of hydroxyapatite, while 14% is located inside cells, and only 1% exists in extracellular fluids, mainly as inorganic phosphate. P often occurs as a salt of phosphoric acid, serving as a crucial physiological buffer. It is also a key component of molecules like phospholipids, DNA, RNA, ATP, and creatine phosphate (Serna and Bergwitz, 2020).

P content in the halva samples ranged from 725 mg/kg to 1505 mg/kg. The highest P concentration was found in halva made with 100% sesame tahini (X), while the lowest P content was observed in halva made with 100% peanut tahini (Z) (Table 1). The type of tahini used significantly influenced the P levels ($p<0.01$).

Iron (Fe) is an essential nutrient vital for numerous biological functions, including oxygen transport and cellular respiration. The adult body contains approximately 3-5 g of Fe, with about 70% found in hemoglobin. The daily requirement for Fe, primarily for erythropoiesis, is estimated at 25-30 mg, largely fulfilled by recycling iron from aged red blood cells via tissue macrophages (Charlebois and Pantopoulos, 2023).

The concentrations of trace minerals in halva produced with different tahini blends are shown in Table 2. The Fe content of the halva samples varied between 30.91 mg/kg and 42.85 mg/kg. The highest Fe concentration was recorded in halva made with 100% peanut tahini (Z), whereas the lowest was found in halva made with 100% sesame tahini (X). The type of tahini used had a statistically significant effect on the Fe content of halva ($p<0.01$).

Table 2. Minor Mineral Content of Halvas (mg/kg)

Halvas	Fe	Zn	Mn
X	30.91 ^{c#} ±0.71	28.46 ^{a#} ±0.56	3.26 ^{c#} ±0.07
Y	34.15 ^b ±0.49	23.18 ^b ±0.30	4.86 ^b ±0.05
Z	42.15 ^a ±0.50	19.38 ^c ±0.06	5.97 ^a ±0.42

X: halva made with 100% sesame tahini, Y: halva made with 50% sesame tahini and 50% groundnut tahini, Z: halva made with 100% groundnut tahini. #: Means with different letters in the same column are statistically different from each other ($p<0.05$).

In a study conducted by Kilci and Çetin (2023), the Fe content of halva made with sesame tahini was reported to range from 14.27 mg/kg to 22.33 mg/kg. Fe levels identified in the current study were significantly higher than those reported by Kilci and Çetin (2023). This discrepancy is likely attributable to the differing ingredient ratios utilized in the production processes.

Zinc (Zn) plays a vital role in regulating numerous physiological functions in the human body, acting as an activator of enzymes, a structural component of zinc-dependent proteins, and a contributor to protein anabolism, growth, and development (Duan et al., 2023).

In this study, the Zn content of halva samples ranged from 19.36 mg/kg in halva made with 100% peanut tahini (Z) to 28.46 mg/kg in halva made with 100% sesame tahini (X) (Table 2). The type of tahini used had a statistically significant impact on the Zn content of halva ($p<0.05$). A study by Oduma et al. (2020) found that varying ratios of sesame added to peanut butter resulted in increased Zn levels, which aligns with the findings of the present study.

Manganese (Mn) is essential for various metabolic processes, including glucose and lipid metabolism, protein synthesis, and the functioning of vitamins C and B. It also plays a role in haematopoiesis, endocrine regulation, bone and tissue formation, skeletal growth, reproduction, and immune function (Mehri, 2020).

The type of tahini used in halva production significantly influenced the Mn content ($p<0.01$). The highest Mn concentration was found in halva made with 100% peanut tahini (Z), while the lowest was recorded in halva made with 100% sesame tahini (X) (Table 2). Arifoglu et al. (2017) reported Mn levels in summer tahini halva ranging from 0.099 to 0.124 mg/kg. The Mn values observed in this study were lower than those reported by Arifoglu et al (2017). This difference is likely attributed to variations in raw materials and production methods.

CONCLUSIONS

This study investigated the production of halva using varying ratios of peanut tahini (50% and 100%) alongside 100% sesame tahini as a control. The mineral content of the resulting halva samples was analyzed, revealing the presence of seven key minerals: calcium, potassium, sodium, magnesium, phosphorus, iron, zinc, and manganese.

The findings demonstrated that the incorporation of peanut tahini significantly influenced the mineral composition of halva ($p < 0.05$). Specifically, halva produced with sesame tahini exhibited higher levels of Ca, Na, Mg, P, and Zn. In contrast, halva made with peanut tahini showed elevated levels of K, Fe, and Mn.

Based on these results, the use of peanut tahini at a 50% ratio is recommended as a viable approach to enhance the mineral content of halva. Future research could explore additional ingredient combinations and production techniques to further optimize the nutritional profile of this traditional dessert. Additionally, consumer acceptability and sensory evaluations of halva made with varying tahini ratios should be investigated to ensure market viability.

ACKNOWLEDGEMENT

This article is derived from Venüs KARAKUŞ's master's thesis. This study was supported by the Osmaniye Korkut Ata University Scientific Research Project Fund (OKÜBAP-2021-PT3-020).

REFERENCES

- Akbulut, M. (2008). Comparative studies of mineral contents of hulled sesame paste (tahin), unhulled sesame paste (bozkir tahin) and their blends. *Asian Journal of Chemistry*, 20(3), 1801.
- Arifoglu, N., Turker, G., Ogutcu, M., & Yilmaz, E. (2017). Mineral Composition of Summer Halva. *Journal of International Scientific Publications: Agriculture & Food*, 5(1000023), 188-194.
- Badem, A. (2020) Geographical indication helvas in Turkey. *International Journal of English Literature and Social Sciences*, 5(6), 2252-2262.
- Bakal, H. (2022). Comparison Of Oil Content and Fatty Acid Composition of Sesame (*Sesamum indicum* L.) Varieties Grown as Main and Double Crop In Mediterranean Environment In Turkey. *Turkish Journal of Field Crops*, 27(1), 119-126.
- Boukid, F. (2022). Peanut protein—an underutilized by-product with great potential: a review. *International Journal of Food Science & Technology*, 57(9), 5585-5591.
- Charlebois, E., & Pantopoulos, K. (2023). Nutritional aspects of iron in health and disease. *Nutrients*, 15(11), 2441.
- Chen, F., Wang, J., Cheng, Y., Li, R., Wang, Y., Chen, Y., & Tucker, K. L. (2024). Magnesium and Cognitive Health in Adults: A Systematic Review and Meta-Analysis. *Advances in Nutrition*, 100272.
- D'Elia, L., Cappuccio, F. P., Masulli, M., La Fata, E., Rendina, D., & Galletti, F. (2023). Effect of potassium supplementation on endothelial function: a systematic review and meta-analysis of intervention studies. *Nutrients*, 15(4), 853.
- Duan, M., Li, T., Liu, B., Yin, S., Zang, J., Chenyan L., Zhaoa G., & Zhang, T. (2023). Zinc nutrition and dietary zinc supplements. *Critical Reviews in Food Science and Nutrition*, 63(9), 1277-1292.
- H. D. Chapman, P. F. Pratt, (1961). 'Methods of analysis for soils, plants and water', University of California Berkeley CA USA.
- Kaplan, K. (2022). Investigation of changes in some physicochemical properties during conventional and organic tahini production. Trakya University, Institute of Science and Technology, Department of Food Engineering, Master's Thesis, 58 p.
- Karakahya, E. (2006). The effect of different vegetable oil and soya protein usage on quality properties in tahini halva production, Trakya University, Institute of Science and Technology, Department of Food Engineering, Master's Thesis, 53 p.
- Kıvrık, M., Süfer, Ö., & Bozok, F. (2022). A Research on Quality Evaluation of Eight Wild Edible Macrofungi Collected from East Mediterranean Region of Turkey. *Chemistry & Biodiversity*, 19 (3), e202100967.
- Kilci, Z., & Çetin, R. Ü. (2023). Chemical Properties of Tahini Halva Marketed in The Southern Marmara Region of Turkey and Their Compliance with Turkish Food Codex. *Akademik Gıda*, 21(1), 20-26.

- Lin, S., Li, J., Hu, X., Chen, S., Huang, H., Wu, Y., & Li, Z. (2024). Potential dietary calcium supplement: Calcium-chelating peptides and peptide-calcium complexes derived from blue food proteins. *Trends in Food Science & Technology*, 104364.
- Lokumcu Altay, F., Ak, M. M. (2005). Effects of temperature, shear rate and constituents on rheological properties of tahin (sesame paste). *Journal of the Science of Food and Agriculture*, 85 (1), 105-111.
- Mehri, A. (2020). Trace elements in human nutrition (II)–an update. *International Journal of Preventive Medicine*, 11 (1), 2.
- Mingrou, L., Guo, S., Ho, C. T., & Bai, N. (2022). Review on chemical compositions and biological activities of peanut (*Arachis hypogaea* L.). *Journal of Food Biochemistry*, 46 (7), e14119.
- Oduma, O. V., Inyang, U. E., & Okongoh, O. N. (2020). Impact of partial replacement of peanut paste with sesame seed paste on the nutritional and anti-nutritional components of butter made from the blends. *European Journal of Nutrition & Food Safety*, 12 (6), 53-66.
- Öğütçü, M., Arifoğlu, N., & Yılmaz, E. (2017). Restriction of oil migration in tahini halva via organogelation. *European Journal of Lipid Science and Technology*, 119 (9), 1600189.
- Serna, J., & Bergwitz, C. (2020). Importance of dietary phosphorus for bone metabolism and healthy aging. *Nutrients*, 12(10), 3001.
- Sahin, K., Bozdogan, A., Yasar, K., Eker, T., & Kabak, B. (2022). Impact of different extraction processes on aflatoxin contamination in peanut oil. *Journal of Food Science and Technology*, 1-10.
- Toomer, O. T. (2020). A comprehensive review of the value-added uses of peanut (*Arachis hypogaea*) skins and by-products. *Critical Reviews in Food Science and Nutrition*, 60 (2), 341-350.
- Torlak, E., Sert, D., & Serin, P. (2013). Fate of Salmonella during sesame seeds roasting and storage of tahini. *International Journal of Food Microbiology*, 163 (2-3), 214-217.
- Var, I., Kabak, B., & Gök, F. (2007). Survey of aflatoxin B1 in helva, a traditional Turkish food, by TLC. *Food Control*, 18 (1), 59-62.
- Vidal, V. A., Paglarini, C. S., Lorenzo, J. M., Munekata, P. E., & Pollonio, M. A. (2023). Salted meat products: nutritional characteristics, processing and strategies for sodium reduction. *Food Reviews International*, 39 (4), 2183-2202.
- Wei, P., Zhao, F., Wang, Z., Wang, Q., Chai, X., Hou, G., & Meng, Q. (2022). Sesame (*Sesamum indicum* L.): A comprehensive review of nutritional value, phytochemical composition, health benefits, development of food, and industrial applications. *Nutrients*, 14 (19), 4079.
- Weyh, C., Krüger, K., Peeling, P., & Castell, L. (2022). The role of minerals in the optimal functioning of the immune system. *Nutrients*, 14(3), 644.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 02.10.2024
Kabul Tarihi : 08.11.2024

Received Date : 02.10.2024
Accepted Date : 08.11.2024

AUTOMATIC DETECTION OF MENISCUS TEARS FROM KNEE MRI IMAGES USING DEEP LEARNING: YOLO V8, V9, AND V10 SERIES

DİZ MRI GÖRÜNTÜLERİNDEN MENİSKÜS YIRTIKLARININ DERİN ÖĞRENME İLE OTOMATİK TESPİTİ: YOLO V8, V9 VE V10 SERİLERİ

Mehmet Ali ŞİMŞEK^{1*} (ORCID: 0000-0002-6127-2195)
Ahmet SERTBAŞ² (ORCID: 0000-0001-8166-1211)

¹ Department of Computer Technologies, Vocational School of Technical Sciences, Tekirdag Namik Kemal University, Tekirdag, TURKEY.
² Department of Computer Engineering, Faculty of Engineering, Istanbul University-Cerrahpaşa, Istanbul, TURKEY.

*Sorumlu Yazar / Corresponding Author: Mehmet Ali ŞİMŞEK, masimsek@nku.edu.tr

ABSTRACT

Meniscal tears are a disease that occurs in the knee joint and negatively affects people's mobility. In this study, the performance of the state-of-the-art (SOTA) YOLO (You Only Look Once) models, in particular YOLOv8l, YOLOv8x, YOLOv9c, YOLOv9e, YOLOv10l, and YOLOv10x, for the detection of meniscal tears was investigated. The algorithms were trained and tested with data from magnetic resonance imaging (MRI). In our study, the YOLOv9e model showed the highest performance and achieved the best results in the training phase with a mAP50 of 0.91807, a precision of 0.87684, a recall of 0.93871 and an F1 score of 0.90672. This study makes a unique contribution to the field with its advanced algorithms and comprehensive performance analysis. The findings show that deep learning algorithms are suitable for clinical use in the automatic detection and localization of meniscal tears. In this way, the possibility of early diagnosis increases, and patients can be directed to the right treatment, preventing joint problems that may occur in the future. In future studies, it is aimed to increase the generalization capabilities of the models with larger data sets and different anatomical structures.

Keywords: Osteoarthritis, meniscus tear, magnetic resonance imaging, deep learning, YOLO series,

ÖZET

Menisküs yırtıkları diz eklemde meydana gelen ve insanların hareket kabiliyetlerini olumsuz etkileyen bir hastalıktır. Bu çalışmada, menisküs yırtıklarının tespiti amacıyla YOLOv8l, YOLOv8x, YOLOv9c, YOLOv9e, YOLOv10l ve YOLOv10x gibi son teknoloji YOLO (You Only Look Once) modellerinin performansı incelenmiştir. Algoritmalar, manyetik rezonans görüntüleme (MRG) görüntülerinden elde edilen veriler üzerinde eğitilmiş ve test edilmiştir. Çalışmamızda kullanılan YOLOv9e modeli, eğitim sürecinde elde edilen en iyi sonuçlarda 0,91807 mAP50, 0,87684 Precision, 0,93871 Recall ve 0,90672 F1 Score değerleriyle en yüksek başarıyı göstermiştir. Bu çalışma, kullanılan ileri seviye algoritmalar ve kapsamlı performans analizi ile alanda özgün bir katkı sağlamaktadır. Elde edilen bulgular, derin öğrenme algoritmalarının menisküs yırtıklarının otomatik tespiti ve lokalizasyonunda klinik kullanıma uygun olduğunu göstermektedir. Bu sayede erken teşhis olasılığı artmakta ve hastaların doğru tedaviye yönlendirilmesi sağlanarak ilerleyen dönemde oluşabilecek eklem sorunlarının önüne geçilebilmektedir. İlerleyen çalışmalarda daha geniş veri setleri ve farklı anatomik yapılarla yapılacak araştırmalarla modellerin genelleme yeteneklerinin artırılması hedeflenmektedir.

Anahtar Kelimeler: Osteoartrit, menisküs yırtığı, manyetik rezonans görüntüleme, derin öğrenme, YOLO serileri.

INTRODUCTION

Osteoarthritis (OA) is a degenerative joint disease caused by damage to the articular cartilage and underlying bone, particularly in weight-bearing joints. OA of the knee is the most common type of recurrent arthritis affecting older people. This disease is characterized by the wear and deterioration of the cartilage in the knee joint over time, resulting in significant disability and limitations in the activities of older people (Almajalid et al., 2019; Bilge et al., 2018; Gaj et al., 2020a).

The meniscus is an important component of the human body. Each knee has two fiber-reinforced menisci, one on the inside and one on the outside. The menisci are crescent-shaped, convex, and triangular on the outside, tapering from the outside inwards and covering two thirds of the surface of the tibial plateau. The menisci are flexible and consist of dense and tightly woven collagen fibers to withstand compressive forces. The shock-absorbing properties of the menisci nourish the articular cartilage and stabilize the knee by protecting it from high pressure and distributing weight evenly (Bryceland et al. 2017; Makris et al., 2011; Ölmez et al., 2020). Degeneration or tearing of the meniscal tissue is an important factor in the development of OA. Since the meniscus contributes to the stability and shock absorption of the knee joint, damage to this tissue can lead to wear and degeneration of the articular cartilage, which can trigger or accelerate the OA process. Meniscus tears are common knee injuries and can occur in people of all ages. Meniscus tears can occur as a result of sporting activities, aging, or trauma. Figure 1 shows examples of healthy and tear meniscus. These images visually illustrate the textural differences that our model attempts to recognize and concretize the structural differences between a torn meniscus and a healthy meniscus.




Figure 1. Examples of Healthy and Tear Meniscus. (a) and (b) Show Images of a Healthy Meniscus, While (c) and (d) Show Images of a Tear Meniscus (The Red Arrows Indicate the Tear).

Modern imaging techniques such as MRI, which are widely used in clinical practice, make it possible to examine joint structures. However, the manual measurement of these structures is time-consuming (Almajalid et al., 2019). The difficulty in diagnosing meniscus tears can lead to incorrect treatment or late diagnosis of the condition, which can have a negative impact on the treatment process and even cause permanent damage to the knee joint if left untreated.

Recent advances in deep learning (DL) algorithms have led to significant improvements in the diagnosis of meniscal tears, which present a clinical challenge. These tears are usually detected by MRI. However, they can be difficult to diagnose due to structural defects in the image. DL algorithms, in particular convolutional neural networks (CNN), have shown remarkable performance in accurately detecting these injuries (Botnari et al., 2024; Ozeki et al., 2021).

The success of DL methods, especially in analyzing image data, is quite high. Neural networks and in particular CNN architecture make it possible to detect lesions and anomalies in medical images. Some studies have successfully detected meniscus tears using machine learning (ML) and DL methods (Couteaux et al., 2019; Gaj et al., 2020b; Harman et al., 2023; Hung et al., 2023; Ma et al., 2023; Roblot et al., 2019; Saygili & Albayrak, 2017a, 2020; Saygılı & Albayrak, 2017b; Ying et al., 2024). Further integration of these DL-based technologies into clinical workflows will streamline diagnostic processes and contribute significantly to the reliable detection of meniscal pathologies, improving patient outcomes (Ma et al., 2023).

One of the latest DL methods is YOLO, an object detection algorithm proposed by Redmon et al. in 2016. This algorithm divides an input image into $S \times S$ grid cells and estimates B bounding boxes and the corresponding class probabilities for each cell. YOLO aims at fast and accurate object detection by converting the object detection problem into a regression problem (Redmon et al., 2016; Su et al., 2023). The latest version of YOLO-based algorithms is the YOLOv11 algorithm. In this study, we used the current YOLO algorithms and investigated the performance of these algorithms on meniscal tears.

The use of YOLO series and YOLO-based hybrid architectures in MRI imaging of knees has shown promising results. For example, one study investigated the effectiveness of advanced deep learning models such as YOLOv8 and EfficientNetV2 on sagittal and coronal MRI images of meniscus tears. In this study, the YOLOv8 version was used to localise the meniscus and then the EfficientNetV2 model was used to detect meniscus tears (Güngör et al., 2024). In another study using EfficientNet and YOLO series, the Scaled-YOLOv4 model detects the location of the meniscus and the EfficientNet-B7 model classifies meniscal tears (Chou et al., 2023).

In addition, the SE-YOLOv5 model based on squeeze-and-excitation (SE) inception attention was developed in a study on the automatic detection of cystic lesions in the knee using deep learning methods based on MRI images (Xiongfeng et al., 2022). In another study, a recurrent neural network (RNN) model was proposed for the classification and localization of knee ligament injuries on MRI images. This model was shown to provide better classification and localization compared to YOLOv3 (Zhu et al., 2022).

In a study on the automatic diagnosis of discoid lateral meniscus, it was reported that the YOLOv3 algorithm can diagnose this condition (Li et al., 2021a). In another study, a lesion detection network was trained using the YOLOv5S architecture for the detection of meniscal tears (Li et al., 2021b). In another study, a lesion detection network was trained using the YOLOv5S architecture for the detection of meniscus tears (Zhao et al., 2021). In another study, Darknet-53 proposed a new model that can be integrated into the YOLOv4 algorithm to analyze coronal and sagittal MRI images (Hung et al., 2023).

Although there are already several studies analysing MRI images of the knee using YOLO series, there is still potential for development in this area. Few studies are comparing the performance of the different versions of the YOLO algorithm in detecting meniscal tears. In particular, a comprehensive evaluation of the accuracy, precision, and overall efficiency of the latest versions in detecting meniscal pathologies has not yet been performed. In this study, we focus on the diagnosis of meniscal tears with the current YOLO series (YOLOv8, YOLOv9, YOLOv10) using the MRNet dataset.

The clinical contributions of our work focus on the accurate and rapid diagnosis of meniscal tears. The developed DL-based methods will relieve radiologists and help them to diagnose faster. In particular, early diagnosis of a meniscus tear will ensure that the appropriate treatment plan is implemented in a timely manner and prevent meniscus tears from progressing and causing more serious joint problems. This can improve the patient's general condition, reduce the need for surgery, and speed up the rehabilitation process.

MATERIALS AND METHODS

Selection of the Dataset and Labeling of the Data

The MRNet dataset consists of 1,370 knee MRI examinations performed at Stanford University Medical Centre. The dataset contains 1,104 (80.6%) abnormal exams with 319 (23.3%) ACL tears and 508 (37.1%) meniscal tears; the labels were manually extracted from the clinical reports (Bien et al., 2018). For this study, 250 examinations were randomly selected from the MRNet dataset and 203 examination images were used based on the exclusion criteria. Of these examinations, 97 (47.78%) were examinations without meniscal tears and 106 (52.22%) were examinations with meniscal tears. Figure 2 shows the dataset selection process and exclusion criteria.

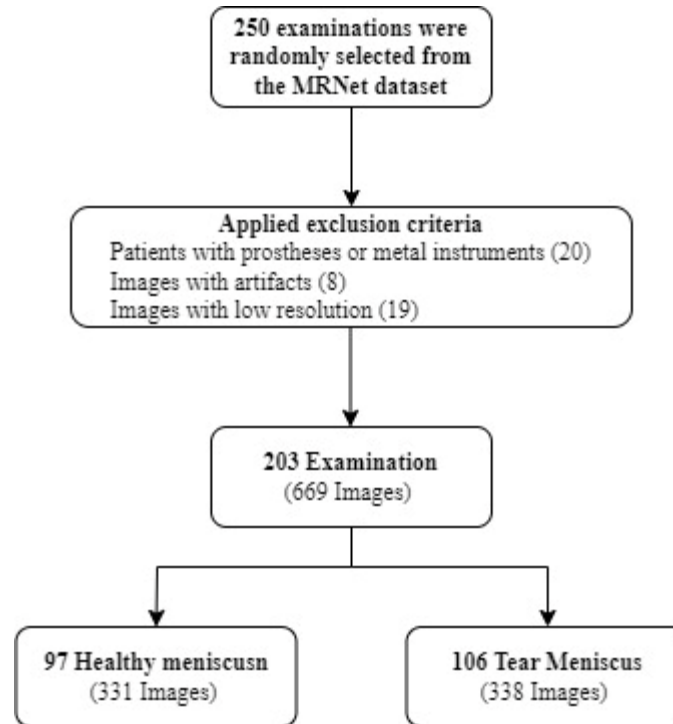


Figure 2. Process of Dataset Creation.

Since the sagittal section provides the most information about meniscal tears (Ma et al., 2023) only sagittal section images were used in this study. Images showing both the anterior and posterior horn in the sagittal plane were selected. From the images of 203 examinations, a total of 669 images were extracted in PNG (Portable Network Graphic) file format. Of these images, 338 (50.52%) were images with meniscal tears and 331 (49.48%) were healthy images without meniscal tears. The dataset was split to 70:25:5 for train, validation, and testing. Table 1 shows the distribution of the dataset.

Table 1. Number of Images in the Train, Validation, and Test Dataset.

	Healthy	Tear	Total
Train	237	232	469
Validation	84	83	167
Test	17	16	33

The meniscus area in images with a meniscus tear is labeled “tear” and the meniscus area in images without a meniscus tear is labeled “no tear”. The anterior horn and posterior horn were labeled separately in images without a meniscal tear, while only the tear area was labeled in images with a meniscal tear. The number of labels in the images of the train, validation, and test sets can be found in Table 2. The online tool RoboFlow was used for labeling the images, sizing, and partitioning the dataset.

Table 2. Number of Tags in the Train, Validation, and Test Dataset.

	Train	Valid	Test
no_tear	417	140	32
tear	333	117	24

Preprocessing of Images

Since the obtained MRI images have different resolutions, they were preprocessed and converted to the input sizes (640x640 pixels) of the YOLO algorithm. This process was performed with RoboFlow.

Experimental Setup and Hyperparameters

All experiments in this study were conducted using the Google Colab platform, where computationally intensive operations are performed by Google servers. The required libraries were provided by this platform. The analysis of the dataset was performed on an NVIDIA A100-SXM4-40GB GPU with the Python-3.10.12 programming language using torch-2.4.1+cu121 with the latest YOLOv8, YOLOv9 and YOLOv10 libraries from Ultralytics. The hyperparameters used in these experiments were kept constant throughout the study and are listed in Table 3.

Table 3. Experimental Hyperparameters.

Hyperparameter	Value
workers	2
batch	12
device	0
epochs	100
lr0	0.01
lrf	0.01
momentum	0.95
weight_decay	0.0001
warmup_epochs	10
warmup_momentum	0.5
warmup_bias_lr	0.1
optimizer	SGD

The hyperparameters used in this study were carefully selected to efficiently train the model and optimize its overall performance. The batch size was set to 12 to compensate for memory usage during training, while the value of epochs was set to 100 to ensure that the model processes the data appropriately. The learning rate (lr0) was set to 0.01 and the momentum to 0.95 to achieve rapid convergence of the model. The weight decay was set to 0.0001 to increase the generalization ability of the model. At the beginning of the training process, a low momentum (0.5) and learning rate (0.1) were used for 10 epochs in the warm-up phase so that the model learns more stably. Finally, the SGD optimization algorithm was used to update the model parameters. The balanced use of these hyperparameters contributed to the high performance of the model in detecting meniscus tears.

YOLO Series

YOLO is an object recognition algorithm proposed by Redmon et al. in 2015. YOLO aims at fast and accurate object recognition by converting the object recognition problem into a regression problem (Redmon et al., 2015; Su et al., 2023). The latest version of YOLO-based algorithms is YOLOv11. Over the years, numerous versions of YOLO have been released with innovative techniques to improve performance. Figure 3 shows the timeline of YOLO versions.

The three current versions of the YOLO algorithms and the models with the highest number of parameters (YOLOv8l, YOLOv8x, YOLOv9c, YOLOv9e, YOLOv10l, and YOLOv10x) were used in this study. The reason for choosing these models is that they have the potential to learn more complex structures and provide more accurate results due to their high number of parameters. Especially when detecting subtle structural changes such as meniscus tears, the deeper learning capacity of larger models can improve accuracy and allow better generalization to complex images.

YOLOv8(Jocher et al., 2023; Sohan et al., 2024; Terven et al., 2023), 2023 is an object detection model released by Ultralytics in 2023 that offers significant improvements over previous versions. This model offers flexibility through multiple scaled versions for different application domains, including YOLOv8n (nano), YOLOv8s (small), YOLOv8m (medium), YOLOv8l (large) and YOLOv8x (extra-large). YOLOv8 introduces the C2f module, which significantly improves its architecture and extends the CSP (Cross-Stage Partial) layer. This module enables the combination of high-level features with contextual information, improving the accuracy of the model. YOLOv8 also

improves the overall accuracy of the model by moving to a decoupled header structure that independently handles object presence, classification, and regression tasks (Alif & Hussain, 2024; Sapkota et al., 2024; Wang & Liao, 2024).

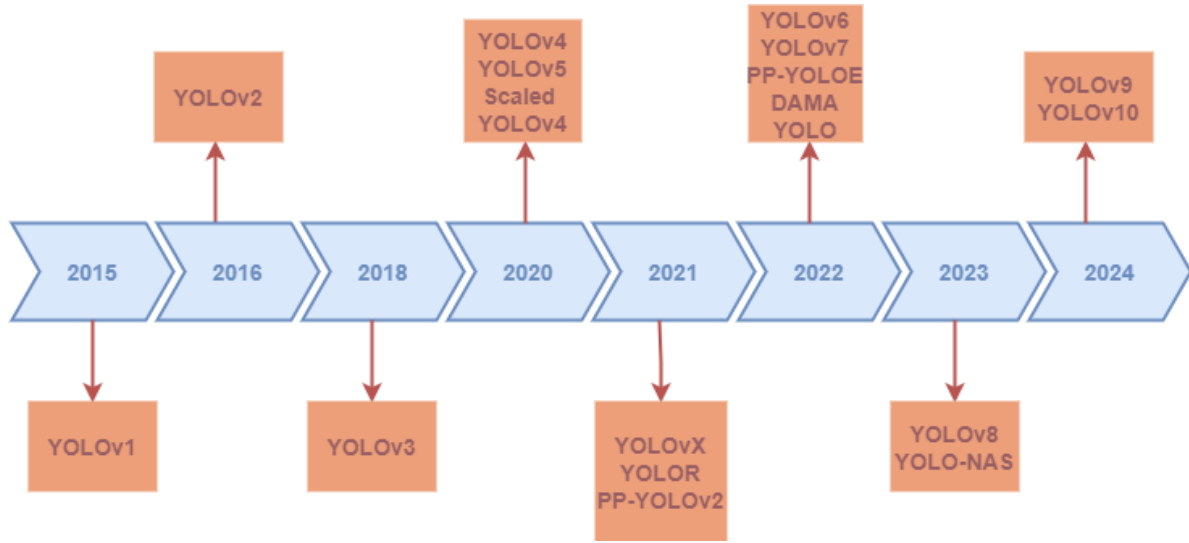


Figure 3. Timeline of the YOLO Versions: YOLOv1 Through YOLOv10.

YOLOv9 is the next generation object recognition model, launched in 2024, and builds on the benefits of previous versions. It aims to preserve data integrity in deep learning processes by introducing Programmable Gradient Information (PGI) and the Generalized Efficient Layer Aggregation Network (GELAN) architecture, an innovative approach to reduce information loss. YOLOv9 is designed to prevent data corruption - a common problem with deep neural networks - while ensuring a better flow of information and improving object recognition capabilities in complex and dynamic environments (Alif & Hussain, 2024; A. Wang et al., 2024; Wang & Liao, 2024).

YOLOv10 (A. Wang et al., 2024; Wang & Liao, 2024) is the latest object recognition model released in 2024. It offers significant innovations and combines all the advantages of the previous versions. It significantly reduces recognition time by eliminating the need for traditional NMS (Non-Maximum Suppression). YOLOv10 manages to increase detection accuracy without compromising speed by optimizing the training protocol with a double label assignment strategy. The architecture of the model includes innovative components such as lightweight classifier heads and discrete subsampling with spatial channels that minimize information loss (Alif & Hussain, 2024; Sapkota et al., 2024; A. Wang et al., 2024; Wang & Liao, 2024).

YOLOv8, YOLOv9, and YOLOv10 can be seen as successive advances in the field of object recognition in the context of deep learning. Each model improves the functions of the previous versions and offers greater speed, accuracy, and efficiency. While YOLOv8 provides flexibility with architectural improvements and multiscale versions, YOLOv9 improves performance with innovative approaches to reduce information loss. YOLOv10 combines all the advantages of the previous versions and offers innovative features that reduce recognition time and increase accuracy. These three models play an important role in the development of object recognition technology and pave the way for future applications.

Metrics of Success

The metrics Recall (R), Precision (P), Average Precision (AP), Mean Average Precision (mAP) and F1 score were used to evaluate the performance of the model. These metrics are the most used metrics for evaluating object recognition models and their expressions are given in Equations 1-5.

$$R = \frac{TP}{TP+FN} \quad (1)$$

$$P = \frac{TP}{TP+FP} \quad (2)$$

$$AP = \int_0^1 P(r)dr \quad (3)$$

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (4)$$

$$F1 \text{ score} = 2 \frac{P \times R}{P + R} \quad (5)$$

True Positive (TP) refers to the number of instances in the dataset that the model correctly predicts as positive, while False Negative (FN) describes cases where the model incorrectly classifies an instance that should be positive as negative. False Positive (FP) is when the model incorrectly predicts a sample as positive when it should be negative. Recall indicates how many instances the model correctly predicts as positive and evaluates the ratio between TP and FN. Precision indicates how many of the instances that the model predicts as positive are correct and measures the trade-off between TP and FP. Ideally, a model should have high precision and recall values, but it can often be difficult to achieve a balance between these two metrics. The mean average precision (mAP) represents the average of the average precision (AP) values calculated for each class. AP is a metric that is calculated considering the precision and recall of the model at a given threshold and is usually presented as an average of the performance obtained for different classes.

F1 score is a metric that evaluates the trade-off between precision and recall. This metric is calculated as the harmonic mean of precision and recall and measures the model's performance on false-positive and false-negative predictions in a balanced way. The F1 score is an important indicator, especially for unbalanced datasets, as it more accurately reflects the overall performance of the model.

RESULTS

This study evaluates the performance of the YOLOv8, YOLOv9 and YOLOv10 series for the detection of meniscal tears based on the results from the training, validation, and testing phases. The performance measures such as mAP, precision, recall, and F1 score of each of the models in the training process were examined and qualitative and quantitative analyses were performed based on the classification results obtained in the test set.

A total of 6 experiments were carried out with the two versions of the YOLOv8, YOLOv9, and YOLOv10 series with the most parameters. Table 4 shows the comparison of the number of parameters, GFLOPs, and processing time for these trainings. The YOLOv8x model has the highest value with 68.1 million parameters, while the YOLOv9c and YOLO10l models have the lowest values with around 25 million parameters. In terms of FLOPs, the YOLOv8x model has the highest value with 257.4 GFLOPs. This indicates that the model is more computationally intensive, while the YOLOv9c model requires the least computing power with 102.3 GFLOPs. In terms of processing time, the Yolov8l model requires the shortest time (13 min 8 sec), while the YOLOv9e model requires the longest time (27 min 40 sec). In particular, the YOLOv9c model stands out as a computationally efficient model with its small number of parameters and FLOPs, while models such as YOLOv8x and YOLOv9e, as complex structures that require more calculations, have longer processing times.

Table 4 Comparison of the Number of Parameters, FLOP and Processing Time of the Train.

	Parameters/M	FLOPs/G	Time/min
YOLOv8l	43,6	164.8	13 min 08 sec
YOLOv8x	68,1	257.4	16 min 56 sec
YOLOv9c	25,3	102.3	15 min 42 sec
YOLOv9e	57,4	189.1	27 min 40 sec
YOLOv10l	25,7	126.3	16 min 56 sec
YOLOv10x	31,6	169.8	18 min 44 sec

Table 5 shows the values of the performance indicators Last and Best achieved by the models during the training process. In comparison between the models, the YOLOv9e model achieved the highest performance metrics overall. In both the last training results and the best results, this model had the highest values in terms of mAP50 (Last: 0.90308, Best: 0.91807) and recall (Last: 0.90522, Best: 0.93871), showing significant success in recognizing complex objects. The high mAP50 metric indicates that the intersection between the recognized area and the labeled area is high. On the other hand, the YOLOv8l and YOLOv8x models stand out as lower cost models that offer a balanced performance in terms of precision and F1 score values. The YOLOv10x model, on the other hand, generally has lower accuracy values. Considering the high number of parameters and FLOPs, it can be said that the YOLOv9e model is preferable for complex and challenging object detection problems in terms of accuracy and efficiency.

The YOLOv9e model showed the highest overall performance among the models tested and achieved the best values. In particular, it achieved a peak mAP50 of 0.91807, a precision of 0.87684, a recall of 0.93871, and an F1 score of 0.90672 during training. These metrics show that the YOLOv9e model is particularly effective at recognizing complex objects and has high accuracy in matching detected regions to labeled regions in the dataset. This performance makes it particularly suitable for demanding applications, such as the automatic detection and localization of meniscus tears.

Table 5. Comparison of the Last and Best Performance Metrics Achieved by the Models During the Training Process.

	LAST				BEST			
	mAP50	Precision	Recall	F1 Score	mAP50	Precision	Recall	F1 Score
YOLOv8l	0.88859	0.83977	0.86968	0.85446	0.89789	0.87019	0.91230	0.89075
YOLOv8x	0.89370	0.83390	0.87592	0.85439	0.89896	0.85991	0.92659	0.89201
YOLOv9c	0.88149	0.83096	0.85610	0.84334	0.90505	0.85839	0.93654	0.89576
YOLOv9e	0.90308	0.82948	0.90522	0.86570	0.91807	0.87684	0.93871	0.90672
YOLOv10l	0.89527	0.83659	0.85668	0.84652	0.89527	0.86764	0.89942	0.88324
YOLOv10x	0.86525	0.83454	0.85458	0.84444	0.88694	0.86887	0.90943	0.88869

During training, performance analysis was performed using graphs showing the mAP50, precision, recall, and F1 score values of the models during each epoch. Figure 4 shows the mAP50 metric values of the models during training. In the beginning, all models increase their performance at a certain rate, but this increase slows down over time. After the 40th epoch, the learning rate slows down for all models. After 80 epochs, the models show that the increase in performance slows down and eventually reaches a constant level. This saturation point indicates that the model will no longer achieve a significant improvement in performance with further training. Although the YOLOv10l model achieves higher mAP50 values with fewer epochs, the YOLOv9e model achieves the best mAP50 value at the end of training.




Figure 4. Variation of the mAP50 Metric Over 100 Epochs.

Figure 5 shows the precision metric values of the models during training. It can be seen that the precision values of all models increase at the beginning of the training process, but after 80 epochs the increase slows down or even stops. The YOLOv9c and YOLOv9e models showed good overall performance among their peers and achieved higher accuracy values without overfitting. Although YOLOv8l has the highest value at the end of training, YOLOv9e has the highest value throughout training. Eliminating the drop of the YOLOv9e model at the end of training indicates that this model will be the optimal choice for solving the meniscus tear recognition problem.




Figure 5. Variation of the Precision Metric Over 100 Epochs.

Figure 6 shows the recall metric values of the models during training. Although the models YOLOv8l and YOLOv8x achieve higher recall values in a shorter time than the other models, YOLOv9e provides the best recall value. Although all models show high performance in the first epochs, it can be observed that the performance decreases after the trial.




Figure 6. Variation of the Recall Metric Over 100 Epochs.

Figure 7 shows the F1 score of each model during training. This metric is used to balance precision and recall and is suitable for models with an unbalanced class distribution. It may improve rapidly at a certain point during training. This indicates that the learning process of the model is efficient. It shows that the learning process is high in the first

epochs of training. The fact that the F1 score of the YOLOv9e model increases faster compared to other models may indicate that this model has a high learning capacity and is trained more effectively.




Figure 7. Variation of the F1 Score Metric Over 100 Epochs.

The YOLOv8, YOLOv9 and YOLOv10 series provide reliable and very accurate results for the detection of meniscal tears. In particular, the high values achieved for critical metrics such as mAP50 and recall speak for the use of these models for real-time applications in the medical field.

Table 6 shows the precision, recall and AP50 values of the models used in the train set for the classes no_tear and tear. The YOLOv9c and YOLOv9e models are characterized by their strong performance, especially in the recognition of complex objects. The YOLOv9c model achieved the best results in the “no_tear” class with an AP50 value of 0.909. The same model also showed a balanced performance in the precision and recognition values and achieved successful recognition in both classes. The YOLOv9e model also has a high recall value of 0.950 in the “no_tear” class and a high performance in the “tear” class with a precision of 0.888 and an AP50 of 0.895. The YOLOv10l model achieved the highest AP50 value (0.906), especially in the recognition of healthy images and proved to be an ideal model for this class.

Table 6. Performance Comparison of the Models Used in the Train Set for the Classes.

Model	Class	Precision	Recall	AP50
YOLOv8l	no_tear	0.819	0.893	0.887
	tear	0.828	0.855	0.898
YOLOv8x	no_tear	0.803	0.903	0.888
	tear	0.804	0.841	0.884
YOLOv9c	no_tear	0.810	0.943	0.909
	tear	0.906	0.786	0.899
YOLOv9e	no_tear	0.805	0.95	0.894
	tear	0.888	0.88	0.895
YOLOv10l	no_tear	0.841	0.893	0.886
	tear	0.833	0.821	0.906
YOLOv10x	no_tear	0.839	0.900	0.876
	tear	0.847	0.786	0.865

Table 7 shows the precision, recall and AP50 values of the models used in the validation set for the classes no tear, and tear. The YOLOv9e and YOLOv9c models perform well on the data without meniscus tears, while the

performance of these models is lower on the data with meniscus tears. If we evaluate Table 6 and Table 7 together, we see that a good balance is achieved between the train and validation sets of the YOLOv9e and YOLOv9c models.

Table 7. Performance Comparison of the Models Used in the Validation Set for the Classes.

Model	Class	Precision	Recall	AP50
YOLOv8l	no_tear	0.820	0.893	0.887
	tear	0.837	0.863	0.906
YOLOv8x	no_tear	0.797	0.896	0.88
	tear	0.803	0.838	0.885
YOLOv9c	no_tear	0.807	0.943	0.909
	tear	0.906	0.786	0.899
YOLOv9e	no_tear	0.805	0.95	0.894
	tear	0.888	0.879	0.895
YOLOv10l	no_tear	0.840	0.893	0.885
	tear	0.833	0.821	0.906
YOLOv10x	no_tear	0.839	0.892	0.875
	tear	0.847	0.786	0.865

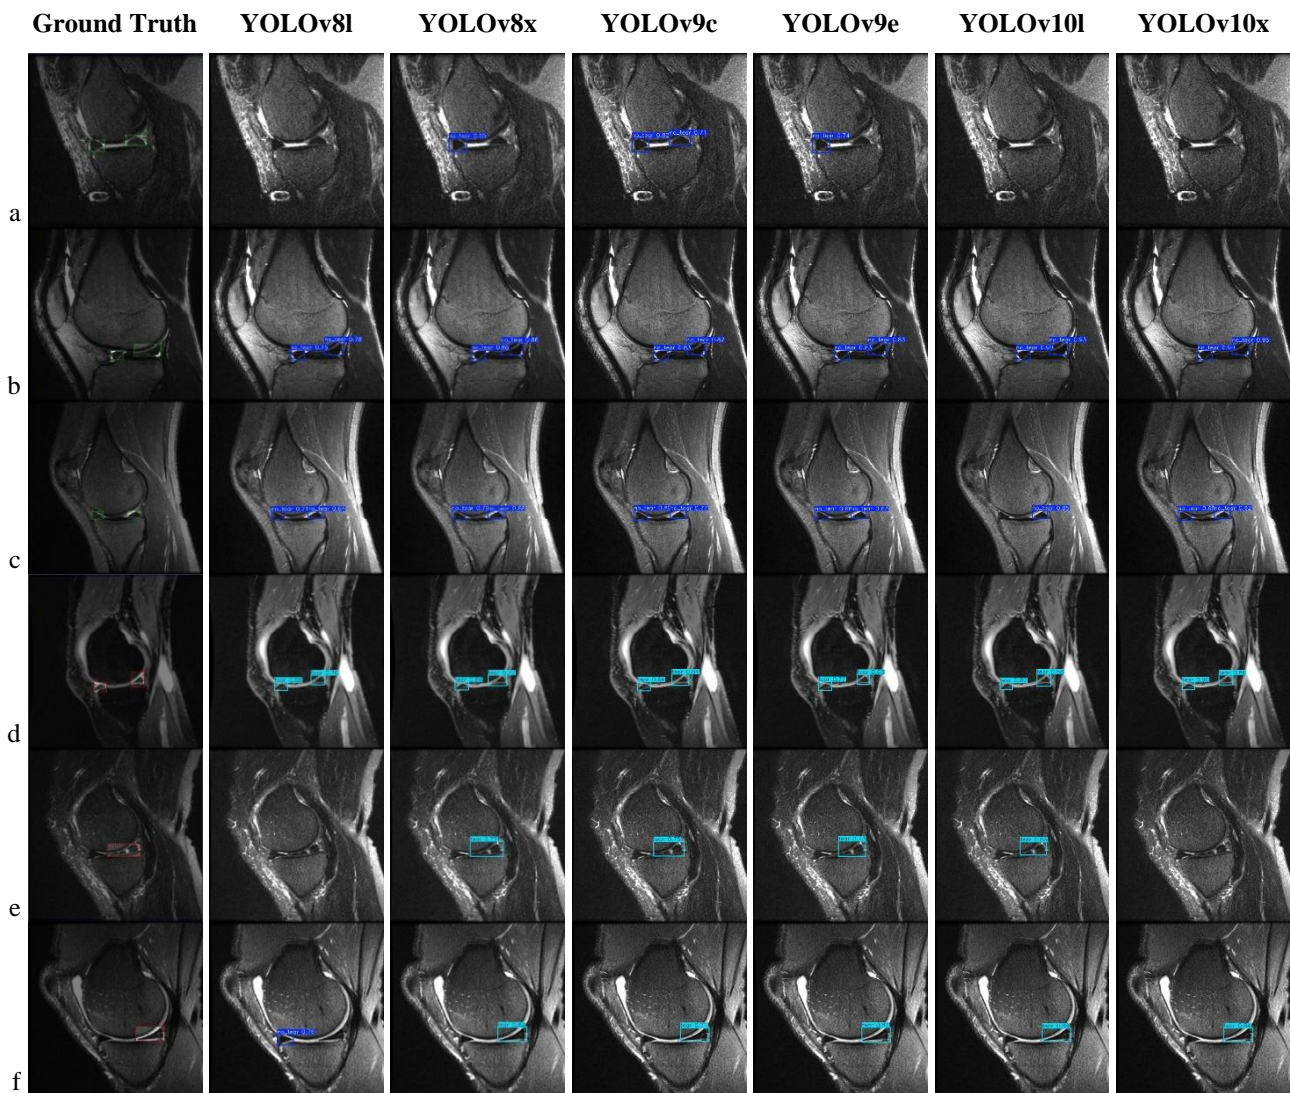


Figure 8. Comparison of the Prediction Results of the Models Used with Ground Truth.

Examples of the prediction results of the architectures YOLOv8, YOLOv9, and YOLOv10 are shown in Figure 8. From the MRI images in the sagittal plane of the test dataset, 3 healthy images and 3 images with meniscal tears were selected. Although the meniscus in the image in Figure 8a is healthy in both the anterior and posterior horns, this region could not be correctly predicted in the YOLOv8l, YOLOv10l, and YOLOv10x models. In the architectures YOLOv8x and YOLOv9e, only the anterior horn could be predicted correctly. In the image in Figure 8c, both horns

of the meniscus are healthy, but only the posterior horn was incorrectly predicted in the YOLOv10l model. In the image in Figure 8e, there is a vertical meniscal tear in the posterior horn. This tear was not correctly predicted by the YOLOv8l and YOLOv10x models. Finally, the image in Figure 8f shows a horizontal meniscus tear in the posterior horn that was not predicted by the YOLOv8x model but correctly identified the anterior horn as healthy. The same tear was not correctly predicted in the YOLOv10x model. Looking at the accuracy of the predictions for the test dataset shown in Table 8 by class, it can be seen that the YOLO models provide results with high accuracy in most cases and the number of correct predictions is high. However, in this section, the cases with incorrect predictions are highlighted.

The test dataset consists of 33 images. Table 8 shows the number of correct and incorrect detections of the YOLO algorithms according to the classes tear and no tear in the test set. In general, all models achieved a high number of correct detections in both classes. YOLOv9c performed the best with 0 false detections in the classes tear and no tear, while YOLOv8x performed the worst with 5 false detections. All models appear to be successful in detecting meniscus tears.

Table 8. Number of Correct and Incorrect Recognitions of YOLO Models According to the Classes "Tear" and "No_Tear" in the Test Set.

	YOLOv8x			YOLOv8l	
	Correct	Incorrect		Correct	Incorrect
tear	24	0	tear	22	2
no_tear	31	1	no tear	29	3
	YOLOv9c			YOLOv9e	
	Correct	Incorrect		Correct	Incorrect
tear	24	0	tear	24	0
no_tear	32	0	no tear	31	1
	YOLOv10l			YOLOv10x	
	Correct	Incorrect		Correct	Incorrect
tear	24	0	tear	23	1
no_tear	29	3	no tear	29	3

DISCUSSION

In this study, the most parameterized (YOLOv8x, YOLOv8l, YOLOv9c, YOLOv9c, YOLOv9e, YOLOv10l, YOLOv10x) models of the current YOLO algorithms YOLOv8, YOLOv9, and YOLOv10 are examined for their success in detecting meniscal tears.

Examinations were randomly selected from the examination images in the MRNet dataset and a suitable dataset for the study was created through the necessary pre-processing. As can be seen in Figure 2, the number of healthy images and images with meniscus tears are close to each other. Looking at Table 1 and Table 2, it can be said that the created dataset is balanced. Each class is evenly distributed in the train, validation, and test sets. This is to reduce the risk of overfitting the models, achieve better generalization ability, and obtain consistent metric values. This helps to obtain more reliable and accurate predictions when fitting the models to real data.

During the training process, the models were evaluated using the metrics mAP50, precision, recall, and F1 score. The scores of the individual classes in both the train and validation process were calculated using the metrics precision, recall AP50. The comparison of the last and best performance metrics achieved by the models in the training process is shown in Table 5. The YOLOv9e model is one of the models with the most parameters, as can be seen in Table 4. Due to its large number of parameters and compact structure, YOLOv9e seems to be the most successful model. The YOLOv9e model seems to give the best results for both the last metric values and the best metric values. YOLOv9c has relatively few parameters, but the model is free of unnecessary parameters and its compact structure ensures that the model performs more optimally. Considering the performance of the metrics, the YOLOv9c model seems to be very balanced, and considering the number of parameters, FLOPs, and performance results, it can be said that it can be preferred in real-time applications. Compared to the other models, it has the least training time, and the training time is shorter than the other models (except YOLOv8l), indicating that it generalizes quickly. YOLOv9 shows better results in object recognition thanks to its more complex structures and attention mechanisms in the backbone and head networks.




Figure 9. Comparison of Prediction Results Between the YOLOv9e and YOLOv8l Models on MRI Images. Images (a), (b), and (c) Show the Predictions of YOLOv9e, While Images (d), (e), and (f) Show the Predictions of YOLOv8l.

The performance of the models in the two classes tear and no tear was analyzed during training (Table 6) and validation (Table 7). The class predictions generally show high accuracy. However, it was found that some models made relatively many false detections in the no_tear class (e.g. the YOLOv8x model). The models show good results in detecting meniscus tears in both training and validation.

Low false positive (FP) rates in medical image analysis, especially in the tear class, are of great clinical importance. It helps to ensure an accurate diagnosis. Failure to detect a meniscal tear (FN) may result in the patient not receiving treatment or delayed treatment. Incorrect detections in both classes can have a significant impact on medical decisions, so the models need to be evaluated in this respect. Table 8 shows the number of correct and incorrect detections of the YOLO models according to the tear and no_tear classes in the test set. YOLOv9c showed the best performance with 0 errors in the tear and no_tear classes, while YOLOv8x showed the worst performance with 5 false detections. The analysis of Table 8 shows that the models are more successful in detecting meniscal tears than in detecting a healthy meniscus. The low contrast and ambiguity of the meniscus structure in some regions of the images lead to inaccurate predictions. In particular, the models did not capture enough discriminative features when localizing vertical and horizontal tears, which also led to incorrect predictions. In addition, the generalization performance decreased because the models failed to detect some small tears or focused on specific tear types during training. Although the dataset is balanced, the type of tears in the images with meniscal tears varies.

Figure 8 compares example prediction results of the models used with real data. The image in Figure 8a was either not predicted or only the anterior horn was predicted in all models except YOLOv9c. The low resolution of the image

and the presence of artifacts mean that the models cannot make accurate predictions. Figure 9 displays the prediction results on the test dataset for YOLOv9e, which achieved the highest performance among the models tested, and YOLOv8l, which showed one of the lower performances. In these images, YOLOv9e (a, b, c) generally provides higher confidence levels and more accurate predictions compared to YOLOv8l (d, e, f). The YOLOv9e model makes correct predictions in Figures 9a and 9b, while in Figure 9c, it accurately detects the anterior horn but fails to identify the healthy meniscus in the posterior horn. On the other hand, the YOLOv8l model correctly identifies the anterior horn in Figure 9d but fails to detect the posterior horn and makes no predictions in Figures 9e and 9f. Analyzing these examples reveals that image quality, contrast, and the presence of artifacts play a significant role in prediction accuracy. Future improvements in image preprocessing and model fine-tuning could help mitigate these issues, enabling more reliable detection of meniscal tears.

In the literature, there are CNN-based studies on the detection, localization, and characterization of meniscal tears (Couteaux et al., 2019; Hung et al., 2023; Ma et al., 2023). There are also studies using YOLO series, which also form the basis of this study, but they are not at a sufficient level. Some of these studies also propose YOLO-based hybrid architectures (Chou et al., 2023; Güngör et al., 2024; Zhao et al., 2021). Some studies propose architectures developed using YOLO series (Chou et al., 2023; Xiongfeng et al., 2022). In these studies, YOLO versions YOLOv3(Li et al., 2021b; Zhu et al., 2022), YOLOv4 (Chou et al., 2023), YOLOv5(Xiongfeng et al., 2022) and YOLOv8 (Güngör et al., 2024) have been used. Although there have been several studies analysing MRI images of the knee using YOLO series, both the developments in the YOLO series and the inadequacy of the existing literature suggest that there is still potential for development in this area. The application of the current YOLO series in this study will contribute to the literature. A summary and comparison of these studies can be found in Table 9, which highlights the models, architectures, and objectives of existing approaches to meniscal tear detection.

Table 9. Comparison of Studies on Models for the Detection of Meniscus Tears.

Study	Model Used	Architecture	Objective	Description
(Couteaux et al., 2019; Hung et al., 2023; Ma et al., 2023)	CNN-based models	Standard CNN architecture	Meniscus tear detection, localization, and characterization	CNN-based models were utilized for meniscus tear detection, but detailed localization and characterization were limited.
(Chou et al., 2023; Güngör et al., 2024; Zhao et al., 2021)	YOLO + Hybrid	YOLO-based hybrid architectures	Meniscus tear detection and localization	Proposed YOLO-based hybrid architecture, but studies in this area are still developing within the literature.
(Chou et al., 2023; Xiongfeng et al., 2022)	Enhanced YOLO	Custom architectures using YOLO series	Meniscus tear detection	Custom YOLO-based architectures with modifications to various YOLO versions were proposed.
(Li et al., 2021b; Zhu et al., 2022)	YOLOv3	YOLOv3 standard	Meniscus tear detection	YOLOv3 was employed as a foundational model for meniscus detection.
(Chou et al., 2023; Xiongfeng et al., 2022)	YOLOv4	YOLOv4 standard	Meniscus tear detection	YOLOv4 was utilized but showed limited performance compared to newer models in the literature.
(Xiongfeng et al., 2022)	YOLOv5	YOLOv5 standard	Meniscus tear detection	YOLOv5 showed improved accuracy and was more effective for meniscus tear detection.
(Güngör et al., 2024)	YOLOv8	YOLOv8 standard	Meniscus tear detection	YOLOv8 was employed, but its application in the literature remains relatively limited.
Our Study	YOLOv8 YOLOv9 YOLOv10	YOLOv8 standard YOLOv9 standard YOLOv10 standard	Meniscus tear detection and localization	Utilizing the YOLOv9e model for improved accuracy in meniscus tear detection, our study achieved high precision and recall values, indicating the model's reliability for clinical applications.

The current study has some limitations. Firstly, the dataset used consists of 203 examinations and 669 images. Medical imaging often requires large datasets to effectively train deep learning models. In addition, the quality of images can vary significantly due to differences in imaging equipment, settings, and patient conditions. These differences can affect the performance of the model. Secondly, the MRNet dataset also contains low resolution images and the dataset consists of only sagittal slices. Although the models have shown great potential for analyzing meniscal tears, these limitations need to be addressed and the models need to be successfully integrated into clinical applications.

CONCLUSION

In this study, the YOLOv8, YOLOv9, and YOLOv10 algorithms were used to detect meniscus tears, and the results were compared. The results show that all three models can detect meniscal tears with high accuracy. In particular, the YOLOv9e model performed best in both the tear and no tear classes, making it the most successful model for clinical applications. The YOLOv9e model achieved the highest performance in the training phase with a mAP50 of 0.91807, a precision of 0.87684, a recall of 0.93871, and an F1 score of 0.90672.

This work makes several important contributions to the field of automated medical imaging analysis and meniscal tear detection. First, it provides a detailed evaluation of SOTA YOLO models for meniscal tear detection. The findings demonstrate that the YOLOv9e model, with its high accuracy metrics, can be a reliable tool for clinical diagnosis, potentially aiding radiologists by reducing time and improving diagnostic consistency. Additionally, this study introduces a robust methodology for high-quality data preparation and model optimization, which may serve as a reference for future applications in radiologic imaging. By addressing the challenges of meniscal tear localization and classification, this research sets a foundation for extending deep learning techniques to other joint pathologies, thus expanding the role of AI in radiologic diagnostics.

In future studies, expanding the dataset by increasing the number and variety of samples and including images of different anatomical structures could improve the generalizability and robustness of the model. In addition, improving the quality and resolution of the MRI data could allow the model to capture finer structural details, which could increase detection accuracy. Future research could also focus on improving the interpretability of the model so that clinicians can better understand the basis of the predictions. Beyond just localization, research could also be conducted into categorizing different types of meniscal tears according to their severity and characteristics. Finally, the development of hybrid models that combine YOLO with other deep learning architectures could improve the model's ability to handle complex cases and expand its application to other areas of knee and joint pathology.

In summary, the YOLO model series provides successful results in the automatic detection and localization of meniscal tears and is considered a powerful option to support radiologists in the clinical setting.

Contribution and Acknowledgements

We thank radiologist Dr. Hadi SASANI for his valuable contribution to this study. His expertise and support played an important role in the success of our study.

This manuscript was prepared using part of Mehmet Ali ŞİMŞEK's PhD thesis, conducted at İstanbul University-Cerrahpaşa.

REFERENCES

- Alif, M. A. R., & Hussain, M. (2024). YOLOv1 to YOLOv10: A comprehensive review of YOLO variants and their application in the agricultural domain.
- Almajalid, R., Shan, J., Zhang, M., Stonis, G., & Zhang, M. (2019). Knee Bone Segmentation on Three-Dimensional MRI. 2019 18th IEEE International Conference On Machine Learning And Applications (ICMLA), 1725–1730. IEEE. <https://doi.org/10.1109/ICMLA.2019.00280>
- Bien, N., Rajpurkar, P., Ball, R. L., Irvin, J., Park, A., Jones, E., ... Lungren, M. P. (2018). Deep-learning-assisted diagnosis for knee magnetic resonance imaging: Development and retrospective validation of MRNet. *PLOS Medicine*, 15(11), e1002699. <https://doi.org/10.1371/journal.pmed.1002699>

- Bilge, A., Ulusoy, R. G., Üstebay, S., & Öztürk, Ö. (2018). Osteoarthritis. *Kafkas Journal of Medical Sciences*, 8(50), 133–142. <https://doi.org/10.5505/kjms.2016.82653>
- Botnari, A., Kadar, M., & Patrascu, J. M. (2024). A Comprehensive Evaluation of Deep Learning Models on Knee MRIs for the Diagnosis and Classification of Meniscal Tears: A Systematic Review and Meta-Analysis. *Diagnostics*, 14(11), 1090. <https://doi.org/10.3390/diagnostics14111090>
- Bryceland, J. K., Powell, A. J., & Nunn, T. (2017). Knee Menisci. *CARTILAGE*, 8(2), 99–104. <https://doi.org/10.1177/1947603516654945>
- Chou, Y.-T., Lin, C.-T., Chang, T.-A., Wu, Y.-L., Yu, C.-E., Ho, T.-Y., ... Kuang-Sheng Lee, O. (2023). Development of artificial intelligence-based clinical decision support system for diagnosis of meniscal injury using magnetic resonance images. *Biomedical Signal Processing and Control*, 82, 104523. <https://doi.org/10.1016/j.bspc.2022.104523>
- Couteaux, V., Si-Mohamed, S., Nempont, O., Lefevre, T., Popoff, A., Pizaine, G., ... Bousset, L. (2019). Automatic Knee Meniscus Tear Detection and Orientation Classification with Mask-RCNN. *Diagnostic and Interventional Imaging*, 100(4), 235–242. <https://doi.org/10.1016/j.diii.2019.03.002>
- Gaj, S., Yang, M., Nakamura, K., & Li, X. (2020a). Automated cartilage and meniscus segmentation of knee MRI with conditional generative adversarial networks. *Magnetic Resonance in Medicine*, 84(1), 437–449. <https://doi.org/10.1002/mrm.28111>
- Gaj, S., Yang, M., Nakamura, K., & Li, X. (2020b). Automated Cartilage and Meniscus Segmentation of Knee MRI with Conditional Generative Adversarial Networks. *Magnetic Resonance in Medicine*, 84(1), 437–449. <https://doi.org/10.1002/mrm.28111>
- Güngör, E., Vehbi, H., Cansın, A., & Ertan, M. B. (2024). Achieving high accuracy in meniscus tear detection using advanced deep learning models with a relatively small data set. *Knee Surgery, Sports Traumatology, Arthroscopy*. <https://doi.org/10.1002/ksa.12369>
- Harman, F., Selver, M. A., Baris, M. M., Canturk, A., & Oksuz, I. (2023). Deep Learning-Based Meniscus Tear Detection From Accelerated MRI. *IEEE Access*, 11, 144349–144363. <https://doi.org/10.1109/ACCESS.2023.3344456>
- Hung, T. N. K., Vy, V. P. T., Tri, N. M., Hoang, L. N., Tuan, L. Van, Ho, Q. T., ... Kang, J. (2023). Automatic Detection of Meniscus Tears Using Backbone Convolutional Neural Networks on Knee MRI. *Journal of Magnetic Resonance Imaging*, 57(3), 740–749. <https://doi.org/10.1002/jmri.28284>
- Jocher, G., Chaurasia, A., & Qiu, J. (2023). Yolov8 by Ultralytics.
- Li, X., Sun, Y., Jiao, J., Wu, H., Yang, C., & Yang, X. (2021a). Automatic Discoid Lateral Meniscus Diagnosis from Radiographs Based on Image Processing Tools and Machine Learning. *Journal of Healthcare Engineering*, 2021, 1–7. <https://doi.org/10.1155/2021/6662664>
- Li, X., Sun, Y., Jiao, J., Wu, H., Yang, C., & Yang, X. (2021b). Automatic Discoid Lateral Meniscus Diagnosis from Radiographs Based on Image Processing Tools and Machine Learning. *Journal of Healthcare Engineering*, 2021, 1–7. <https://doi.org/10.1155/2021/6662664>
- Ma, Y., Qin, Y., Liang, C., Li, X., Li, M., Wang, R., ... Jiang, Y. (2023). Visual Cascaded-Progressive Convolutional Neural Network (C-PCNN) for Diagnosis of Meniscus Injury. *Diagnostics*, 13(12), 2049–2062. <https://doi.org/10.3390/diagnostics13122049>
- Makris, E. A., Hadidi, P., & Athanasiou, K. A. (2011). The knee meniscus: Structure–function, pathophysiology, current repair techniques, and prospects for regeneration. *Biomaterials*, 32(30), 7411–7431. <https://doi.org/10.1016/j.biomaterials.2011.06.037>
- Ölmez, E., Akdoğan, V., Korkmaz, M., & Er, O. (2020). Automatic Segmentation of Meniscus in Multispectral MRI Using Regions with Convolutional Neural Network (R-CNN). *Journal of Digital Imaging*, 33(4), 916–929. <https://doi.org/10.1007/s10278-020-00329-x>
- Ozeki, N., Seil, R., Krych, A. J., & Koga, H. (2021). Surgical treatment of complex meniscus tear and disease: state of the art. *Journal of ISAKOS*, 6(1), 35–45. <https://doi.org/10.1136/jisakos-2019-000380>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2015). You Only Look Once: Unified, Real-Time Object Detection.

- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 779–788.
- Roblot, V., Giret, Y., Bou Antoun, M., Morillot, C., Chassin, X., Cotten, A., ... Fournier, L. (2019). Artificial Intelligence to Diagnose Meniscus Tears on MRI. *Diagnostic and Interventional Imaging*, 100(4), 243–249. <https://doi.org/10.1016/j.diii.2019.02.007>
- Sapkota, R., Qureshi, R., Calero, M. F., Badjugar, C., Nepal, U., Poulouse, A., ... Karkee, M. (2024). YOLOv10 to Its Genesis: A Decadal and Comprehensive Review of The You Only Look Once (YOLO) Series.
- Saygili, A., & Albayrak, S. (2017a). Meniscus segmentation and tear detection in the knee MR images by fuzzy c-means method. *2017 25th Signal Processing and Communications Applications Conference (SIU)*, 1–4.
- Saygili, A., & Albayrak, S. (2020). Knee Meniscus Segmentation and Tear Detection from MRI: A Review. *Current Medical Imaging Formerly Current Medical Imaging Reviews*, 16(1), 2–15. <https://doi.org/10.2174/1573405614666181017122109>
- Saygili, A., & Albayrak, S. (2017b). A new computer-based approach for fully automated segmentation of knee meniscus from magnetic resonance images. *Biocybernetics and Biomedical Engineering*, 37(3), 432–442. <https://doi.org/10.1016/j.bbe.2017.04.008>
- Sohan, M., Sai Ram, T., & Rami Reddy, Ch. V. (2024). A Review on YOLOv8 and Its Advancements. In *Data Intelligence and Cognitive Informatics* (pp. 529–545). https://doi.org/10.1007/978-981-99-7962-2_39
- Su, Y., Cheng, B., Conference, Y. C.-2023 I. 6th I., & 2023, undefined. (n.d.). Detection and Recognition of Traditional Chinese Medicine Slice Based on YOLOv8. *Ieeexplore.Ieee.Org* Y Su, B Cheng, Y Cai 2023 IEEE 6th International Conference on Electronic Information, 2023•ieeexplore.Ieee.Org. Retrieved from <https://ieeexplore.ieee.org/abstract/document/10245026/>
- Terven, J., Córdova-Esparza, D.-M., & Romero-González, J.-A. (2023). A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS. *Machine Learning and Knowledge Extraction*, 5(4), 1680–1716. <https://doi.org/10.3390/make5040083>
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., & Ding, G. (2024). YOLOv10: Real-Time End-to-End Object Detection.
- Wang, C.-Y., & Liao, H.-Y. M. (2024). YOLOv1 to YOLOv10: The fastest and most accurate real-time object detection systems.
- Xiongfeng, T., Yingzhi, L., Xianyue, S., Meng, H., Bo, C., Deming, G., & Yanguo, Q. (2022). Automated detection of knee cystic lesions on magnetic resonance imaging using deep learning. *Frontiers in Medicine*, 9. <https://doi.org/10.3389/fmed.2022.928642>
- Ying, M., Wang, Y., Yang, K., Wang, H., & Liu, X. (2024). A Deep Learning Knowledge Distillation Framework using Knee MRI and Arthroscopy Data for Meniscus Tear Detection. *Frontiers in Bioengineering and Biotechnology*, 11. <https://doi.org/10.3389/fbioe.2023.1326706>
- Zhao, R., Zhang, Y., Yaman, B., Lungren, M. P., & Hansen, M. S. (2021). End-to-End AI-based MRI Reconstruction and Lesion Detection Pipeline for Evaluation of Deep Learning Image Reconstruction.
- Zhu, K., Chen, Y., Ouyang, X., White, G., & Agam, G. (2022). Fully RNN for knee ligament tear classification and localization in MRI scans. *Electronic Imaging*, 34(14), 227-1-227–6. <https://doi.org/10.2352/EI.2022.34.14.COIMG-227>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 04.10.2024
Kabul Tarihi : 12.12.2024

Received Date : 04.10.2024
Accepted Date : 12.12.2024

GENETİK ALGORİTMA TEMELLİ ÖZİNİTELİK SEÇİMİNİN ANEMİ HASTALIĞININ TESPİTİNE ETKİSİ

THE EFFECT OF GENETIC ALGORITHM BASED FEATURE SELECTION ON DETECTION OF ANAEMIA DISEASE

Mehtap ÖKLÜ¹ (ORCID: 0000-0002-8833-2231)

Hasan BADEM^{2*} (ORCID: 0000-0002-4262-8774)

¹ Kahramanmaraş Sütçü İmam Üniversitesi, Bilişim Sistemleri Bölümü, Kahramanmaraş, Türkiye
^{2*} Kahramanmaraş Sütçü İmam Üniversitesi, Bilgisayar Mühendisliği Bölümü, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: Hasan BADEM, hbadem@ksu.edu.tr

ÖZET

Vücuttaki oksijen ihtiyacının farklı sebeplerle karşılanamaması durumunda ortaya çıkan anemi, 2023'de Dünya Sağlık Örgütü 500 milyondan fazla kişide görüldüğünü rapor etmiştir. Ayrıca, anemi dünyada en sık görülen kan hastalığıdır. Bu hastalığın en önemli önlemlerinden biri erken teşhistir. Literatürde teşhis konusunda hızlı ve başarılı sonuçların elde edilebilmesi için makine öğrenmesi modelleri önerilmektedir. Ancak makine öğrenmesi modelleri arzu edilen düzeyde etkin sonuçlar veremeyebilir. Optimizasyon algoritmaları ile gerçekleştirilen öznelik seçimi, makine öğrenmesi modellerinin başarı oranlarını arttırabilmektedir. Bu çalışmada hastaların tahlil sonuçları üzerinden gerçekleştirilen anemi tespitinin başarı oranını, öznelik seçici olarak genetik algoritma ile artırılması amaçlanmıştır. K-en yakın komşu, naive bayes, karar ağaçları, lojistik regresyon ve destek vektör makinesi makine öğrenmesi yöntemlerinin sınıflandırma başarımını artırmak için genetik algoritma ile öznelik seçimi gerçekleştirilmiştir. Elde edilen deneysel sonuçlarda önerilen yöntem ile öznelik seçimi yapılmadan elde edilen sonuçlara göre daha yüksek doğruluk oranları elde edilmiştir.

Anahtar Kelimeler: Anemi, makine öğrenmesi, genetik algoritma, öznelik seçimi

ABSTRACT

Anaemia, which occurs when the body's oxygen needs cannot be met for various reasons, has been reported by the World Health Organization to be seen in more than 500 million people in 2023. Additionally, the anemia is the most common blood disease in the world. One of the most important precautions for this disease is early diagnosis. In the literature, machine learning models have been proposed for achieving rapid and accurate diagnostic results. However, machine learning models may not always provide the desired level. Feature selection utilized with optimization algorithms can enhance the accuracy rates of machine learning models. In this study, improving the accuracy of anemia detection has been aimed on patients' test results through a genetic algorithm as a feature selection operator. Genetic algorithm has been performed as feature selection to improve the classification performance of machine learning methods including k-nearest neighbors, naïve bayes, decision trees, logistic regression, and support vector machine. In the experimental results, higher accuracy rates have been obtained by the proposed method compared with obtained results without feature selection.

Keywords: Anaemia, machine learning, genetic algorithm, feature selection

ToCite: BADEM, H., & ÖKLÜ, M., (2025). GENETİK ALGORİTMA TEMELLİ ÖZİNİTELİK SEÇİMİNİN ANEMİ HASTALIĞININ TESPİTİNE ETKİSİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 309-321.

GİRİŞ

Anemi, diğer adıyla kansızlık, vücuttaki oksijen ihtiyacı duyan dokulara yeterli oksijen taşıyabilecek kırmızı kan hücrelerinin yetersizliği ile ortaya çıkan bir sağlık sorunudur. Dünya genelinde en sık görülen kan hastalığıdır (Vohra vd., 2022). Aneminin en sık görülen türü demir eksikliği anemisidir. Demir anemisinin ortaya çıkma sebebi ise ihtiyaç duyulan demirin besinlerden yeterli seviyede alınamıyor olmasıdır (Yıldız at al., 2021; Seymen, 2014; Cheng at al., 2024).

Dünyada anemi küresel bir sağlık sorunudur. Dünya Sağlık Örgütü (DSÖ) raporlarına göre, 15-49 yaş arası kadınlarda görülme oranı %30 (571 milyon) Gebe kadınlarda %37 ve orta düzey anemiye sahip olan kişi sayısının 1-5 yaş arası çocuklarda görülme oranı ise %40 olduğu rapor edilmiştir (WHO, 2024). Ayrıca, DSÖ'ne göre aneminin önlenmesi, erken müdahale için kritik önem taşımaktadır (WHO, 2014). Anemi hastalığının tespit edilmesi için hemoglobin oranı ve hemoglobinin konsantrasyonu değerlerinin bilinmesi gerekmektedir. Hemoglobin konsantrasyonunun cinsiyetlere bağlı olarak belirli oranların altında olması gerekmektedir. Bu oranların üstünde kalan bireylerde anemi olduğu kabul edilmektedir (Seymen, 2014; Cheng at al., 2024).

Son zamanlarda karmaşıklaşan dünya problemlerinin çözümü için nümerik yaklaşımla veya sezgisel yaklaşımla birçok farklı türde metod geliştirilmiştir. Gerçek dünya problemlerinin çözümünde yapay zeka yaklaşımları oldukça etkin sonuçlar üretmektedir (Alam vd., 2020; Lambora vd., 2019; Badem, 2019). Probleme özgü getirilen yapay zeka yaklaşımları tek başına arzu edilen başarıyı göstermekte sınırlı kalabilmektedir (Shukla vd., 2015; Gizzi vd., 2022). Yapay zeka modellerinin başarı oranlarını arttırmak için hiperparametre optimizasyonu gerçekleştirilmektedir. Hiperparametre optimizasyonu için yenilikçi yapay zeka destekli olan optimizasyon algoritmaları ortaya çıkmıştır (Badem vd., 2017; Lambora vd., 2019; Khari vd., 2023).

Optimal modelleri elde edilen makine öğrenmesi yöntemlerinin başarımı uzman tasarımı özneliklerden oldukça etkilenmektedir. Bu nedenle uzman tasarımı özneliklerden problemi temsil kabiliyeti yüksek olanların araştırılması da sınıflandırma başarımını artırabilmektedir. Özneliklerin seçilmesi için küresel arama yeteneğine sahip optimizasyon algoritmaları kullanılabilir. Literatürde Genetik Algoritma (Genetic Algorithm, GA) küresel arama ve yerel tüketme yeteneği açısından en etkin algoritmalar arasındadır. GA'nın bu üstün özellikleri sayesinde literatürde pek çok mühendislik probleminde kullanıldığı rapor edilmektedir (Alp ve Soygazi, 2024; Pertiwi vd., 2024).

Anemi hastalığı teşhisi makine öğrenmesi yöntemleri ile gerçekleştirilmesi etkin sonuçlar verebilir. Fakat, uzman tasarımı öznelikler makine öğrenmesi yöntemlerinin başarımını doğrudan etkilemektedir. Bu çalışmada anemi tespiti için GA temelli öznelik seçimi ile K-En Yakın Komşu (K-Nearest Neighbors, KNN), Naive Bayes (NB), Karar Ağaçları (Decision Trees, DT), Lojistik Regresyon (Logistic Regression, LR) ve Destek Vektör Makinesi (Support Vector Machine, SVM) makine öğrenmesi yöntemlerinin performanslarının artırılması amaçlanmıştır. Bu amaç doğrultusunda anemi hastalığının tespitinde öznelik seçiminin başarı oranına olan etkisinin değerlendirilmesi sağlanmıştır. Bu çalışmanın literatüre katkısı:

- Anemi hastalığının tespitinde makine öğrenmesi yöntemlerinin başarımı karşılaştırmalı olarak sunulmuştur.
- Anemi hastalığının tespitinde ilk defa GA tabanlı bir öznelik seçim operatörü uygulanmış ve geleneksel makine öğrenmesi yöntemlerinin başarımına etkisi değerlendirilmiştir.
- Anemi hastalığının tespitinde karar destek sistemlerinin geliştirilebilmesi için yapay zekâ temelli bir yöntem tanımlanmıştır.

Çalışmanın ikinci kısmında literatür taraması, üçüncü kısmında materyal ve metod, dördüncü kısmında deneysel sonuç ve beşinci kısmında ise tartışma bölümlerine yer verilmiştir.

LİTERATÜR ÖZETİ

DSÖ, insanlarda en sık görülen kan hastalığının anemi olduğunu rapor etmektedir. Kandaki alyuvarların az olması ve oksijen taşıma kapasitesinin az olması anemiye tetikleyen etkenlerdendir (WHO, 2008). İnsanların yaşam kalitesini olumsuz yönde etkileyen bu hastalığın erken teşhisi oldukça önemlidir. Ancak dünya nüfusunun artışı, hastalardaki yaş ve engel durumu öncelikleri gibi zorluklar erken teşhisi geciktirmektedir. Tuba Karagül Yıldız ve arkadaşlarının yaptığı çalışmada aneminin tespit edilmesini sağlayacak bir sistem önerilmiştir. Sistem, Yapay Sinir Ağları (Neural Networks, NN), SVM, NB ve Karar Ağacı olmak üzere dört farklı modelden oluşturulmuştur. Çalışma için hemogram verileri, yaş, cinsiyet, kronik rahatsızlıkların olduğu 25 farklı öznelikten oluşan ve 1663 örnek

bulunduran bir veri seti kullanılmıştır. Veri seti Türkiye'deki bir üniversite hastanesindeki hastaların dosyaları incelenerek toplanmıştır. Oluşturulan modelde tüm verilere ek olarak, bazı özellik seçme teknikleriyle oluşturulan sekiz farklı veri seti kullanılmıştır. Çalışma sonucunda en yüksek doğruluğu %85,6 ile Karar Ağaçları vermiştir (Yıldız vd., 2021).

Çocuklarda sık görülen anemi, Bangladeş'te ciddi bir sağlık sorunu olarak baş göstermektedir. Anemi ile alakalı olan çevresel faktörlerin tespit edilmesinin yanı sıra, bu faktörler göz önünde bulundurularak anemi hastalığına yakalanma olasılığının tahmin edilmesi de oldukça önemlidir. Anemiye yakalanma ihtimalinin tahmini; toplum hizmetleri, sağlık hizmetleri ve kaynak planlaması için de oldukça önemli bir konudur. JR Khan ve arkadaşlarının yaptığı çalışmada Bangladeş Demografi ve Sağlık Araştırması tarafından 2011'de sunulan veriler kullanılarak 5 yaş altı çocuklardaki anemi ihtimalinin tahmin edilmesi amacıyla Doğrusal Diskriminant Analizi, sınıflandırma/regresyon ağaçları, KNN, SVM, Rastgele Orman (Random Forest, RF) ve LR gibi makine öğrenmesi algoritmaları kullanılmıştır. Algoritmaların değerlendirmeleri doğruluk, duyarlılık, özgüllük ve eğri altındaki alan (AUC) metrikleri göz önünde bulundurularak yapılmıştır. RF algoritmasının %70,73 duyarlılık, %66,41 özgüllük ve 0,6857 AUC ile en başarılı sonucu elde ettiği tespit edilmiştir. Anemi tahmininin öncelikli odak noktası olduğu durumlarda klasik regresyon tekniklerine ek olarak makine öğrenmesi yöntemlerinin de dikkate alınabileceği sonucuna varılmıştır (Khan vd., 2019).

Aneminin fiziksel teşhisi, çok sayıda semptomun varlığı nedeniyle zaman alıcı ve yoğun bir işlemdir. Aneminin en hızlı ve en kolay yoldan teşhisi tam kan sayımı ile sağlanmaktadır. Ancak bu yöntem ile farklı anemi türleri doğrudan tanımlanamamaktadır. Bu durumdan dolayı hastadaki anemi tipine yönelik standardı oluşturabilmek için ileri seviye testler gerekmektedir. Bu testler maliyetli olduğu için küçük ölçekte sağlık hizmeti sunan ortamlarda nadir bulunmaktadır. Birden fazla kırmızı kan hücresi formülü ve farklı optimal kesim değerlerine sahip indekslerin varlığına rağmen beta talasemi, demir eksikliği anemisi, hemogloblin E ve kombinasyon anemileri arasında ayırım yapmak oldukça güçtür. Bu durumun önüne geçebilmek Saputra ve arkadaşları tarafından yapılan çalışmada tanımlama sürecini hızlandırmak için daha kesin ve otomatikleştirilmiş bir tahmin modeli önerilmiştir. Veri seti olarak Yogyakarta kentindeki bir laboratuvarından elde edilen geçmiş veriler kullanılmıştır. Uç Öğrenme Makinesi kullanılarak geliştirilen model üzerinde hata matrisi ve dört sınıfı temsil eden 190 veri kullanılarak performans ölçümü izlenmiştir. Model %99,21 doğruluk, %98,44 duyarlılık, %99,30 kesinlik göstermiştir (Saputra vd., 2023).

Özellikle çocukları ve hamile kadınları etkileyen anemi, önemli küresel halk sağlığı sorunlarından biridir. Vücuttaki alyuvar hücrelerinin seviyesinin azalması, yapısının bozulması veya hemogloblin seviyesinin normal eşliğinden düşük olması durumunda anemi ortaya çıkmaktadır. P Appiahene ve arkadaşlarının gerçekleştirdiği çalışmada Evrişimli Sinir Ağı, KNN, NB, SVM ve DT yöntemleri kullanılarak aneminin tespit edilmesi amaçlanmıştır. En yüksek başarılı sonucu %99,96 doğruluk ile NB algoritması sağlarken en düşük başarılı sonucu ise %96,34 ile SVM algoritması sağlamıştır (Appiahene vd., 2023).

Aneminin teşhisi ve tedavisi için birçok kan testi, radyolojik görüntü ve tahlile ihtiyaç duyulur. Bu ölçümler kendi başına yeterli gelmez, sonuçların yorumlanması ve teşhisin koyulabilmesi için doktor kararı gerekir. Tüm bunlara rağmen koyulan teşhisler kesin olamaz, hata payı içerebilir. Yağmur ve arkadaşlarının gerçekleştirdiği çalışmada Kaggle'dan elde edilen bir veri seti ile anemi teşhisinin sınıflandırma problemi ile çözülmesi amaçlanmıştır. Bu doğrultuda NN yöntemlerinden Öğrenmeli Vektör Kuantalama (Learning Vector Quantization , LVQ), Rekabetçi Katman Sinir Ağı, Örüntü Tanıma Yapay Sinir Ağı (Pattern Recognition Artificial Neural Network , PRNN) ve Kendiliğinden Organize Olan Harita kullanılarak başarı oranları hesaplanmıştır. En iyi başarı performansı %100 hassasiyet, %99,88 doğruluk, %99,86 özgüllük, %99,43 kesinlik ile PRNN algoritmasından elde edilmiştir. PRNN'yi takiben LVQ algoritması ise en başarılı ikinci model olmuştur (Yağmur vd., 2023).

Sari ve arkadaşlarının yaptığı çalışmada Parçacık Sürü Optimizasyonu (Particle Swarm Optimization, PSO) ve SVM kümeleri birleştirilerek biyolojik veriler dikkate alınmış ve patolojik verilerin tahmin edilmesi amaçlanmıştır. 539 kişiden oluşan veri seti 5 kümeye bölünmüş ve her bir deneğin değerleri bağımsız olarak alınan ilgili biyomedikal değişkenlere göre kaydedilmiştir. Hibrit PSO-SVM yönteminin, özellikle kümelenebilir hastalık türlerinin teşhisinde oldukça etkili olduğu gözlenmiştir (Arshed vd., 2023).

MATERYAL VE METOT

Bu çalışmada, anemi hastalığının teşhisinde genetik algoritma temelli öz nitelik seçiminin makine öğrenmesi yöntemleri üzerinden etkisinin değerlendirilmesi amaçlanmıştır. Bu amaç için kullanılan veri seti, kullanılan makine öğrenmesi yöntemleri, genetik algoritma ve önerilen yöntem bu bölümde sunulmuştur.

Veri Seti

Çalışma kapsamında “Complete Blood Count Anemia Diagnosis” veri seti (Vohra vd., 2022) kullanılmıştır. Bu veri seti, anemi şüphesi taşıyan hastaların kan testi değerlerini içermektedir. İçerdiği öznitelikler Tablo 1’de sunulmuştur. Ayrıca, modelleme de kullanılan veri örneği Tablo 2’de yer almaktadır.

Tablo 1. Kan Örneği Parametreleri

Kısaltma	Açıklama
Age	Yaş
Sex	Cinsiyet
RBC	Kırmızı Kan Hücre Sayımı
PCV	Paketli Hücre Hacmi
MCV	Ortalama Hücre Hacmi
MCH	Ortalama Hücre Hemoglobini
MCHC	Ortalama Hücre Hemoglobin Konsantrasyonu
RDW	Kırmızı Hücre Dağıtım Genişliği
TLC	Beyaz Kan Hücre Sayımı
PLT	Trombosit Sayımı
HGB	Hemoglobin

Bu veri setinde, her bir örneğin anemi olup olmadığı bilgisine yer verilmemiştir. Etiketleme DSÖ tarafından belirlenen anemi eşik değeri (De Benoist vd., 2008) üzerinden gerçekleştirilmiştir. DSÖ tarafından düzenlenen anemi eşik değerleri Tablo 3’te rapor edilmiştir. Tablo 3 incelendiğinde anemi teşhisi yaş ve cinsiyet durumlarına göre değişebilmektedir. Hastaların tanılarını içeren anemi sütunu da 0 (sağlıklı) ve 1 (anemi) olacak şekilde oluşturulmuştur. Veri setinde yer alan parametrelerin farklı birimlerden oluşmasından dolayı veri setinin normalize edilmesi için Z-skor normalizasyon yöntemi kullanılmıştır.

Makine Öğrenmesi Yöntemleri

K-En Yakın Komşu

KNN yöntemi, gözetimli (denetimli) öğrenme metotlarından olup sınıflandırma işlemlerinde kullanılır (Canbay & Öklü, 2023; Zhang & Li, 2021). Sınıflandırma çalışması yaparken elimizdeki veriler hakkında kısıtlı ön bilgiye sahip olduğunda en çok tercih edilen makine öğrenmesi yöntemi KNN’dir (Canbay & Öklü, 2023; Zhang & Li, 2021). Bu algoritmanın performansını etkileyen parametreler; uzaklık ölçütü, komşu sayısı (k) ve ağırlıklandırma yöntemidir (Canbay & Öklü, 2023; Taşcı & Onan, 2016). Çalışmada k değeri olarak 5, uzaklık ölçütü olarak da Manhattan uzaklığı kullanılmıştır (n boyutlu düzlemdeki iki konum arasındaki farkların, mutlak değerlerinin toplamı). X-Y konumları arasındaki Manhattan uzaklığı: $P=(x_1, x_2, \dots, x_n)$ ve $Q=(y_1, y_2, \dots, y_n)$ olmak üzere, Eşitlik 1’e göre hesaplanır (Taşcı & Onan, 2016; Peterson, 2009).

$$\sum_{i=1}^n |x_i - y_i| \quad (1)$$

Karar Ağaçları

DT, veri setini yinelemeli olarak küçük alt bölümlere ayıran bir sınıflandırma yöntemidir. DT, ele aldığı problemi böl ve yönet tekniğiyle çözmeye çalışır. Her bir karar ağacı; kök düğüm, dizi dâhili bölüm ve dizi uç düğümünden (yaprak) oluşur (Canbay & Öklü, 2023). Veri setindeki öznitelikleri mantıksal sıraya uygun dallara ayırarak ağaç yapısı oluşturur. Oluşturulan ağaçta; veri setindeki öznitelikler düğümleri, tahmin edilecek olan sütundaki değerler ise yaprakları temsil eder. Veri setine eklenen her yeni veri, mevcut öznitelik değerleri baz alınarak ağaçtaki uygun

sınıfa dahil edilir. Verinin doğru sınıfa dâhil edilebilmesi için, eklenecek olan verinin ağaç üzerinde gezdirilmesi sağlanır. Bu sayede en uygun sınıf tespit edilir.

Tablo 2. Örnek Veri Seti

Age	Sex	RBC	PCV	MCV	MCH	MCHC	RDW	TLC	PLT	HGB	Anemi
28	0	5,66	34,0	60,1	17,0	28,2	20,0	11,10	128,3	9,6	1
41	0	4,78	44,5	93,1	28,9	31,0	13,0	7,02	419,0	13,8	0
40	1	4,65	41,6	89,5	28,8	32,2	13,0	8,09	325,0	13,4	0
76	0	4,24	36,7	86,6	26,7	30,8	14,9	13,41	254,0	11,3	1
20	1	4,14	36,9	89,1	27,8	31,2	13,2	4,75	196,0	11,5	1
24	0	4,29	40,1	93,5	29,6	31,7	14,5	13,96	233,0	12,7	0
28	1	4,98	42,3	84,9	24,9	29,3	16,2	9,33	213,0	12,4	1
14	0	4,97	43,8	88,1	28,0	31,7	15,2	3,92	229,0	13,9	0
16	0	4,16	38,7	93,0	28,8	31,0	17,9	5,77	211,0	12,0	0
62	0	5,25	45,6	86,9	25,3	29,2	15,6	10,68	151,0	13,3	0

Tablo 3. Anemi Teşhisinde Kullanılan Hemoglobin Eşik Değerleri

Kısaltma	Açıklama
Çocuk (5 yaştan küçük)	110
Çocuk (5-12 yaş arası)	115
Çocuk (12-15 yaş arası)	120
Kadın (15 yaş ve üstü)	120
Hamile kadın	110
Erkek (15 yaş ve üstü)	130

Lojistik Regresyon

LR, istatistiksel bir sınıflandırma yöntemidir. Parametrik olan LR, en çok kullanılan sınıflandırma yöntemlerinden biridir. Bir veya birden çok değişkene bağımlı olan değişkenlerin modellenmesinde kullanılır (Canbay & Öklü, 2023).

Naive Bayes

NB, olasılık tabanlı sınıflandırma algoritmalarından birisidir. Bayes teoreminin uygulandığı bu algoritma özellikle denetimli öğrenme problemlerinde başarılı sonuçlar üretmektedir. Algoritma probleme uyarlanırken veri setindeki öznelilikler arasında şartlı bağımsız, sınıflar üretilirken şartlı bağımlı yaklaşım izler. Veri setinde bulunan sınıfların Gaussian dağılımını takip ettiğini varsayarak hatalı tahmin etme oranını azaltmayı amaçlar (Canbay & Öklü, 2023; Narayan, 2021).

Destek Vektör Makinesi

SVM sınıflandırma problemlerinde sıkça tercih edilen denetimli bir makine öğrenmesi modelidir. SVM, veri setindeki sınıflar arasındaki en yüksek mesafeli hiper düzlemi bulmayı amaçlar (Canbay & Öklü, 2023; Narayan, 2021). Veri setindeki sınıfların örneklerinin arasındaki mesafelere göre sınıfları ayırt etmeyi amaçlar. Ayırt etmeyi düzgün bir şekilde yapabilmek için hiper düzlem(ler) oluşturur. Sınıflandırmadaki hata oranının minimuma indirilmesi için hiper düzlemler arasındaki mesafenin olabilecek maksimum uzaklıkta olması hedeflenir.

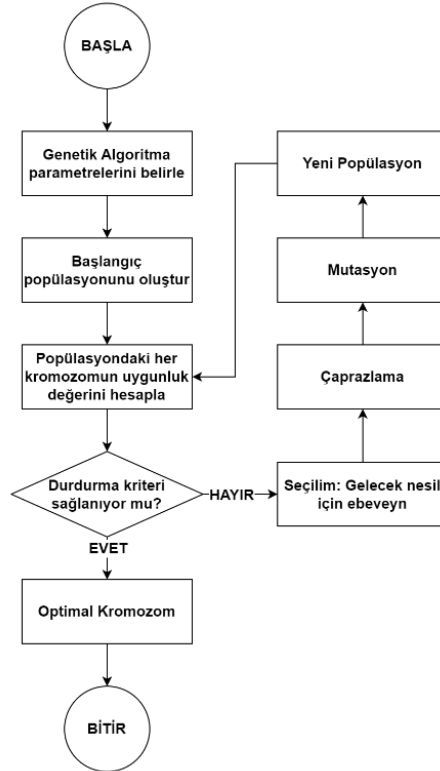
10-Kat Çapraz Doğrulama

Bu veri setini 10 eşit parçaya böler ve her parçanın hem eğitim hem de test seti olarak kullanılmasını sağlayarak model performansını değerlendirir. 10 parçanın 9'unu eğitim 1'ini test olarak kullanır. Bu işlemi her 10 parçanın da ayrı ayrı test olarak kullanılmasını sağlayacak şekilde 10 kez tekrar eder (Anguita vd., 2012). Bu şekilde 10-kat

çapraz doğrulama (Cross Validation- CV) tamamlanmış olur. 10-Kat Çapraz Doğrulama yöntemini kullanarak modelin doğrulanması sağlanır.

Genetik Algoritma

GA, en yaygın kullanılan optimizasyon algoritmalarından biridir (Türkkahraman & Karabulut, 2023; Kaleli, 2023; Acar vd., 2023; Eke, 2022; Weile & Michielssen, 1997; Holland, 1992). Evrim teorisine dayanan GA, evrimin temel süreçlerini baz alan bir çalışma sistemi üzerine geliştirilmiştir. Bu süreçler; seçim, çaprazlama ve mutasyondur. Üç ana süreçten geçen veriler, süreç boyunca uğradığı etkiler sonucunda bir skora sahip olur. Yüksek skora sahip olan veriler saklanırken düşük skora sahip olan veriler yok edilir. Bu eleme yöntemi, “Güçlü olan hayatta kalır.” felsefesini baz almaktadır (Acar vd., 2023; Eke, 2022; Lambora vd., 2019). GA'nın akış şeması (Gülmez, 2023) Şekil 1'de sunulmuştur.



Şekil 1. GA Akış Diyagramı

GA çalışırken bireylerden (kromozomlar) oluşan bir arama uzayı oluşturur. Her bir birey, vektör olarak temsil edilen bir kromozomdur (Gülmez, 2023). Her bir iterasyonda her bir kromozom incelenir ve uygunluk değeri hesaplanır. Uygunluk değeri; yüksek olan kromozomların hayatta kalma ihtimali yüksek (Keklik & Özcan, 2023), düşük olan kromozomların hayatta kalma ihtimali ise düşük olacaktır (Gülmez, 2023). Uygunluk değeri hesaplandıktan sonra elemelerden başarıyla geçen örnekler seçim aşamasını tamamlamış ve çaprazlama aşamasına geçmiştir. Birden fazla çaprazlama tekniği bulunmaktadır. Bu teknikler sayesinde örnekler arasında veri (gen) değiş tokuşu sağlanarak çeşitliliğin artması sağlanır. Daha sonra önceden belirlenmiş mutasyon oranı kadar kromozom mutasyona uğratılır (İnneci & Badem, 2023). Bu sayede yavru bireyler elde edilmiş ve bir iterasyon tamamlanmış olur. Yavru bireylerin uygunluk derecesi hesaplanarak karşılaştırılır. Başarılı sayılan bireyler sonraki nesle aktarılırken geri kalan bireyler ise elenir. Bu döngü, durdurma kriteri sağlanıncaya kadar devam eder (Wan, 2024; Gülmez, 2023; Lambora vd., 2019).

Gen

GA'nın en küçük yapı taşıdır. Nesiller arası kalıtsallığı sağlar. GA'da incelenen her bir karar parametresi gen olarak tanımlanmaktadır. Yani incelenen problemde, gen sayısı ile karar değişkeni sayısı eşittir. Genler aracılığıyla taşınan bilgiler, probleme göre ikilik, ondalık, reel ya da veri kombinasyonu olarak kodlanabilir (Keklik & Özcan, 2023; Katoch vd., 2021; Lambora vd., 2019).

Kromozom

Genler bir araya gelerek kromozomları oluştururlar. Her bir kromozom GA'daki bir bireyi temsil etmektedir. Oluşturulan bu bireyler mevcut problemin bir çözümüne karşılık gelmektedir (Keklik & Özcan, 2023; İnneci & Badem, 2023; Katoch vd., 2021; Lambora vd., 2019).

Popülasyon

GA'daki çözüm kümeleri olan popülasyon, birden fazla kromozomun bir araya gelmesiyle oluşur. Optimal sonuca ulaşabilmek için popülasyon içerisindeki bazı kromozomlar popülasyon dışına atılarak yeni kromozomlar üretilir (İnneci & Badem, 2023; Katoch vd., 2021; Lambora vd., 2019).

Uygunluk Fonksiyonu

Amaç (uygunluk) fonksiyonu, bir kromozomun çözüm için uyumlu olup olmadığını tespit eder. Bu sayede kromozomlar arasında rekabet oluşur. Her kromozom için uygunluk fonksiyonu çalışır ve bir skor elde edilir. Kromozomun sonraki nesle aktarılma ve üreme için seçilme ihtimalleri bu skora bağlıdır (Ajder, 2023; Gülmez, 2023, Lambora vd., 2019).

Rulet Tekerleği

Rulet tekerleğinde bireylerin seçilme olasılığını, her bir bireyin uygunluk fonksiyonu değeri ile ilişkilendirerek belirler. Bu yöntemde her bir birey, rulet tekerleğinde bir dilimi temsil eder ve dilimlerin büyüklüğü, bireyin uygunluk fonksiyonu değerine bağlıdır. Yani, daha iyi uygunluk değerine sahip bireyler, rulet tekerleğinde daha geniş bir dilimi kaplar ve dolayısıyla seçilme olasılıkları daha yüksektir (Keklik & Özcan, 2023).

Çaprazlama için eşleştirilecek bireyler, bu rulet tekerleği üzerinde rastgele bir şekilde seçilir. Bu, popülasyon içindeki çeşitliliği korurken, daha iyi uygunluk değerine sahip bireylerin de çaprazlama operatörüne dahil edilmesini ve bu sayede başarı oranlarının yüksek değerlerde kalmasını sağlar. Rulet tekerleği sistemi, çaprazlama operatörünün adil ve çeşitli bir şekilde uygulanmasını sağlar. Bu sistem, bireylerin uygunluk değerlerine dayalı olarak seçilme olasılıklarını dengeler. Genellikle GA'nın performansını artırır (Keklik & Özcan, 2023). Bu çalışmada, çaprazlama operatörünün uygulanması için eş seçme sürecinde rulet tekerleği sistemi tercih edilmiş ve bireylerin eşleştirilmesinde bu yöntem kullanılmıştır.

Önerilen Yöntem

GA temelli öznitelik seçim yöntemi ile anemi hastalığının teşhisi için önerilen yöntem Şekil 2'de sunulmuştur. Önerilen yöntemde, veri setinde bulunan öznitelik sayısı kadar parametreye sahip bireyler için bir başlangıç popülasyonu oluşturulur. Her bir parametre [0-1] arası rastgele değerler ile başlatılır. GA'nın maksimum iterasyonuna ulaşana kadar her birey Şekil 3'te sunulan öznitelik seçimine göre uygunluk değeri hesaplanır. Araştırma durduğunda belirlenen en iyi bireyin temsil ettiği seçim vektörüne göre elde edilen alt veri seti ile makine öğrenmesi ile sınıflandırma gerçekleştirilir. Bu süreçte seçim, çaprazlama ve mutasyon işlemi sırası ile aşağıdaki gibi gerçekleştirilir.

Seçim: Yüksek uyumluluk skoruna göre seçilen kromozomlar, birbirleri arasında çaprazlanmak üzere ele alınır (Ajder, 2023; Gülmez, 2023). Başarısız sayılan kromozomlar ise yok edilir. Çalışma kapsamında rulet çemberi seçim tekniği kullanılmıştır.

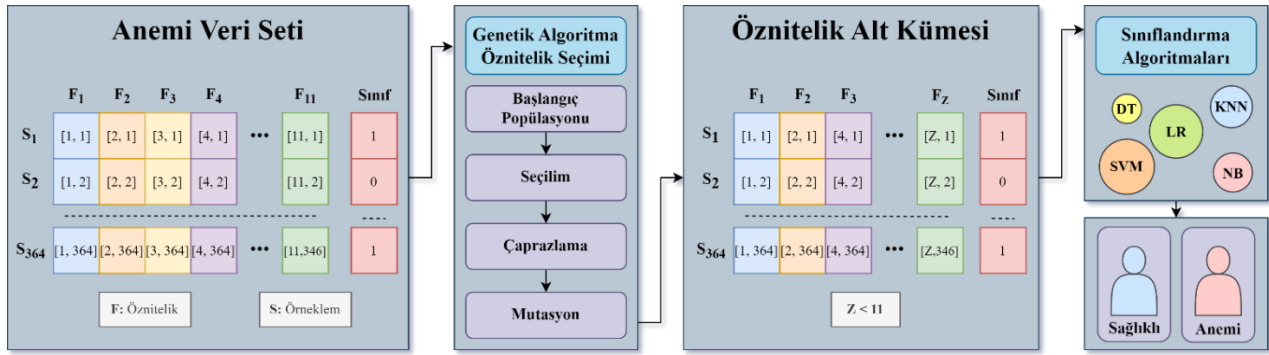
Çaprazlama: Seçim aşamasından başarıyla geçen kromozomlar, çeşitlilik oranının artması için birbirleri arasında çaprazlanır. Çaprazlama sonucunda elde edilen veriler, yeni veri olarak havuza eklenir (Ajder, 2023; Acar vd., 2023; Gülmez, 2023). Çalışma kapsamında tek noktalı çaprazlama yöntemi kullanılmıştır.

Mutasyon: Çaprazlama aşamasında elde edilen yeni bireylerle beraber tüm bireyler ele alınır. Probleme özgü olarak belirlenmiş olan mutasyon oranında, rastgele olarak farklı kromozomlar üzerindeki veriler değiştirilir. Çalışmada Sürünme mutasyonu (Creep mutation) tekniği uygulanmıştır. Bu teknikte, her bir bireyin genetik materyali içerisinde rastgele seçilen gen(ler), mevcut değerlerinden bağımsız olarak tamamen rastgele yeni değerler alacak şekilde değiştirilir. Bu işlem, gen havuzunun çeşitliliğini artırmayı ve algoritmanın yerel minimumlara sıkışmasını önlemeyi amaçlar. Mutasyon sonucunda oluşan kromozomlar, mevcut kromozomların yerine kaydedilir ve yeni

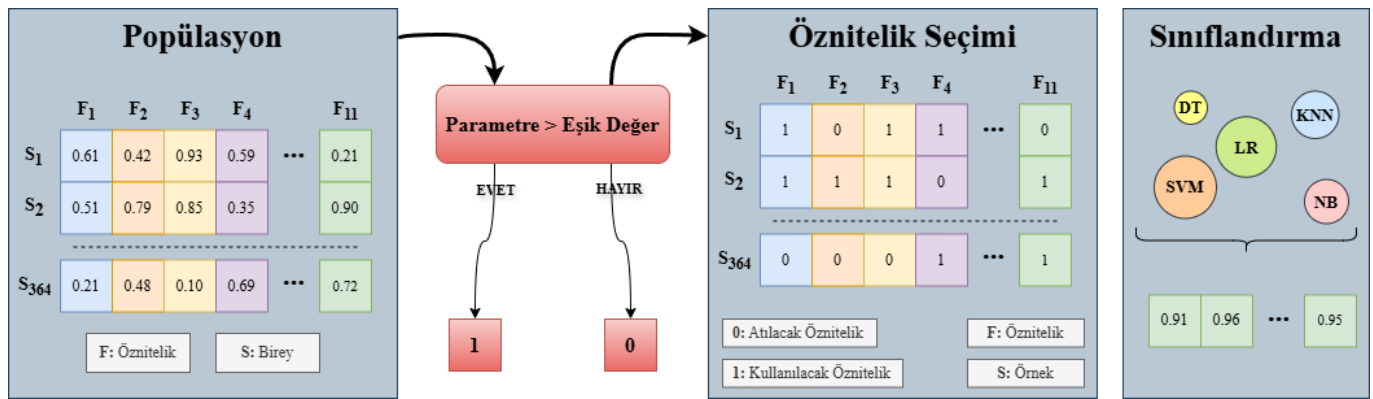
kromozomlar üretilmez. Mutasyon sonucunda uygunluk hedefine ulaşıldığı zaman döngü durur ve en optimal çözüm aranır (Keklik & Özcan, 2023).

Uygunluk Fonksiyonu: Makine öğrenmesi ile elde edilen doğruluk skoru, uygunluk fonksiyonu olarak kullanılır. Dolayısıyla Doğruluk değerini maksimize edilmesi amaçlanmıştır

Önerilen yöntemin optimizasyon iş akışı Şekil 2’de, öznelik seçim akışı ise Şekil 3’te sunulmuştur. Popülasyonda seçim vektörü olarak araştırma yapılırken tüm parametreler 0-1 arası reel sayılar olarak tanımlıdır. Seçim işlemi gerçekleştirilirken eşik değer altında kalan öznelikler 0 olarak, üstünde kalanlar ise 1 olarak temsil edilmektedir. Bu sayede veri setinden problemi temsil etme gücü yüksek olanlar belirlenmektedir. Çalışmamızda Eşik değer olarak 0,5 alınmıştır.



Şekil 2. Çalışma Akış Şeması



Şekil 3. Öznelik Seçimi Akış Şeması

DENEYSEL SONUÇLAR

Önerilen yöntemde KNN, SVM, LR, NB ve DT makine öğrenmesi yöntemleri sınıflandırıcı olarak kullanılmıştır. Her bir yöntem öznelik seçilimi uygulanmadan koşturulmuştur. Ayrıca, bahsedilen makine öğrenmesi yöntemleri için GA ile öznelik seçimi gerçekleştirilerek önerilen yöntemin anemi hastalığı tespitindeki etkisi gözlenmiştir. Önerilen yöntem için kullanılan kontrol parametreleri Tablo 4’te sunulmuştur.

Tablo 4 incelendiğinde, kullanılan yöntemlerin parametre ve değerleri görülmektedir. Genetik algoritmaya özgü kontrol parametreleri sezgisel olarak deneme-yanımla yöntemi ile belirlenmiştir. Popülasyon boyutu 50 olarak belirlenmiştir. Bu değer çeşitliliğin düşük olmamasını sağlarken hesaplama maliyetini de makul seviyede tutmayı sağlamaktadır. Seçilim oranı %20’dir. Bu oran sonraki nesle başarılı bireyler taşınmasını sağlamaktadır. Çaprazlama oranının %20 olarak belirlenmiştir. Bu sayede karışma oranının yüksek seviyelere çıkarak başarılı grupların bozulmasının önüne geçilmesi amaçlanmıştır (Karaboğa 2020). Mutasyon oranı %20 olarak belirlenmiştir. Veri setinde 11 adet parametre bulunmaktadır. Bu nedenle mutasyon etkisinin gözlenebilmesi adına mutasyon oranı literatüre göre yüksek tutulmuştur. Bu sayede mevcut bireylerin değişime uğratılarak algoritmanın daha verimli bir

şekilde çalışmasına olanak sağlayarak dengeli bir araştırma modeli elde edilebilmesi sağlanmıştır. KNN modelinin komşu sayısı 5'tir. SVM modelindeki C parametresi, modelin hata toleransı ve marj genişliği arasındaki dengenin kurulmasını sağlarken LR modelindeki C parametresi ise regularizasyon gücünü kontrol ederek modelin genelleştirme yeteneğinin ayarlanabilmesini sağlar (Mirjalili vd., 2020; Lambora vd., 2019). Tablo 4'teki parametreler tanımlanırken literatürde genel olarak kullanılan oranlar tercih edilmiştir

Tablo 4. Simülasyon Parametreleri

Algoritma	Parametre	Değer
GA	Popülasyon Boyutu	50
	Seçilim Oranı	%20
	Çaprazlama Oranı	%20
	Mutasyon Oranı	%20
KNN	Komşu Sayısı	5
SVM	C (hata toleransı ve marj genişliği arasındaki denge)	10
LR	C (regularizasyon gücü ve genelleştirme yeteneği)	10

Modelleme sürecinde elde edilen koşma süreleri Tablo 5'te sunulmuştur. Tablo 5 incelendiğinde, Tüm makine öğrenmesi modellerinin GA ile çalışma süreleri görülmektedir. Her bir iterasyonda makine öğrenmesi modellerine giren verilerin aynı olması, rastgelelik durumu ortadan kaldırılarak sağlanmıştır. Bu durumda aynı verilerle çalışan modellerden en hızlı sonuç veren model 104 saniye ile NB olmuştur.

Tablo 5. Model Çalışma Süreleri

Metot	Süre (sn)
DT	186
KNN	180
LR	265
NB	104
SVM	171

Tablo 6. Simülasyon Sonuçları


Algoritmalar	Doğruluk (Accuracy)				Kazanç
	Ortalama	Minimum	Maximum	Standart Sapma	
KNN	0,8803	0,7188	1,0	0,0653	%8,66
KNN + GA	0,9565	0,8485	1,0	0,0372	
DT	0,9932	0,9062	1,0	0,0149	%0,34
DT + GA	0,9966	0,9688	1,0	0,0096	
LR	0,9654	0,8750	1,0	0,0338	%1,37
LR + GA	0,9786	0,9062	1,0	0,0251	
NB	0,9146	0,7576	1,0	0,0517	%3,59
NB + GA	0,9474	0,7879	1,0	0,0411	
SVM	0,9222	0,7812	1,0	0,0527	%5,88
SVM + GA	0,9764	0,8788	1,0	0,0263	

GA ile öznitelik seçimi üzerinden elde edilen doğruluk değerleri ile makine öğrenmesi yöntemlerinin doğruluk değerleri Tablo 6'da karşılaştırmalı olarak sunulmuştur. Tablo 6 incelendiğinde, öznitelik seçimi uygulanmadan makine öğrenmesi modelleri ile 10-Kat Çapraz Doğrulama üzerinden ortalama %88,03 ile %99,32 aralığında doğruluk oranları elde ettiği gözlemlenmiştir. GA desteği olmadan en yüksek skoru %99,32 doğruluk oranıyla DT elde etmiştir. Ardından %96,54 oranıyla LR, ardından %92,22 oranıyla SVM, ardından %91,46 oranıyla NB ve son olarak %88,03 oranıyla KNN takip etmiştir. Önerilen yöntem ile makine öğrenmesi yöntemlerinin başarı oranları ise %0,34-%8,66 aralığında artış gösterdiği görülmektedir. Önerilen yöntem ile en düşük performans artışı %0,34 ile DT

üzerinde etkili olurken, en yüksek performans artışı ise %8,66 ile KNN üzerinde etkili olmuştur. Burada öznelik seçimi olmadan DT ile %99,32 ile oldukça yüksek doğruluk değeri elde edildiğinden performans artışı sağlanabilecek aralığın çok sınırlı kaldığı görülmektedir. Ancak KNN modeli diğer modellere göre daha düşük başarı oranı sağladığından, daha yüksek kazanç oranına sahiptir. Sonuç olarak KNN + GA modeli, GA ile öznelik seçimi sayesinde rakip modeller arasında en yüksek başarıya sahip olduğu görülmektedir.

Tablo 6 dan görüldüğü üzere en başarılı model %99,66 oranıyla önerilen yöntem üzerinden DT+GA olmuştur. Bu modelde öznelik seçimi sonucunda seçilen parametreler **yaş**, **cinsiyet**, **PCV**, **MCHC** ve **hemoglobin** olduğu görülmüştür.

Optimizasyon algoritmalarının performans değerlendirilmesinde, yakınsama grafikleri de oldukça önemlidir. Önerilen yöntemde kullanılan her bir makine öğrenmesi yöntemleri için elde edilen yakınsama grafikleri de Şekil 4'te sunulmuştur. Ayrıca önerilen yöntemin 10 kat çapraz doğrulama üzerinden elde edilen simülasyon sonucunda Keskinlik, Geri çağırma, F1 skor ve Özgüllük metrikleri için sonuçlar da Tablo 7'de yer almaktadır.



Şekil 4. Genetik Algoritma Yakınsama Grafiği

Tablo 7. Simülasyon Metrikleri

Algoritmalar	Ortalama			
	Keskinlik (Precision)	Geri Çağırma (Recall)	F1	Özgüllük (Specificity)
KNN+GA	0,9082	0,9019	0,9033	0,8909
DT+GA	0,9286	0,9301	0,9278	0,9159
LR+GA	0,9344	0,9235	0,9265	0,9193
NB+GA	0,9001	0,8756	0,8831	0,8887
SVM+GA	0,9297	0,9204	0,9231	0,9172

Şekil 4, GA'nın çeşitli makine öğrenmesi modelleri üzerindeki yakınsama sürecini göstermektedir. Bu grafikte beş farklı modelin genetik algoritma tarafından optimize edilen uygunluk değerlerinin iterasyon sayısına göre değişimi izlenmektedir. DT modeli, iterasyonların başında neredeyse %100'lük bir uygunluk değerine ulaşarak en yüksek performansı sergilemiş ve bu değeri süreç boyunca korumuştur. LR, %98'e yakın bir uygunluk değeri ile ikinci sırada yer alırken, SVM ise %97-%98 aralığında üçüncü sırada yer almaktadır. KNN modeli %95-%96 düzeylerinde sabitlenmiştir. NB ise diğer modellere kıyasla daha düşük bir performans göstermiş ve %94-%95 seviyesinde kalmıştır. Her modelin belirli bir iterasyon sonrasında uygunluk değerlerinde durağanlaşma gözlemlenmiş, bu da genetik algoritmanın modeller üzerinde optimal çözüme yakınsadığını ve daha fazla gelişim göstermediğini işaret etmektedir. Özellikle DT'nin yüksek performansı, bu modelin genetik algoritma ile en iyi uyumu gösterdiğini ortaya koymaktadır.

Tablo 7 incelendiğinde ise, kesinlik açısından en yüksek değeri LR üzerinden alırken, geri çağırma ve F1-skor için ise en başarılı makine öğrenmesi yöntemi DT olduğu görülmektedir. Aynı zamanda SVM'nin özgüllük metriğinde en başarılı yöntem olduğu görülmektedir. DT'nin doğruluk üzerinde sağlamış olduğu başarıda da dikkate alındığında anemi hastalığı tespitinde daha etkin olabileceği değerlendirilebilir.

SONUÇ

En yaygın kan hastalıklarından olan aneminin teşhis edilebilmesinde makine öğrenmesinin etkisi oldukça önemli bir araştırma alanıdır. Bu çalışmada makine öğrenmesi ile gerçekleştirilen sınıflandırma başarımı, GA tabanlı öznelik seçim yöntemi ile artırılması amaçlanmıştır. Literatürde yaygın olarak kullanılan KNN, SVM, LR, NB ve DT makine öğrenmesi yöntemleri temel sınıflandırıcı olarak kullanılmıştır. Elde edilen deneysel sonuçlar incelendiğinde; GA öznelik seçimi ile elde edilen sonuçların, seçim olmadan elde edilen sonuçlara göre daha başarılı sonuçlar verdiği gözlemlenmiştir. Başlangıç popülasyonunun, çaprazlama oranının, mutasyon oranının, seçim metotlarının ve makine öğrenmesi modelinin değiştirilmesi ile başarının daha yüksek oranlara çıkabileceği öngörülmektedir. Ayrıca, anemi hastalığının tespitinde literatüre sunulmuş yeni meta sezgisel optimizasyon algoritmalarının başarısının araştırılması daha etkin sonuçların elde edilmesine olanak sağlayacağı öngörülebilir.

KAYNAKLAR

- Acar, E. B., Karabey, C., & Köse, B. İnsansız Hava Aracı İle Paket Dağıtımında Gezgin Satıcı Probleminin Genetik Ve Parçacık Sürü Optimizasyon Algoritmaları İle Çözümü. Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi, 10(20), 168-181. <https://doi.org/10.54365/adyumbd.1249391>
- Ahmad, A., Alzaidi, K., Sari, M., & Uslu, H. (2023). Prediction of anemia with a particle swarm optimization-based approach. *An International Journal of Optimization and Control: Theories & Applications (IJOCTA)*, 13(2). 10.11121/ijocta.2023.1269
- Ajder, A. (2023). Geleneksel Yaklaşımlar: Parçacık Sürü Optimizasyonu Algoritması. *Teknobilim-2023: Yapay Zeka ve Mühendislik*, 21.
- Alam, T., Qamar, S., Dixit, A., & Benaida, M. (2020). Genetic algorithm: Reviews, implementations, and applications. *arXiv preprint arXiv:2007.12673*. <https://doi.org/10.48550/arXiv.2007.12673>
- Alp, G., & Soygazi, F. (2024, May). Meta-Heuristic Supported Feature Selection in Classification Algorithms for Diabetes Diagnosis. In *2024 32nd Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE. 10.1109/SIU61531.2024.10601062
- Anguita, D., Ghelardoni, L., Ghio, A., Oneto, L., & Ridella, S. (2012, April). The K'in K-fold Cross Validation. In *ESANN* (Vol. 102, pp. 441-446).
- Appiahene, P., Asare, J. W., Donkoh, E. T., Dimauro, G., & Maglietta, R. (2023). Detection of iron deficiency anemia by medical images: a comparative study of machine learning algorithms. *BioData mining*, 16(1), 2. <https://doi.org/10.1186/s13040-023-00319-z>
- Badem, H., Basturk, A., Caliskan, A., & Yuksel, M. E. (2017). A new efficient training strategy for deep neural networks by hybridization of artificial bee colony and limited-memory BFGS optimization algorithms. *Neurocomputing*, 266, 506-526. <https://doi.org/10.1016/j.neucom.2017.05.061>
- Badem, H. (2019). Parkinson Hastalığının Ses Sinyalleri Üzerinden Makine Öğrenmesi Teknikleri ile Tanımlanması. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 8(2), 630-637. 10.28948/ngumuh.524658
- Cheng, L., Nie, Y., Wen, H., Li, Y., Zhao, Y., Zhang, Q., ... & Fu, S. (2024). An ensemble machine learning model for predicting one-year mortality in elderly coronary heart disease patients with anemia. *Journal of Big Data*, 11(1), 1-20. <https://doi.org/10.1186/s40537-024-00966-x>
- Eke, İ. (2022). Optimum PID Kazançları Genetik Algoritma İle Hesaplanan Otomatik Gerilim Regülatörü. *International Journal of Engineering Research and Development*, 14(3), 351-361. <https://doi.org/10.29137/umagd.1176936>
- Gizzi, E., Nair, L., Chernova, S., & Sinapov, J. (2022). Creative problem solving in artificially intelligent agents: A survey and framework. *Journal of Artificial Intelligence Research*, 75, 857-911. <https://doi.org/10.1613/jair.1.13864>

- Gülmez, B. (2023). Market zinciri ürün dağıtım problemi için farklı genetik algoritma versiyonları ile çözümü ve karşılaştırması. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 6(1), 180-196.
- Holland, J. H. (1992). Genetic algorithms. *Scientific american*, 267(1), 66-73.
- Inneci, T., & Badem, H. (2023). Detection of Corneal Ulcer Using a Genetic Algorithm-Based Image Selection and Residual Neural Network. *Bioengineering*, 10(6), 639. <https://doi.org/10.3390/bioengineering10060639>
- Kaleli, S. S. (2023). Bist-30 Şirketlerinin Pandemi Öncesi-Sonrası Satış Verilerinin Genetik Algoritma ile Analizi ve Optimum Portföy Oluşturma. *MANAS Sosyal Araştırmalar Dergisi*, 12(2), 557-565. <https://doi.org/10.33206/mjss.1215054>
- Karaboğa, D. (2020). Yapay zeka optimizasyon algoritmaları (7.Baskı). Nobel Akademi Yayıncılık.
- Katoch, S., Chauhan, S. S., & Kumar, V. (2021). A review on genetic algorithm: past, present, and future. *Multimedia tools and applications*, 80, 8091-8126. <https://doi.org/10.1007/s11042-020-10139-6>
- Keklik, G., & Özcan, B. D. (2023). Genetik Algoritmaların İşleyişi ve Genetik Algoritma Uygulamalarında Kullanılan Operatörler. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 6(1), 1052-1066. <https://doi.org/10.47495/okufbed.1161413>
- Khan, J. R., Chowdhury, S., Islam, H., & Raheem, E. (2019). Machine learning algorithms to predict the childhood anemia in Bangladesh. *Journal of Data Science*, 17(1), 195-218. 10.6339/JDS.201901_17(1).0009
- Lambora, A., Gupta, K., & Chopra, K. (2019, February). Genetic algorithm-A literature review. In 2019 international conference on machine learning, big data, cloud and parallel computing (COMITCon) (pp. 380-384). IEEE, 10.1109/COMITCon.2019.8862255
- Mirjalili, S., Song Dong, J., Sadiq, A. S., & Faris, H. (2020). Genetic algorithm: Theory, literature review, and application in image reconstruction. *Nature-inspired optimizers: Theories, literature reviews and applications*, 69-85. https://doi.org/10.1007/978-3-030-12127-3_5
- Narayan, Y. (2021). Comparative analysis of SVM and Naive Bayes classifier for the SEMG signal classification. *Materials Today: Proceedings*, 37, 3241-3245. <https://doi.org/10.1016/j.matpr.2020.09.093>
- Öklü, M., & Canbay, P. (2023). Makine Öğrenmesi Yöntemleri ile Şehirlerin Hava Kalitesi Tahmini. *International Journal of Advances in Engineering and Pure Sciences*, 35(1), 39-53. <https://doi.org/10.7240/jeps.1175507>
- Pertiwi, D. A. A., Ahmad, K., Salahudin, S. N., Annegrat, A. M., & Muslim, M. A. (2024). Using genetic algorithm feature selection to optimize XGBoost performance in Australian credit. *Journal of Soft Computing Exploration*, 5(1), 92-98. <https://doi.org/10.52465/josce.v5i1.302>
- Peterson, L. E. (2009). K-nearest neighbor. *Scholarpedia*, 4(2), 1883. 10.4249/scholarpedia.1883
- Saputra, D. C. E., Sunat, K., & Ratnaningsih, T. (2023, February). A new artificial intelligence approach using extreme learning machine as the potentially effective model to predict and analyze the diagnosis of anemia. In *Healthcare* (Vol. 11, No. 5, p. 697). MDPI. <https://doi.org/10.3390/healthcare11050697>
- Seymen, V. (2014). Demir eksikliği anemisi hastalığının tespitinde kullanılan sınıflandırma algoritmalarının karşılaştırılması (Master's thesis, Sakarya Üniversitesi (Turkey)).
- Shukla, A., Pandey, H. M., & Mehrotra, D. (2015, February). Comparative review of selection techniques in genetic algorithm. In 2015 international conference on futuristic trends on computational analysis and knowledge management (ABLAZE) (pp. 515-519). IEEE. 10.1109/ABLAZE.2015.7154916
- Taşcı, E., & Onan, A. (2016). K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. *Akademik Bilişim*, 1(1), 4-18.
- Türkkahraman, Ş. M., & Karabulut, K. (2023). Sosyal Ağ Varlığında Takım Oluşturma Problemine Hibrit Bir Genetik Algoritma Önerisi. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 25(73), 181-192. <https://doi.org/10.21205/deufmd.2023257315>
- Vohra, R., Dudyala, A. K., Pahareeya, J., & Hussain, A. (2022). Decision rules generation using decision tree classifier and their optimization for anemia classification. In *Inventive Computation and Information Technologies: Proceedings of ICICIT 2021* (pp. 721-737). Singapore: Springer Nature Singapore. https://doi.org/10.1007/978-981-16-6723-7_53

- Wan, H. (2024). Applying the genetic algorithm to optimization problems. *WIT Transactions on Information and Communication Technologies*, 2. 10.2495/AIENG930332
- Weile, D. S., & Michielssen, E. (1997). Genetic algorithm optimization applied to electromagnetics: A review. *IEEE Transactions on Antennas and Propagation*, 45(3), 343-353. 10.1109/8.558650
- World Health Organization (WHO) (2008). Worldwide prevalence of anaemia 1993-2005: WHO global database on anaemia.
- World Health Organization (WHO). (2014). Global nutrition targets 2025: Stunting policy brief (No. WHO/NMH/NHD/14.3).
- World Health Organization (WHO). (2024). Guideline on haemoglobin cutoffs to define anaemia in individuals and populations. World Health Organization.
- Yağmur, N., Temurtaş, H., & Dağ, İ. (2023). Anemi Hastalığının Yapay Sinir Ağları Yöntemleri Kullanılarak Sınıflandırılması. *Journal of Scientific Reports-B*, (008), 20-34.
- Yıldız, T. K., Yurtay, N., & Öneç, B. (2021). Classifying anemia types using artificial learning methods. *Engineering Science and Technology, an International Journal*, 24(1), 50-70. <https://doi.org/10.1016/j.jestch.2020.12.003>
- Zhang, S., & Li, J. (2021). KNN classification with one-step computation. *IEEE Transactions on Knowledge and Data Engineering*, 35(3), 2711-2723. 10.1109/TKDE.2021.3119140



Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences



Geliş Tarihi : 06.10.2024
Kabul Tarihi : 22.02.2025

Received Date : 06.10.2024
Accepted Date : 22.02.2025

LSTM AND ANFIS MACHINE LEARNING ALGORITHMS IN ESTIMATING THE SEA WATER TEMPERATURE IN TÜRKİYE AT VARIOUS SEA LOCATIONS

TÜRKİYE'DE FARKLI DENİZ MEVKİLERİNDEKİ DENİZ SUYU SICAKLIĞININ LSTM VE ANFIS MAKİNE ÖĞRENMEŞİ ALGORİTMALARI KULLANILARAK TAHMİN EDİLMESİ

*Akın İLHAN*¹ (ORCID: 0000-0003-3590-5291)
*Sergen TÜRMEŞE*² (ORCID: 0000-0003-4764-747X)
*Mehmet BİLGİLİ*³ (ORCID: 0000-0002-5339-6120)
*Alper YILDIRIM*⁴ (ORCID: 0000-0002-5339-6120)
Besir SAHİN^{5*} (ORCID: 0000-0003-0671-0890)

¹ Ankara Yıldırım Beyazıt University, Department of Energy Systems Engineering, Ankara, Türkiye

² Cukurova University, Department of Mechanical Engineering-Engineering Faculty, Adana, Türkiye

³ Cukurova University, Department of Mechanical Engineering-Ceyhan Engineering Faculty, Adana, Türkiye

⁴ Osmaniye Korkut Ata University, Department of Machinery and Metal Technology, Osmaniye, Türkiye

⁵ Istanbul Aydın University, Department of Mechanical Engineering, Istanbul, Türkiye

*Sorumlu Yazar / Corresponding Author: Besir SAHİN, besirsahin@aydin.edu.tr

ABSTRACT

The World's temperature is experiencing a rapid increase, leading to negative consequences for aquatic ecosystems such as oceans, seas, lakes, and rivers. There are also other negative influences consisting of changing precipitation patterns, disruptions in marine current circulation, and formation of negative impacts on marine life. Ultimately, there is a compelling need for careful monitoring of sea temperatures to understand and address these interconnected environmental changes. The daily temperature of seawater (SWT) is a crucial abiotic variable that changes both the chemical composition of water and aquatic life in seas and oceans. The present study explored the capabilities of artificial intelligence techniques in one-day-ahead SWT predictions. These techniques are fuzzy c-means adaptive neuro-fuzzy inference system (ANFIS-FCM), subtractive clustering ANFIS (ANFIS-SC), grid segmentation ANFIS (ANFIS-GP), and long short-term memory (LSTM) and artificial neural network (ANN). Accordingly, daily SWT data that was collected from Alanya, Bodrum, and Akcakoca measurement stations located in Türkiye's Mediterranean, Aegean, and Black Sea locations were used in SWT predictions. Estimated results obtained by these five estimation methods were compared to the real observed values by interpreting four statistical metrics. Consequently, the most accurate estimates were obtained utilizing the fuzzy c-means (FCM) of ANFIS. Besides, it was reported that the LSTM approach closely followed the accuracy of this prediction of FCM. Both proposed models have generated superior statistical accuracy results corresponding to 0.34% MAPE, 0.0765 °C MAE, 0.1585 °C RMSE, and 0.9990 *R*. Those results have indicated the closest match of the predictions on the real measured data that have been acquired by ANFIS-FCM and LSTM models.

Keywords: Machine learning, artificial neural network, prediction of seawater temperature

ÖZET

Dünyanın sıcaklığında hızlı bir artış yaşanmaktadır ve bu durum, yağış düzenlerinde değişimlere, deniz akıntısı dolaşımında bozulmalara ve deniz yaşamında olumsuz etkilere neden olur. Ayrıca, bu durumun, okyanuslar, denizler, göller ve nehirler gibi su ekosistemleri üzerinde diğer olumsuz etkileri de bulunmaktadır. Sonuçta, birbiriyle bağlantılı olan bu çevresel değişiklikleri anlamak ve ele almak için deniz sıcaklıklarının dikkatli bir şekilde ToCite: İLHAN, A., TÜRMEŞE, S., BİLGİLİ, M., YILDIRIM, A., & SAHİN, B., (2025). LSTM AND ANFIS MACHINE LEARNING ALGORITHMS IN ESTIMATING THE SEA WATER TEMPERATURE IN TÜRKİYE AT VARIOUS SEA LOCATIONS. *Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences*, 28(1), 322-333.

izlenmesine ve yorumlanmasına zorunlu bir ihtiyaç vardır. Diğer taraftan, deniz suyunun günlük sıcaklıkları (SWT), denizlerdeki ve okyanuslardaki hem suyun hem de su yaşamının kimyasal bileşimini değiştiren çok önemli bir abiyotik değişkendir. Bu çerçevede, bu çalışma, bir gün sonrası SWT tahminlerinde yapay zekâ tekniklerinin kabiliyetlerini araştırmıştır. Bu teknikler, bulanık c-ortalamar uyarlamalı nöro-bulanık çıkarım sistemi (ANFIS-FCM), çıkarımlı kümeleme ANFIS (ANFIS-SC), ızgara bölümlenme ANFIS (ANFIS-GP) ve uzun kısa süreli bellek (LSTM) sinir ağı ve yapay sinir ağıdır (ANN). Bu doğrultuda, Türkiye'nin Akdeniz'de yer alan Alanya, Ege'de bulunan Bodrum ve Karadeniz'de kurulmuş olan Akçakoca ölçüm istasyonlarından elde edilen günlük SWT verileri kullanılmıştır. Beş farklı tahmin yöntemi kullanılarak üretilen tahmin sonuçları, gerçek gözlemlenen değerlere göre dört farklı istatistiksel ölçüm yaklaşımı kullanılarak karşılaştırıldı ve yorumlandı. Neticede, en doğru tahminlerin, ANFIS'in bulanık c-ortalamar (FCM) yöntemi kullanıldığında elde edildiği sonucuna varılmıştır. Bu modeli en yakından takip eden ikinci en iyi modelin ise; LSTM yaklaşımı olduğu sonucuna varılmış ve bulunan sonuçlar rapor edilmiştir. Önerilen bu iki model de %0,34'lük MAPE, 0,0765 °C'lik MAE, 0,1585 °C'lik RMSE ve 0,9990'lık R'ye karşılık gelen üstün istatistiksel doğruluk sonuçlarını üretmiştir. Bu sonuçlar, gerçek ölçülen verilere en yakın eşleşmelerin ANFIS-FCM ve LSTM modelleri ile elde edildiğini göstermiştir.

Anahtar Kelimeler: Makine öğrenmesi, yapay sinir ağı, deniz suyu sıcaklığının tahmini

INTRODUCTION

Over the last few decades, the impacts of global warming that is eventuated by increased greenhouse gas emissions have become a significant issue, this is not only a case in terrestrial areas but has also become a problem within aquatic ecosystems including oceans, seas, lakes, and rivers (Kayhan et al., 2015). Global temperature is increasing rapidly and this situation has adversely affected various marine events such as precipitation regimes, sea current circulation, and the lives of marine creatures. Moreover, they have also brought many problems, such as the efforts of fish living in cold seas to adapt to warm seas with changes in their migration routes, changing the variety and quality of products obtained from the sea, and decreasing the number of the products (Bilgili, 2023). On the other hand, a detailed analysis of trends and changes in SWT data is necessary to assess the negative influences of weather alteration on various fields such as hydrology, meteorology, agriculture, animal farming, and tourism. This analysis will also make important contributions to the prediction and determination of various atmospheric events such as future precipitation, evapotranspiration, wind speed, humidity, and temperature (Şişman, 2019). In this sense, the SWT greatly affects the efficiency of these applications. Because of these compelling factors, precise estimates of SWT play a pivotal role in the analysis and planning of marine events, as well as in the effective planning, operation, and management of energy generation plants.

Recently, several approaches were constructed to estimate and determine the magnitude of SWT. These approaches have been used to examine various processes: Cooling water discharges from thermal power plants, the interaction of increasing flood hydraulics with the environment, spatial and seasonal heat fluxes, volatility, and most importantly, environmental changes increase substantially (Gooseff et al., 2005; Webb and Zhang, 1997; Sinokrat and Stefan, 1993; Bowles et al., 1977; Morse, 1970). However, it is possible to develop some models for these cases as well, although the exact estimation of SWT is rather uncertain and complex since the heat flux, solar radiation, and wind speed differences are quite large; and usually, there are not direct available analytical equations to solve such cases to configure the magnitude of SWT. Consequently, a range of methods are employed, encompassing basic statistical and stochastic methods, as well as advanced artificial intelligence and machine learning techniques are considered for this purpose (Patil and Deo, 2017). Among modern data-based techniques, recently, ANNs have recently become one of the most prevalent types of prediction methods due to the flexibility of fitting stochastic data, they have comparatively simple developing characteristics, and generally, ANNs could be easily developed with a limited background of programming knowledge. On the other hand, SWT has been predicted using ANNs in several works of past researchers, available in the literature. For instance, seasonal SWT predictions have been performed by Tangang et al. (1997), and in the study, a specific area located in the tropical Pacific was taken into account. Besides, ANN was utilized considering wind stress as well as temperature anomalies of sea surface water as inputs to empirical orthogonal functions. Similarly, in the tropical Pacific region, the SWT was predicted by Wu et al. (2006), by utilizing ANN. Here, the artificial neural network (ANN) architecture involved extracting the key factors affecting the sea surface temperature (SST) throughout 3 to 15 months. These factors included the SWT itself and the sea level pressure. On the other hand, in the context of estimating the increase in SWT during the desalination process, several ANN-based correlations have been established with the work of Tanvir and Mujtaba (2006) (Patil and Deo, 2017). The forecasting skills of distinct models regarding regressions, transfer functions, and ANN at the Antarctic and Pacific Oceans were compared by the prediction capabilities of the models implemented by Gupta and Malmgren

(2009). This study determined that the ANN method performed superior estimation outcomes compared to the other approaches. The SWT estimate was exerted by Mahongo and Deo (2013), and it was applied to the east African coastline to approximately predict the SWT for subsequent months and seasons. Furthermore, the predictions of SWT also included the applications of various ANN models and the autoregressive integrated moving average (ARIMA) techniques. This analysis shows that data-driven methodologies used in previous research often revolve around time-series predictions. In these studies, it was observed that SWT predictions were performed by shifting such a pattern upwards along the time axis. The conducted overview of the available literature studies stated above demonstrates that the ANN is an interesting method in SWT forecasts. Also, ANN can be made more beneficial by taking into account the fast developments in this area, and this may be the main opportunity in this direction. The SWT is a significant indicator that influences the overall health of seas, and accordingly, precise anticipation of the SWT is one of the most important issues for a lot of agencies in the World. The tasks of those agencies may be diverse such that the monitoring of climate variability, obtaining seasonal predictions, performing operational weather and ocean predictions, executing operations regarding the military and the defense, verifying or enforcing models for the ocean and the atmosphere, the assessment of the ecosystems, and achieving researches on the tourism as well as the fishery jobs.

A review of the available literature in this study addresses the challenge of estimating SWT through short-term time-series analysis. There are a limited number of researchers working with the methods studied here in this area. The methods considered in this study are ANFIS models using subtraction clustering (ANFIS-SC) and grid partitioning (ANFIS-GP), as well as a deep learning (DL) model using fuzzy c-means (ANFIS-FCM). Additionally, the LSTM neural network and ANN models were taken into account.

Recently, data predictions have gained significant importance. In this way, the future unrealized magnitude of the considered physical parameter can be easily forecasted. And more importantly, precautions can be taken against some negative situations, when the future value of the considered parameter is known before. For example, predictions related to the SWT are so important in taking prevention for the benefit of nature, the sea itself, life on the sea, and the sea animals. Furthermore, excess rise of the sea temperature due to greenhouse gas emissions and global warming can be known earlier and some measures against those can be brought to life. Of course, there may be many other advantages of data estimates that are not covered here. On the other hand, there are lots of application areas of machine learning and artificial intelligence taken into account in physical and engineering sciences. For instance, they are mainly considered in estimations of air pressure and temperature, wind speed as well as direction, humidity anticipations, and precipitation forecasts. Besides, machine learning can also be utilized to obtain predictions on water flow speeds of the rivers, or information on sea wave height can be obtained by usage of proper artificial intelligence algorithms. More recently, guesses on wind power and solar energy have been achieved by different types of algorithms created by machine learning and artificial intelligence.

In this study, in the following sections, initially, the working principles and the methodologies of five algorithms including ANFIS-FCM, ANFIS-SC, ANFIS-GP, LSTM, and ANN have been given. Later, the study region and SWT data for the three stations are introduced. The plot of the fluctuating distributions of SWT data for all stations given for five years has been demonstrated. The tuning parameters of the algorithms that are used to have the best quality predictions are given in the model structure. Finally, the performance of the estimation algorithms is determined for three stations with the utilization of the tabulated results and by the usage of a graphical representation of the functional distributions of the real measured SWT data versus the forecast functions. Finally, the obtained prediction outcomes are interpreted.

MATERIALS AND METHODS

Adaptive Neuro-Fuzzy Inference System

The techniques developed using artificial intelligence (AI) methods to perform predictions in engineering applications with minimal error require a combination of two different techniques. Those techniques are ANN and FIS (fuzzy inference system). Namely, the ANFIS model combines the strengths of these two approaches, effectively capturing the intricacies of complex processes. This combination ultimately results in an advanced and superior technique. There are a lot of investigations about the ANFIS machine learning technique in the prediction of different environmental aspects and matters (Reddy and Krishna, 2023; Alver et al., 2020; Mashaly and Alazba, 2018; Saghafi and Arabloo, 2017). The ANFIS model works by training the system initially, similar to artificial neural networks (ANNs). In this way, a proper algorithm and link between each instantaneous data of all data clouds can be formed.

Next, the trained system functions as a FIS. This dual combination of FIS and ANN within ANFIS creates an integrated framework that maximizes the benefits of each component (Jang, 1993).

In the typical process of developing an ANFIS model, there are distinct stages involving construction and training, which are private to those found in other similar models. Throughout the model's creation, crucial decisions revolve around selecting the appropriate membership functions (MFs) and the associated parameters. This entails segmenting the data of input and output into the rule patches. The ANFIS approach thus streamlines the training phase by integrating commonly used clustering methods, facilitating a comprehensible organization and finally categorization of the input data. To accomplish this objective, three distinct clustering techniques were employed: Fuzzy c-means (FCM), inferential clustering (SC), else grid partitioning (GP). These techniques serve the purpose of enhancing the understanding and arrangement of the input data, ultimately contributing to the overall efficacy of the training process of the ANFIS model.

Long Short-Term Memory (LSTM)

A pioneering role by Hochreiter (1997) was played in the introduction of LSTM. While initially classified as a kind of RNN (recurrent neural network), this approach tackles the challenges faced by traditional RNNs by incorporating memory cells or cell states, which effectively manage the issue of vanishing errors. Figure 1 illustrates the LSTM layer. In the figure, how a time series indicated by X , having C properties (channels), as well as the length of S , progresses through the LSTM layer is demonstrated. Besides, the hidden element that is labeled with h_t , serves as both the output and a representation of the cell status at a time step of t . In the initial time step and for the first state of the network, the first LSTM component reckons the initial output as well as updates the cell state. As the sequence unfolds, the subsequent time step and the current network status (c_{t-1}, h_{t-1}) are used by this component to reckon both the output as well as the updated cell status (c_t) at a time step of t (Mathworks, 2020).




Figure 1. A Structure of an LSTM Layer (Mathworks, 2020)

Three learnable weights of the LSTM layer include input weights exposed by the denotation of W , recurrent weights signified by the abbreviation of R , and bias pointed by a symbol of b . Accordingly, three matrices are formed to include the combinations of input weights, recurrent weights, else the bias, respectively, comprising each gate component. Namely, Eq. (1) below shows the combination of these matrices including each gate component;

$$W = \begin{bmatrix} W_i \\ W_f \\ W_g \\ W_o \end{bmatrix}, R = \begin{bmatrix} R_i \\ R_f \\ R_g \\ R_o \end{bmatrix}, b = \begin{bmatrix} b_i \\ b_f \\ b_g \\ b_o \end{bmatrix} \quad (1)$$

In Eq. (1), while the input gate is designated by the abbreviation i , the forget gate and the cell candidate are demonstrated by the abbreviations f and g , respectively. Moreover, the designation of o refers to the output gate, given at each learnable weight matrices.

Artificial Neural Networks (ANNs)

An ANN in the form of a three-layered structure including i, j , as well as k layers having the weights of W_{ij} else W_{jk} are presented in Figure 2. In this figure, i, j , and k layers correspond respectively to the layer of input, a layer of

hidden as well as the layer of output. On the other hand, weights W_{ij} and W_{jk} are defined between input and hidden layers as well as hidden and output layers. The structure is composed of the layer of input, the layer of hidden, and the layer of output from the multilayer perceptron (MLP), as presented in this figure. Besides, the input and output layers include input and output variables, respectively (Kisi et al., 2016). In ANN structures, every neuron owns an adjustable weight factor (w) as well as a bias (b), defined between successive layers. In this context, the input variables at the network's input layer are multiplied with regard to the connection weights, and then biases are added to these multiplications. In the network's hidden layer, the formation of many artificial links associated with the previous layer, results in the collection of variables. Then, the output for the neuron is obtained by adjusted parameters which are passed through a function of transfer. Namely, the activation process is performed by this transfer function. Finally, the first hidden layer's outputs eventuate as the inputs of the network output layer (Kisi et al., 2015).

The widely utilized activation function, i.e., the definition of the logistic function is provided in Eq. (2) (Mansouri et al., 2016). This is defined with the reciprocal of the addition of the negative power of the exponential function added to the unity.

$$f(y) = \frac{1}{1+e^{-y}} \tag{2}$$

To decrease the errors during the training operation, the most appropriate learning algorithm should be searched and implemented. After the training process, the assimilation of the network can be observed as the output. A back propagation (BP) technique is generally taken into account in the learning algorithms for a multi-layer perceptron approach. The main intent of BP method is to acquire a significant reduction in the total amounts of network errors.




Figure 2. ANN Structure of a Multilayer Perceptron Presented in Three-layered Form (Sharma et al., 2023)

The accuracy of the machine learning and artificial intelligence estimations have been evaluated according to four statistical accuracy parameters, given with Eqs. (3), (4), (5), and (6). Namely, in those equations, mathematical statements of mean absolute percentage error, mean absolute error, root mean square error, and the correlation coefficient, corresponding to abbreviations of MAPE, MAE, RMSE, and R have been respectively indicated. In this way, comparison as well as the assessment of the implemented models are acquired by these 4 statistical accuracy parameters. In short, those parameters indicate which method is better than the other.

$$MAPE = \left(\frac{1}{n} \sum_{i=1}^n \left| \frac{r(i)-f(i)}{r(i)} \right| \right) \times 100 \tag{3}$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |f(i) - r(i)| \tag{4}$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [f(i) - r(i)]^2} \tag{5}$$

$$R = \left(\sum_{i=1}^N [f(i) - \bar{f}][r(i) - \bar{r}] \right) / \left(\sqrt{\sum_{i=1}^N [f(i) - \bar{f}]^2} \sqrt{\sum_{i=1}^N [r(i) - \bar{r}]^2} \right) \tag{6}$$

The $f(i)$ function shown in all four above equations demonstrates the instantaneous forecasted SWT data at the instantaneous observation of i , obtained by five models. Besides, the function of $r(i)$ used in the same four equations exhibits the instantaneous actual measured SWT data at the instantaneous observation of i . Eventually, the mean values of the forecasts and the real observations in the computations of the R given in Eq. (5), are respectively exposed by symbols \bar{f} and \bar{r} .

In this study, four verification criteria including MAPE, MAE, RMSE, and R have been utilized. Those are the most commonly used statistical accuracy parameters in the evaluation of the accuracy of the implemented models. They enable comparison of the predictions with respect to the actual observed data clouds. With the utilization of those error parameters, how much an estimation function approximates the counterpart's actual data function can be evaluated and answered. On the other hand, it also provides answers to the quality of the predictions and thus compares all anticipation obtained by different methodologies. The studies of Bilgili (2010) and İlhan (2023) have considered those parameters in the evaluation of the comparison of the estimations according to the real observed data clouds.

In this study, the prediction models defined above were tested on a total of 1,826 data for each station that corresponded to five years of daily average SWT magnitudes of three different measurement stations found in Türkiye. For each station, four years of a total of five years were chosen as the training data cluster, whereas, the rest of one year of cumulative of five years was selected as testing data cluster. The forecast capacities of the implemented LSTM, ANFIS-FCM, ANFIS-SC, ANFIS-GP, and ANN models were tested according to the testing phases of the simulations, namely last year's predictions were revealed on the actual data SWT function for three measurement stations in the following figures of the text.

RESULTS AND DISCUSSIONS

The Study Region and SWT Data

Special attention was given to collecting SWT data from various regions and seas found in Türkiye. The SWT data that was obtained from Turkish meteorological stations (MS) found in Alanya, Bodrum, and Akcakoca provinces, were utilized for this purpose. These stations are strategically located, representing the geographical regions of the Mediterranean, Aegean, and Black seas.

On the other hand, Figure 3 presents all of the SWT instantaneous data found in the data cloud that was used in predictions, considering these three MSs. In this figure, those cited stations are shown with the color patterns corresponding to blue, red, and green, showing Akcakoca, Bodrum, and Alanya MSs, respectively. On the other hand, the daily instantaneous SWT values at these measurement stations were measured in the date range between 01 January 2015 and 31 December 2019. The measured temperature values ranged from 7.5 °C to 27 °C at Akcakoca MS, from 15 °C to 28 °C at Bodrum MS, and from 16 °C to 31 °C at Alanya MS. As seen from this figure that the minimum daily SWT was generally realized in January months, whereas, the maximum daily SWT was actualized in August months for all of the measurement stations. And, this is also a feature of the northern hemisphere of the globe. When the alteration of daily data for five years is examined, it is clear that the data of three MSs has an annual periodic fluctuation and therefore is quite appropriate for the time-series forecasting models created by machine learning.




Figure 3. Time-series of Observed Daily SWT Data for Akcakoca, Bodrum, and Alanya MSs

The Model Structure

The SWT predictions were conducted by considering the daily average values of SWT data measured at three different locations of measurement stations (MS), found in Türkiye. For the predictions, the instantaneous input data in the models were derived from the average values of 1,826 daily SWTs obtained from measurement stations located in Akçakoca, Bodrum, and Alanya provinces of the country. However, a split on these data was implemented to form a discretization including two data clouds, in which one is formed to consist of 80% of the cumulative and named as training data cluster; whereas, the rest is formed of 20% of the cumulative and named as testing data cluster. Then, following the planned workflow of the forecasting methods, the selected forecasting models were trained to utilize the data cloud that was allocated for training. After, the validation was implemented using the data cloud that was allocated for testing. The time-series methodology includes the univariate modeling approach that was implemented to the time-series data of the targeted variable. This approach captures patterns within the dataset by recognizing the natural periodicities of the time-series data function. For instance, in SWT data distributions, an annual periodic trend is occurring on the data of all stations. Thus, for a considered station, the next periodic cycle imitates the former one, however being slightly different than the former one. For the current study, initially, the SWT estimates were made using a time-series analysis depending on the LSTM approach. Then, SWT estimations were actualized using the ANFIS-FCM method as a second technique. As a third method, SWT estimates were modeled using the ANFIS-SC configuration. Then, the ANFIS-GP tool was used as the fourth approach, and then the method of ANN was utilized and discussed as the last step.

Among the configuration adjustments for the LSTM algorithm: The hidden layer (HL) number was set to 5 for all MSs. On the other hand, the max epoch number was kept at a constant value of 300, throughout all trials. In the field of LSTM applications, although experiments involved the alteration of the *HL* in the range of 5 and 150, in the end, it was concluded to keep the hidden layer at a constant value of 5, since it revealed the highest accuracy for all constructed models.

On the other hand, the ANFIS approach was adopted to obtain the desired output values from the input variables. In ANFIS-FCM type of models, the number of members per step is gradually increased by setting the number of MFs to be in a range of 2 to 10. Conversely, the ANFIS-SC model was examined with radius spacing to evaluate the effect of radius. In SC type of models, an increment of 0.1 was implemented at the influence radius range between 0.2 to 0.9. Finally, while the number of entries and the maximum number of periods were adjusted alike in GP of ANFIS, resembling FCM and SC algorithms of ANFIS; the number of MFs was adjusted either to 2 or 3 in this particular type of modeling.

Case Study 1: Results of Akçakoca MS

The displayed prediction results in Table 1, which were exhibited in terms of the statistical error parameters, demonstrate the acceptability of LSTM, ANFIS, and ANN models which showed satisfactory performance in daily SWT predictions. However, the best outcome was achieved by the ANFIS-FCM model, yielding a result of MAE of 0.1939 °C, a MAPE of 1.20%, an RMSE of 0.3597 °C, and an R statistic of 0.9983. When all of the model results were analyzed, it can be observed that these statistical accuracy results are the lowest with regards to MAE, MAPE as well as RMSE, whereas, the highest with regards to R. In this regard, a model that already has these features is referred to be the model that produces the best quality and the best prediction. In a similar approach, the second superior model evaluated in terms of the statistical error parameters, was also reported. Namely, the second superior model for Akçakoca MS was determined and reported to be ANFIS-SC, generating statistical results of 0.1948 °C MAE, 1.21% MAPE, 0.3624 °C RMSE, and an R-value of 0.9983. Accordingly, Figure 4 provides the function of the measured actual SWT data obtained from this station, given with respect to the five different prediction approaches. In this figure, the predicted values of one day ahead of SWT using five distinct models were compared against the actual measured SWT values obtained from Akçakoca MS; revealing the high degree of alignment between the measured and predicted results.

Table 1. Statistical Results of SWT Forecasts for Akçakoca MS

Model	MAPE (%)	MAE (°C)	RMSE (°C)	R
LSTM	1.34	0.2118	0.3707	0.9982
ANFIS-FCM	1.20	0.1939	0.3597	0.9983
ANFIS-SC	1.21	0.1948	0.3624	0.9983
ANFIS-GP	1.49	0.2523	0.5809	0.9958
ANN	1.23	0.1982	0.3648	0.9983

This figure clearly demonstrates the exceptional congruence between the time-series functions of the applied models performing prediction calculations and the real measured time-series function. This alignment is also evident from the statistical error parameters presented in Table 1.




Figure 4. The Forecasts on the Actual SWT Data of Akcakoca MS

Case Study 2: Results of Bodrum MS

The procedure applied to Bodrum MS follows the same process as the previous Akçakoca station. In this context, a summary of the error estimation obtained through statistical evaluation results from the testing process of this station is presented in Table 2. The models used perform commendable outcomes in estimating daily SWTs. In particular, optimal and fairly accomplished results were achieved through LSTM and ANFIS-FCM methodologies in this case study. Specifically, the ANFIS-FCM method gave superior results when MAPE and MAE error outcomes were taken into account, while the LSTM method was superior when RMSE and *R* statistical evaluation parameters were considered. Namely, it was concluded that the error results of MAPE and MAE of FCM method are the lowest among the five models, whereas, the error outcomes of RMSE of LSTM are the lowest among the others and *R* of LSTM is highest among the others. Accordingly, as observed from Table 2, ANFIS-FCM model generated 0.34% MAPE and 0.0765 °C MAE, whereas, the LSTM model gave the results of 0.1585 °C RMSE and 0.9990 *R*; indicating to be the best two models among the others.

On the other hand, Figure 5 demonstrates testing time-series of real observed data, presented for Bodrum MS. The data cloud function of actual data is given in this figure according to the predicted SWT data clusters, under the usage of the same five prediction tools, including LSTM, ANFIS-FCM, ANFIS-SC, ANFIS-GP, and ANN. A comparison of the predictions against the actual observed data of this Bodrum station is visualized in this figure, similarly, to show the degree of the quality of the computations. Namely, SWT machine learning anticipation models coincided very well with the counterpart actual values and even better than the former analyzed Akçakoca MS. In general, the error parameters including MAPE, MAE, and RMSE were computed to be significantly lower than the corresponding error values of Akçakoca MS, whereas, the correlation coefficient (*R*) was determined to be substantially higher than the counterpart correlation coefficient (*R*) value of the Akçakoca MS. In this regard, the statistical error calculations that are shown in Table 2, belonging to these models also prove the related overlapping incidents and the high qualities of the implemented models.

Table 2. Statistical Results of SWT Forecasts for Bodrum MS

Model	MAPE (%)	MAE (°C)	RMSE (°C)	R
LSTM	0.35	0.0786	0.1585	0.9990
ANFIS-FCM	0.34	0.0765	0.1600	0.9989
ANFIS-SC	0.35	0.0785	0.1602	0.9989
ANFIS-GP	0.41	0.0934	0.1831	0.9986
ANN	0.36	0.0807	0.1609	0.9989

A variety of studies on different areas using different algorithms are available in the literature. In this context, Chen et al. (2018) have considered a model formed of EnsemLSTM using wind speed data of ten-minute intervals. In their study performed in China, they computed a correlation result of *R*=0.9619. On the other hand, Yucel et al. (2016) constructed a forecasting model for daily precipitation predictions in Türkiye. They have concluded a correlation outcome of *R*=0.2939. Khosravi et al. (2018) have performed monthly solar irradiance estimations in Iran. They have obtained a correlation result reaching to *R*=0.9999. Liang et al. (2018) have actualized LSTM anticipations of wind speed using data measured at five-minute intervals. The study that was executed in the USA turned a correlation inference of *R*=0.9996. Benmouiza and Cheknane (2019) who carried out ANFIS-FCM hourly solar radiation

predictions in Algeria have obtained a correlation result of $R=0.9742$. Ultimately, Bilgili and Sahin (2010) made a monthly wind speed forecast in Türkiye. They have concluded a correlation outcome of $R=0.9311$. Accordingly, the SWT prediction performance of the current study obtained from Bodrum station that resulted in a value of $R=0.9990$ has been concluded and signified to be generally higher than the literature studies.




Figure 5. The Forecasts on the Actual SWT Data of Bodrum MS

Case Study 3: Results of Alanya MS

The processes tracked for prior Akcakoca and Bodrum MSs are implemented similarly for Alanya MS. Accordingly, for this MS, the statistical evaluation outcomes obtained from the testing processes of the computations are given in Table 3. The outcomes indicated that these utilized models for daily SWT forecasting had a good performance; however, it is also reported to be unfortunately slightly poorer than case studies 1 and 2 in terms of performance. In addition, interesting findings emerged from the statistical comparison parameters. For instance, while LSTM and ANFIS-FCM methods gave superior outcomes depending on the MAPE and MAE statistics; LSTM and ANFIS-SC methods, withal, generated the best outcomes considering the RMSE and R error statistics. Accordingly, the LSTM method gave 1.48% MAPE and 0.3135 °C MAE, in predictions of SWT. Close to these results, the ANFIS-FCM method produced 1.48% MAPE and 0.3123 °C MAE, in SWT forecasts. On the other hand, the LSTM approach generated prediction values on the real data corresponding to 0.4510 °C in terms of the RMSE and 0.9950 in terms of the R . Lastly, ANFIS-SC method had prediction results close to the LSTM outcomes, procured values of 0.4513 °C for the RMSE and 0.9950 for R .

Conversely, distributions of the real and prediction time series at testing stages for Alanya MS are all demonstrated together in Figure 6. In this figure, SWT data clusters for this province were predicted with the same methodology that was also used in the previous two case studies. Besides, the actual measured data of Alanya MS were also provided in this figure to compare the predictational models for Alanya MS and the real data of the station. According to the figure, it is reported that the functions belonging to the SWT forecasting models generally coincided well with the function of the actual counterpart, but the accuracy of the predictions was reported to be slightly lower concerning the previous two MSs. Especially, when the purple colored curve indicating the predictions acquired by GP tool of the ANFIS is carefully analyzed, it is initially observed from the tabulated results that GP tool had generated higher results depending on MAPE, MAE as well as RMSE. Secondly, depending on the statistical accuracy error of the correlation coefficient (R), GP approach gave lower results. Finally, huge deviations from the general trend of real observed SWT data and other predictions occurred for SWT predictions obtained by the GP algorithm. This is especially the situation in the data range of sample day number of 75 to 100, as well as through the end of the considered data samples, such as in the vicinity of 360, as observed from Figure 6. On the other hand, the statistical evaluation parameters presented in Table 3 generally confirm the high success of the overlapping incidents of the predictions on the observed data function, which are shown in Figure 6.

Table 3. Statistical Results of SWT Forecasts for Alanya MS

Model	MAPE (%)	MAE (°C)	RMSE (°C)	R
LSTM	1.48	0.3135	0.4510	0.9950
ANFIS-FCM	1.48	0.3123	0.4540	0.9949
ANFIS-SC	1.49	0.3148	0.4513	0.9950
ANFIS-GP	1.80	0.3752	0.5779	0.9918
ANN	1.51	0.3184	0.4655	0.9947




Figure 6. The Forecasts on the Actual SWT Data of Alanya MS

CONCLUSIONS

In this study, SWT predictions were performed utilizing a variety of algorithms of machine learning and artificial intelligence. Those mainly included LSTM, FCM, SC, GP, and ANN tools. To this end, three MSs in Türkiye were considered, that are named Akçakoca MS, Bodrum MS, and Alanya MS. Later, the generated forecast results that were obtained by these approaches were compared with the actual observed SST values. Accordingly, these comparative analyses were performed by evaluating key statistical parameters including MAPE, MAE, RMSE, as well as R . The detailed analysis revealed that the most accurate forecast results were obtained at Bodrum MS. Specifically, higher correlation coefficient (R) values were obtained simultaneously for this station, especially while recording lower MAPE, MAE and RMSE values, which is generally the case for all implemented models. In comparisons of data clouds, lower values of statistical error outcomes for MAPE, MAE, and RMSE mean higher quality and correspond to less prediction error within the models, while a higher correlation coefficient (R) means a better fit between actual measured and estimated data distributions. In conclusion, it can be concluded that the best estimates were made in data clusters of Bodrum MS. Among the tested methods, ANFIS-FCM approach gave the most suitable and qualified results for Bodrum MS in terms of MAPE (%) and MAE (°C). Simultaneously, for the same station, the LSTM method outperformed the others in terms of RMSE (°C) and coefficient of determination (R). Based on these best outcomes, those two algorithms generated MAPE, MAE, RMSE, and R results of 0.34 %, 0.0765 °C, 0.1585 °C, and 0.9990, respectively for Bodrum MS. The quality and the success of the estimations were slightly lower in other two stations apart from Bodrum including Akçakoca and Alanya. In Akçakoca MS, the best prediction results were obtained by ANFIS-FCM and ANFIS-SC algorithms. Those two gave satisfactory estimation performance that quite approached the actual measured SWT data function. On the other hand, in Alanya MS, interesting results were acquired. Namely, LSTM, ANFIS-FCM, and ANFIS-SC algorithms gave more or less similar results of statistical error parameters. Besides, the prediction capacities of the three approximated the actual data function by almost the same amount. Moreover, when estimated data of three MSs and whole prediction methods are taken into consideration, the best predictions were reported to be obtained by the ANFIS-FCM method, and secondly by the LSTM method. However, in general, it was concluded that methods including LSTM, ANFIS methods, and ANN, all performed very good estimations, and these methods were shown to be quite suitable for use in SWT estimates.

ACKNOWLEDGMENTS

The authors would like to thank to Turkish State Meteorological Service for supplying data on SWT.

REFERENCES

- Alver, A., Baştürk, E., Tulun, Ş., & Şimşek, İ. (2020). Adaptive neuro-fuzzy inference system modeling of 2, 4-dichlorophenol adsorption on wood-based activated carbon. *Environmental Progress and Sustainable Energy*, 39(5). <https://doi.org/10.1002/ep.13413>
- Benmouiza, K., & Cheknane, A. (2019). Clustered ANFIS network using fuzzy c-means, subtractive clustering, and grid partitioning for hourly solar radiation forecasting. *Theoretical and Applied Climatology*, 137, 31–43. <https://doi.org/10.1007/s00704-018-2576-4>
- Bilgili, M. (2010). Prediction of soil temperature using regression and artificial neural network models. *Meteorology and Atmospheric Physics*, 110, 59–70. [10.1007/s00703-010-0104-x](https://doi.org/10.1007/s00703-010-0104-x)
- Bilgili, M. (2023). Time series forecasting on cooling degree-days (CDD) using SARIMA model. *Nat Hazards*, 118(3), 2569–2592. <https://doi.org/10.1007/s11069-023-06109-4>

- Bilgili, M., & Sahin, B. (2010). Comparative analysis of regression and artificial neural network models for wind speed prediction. *Meteorology and Atmospheric Physics*, 109, 61–72. <https://doi.org/10.1007/s00703-010-0093-9>
- Bowles, D. S., Grenney, W. J., & Fread, D. L. (1977). Coupled dynamic streamflow-temperature models. *Journal of the Hydraulics Division*, 103(5), 515–530. <https://doi.org/10.1061/JYCEAJ.0004750>
- Chen, J., Zeng, G. Q., Zhou, W., Du, W., & Lu, K. D. (2018). Wind speed forecasting using nonlinear-learning ensemble of deep learning time series prediction and extremal optimization. *Energy Conversion and Management*, 165, 681–695. <https://doi.org/10.1016/j.enconman.2018.03.098>
- Gooseff, M. N., Strzepek, K., & Chapra, S. C. (2005). Modeling the potential effects of climate change on water temperature downstream of a shallow reservoir, lower madison river, MT. *Climatic Change*, 68(3), 331–353. [10.1007/s10584-005-9076-0](https://doi.org/10.1007/s10584-005-9076-0)
- Gupta, S. M., & Malmgren, B. A. (2009). Comparison of the accuracy of SST estimates by artificial neural networks (ANN) and other quantitative methods using radiolarian data from the Antarctic and Pacific Oceans. *Earth Science India*, 2(2), 52–75.
- Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735–1780. [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735)
- Ilhan, A. (2023). Forecasting of volumetric flow rate of Ergene river using machine learning. *Engineering Applications of Artificial Intelligence*, 121, 105983. <https://doi.org/10.1016/j.engappai.2023.105983>
- Jang, J. S. R. (1993). ANFIS: Adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), 665–685. [10.1109/21.256541](https://doi.org/10.1109/21.256541)
- Kayhan, F. E., Kaymak, G., Tartar, Ş., Akbulut, C., Esmer, H. E., & Ertuğ, N. D. Y. (2015). Effects of global warming on fish and marine ecosystems. *Erciyes University Journal of the Institute of Science and Technology*, 31(3), 128–134. <https://dergipark.org.tr/tr/download/article-file/236029>
- Khosravi, A., Koury, R. N. N., Machado, L., & Pabon, J.J.G. (2018). Prediction of hourly solar radiation in Abu Musa Island using machine learning algorithms. *Journal of Cleaner Production*, 176, 63–75. <https://doi.org/10.1016/j.jclepro.2017.12.065>
- Kisi, O., Genc, O., Dinc, S., & Zounemat-Kermani, M. (2016). Daily pan evaporation modeling using chi-squared automatic interaction detector, neural networks, classification, and regression tree. *Computers and Electronics in Agriculture*, 122, 112–117. <https://doi.org/10.1016/j.compag.2016.01.026>
- Kisi, O., Sanikhani, H., Zounemat-Kermani, M., & Niazi, F. (2015). Long-term monthly evapotranspiration modeling by several data-driven methods without climatic data. *Computers and Electronics in Agriculture*, 115, 66–77. <https://doi.org/10.1016/j.compag.2015.04.015>
- Liang, S., Nguyen, L., & Jin, F. (2018). A Multi-variable stacked long-short term memory network for wind speed forecasting. *2018 IEEE International Conference on Big Data (Big Data)*, Seattle, WA, USA.
- Mahongo, S. B., & Deo, M. C. (2013). Using artificial neural networks to forecast monthly and seasonal sea surface temperature anomalies in the western Indian Ocean. *International Journal of Ocean and Climate Systems*, 4(2), 133–150. <https://doi.org/10.1260/1759-3131.4.2.133>
- Mansouri, I., Ozbakkaloglu, T., Kisi, O., & Xie, T. (2016). Predicting behavior of FRP-confined concrete using neuro fuzzy, neural network, multivariate adaptive regression splines and M5 model tree techniques. *Materials and Structures*, 49, 4319–4334. [10.1617/s11527-015-0790-4](https://doi.org/10.1617/s11527-015-0790-4)
- Mashaly, A. F., & Alazba, A. A. (2017). Membership function comparative investigation on productivity forecasting of solar still using adaptive neuro-fuzzy inference system approach. *Environmental Progress and Sustainable Energy*, 37(1), 249–259. <https://doi.org/10.1002/ep.12664>
- Mathworks. Long short-term memory networks. (2020). <https://www.mathworks.com/help/deeplearning/ug/long-short-term-memory-networks.html>. Accessed 06.10.2024.
- Morse, W. L. (1970). Stream temperature prediction model. *Water Resources Research*, 6(1), 290–302. <https://doi.org/10.1029/WR006i001p00290>

- Patil, K., & Deo, M. C. (2017). Prediction of daily sea surface temperature using efficient neural networks. *Ocean Dynamics*, 67(3-4), 357–368. [10.1007/s10236-017-1032-9](https://doi.org/10.1007/s10236-017-1032-9)
- Reddy, K. Y., & Krishna, K. V. S. G. M. (2023). Vehicular pollution prediction using HWTO-ANFIS model in urban areas of Hyderabad City. *Environmental Progress and Sustainable Energy*, 42(4). <https://doi.org/10.1002/ep.14082>
- Saghafi, H., & Arabloo, M. (2017). Estimation of carbon dioxide equilibrium adsorption isotherms using adaptive neuro-fuzzy inference systems (ANFIS) and regression models. *Environmental Progress and Sustainable Energy*, 36(5), 1374–1382. <https://doi.org/10.1002/ep.12581>
- Sharma, V., Dhanya, J., Gade, M., & Sivasubramonian, J. (2023). New generalized ANN-based hybrid broadband response spectra generator using physics-based simulations. *Natural Hazards*, 116, 1879–1901. <https://doi.org/10.1007/s11069-022-05746-5>
- Sinokrot, B. A., & Stefan, H. G. (1993). Stream temperature dynamics: Measurements and modeling. *Water Resources Research*, 29(7), 2299–2312. <https://doi.org/10.1029/93WR00540>
- Şişman, E. (2019). Trend analysis for the cooling period for sea water temperatures in Aegean and Mediterranean coasts. *Journal of Natural Hazards and Environment*, 5(2), 291–304. <https://doi.org/10.21324/dacd.492730>
- Tangang, F. T., Hsieh, W. W., & Tang, B. (1997). Forecasting the equatorial Pacific sea surface temperatures by neural network models. *Climate Dynamics*, 13, 135–147. [10.1007/s003820050156](https://doi.org/10.1007/s003820050156)
- Tanvir, M. S., & Mujtaba, I. M. (2006). Neural network based correlations for estimating temperature elevation for seawater in MSF desalination process. *Desalination*, 195(1-3), 251–272. <https://doi.org/10.1016/j.desal.2005.11.013>
- Webb, B. W., & Zhang, Y. (1998). Spatial and seasonal variability in the components of the river heat budget. *Hydrological Processes*, 11(1), 79–101. [https://doi.org/10.1002/\(SICI\)1099-1085\(199701\)11:1<79::AID-HYP404>3.0.CO;2-N](https://doi.org/10.1002/(SICI)1099-1085(199701)11:1<79::AID-HYP404>3.0.CO;2-N)
- Wu, A., Hsieh, W. W., & Tang, B. (2006). Neural network forecasts of the tropical Pacific sea surface temperatures. *Neural Networks*, 19(2), 145–154. <https://doi.org/10.1016/j.neunet.2006.01.004>
- Yücel, İ., Önen, A., Yılmaz, & K. K. (2016). Bir taşkın tahmin sisteminin değerlendirilmesi: Nümerik hava tahmin modeli, veri asimilasyonu ve uydu yağışlarının kullanımı. *Dicle University, Engineering Faculty, Journal of Engineering*, 7, 201–216. <https://hdl.handle.net/11511/74347>



Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences



Geliş Tarihi : 07.10.2024
Kabul Tarihi : 02.12.2024

Received Date : 07.10.2024
Accepted Date : 02.12.2024

SAKARYA GEYVE BÖLGESİ DERE SEDİMANLARININ AĞIR METAL İÇERİKLERİ: OLASI ZENGİNLEŞME VE KİRLENME KAYNAKLARI

HEAVY METAL CONTENTS OF STREAM SEDIMENTS IN THE SAKARYA-GEYVE REGION: POTENTIAL ENRICHMENT AND CONTAMINATION SOURCES

Mustafa Haydar TERZİ^{1*} (ORCID: 0000-0003-4224-6482)

Mehmet Barış DURGUN² (ORCID: 0000-0003-3598-1921)

Gökhan DEMİRELA¹ (ORCID: 0000-0001-8260-8914)

¹ Aksaray Üniversitesi Mühendislik Fakültesi Jeoloji Mühendisliği Bölümü, Aksaray, Türkiye

² Maden Tetkik ve Arama Genel Müdürlüğü, Kuzeybatı Anadolu Bölge Müdürlüğü, Balıkesir, Türkiye

*Sorumlu Yazar / Corresponding Author: Mustafa Haydar TERZİ, mhaydarterzi@aksaray.edu.tr

ÖZET

Bu çalışmanın amacı, Türkiye'nin yaş meyve ve sebze üretiminde önemli bir yere sahip olan Geyve (Sakarya) bölgesindeki yerleşim, tarım ve orman alanlarındaki dere sedimanlarının ağır metal içeriklerini analiz etmektir. Böylece bölgede zenginleşme ya da kirlenme anomalisine sahip alanlar tespit edilerek, bu zenginleşmelerin veya kirlenmelerin olası jeojenik ve antropojenik kökenli süreçlerden kaynaklanıp kaynaklanmadığı araştırılmaktadır. Bu kapsamda drenaj sistemlerinden 133 adet dere sedimanı örneği alınmış ve As, Co, Cu, Ni, Pb, V ve Zn içerikleri ICP-OES cihazı kullanılarak belirlenmiştir. Jeobirikim indeksi hesaplamalarına göre dere sedimanı örneklerinde As ve V açısından kirlilik gözlenmezken, Co, Cu, Pb ve Zn açısından kirlenmemiş-orta seviyede, Ni açısından kirlenmemiş-orta seviyeden orta-yüksek seviyeye değişen derecelerde kirlenmelerin varlığı ortaya konulmuştur. Kirlenme derecesi ve modifiye edilmiş kirlenme derecesi indekslerine göre ise bazı örneklerde orta derecede kirlenme belirlenmiştir. Yapılan değerlendirmeler çalışma alanındaki Co ve Ni zenginleşmelerinin serpantin, Pb zenginleşmelerinin granit ve cevherli zonlardan ayrışma ile türediğini ve dolayısıyla jeojenik kökenli olduğunu göstermiştir. Ni açısından bazı örneklerde ek olarak tarımsal faaliyetler sonucunda da ortaya çıkan antropojenik girdilerin varlığı belirlenmiştir. Çalışma alanındaki Cu ve Zn zenginleşmelerinin ise büyük çoğunlukla tarımsal faaliyetler ile ilişkili olarak antropojenik kökenli olarak geliştiği anlaşılmıştır.

Anahtar Kelimeler: Geyve, ağır metal, antropojenik, dere sedimanı, jeojenik

ABSTRACT

The aim of this study is to analyze the heavy metal contents of stream sediments in the residential, agricultural, and forest areas of Geyve (Sakarya) region, which holds a significant place in Türkiye's fresh fruit and vegetable production. The areas with enrichment/contamination anomalies in the region are identified, and it is investigated whether these enrichment or contamination are caused by geogenic or anthropogenic processes. Within this scope, 133 stream sediment samples were collected from drainage systems, and the contents of As, Co, Cu, Ni, Pb, V, and Zn were determined using ICP-OES. Based on the geoaccumulation index, no pollution was observed for As and V, while Co, Cu, Pb, and Zn showed pollution levels ranging from unpolluted to moderate, and Ni exhibited pollution levels ranging from unpolluted-moderate to moderate-high. Some samples exhibit moderate pollution in the degree of contamination and the modified degree of contamination index. The evaluations indicate that Co and Ni enrichments are derived from serpentin, while Pb enrichments from the weathering of granite and ore-bearing zones, suggesting that geogenic origin. In addition, the presence of anthropogenic inputs resulting from agricultural activities was identified in some samples for Ni. The enrichments of Cu and Zn were mostly determined to be anthropogenic origin, primarily associated with agricultural activities.

ToCite: TERZİ, M.H., DURGUN, M.B., & DEMİRELA, G., (2025). SAKARYA GEYVE BÖLGESİ DERE SEDİMANLARININ AĞIR METAL İÇERİKLERİ: OLASI ZENGİNLEŞME VE KİRLENME KAYNAKLARI. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 334-349.

Keywords: Geyve, heavy metal, anthropogenic, stream sediment, geogenic

GİRİŞ

Yeryuvarının oluşumundan itibaren gerçekleşen jeolojik süreçlerin yanında günümüz teknolojik gelişmeleri, sanayileşme, hızlı nüfus artışı, yapılaşma ve plansız kentleşme, tarım alanlarının verimsiz kullanımı, hammaddeye olan talebin günden güne hızla büyümesine bağlı olarak artan madencilik faaliyetleri gibi birçok faktör sonucunda hem jeojenik hem de antropojenik kökenli olarak ortaya çıkabilen ağır metaller ve oluşturdukları kirlilikler çevre ve insanlık için her geçen gün giderek daha ciddi bir sorun haline gelmektedir (Terzi & Kalkan, 2024; Demirela vd., 2020; Ateş vd., 2017; Ravankhah vd., 2017; Esmaceli vd., 2014; Chen vd., 2009). Adsorpsiyon ve iyon değişimi ile ortamda birikebilen ve uzaklaştırılması oldukça zor olan ağır metaller, bitkiler tarafından özümşenerek bitki bünyesine geçer (Çelenk & Kızıloğlu, 2015; Kızıloğlu Algan & Bilen, 2005). Böylece metabolik fonksiyonları ve büyümesi olumsuz etkilenen organizma en nihayetinde ölür. Bu türden ağır metal kontaminasyonuna maruz kalmış bitkilerin tüketilmesiyle hayvan ve insanların bünyesine geçebilen ağır metaller zamanla ciddi sağlık problemlerine neden olabilir (Isleyen vd., 2019; Ok, 2008). Ağır metaller çevresel kalıcılıkları, toksisiteleri ve besin zincirine dahil olma kabiliyetleri nedeniyle önemli çevresel kirleticiler olarak kabul edilirler (Duman vd., 2007). Dolayısıyla besin zincirinin korunmasında oldukça kritik öneme sahip olmakla birlikte ağır metallere kaynak ve hazne görevi gören hava, su, toprak ve sedimanların gelecek nesiller için periyodik olarak dikkatle izlenmesi zorunludur.


Literatürde Sakarya ili ve çevresindeki toprak ve dere sedimanlarında ağır metaller açısından zenginleşme/kirlenme seviyelerini ve potansiyel kirlilik kaynaklarını belirlemeye yönelik yapılmış çeşitli çalışmalar mevcuttur (Durgun vd., 2024a, b, c; Parlak vd., 2020; Isleyen vd., 2019; Çelenk & Kızıloğlu, 2015; Isen vd., 2013; Dundar vd., 2012; Ok, 2008; Duman vd., 2007; Sisman vd., 2002). Ancak bu çalışmaların bir kısmı geniş alanlarda (bölgesel) az sayıdaki örneğin jeokimyasal analiz sonuçlarını kapsamakta, bir kısmı ise son derece sınırlı alanlar (lokal) üzerinde ağır metaller açısından değerlendirmeleri içermektedir. Çelenk ve Kızıloğlu (2015) Sakarya-Erenler'de D-100 karayolu kenarı topraklarındaki Pb birikiminin karayolundan dikey yönde uzaklaştıkça azaldığını ve hâkim rüzgâr yönünün birikim üzerindeki etkisini vurgulamıştır. Duman vd. (2007) Sapanca Gölü'ne ait yüzey sedimanlarında yaz aylarında Cr, Cu, Mn, Ni ve Zn'nun, sonbahar aylarında Cd'un en yüksek seviyelere ulaştığını ve Pb açısından ise mevsimsel olarak bir zenginleşmenin olmadığını ifade etmiştir. Dundar vd. (2012) Aşağı Sakarya Nehri Havzası'na ait sedimanların ağır metal içeriklerini (Cd, Co, Cr, Cu, Fe, Mn, Ni, Pb ve Zn) 10 ay boyunca düzenli dönemlerde 10 farklı istasyonda takip ederek, BCR metodu ile analiz etmiştir. Isen vd. (2013) Sapanca Gölü kuzeyinde D-100 karayolu boyunca toprakların en çok Zn, Pb, Mn, Fe ve Cr elementleri açısından kirlendiğini ve bu kirliliğe araçlardan salınan egzoz gazı emisyonlarının neden olduğunu vurgulamıştır. Ok (2008) ve Isleyen vd. (2019) Geyve bölgesindeki 5 toprak örneğinde polisiklik aromatik hidrokarbonlar ve Cu, Cr, Ni açısından bazı örneklerin belirlenen sınır değerleri aştığını ve ağır metal kirliliği için önlemler alınması gerektiğini belirtmiştir. Sisman vd. (2002) Sapanca Gölü güneyinde Kınalı-Sakarya Karayolu'nun kenarındaki lokasyonlarda her iki ayda bir farklı mesafelerden aldıkları toprak örneklerindeki Ni içeriklerinin dünya standartlarından düşük, Pb birikimlerinin ise kabul edilebilir sınır değerlerinin üzerinde olduğunu ortaya koymuştur. Bu çalışmalar günümüzde canlı yaşamının sağlıklı bir şekilde sürdürülebilmesi için ülkemiz açısından özellikle yaş meyve ve sebze üretiminde önemli bir yere sahip olan Geyve (Sakarya)'de ağır metal içerikleri açısından bir araştırmanın yapılması gerekliliğine işaret etmektedir. Bu doğrultuda yapılan çalışma ile Geyve'nin kuzeydoğusunda yerleşim, tarım ve orman alanlarını kapsayan çalışma alanından derlenen dere sedimanı örneklerine ait ağır metal içeriklerinin (As, Co, Cu, Ni, Pb, V ve Zn) belirlenerek bölgede zenginleşme/kirlenme anomalisi gösteren alanların tespit edilmesi ve bunların oluşum nedenlerinin araştırılması amaçlanmıştır.

MATERYAL VE YÖNTEM

Çalışma Alanının Tanıtılması

Çalışma alanı, Türkiye'nin kuzeybatısında Sakarya ilinin yaklaşık 38 km güneyindeki Geyve ilçesi sınırları içerisinde yer almaktadır (Şekil 1a). İlçenin yüzölçümünün yaklaşık %60'unu ormanlar oluşturmaktadır. Toplam nüfusun %70'i tarımla uğraşmaktadır. 2015 yılında tarla bitkileri üretimi 52.840 ton, sebze bitkileri üretimi 40.264 ton ve meyve üretimi 194.835 ton olmuştur. En çok üretilen tarım ürünleri azalan sırayla, elma, ayva, üzüm, domates, buğday, soğan, kiraz ve şeftalidir (Sakarya İl Tarım ve Orman Müdürlüğü, 2015). Türkiye yaş meyve ve sebze üretiminin yaklaşık %10-15'lik kısmı Geyve bölgesinde üretilmektedir (Isleyen vd., 2019). İlçe merkezinin 12 kilometre kuzeydoğusunda yer alan çalışma alanı, Adapazarı G24c3 ve G24c4 paftalarının içerisinde yaklaşık 46 km²'lik bir

alan kapsamaktadır. Çalışma alanı sınırları içerisindeki yerleşim merkezleri Akkaya, Dereköy, Yayla, Kamışlı, Celaller ve Setçe Mahalleleridir (Şekil 1a ve 1b).



Şekil 1. Çalışma Alanının a. Konumunu, b. Jeoloji Haritasını (Durgun, 2024; Özer vd., 2021) ve c. Örnekleme Noktalarını Gösterir Harita.

Akdeniz ikliminin hâkim olduğu bölgedeki en düşük ortalama sıcaklıklar (4-8 °C) Ocak ayında gerçekleşirken, en yüksek ortalama sıcaklıklara Ağustos ayında (28,6 °C) ulaşılır. Bütün aylar yağışlı olmakla birlikte en çok yağış kış aylarında bölgeye düşer. Yıllık yağış miktarı 565,3 mm'dir. Akdeniz iklimine göre yaz aylarında rastlanan yağış fazlalığı Sakarya vadisi boyunca iç kesimlere sokulan Karadeniz bölgesi iklimiyle ilgilidir (Geyve Belediyesi, 2024). Çalışma alanındaki yükselti genel olarak batıdan doğu-kuzeydoğuya doğru artmaktadır. Önemli yükseltilere Yayla (710 m), Kuşkayası (410 m), Yamaç (1110 m), Avlukaya (970 m), Güney (1010 m), Yellice (1194 m), Yanık (1073 m), Lemse (1227 m), Kızılcapınar (1384 m), Doruk (1087 m), Dümen (747 m), Eğreltili (1319 m) ve Rüzgarlı (946 m) Tepeleri örnek olarak verilebilir. Bölgenin drenaj sistemi içerisinde 160 adet kuru ve 5 adet sulu dere yer alırken, alanın en kuzey batı kesiminden ise Sakarya Nehri geçmektedir (Şekil 1c).

Çalışma Alanının Jeolojisi

Çalışma alanı, Ketin (1966) tarafından tanımlanan Pontidler'in batı kesiminde yer almaktadır. Bölgede Armutlu-Almacık Zonu'na (Pamukova Metamorfileri ve Abant Formasyonu) ve İstanbul Zonu'na (Çaycuma ve Yığılca Formasyonları) ait kayalar yüzylemektedir (Erturaç, 2018). Bölgenin temelini temsil eden Pamukova metamorfileri, çalışma alanında yüzlek vermemekte olup, düşük dereceli metamorfizma izleri taşıyan farklı türde kırıntılı, karbonat ve volkanik kayalardan oluşmaktadır (Çelik vd., 2009). Bu kayalar Paleozoyik yaşlı granitik intrüzyonlar tarafından kesilmektedir (Okay vd., 2008). Bu kayaların üzerine açılacak uyumsuzlukla çalışma alanında oldukça yaygın olarak gözlenen Üst Kampaniyen-Alt Eosen yaşlı Abant Formasyonu gelmektedir (Özer

vd., 2013). Abant Formasyonu, esas olarak konglomera, kumtaşı, çamurtaşı, marn gibi çeşitli sedimanter kayalardan oluşmaktadır. İçerisinde yer yer farklı yaşlarda ve olistostromal filiş karakterinde çok değişik boyutlarda (haritalanabilir ve haritalanamaz ölçekte) ve türde kayaç blokları (granit, serpantinit, kuvarsit, kireçtaşı, konglomera) içermektedir (Göllü, 2019; Erturaç, 2018; Temur & Aksay, 2002; Şekil 1b). Abant Formasyonu, esas olarak sedimanter kayalar ile temsil edilen ve içerisinde yer yer aglomera ve tuf ara seviyelerine de rastlanan Çaycuma Formasyonu tarafından uyumsuz olarak üzerlenmektedir (Şekil 1b). Çalışma alanının güneydoğusunda yüzlek veren Çaycuma Formasyonu konglomera, sarımsı-açık kahverengi renkli kumtaşı, gri renkli silttaşı, sarımsı-bej renkli kiltası, marn ve Nummulites fosilli kireçtaşlarından oluşmaktadır. Fosil içeriği Alt-Orta Eosen'de çökme yaşına işaret etmektedir (Erturaç, 2018). Çalışma alanının kuzeydoğusunda Yanık Tepe çevresinde gözlenen Alt-Orta Eosen yaşlı Yığılca Formasyonu koyu gri-kızılımsı renkli aglomera, tuf ve andezitler ile temsil edilmektedir (Şekil 1b; Göllü, 2019). Birim içerisinde yer yer volkanojenik kumtaşları ve Nummulites fosilli marn ara katmanları da gözlenmektedir (Erturaç, 2018; Özer vd., 2013). Çaycuma Formasyonu ile geçişli bir ilişki sunan Yığılca Formasyonu, yaklaşık 150 metre kalınlığa sahiptir (Temur & Aksay, 2002). Tüm bu kayaç birimleri Kuvaterner yaşlı birbirine tutturulmamış sedimanlar tarafından stratigrafik olarak örtülmektedir.

Örnekleme ve Analizler

Örnekleme çalışmalarına başlamadan önce çalışma alanı içerisindeki drenaj ağı çıkartılmış, derelerin akış yönleri, çatalanmaları, uzunlukları ve durumları (kuru veya sulu) dikkate alınarak dere sedimanı örnekleme noktalarının konumları belirlenmiştir. Bu çalışma kapsamında drenaj sistemlerinden toplam da 133 adet dere sedimanı örneği alınmıştır (Şekil 1c). Her örnek noktasında el tipi GPS yardımıyla koordinatlar alınmış, dere yatağının memba ve mansap kısımları fotoğraflanmış, jeolojik açıklamalar ve varsa olası antropojenik girdi sağlayacak kaynakların (yerleşim, yol, tarımsal alan vb) detayları not edilmiştir. Sahadan kürekler yardımıyla alınan örnekler plastik poşetlere konularak DS kodu ile etiketlenmiş, kirlenme koşullarına dikkat edilerek temiz bir ortamda kurutulmuş ve 77 mikron (200 mesh) boyutlu paslanmaz çelik elekten elendikten sonra öğütülerek toz haline getirilmiştir. Örneklerin jeokimyasal analizleri Maden Tetkik ve Arama Genel Müdürlüğü Maden Analizleri ve Teknoloji Dairesi Başkanlığı Laboratuvarlarında modifiye edilmiş kral suyunda çözme işlemi uygulandıktan sonra İndüktif Eşleşmiş Plazma Atomik Emisyon Spektroskopisi (ICP-OES) cihazı kullanılarak gerçekleştirilmiştir. Dere sedimanı örnekleri As, Co, Cu, Ni, Pb, V ve Zn olmak üzere 7 ağır metal için analiz edilmiştir. Cihazın dedeksiyon limitleri As ve Cu için 3 ppm, Co, Ni, Pb ve V için 5 ppm ve Zn için 2 ppm olarak raporlanmıştır. Dedeksiyon limitlerinin altında kalan değerler daha sonraki hesaplamalarda ve değerlendirmelerde kullanılmak amacıyla yarıya bölünmüştür.

İndeks Hesaplamaları

Dere sedimanı örneklerinin ağır metaller açısından zenginleşme/kirlenme seviyelerini belirlemek ve bunların oluşturmuş olabileceği ekolojik riski değerlendirmek amacıyla çeşitli kirlilik indeks hesaplama sistemleri literatürde yaygın olarak kullanılmaktadır (Gopal vd., 2024; Durgun vd., 2024a, b, c; Terzi & Kalkan, 2024; Bai vd., 2023; Kalkan & Terzi, 2023; Ochiagha vd., 2020; Özkul vd., 2018; Ravankhah vd., 2017; Esmaeili vd., 2014; Stoffers vd., 1986). Bu indeks sistemleri ilgili örneğin jeokimyasal özelliklerinden yararlanarak çok sayıda ağır metale ait verileri kullanarak tekil bir sonuç değeri hesaplamakta ve kendi sınıflandırma sistemleri yardımıyla ekolojik değerlendirme yapılmasına olanak sağlamaktadır (Yılmaz & Terzi, 2023). Bu çalışmada, dere sedimanı örneklerine ait ağır metallerin kirlilik riski seviyelerini değerlendirmek amacıyla jeobirikim (Igeo; Müller, 1969), kirlenme derecesi (C_d ; Hakanson, 1980), modifiye edilmiş kirlenme derecesi (mC_d ; Abraham & Parker, 2008), ekolojik toprak kirlilik indeksi (ESPI; Yılmaz & Terzi, 2023) ve kirlilik yük indeksi (PLI; Tomlinson vd., 1980) olmak üzere beş farklı indeks hesaplama sistemi kullanılmıştır. Kirlilik indekslerinin hesaplama formülleri ve sınıflandırma sistemleri Tablo 1'de verilmiştir. Her indeks hesaplaması sırasında değerlendirmesi yapılan ilgili ağır metale karşılık gelen ve kirlenmemiş veya bozulmamış özellikler ile temsil edilen bir jeolojik referans değerine (üst kıta kabuğu, alt kıta kabuğu, şeyl vb.) ihtiyaç duyulur. Bu çalışma kapsamında yapılan hesaplamalarda yerkabuğunun en üst seviyesini temsil eden, ince tane boyutları bakımından zengin olan ve herhangi bir kirlilik göstermeyen (sanayileşme öncesi değerleri temsil eden) ortalama şeyl değeri kullanılmıştır (Terzi & Kalkan, 2024; Kalkan & Terzi, 2023; Şener & Şener, 2015; Abraham & Parker, 2008; Reimann & Caritat, 1998; Koljonen, 1992). Ortalama şeyl değeri As için 13 ppm, Co için 20 ppm, Cu için 45 ppm, Ni için 70 ppm, Pb için 22 ppm, V için 130 ppm ve Zn için 100 ppm'dir (Reimann & Caritat, 1998; Koljonen, 1992).

Igeo indeksi, jeojenik ve antropojenik etkilerin ağır metal içeriğini jeolojik referans değere göre nasıl etkilediğini değerlendirir. Formülündeki 1,5 katsayısı litolojik değişimlere (Gopal vd., 2024; Abraham & Parker, 2008; Stoffers vd., 1986) veya antropojenik aktivitelere (Bai vd. 2023; Kalkan & Terzi, 2023; Ochiagha vd. 2020) atfedilebilir. Formülündeki C_n/B_n oranı, örnekte ölçülen ağır metalin karşılık gelen referans değerine bölünmesini ifade eder.

Igeo, ağır metal kirlilik seviyelerini kirlenmemişten çok yükseğe kadar olmak üzere yedi sınıfta değerlendirir (Tablo 1; Abraham & Parker, 2008; Müller, 1969). C_d indeksi, ağır metal içeriklerini düşükten çok yükseğe kadar değişen dört kategoride sınıflandırarak değerlendirir. C_d ilgili örnekteki her ağır metal içeriğinin sanayi öncesi referans değerine bölünmesiyle elde edilen kirlilik faktörünün (C_f^i) toplanmasıyla hesaplanır (Tablo 1; Hakanson, 1980). C_d indeksi Abraham ve Parker (2008) tarafından mC_d olarak yeni bir hesaplama ve sınıflandırma sistemine dönüştürülmüştür. Bu indeks sisteminde C_d 'den farklı olarak tüm ağır metaller için hesaplanan C_f^i değerlerinin toplamı, analiz edilen ve hesaplamalara katılan ağır metal sayısına (n) bölünür. mC_d kirlenmemiş-çok düşükten ultra yükseğe kadar değişen yedi sınıfta kirlilik seviyesini değerlendirir (Tablo 1; Abraham ve Parker, 2008). AHP tabanlı bir indeks sistemi olan ESPI, örnekteki çok sayıda ağır metal değerini hesaplamaya dâhil ederek tek bir indeks skoru

Tablo 1. Kirlilik İndekslerine ait Hesaplama Formülleri ve Sınıflandırma Sistemleri

İndeks	Denklemler	Aralık	Kirlilik Sınıfı	Kaynak
Igeo	$Igeo = \log_2 (C_n / (1.5 \times B_n))$	≤ 0	Kirlenmemiş	[1, 2]
	C _n : Ağır metal konsantrasyonu	0-1	Kirlenmemiş-orta	
	B _n : İlgili ağır metalin referans değeri	1-2	Orta	
		2-3	Orta-yüksek	
		3-4	Yüksek	
		4-5	Yüksek-çok yüksek	
		>5	Çok yüksek	
C_d	$C_d = \sum C_f^i$	<8	Düşük	[3]
	$C_f^i = (C_{0-1}^i / C_n^i)$	8-16	Orta	
	C_f^i : Kirlilik faktörü	16-32	Yüksek	
	C_{0-1}^i : Ağır metal konsantrasyonu	≥ 32	Çok yüksek	
	C_n^i : İlgili ağır metalin referans değeri			
mC_d	$mC_d = \sum C_f^i / n$	<1.5	Kirlenmemiş- çok düşük	[2]
	C_f^i : Kirlilik faktörü	1.5-2	Düşük	
	n: Analiz edilen ağır metal sayısı	2-4	Orta	
	i: i. ağır metal	4-8	Yüksek	
		8-16	Çok yüksek	
		16-32	Oldukça yüksek	
		≥ 32	Ultra yüksek	
ESPI	$ESPI = \sum W_m * P_{fi}$	<1	Kirlenmemiş	[4]
	$P_{fi} = (M_i / S_{vm}) * (M_i / (\sum M_n))$	1-3	Düşük	
	W_m : M ağır metalinin ağırlık değeri; bu çalışma da 1 olarak kullanılmıştır.	3-5	Orta	
	P_{fi} : i alternatifi için kirlilik faktörü	>5	Yüksek	
	M_i : i alternatifi için M ağır metalinin değeri			
	S_{vm} : İlgili ağır metalin referans değeri			
	M_n : M ağır metali değerlerinin toplamı			
n: Ağır metal sayısı				
m: Herhangi bir ağır metal				
PLI	$PLI = \sqrt[n]{(CF_1 \times CF_2 \times CF_3 \times \dots \times CF_n)}$	<1	Kirlilik yok	[5]
	$CF = C_{\text{ağır metal değeri}} / C_{\text{referans değeri}}$	>1	Kirlilik var	
	CF: Kirlilik faktörü			
	n: Kirlilik faktörlerinin sayısı			

[1]: Müller (1969); [2]: Abraham ve Parker (2008); [3]: Hakanson (1980); [4]: Yılmaz ve Terzi (2023); [5]: Tomlinson vd. (1980)

hesaplar. Kirlilik seviyesini ise kirlenmemişten yükseğe kadar değişen dört sınıfta değerlendirir (Tablo 1; Yılmaz & Terzi, 2023). PLI, ilk olarak örnekteki bir ağır metal içeriğini o ağır metal için referans değerine oranı olan kirlilik faktörünü (CF) hesaplar. Daha sonra n sayıda CF'nin birbiriyle çarpılmasıyla elde edilen değer, hesaplamada kullanılan ve toplam ağır metal sayısını temsil eden sayısal değere göre kökü alınır. Sonuçta üretilen PLI değeri 1'in üzerindeyse, çalışılan yerin sedimanının kirliliği, 1'in altındaysa kirlenmemiş olduğu kabul edilir (Tablo 1; Özkul vd., 2018; Tomlinson vd., 1980).

BULGULAR VE TARTIŞMA

Jeokimya

Çalışma alanından derlenen 133 adet dere sedimanı örneğinin ağır metal içeriklerine ait tanımlayıcı istatistiksel bilgiler Tablo 2'de sunulmaktadır. Buna göre As 1,5 ile 9 ppm, Co 2,5 ile 51 ppm, Cu 9 ile 106 ppm, Ni 10 ile 750 ppm, Pb 2,5 ile 37 ppm, V 9 ile 61 ppm ve Zn 5 ile 170 ppm arasında değerlere sahiptir. Dere sedimanı örnekleri ortalama olarak ise 3,5 ppm As, 14,4 ppm Co, 25,8 ppm Cu, 134,5 ppm Ni, 8,1 ppm Pb, 31,5 ppm V ve 46,9 ppm Zn içermektedir. Dere sedimanı örneklerine ait ağır metal içerikleri, üst kıtasal kabuk (Wedepohl, 1995), şeyl ve dünya toprak (Reimann & Caritat, 1998; Koljonen, 1992) ortalama değerleri ile karşılaştırılmıştır (Şekil 2). Bazı dere sedimanı örnekleri As içerikleri açısından üst kıtasal kabuk ve dünya toprak, V içerikleri üst kıtasal kabuk, Co, Cu, Ni, Pb ve Zn açısından üst kıtasal kabuk, şeyl ve dünya toprak ortalama değerlerine göre zenginleşme göstermektedir (Şekil 3).

Dere sedimanı örneklerinin tamamı As açısından şeyl ortalama değerinin (13 ppm) altında değerlere sahip iken, 29 adet örnek dünya toprak (5 ppm) ve 69 adet örnek üst kıtasal kabuk ortalama değerine (2 ppm) göre daha yüksek değerlere sahiptir (Şekil 2). Örnekler içerisindeki en yüksek As içeriği (DS-30, 87, 97, 102 ve 128: 9 ppm) sırasıyla üst kıtasal kabuk ve dünya toprak ortalama değerlerine göre yaklaşık 4,5 ve 1,8 kat zenginleşme göstermiştir. Dünya toprak ortalama değerine göre zenginleşen örnekler çalışma alanının özellikle orta-batı kesiminde yoğunlaşmaktadır. Yayla ve Dereköy mahallelerinin çevresindeki örnekler Abant Formasyonu ve granit birimleri ile ilişkili gözlenirken, Kamışlı Mahallesi doğru daha doğudaki örnekler Abant Formasyonu, Celaller Mahallesi güneybatısındaki örnekler ise Çaycuma Formasyonu ile ilişkili gözlenmektedir (Şekil 3a ve 3h). Dere sediman örneklerinden 13 adedi Ok (2008) ve Isleyen vd. (2019)'nin Geyve kuzey-kuzeydoğusundan aldığı topraklara ait en yüksek değerlerin biraz üzerinde As değerlerine sahip iken, geri kalan örnekler ise benzer değer aralıkları sergilemektedir (Tablo 3).


Co açısından dere sedimanı örneklerinden 16 adedi şeyl (20 ppm), 94 adedi üst kıtasal kabuk (11,6 ppm) ve 104 adedi dünya toprak ortalama değerine (10 ppm) göre daha yüksek değerlere sahiptir (Şekil 2). Örnekler içerisindeki en yüksek Co içeriği (DS-42: 51 ppm) sırasıyla üst kıtasal kabuk, şeyl ve dünya toprak ortalama değerlerine göre yaklaşık 4,4, 2,6 ve 5,1 kat zenginleşme göstermiştir. Şeyl ortalama değerlerine göre zenginleşen örnekler çalışma alanında Yayla Mahallesi-Yamaç Tepe güneydoğusunda Abant Formasyonu, Celaller Mahallesi kuzeydoğusu-Rüzgârlı Tepe kuzeybatısında Abant Formasyonu ve serpantin birimlerine karşılık gelmektedir (Şekil 3b ve 3h). Çalışma alanındaki dere sedimanı örneklerinin 11 adedi Isen vd. (2013) tarafından Sapanca Gölü kuzeyindeki D-100 karayolu kenarından alınan topraklar ile Dundar vd. (2012) tarafından Sakarya Nehri kuzey bölümünden alınan sedimanlara ait Co içeriklerine kıyasla daha yüksek değerlere sahiptir (Tablo 3).

Cu açısından dere sedimanı örneklerinden 9 adedi şeyl (45 ppm), 47 adedi dünya toprak (25 ppm) ve 123 adedi üst kıtasal kabuk ortalama değerine (14,3 ppm) göre daha yüksek değerlere sahiptir (Şekil 2). Örnekler içerisindeki en yüksek Cu içeriği (DS-86: 106 ppm) sırasıyla üst kıtasal kabuk, şeyl ve dünya toprak ortalama değerlerine göre yaklaşık 7,4, 2,4 ve 4,2 kat zenginleşme göstermiştir. Şeyl ortalama değerlerine göre zenginleşen örnekler çalışma alanında Yayla ve Dereköy mahallelerinin çevresinde Abant Formasyonu ve granit birimleri, Kamışlı Mahallesi doğru daha doğuda Abant Formasyonu ve kireçtaşı birimleri ile ilişkili gözlenmektedir (Şekil 3c ve 3h). Bazı dere sedimanı örneklerinin Cu içerikleri, Sapanca Gölü (Duman vd., 2007) ve Sakarya Nehri sedimanları (Dundar vd., 2012) ile Isen vd. (2013)'nin bölge toprakları için belirttiği Cu değerlerinden yüksektir (Tablo 3). Bununla birlikte örneklerin Cu içerikleri, Geyve kuzey-kuzeydoğusunda alınan toprakların bakır içerikleri ile de büyük ölçüde uyumludur (Tablo 3; Isleyen vd., 2019; Ok, 2008).

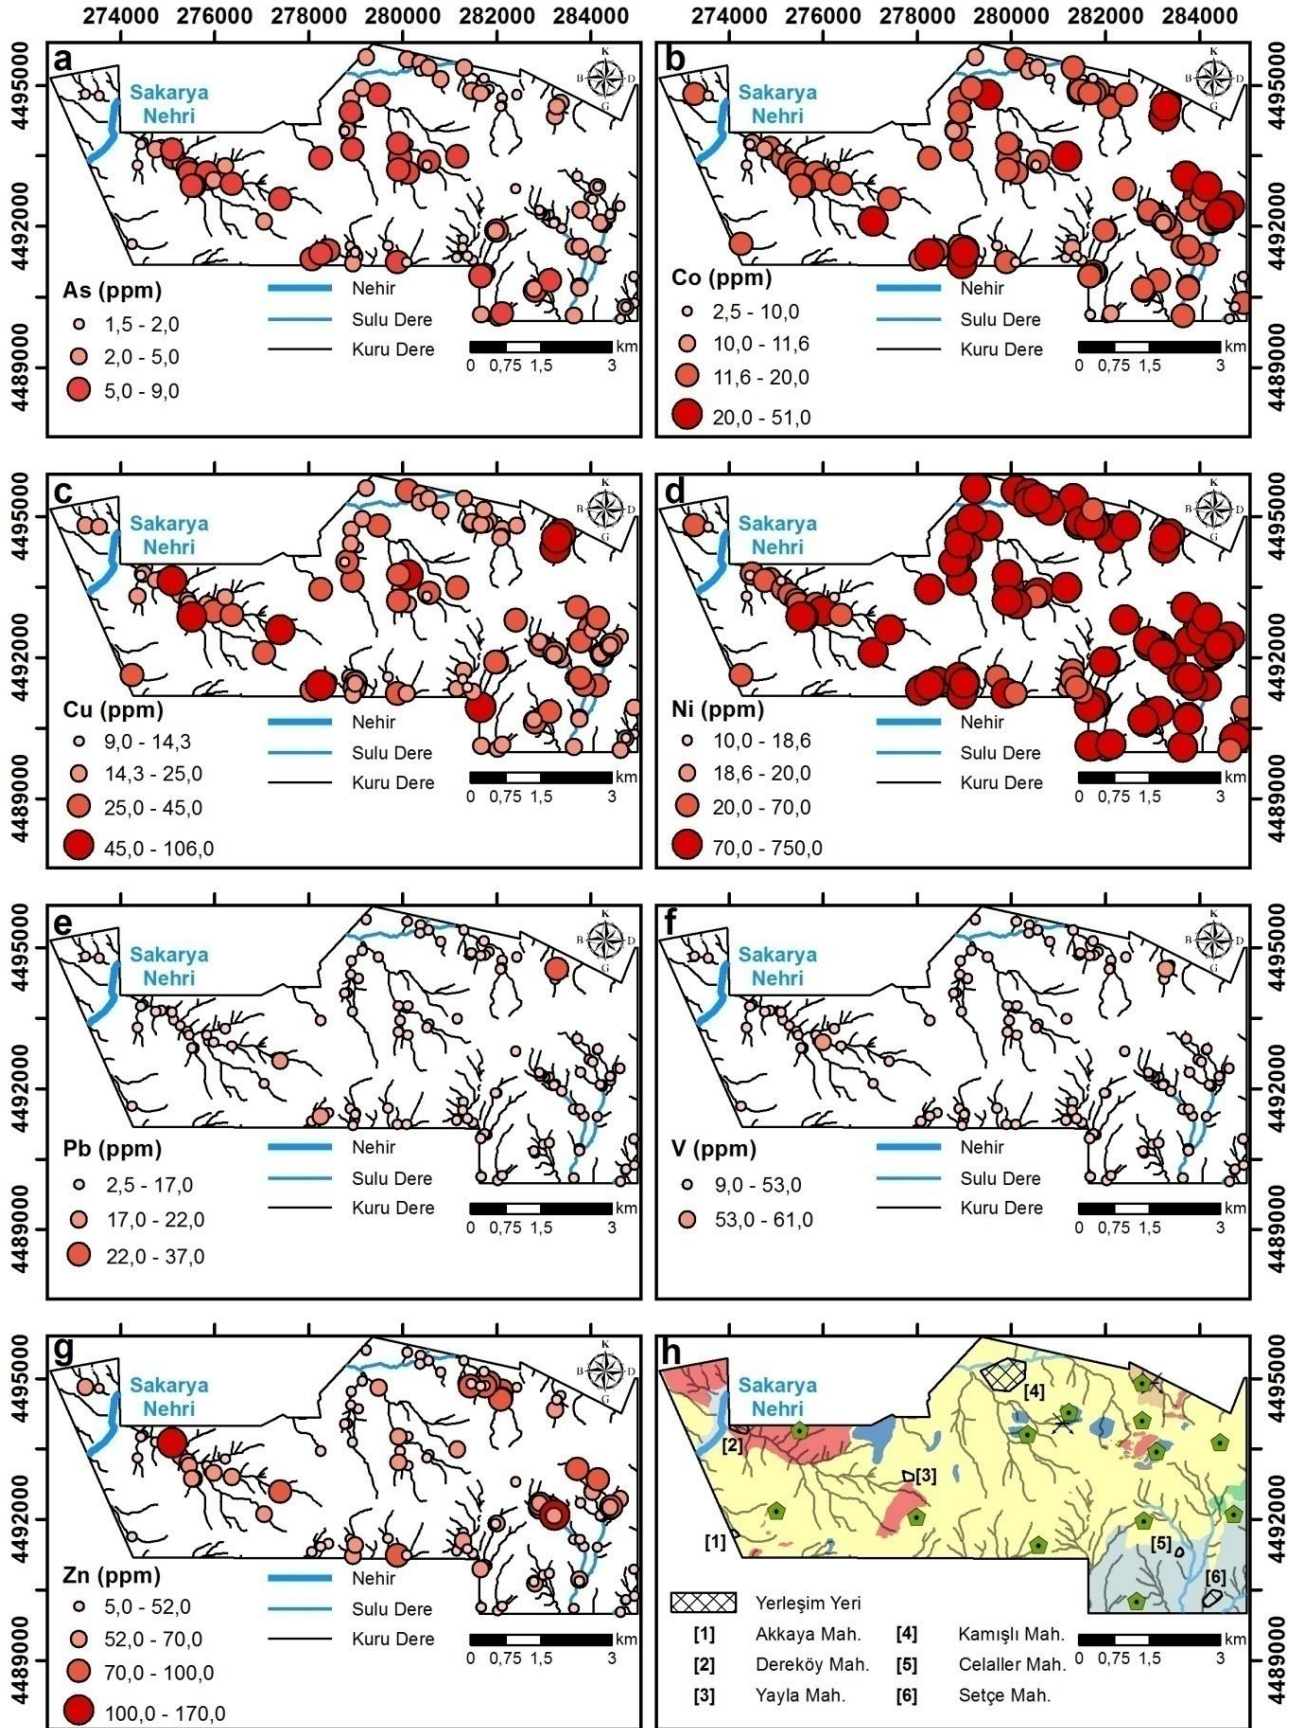
Ni açısından dere sedimanı örneklerinden 99 adedi şeyl (70 ppm), 125 adedi dünya toprak (20 ppm) ve 126 adedi üst kıtasal kabuk ortalama değerine (18,6 ppm) göre daha yüksek değerlere sahiptir (Şekil 2). Örnekler içerisindeki en yüksek Ni içeriği (DS-42: 750 ppm) sırasıyla üst kıtasal kabuk, şeyl ve dünya toprak ortalama değerlerine göre

Tablo 2. Dere Sedimanı Örneklerinin Jeokimyasal Analiz Sonuçlarına ait Tanımlayıcı İstatistikler ve Jeolojik Referans Değerler

	As	Co	Cu	Ni	Pb	V	Zn	Kaynak
	ppm	ppm	ppm	ppm	ppm	ppm	ppm	
Minimum	1,5	2,5	9,0	10,0	2,5	9,0	5,0	Bu Çalışma
Maksimum	9,0	51,0	106,0	750,0	37,0	61,0	170,0	
Ortalama	3,5	14,4	25,8	134,5	8,1	31,5	46,9	
Standart Sapma	2,23	5,95	13,18	95,83	5,16	10,28	21,76	
Çarpıklık	0,64	1,82	2,78	2,48	1,44	0,31	1,63	
Basıklık	-0,66	9,98	11,66	12,29	6,01	-0,25	6,61	
Örnek Sayısı	133							
Üst Kıtasal Kabuk	2	11,6	14,3	18,6	17	53	52	Wedepohl (1995)
Şeyl	13	20	45	70	22	130	100	Koljonen (1992);
Dünya Toprak	5	10	25	20	17	90	70	Reimann ve Caritat (1998)

**Şekil 2.** Dere Sedimanı Örneklerine ait Ağır Metal İçeriklerinin Üst Kıtasal Kabuk (Wedepohl, 1995), Şeyl ve Dünya Toprak (Reimann & Caritat, 1998; Koljonen, 1992) Ortalama Değerleri ile Karşılaştırılması

yaklaşık 40,3, 10,7 ve 37,5 kat zenginleşme göstermiştir. Şeyl ortalama değerlerine göre Ni açısından zenginleşen örnekler çalışma alanında Abant Formasyonu ile ilişkili olarak geniş bir yayılım göstermektedir. Bununla birlikte en yüksek Ni değerleri Rüzgârlı Tepe civarında mostra veren serpantinit birimlerinin içerisinde elde edilmiştir. Bunların yanında çalışma alanının güneydoğusuna doğru Çaycuma Formasyonu üzerinde gözlenen yüksek Ni değerlerinin daha kuzeyde akarsu drenaj sisteminin içerisinde geçtiği Abant Formasyonu ve serpantinit birimlerinden kaynaklandığı düşünülmektedir (Şekil 3d ve 3h). Çalışma alanındaki dere sedimanı örneklerinin 17 adedindeki Ni içerikleri, literatürde Sakarya çevresindeki toprak ve sediman örneklerine ait raporlanan en yüksek Ni içeriklerinden (Isleyen vd., 2019; Ok, 2008) oldukça yüksek değerlere sahiptir (Tablo 3).



Şekil 3. Dere Sedimanı Örneklerine ait Ağır Metal İçeriklerinin Mekânsal Dağılım Haritaları: a. As, b. Co, c. Cu, d. Ni, e. Pb, f. V ve g. Zn (Ağır Metallerle ilgili Sınıf Aralıkları, Üst Kıtasal Kabuk, Şeyl ve Dünya Toprak Ortalama Değerlerine Göre Belirlenmiştir), h. Çalışma Alanının Jeoloji Haritası (Lejant için Şekil 1'e Bakınız)

Tablo 3. Bu Çalışmaya ait Analiz Sonuçları ile Literatürde Sakarya İli Çevresinde Yapılan Araştırmalara ait Ağır Metal İçerik Sonuçlarının Karşılaştırılması

Lokasyon (Örnek Türü) [Kaynak]	As	Co	Cu	Ni	Pb	V	Zn
	ppm	ppm	ppm	ppm	ppm	ppm	ppm
Geyve Kuzeydoğusu (Sediman) [1]	1,5-9,0	2,5-51	9-106	10-750	2,5-37	9-61	5-170
Sapanca Gölü (Sediman) [2]	-	-	17,28-35,51	20,10-34,31	12,94-17,80	-	39,02-75,31
Geyve Kuzey-Kuzeydoğusu (Toprak) [3]	3,24-6,62	-	24,52-108,18	89,06-219,88	3,95-21,10	-	54,95-149,58
Sakarya Nehri (Sediman) [4]	-	21,21	37,54	82,96	41,31	-	76,67
Sapanca Gölü Kuzeyi (Toprak) [5]	-	21,92	69,42	47,70	227,60	20,72	229,07
Sapanca Gölü Güneyi (Toprak) [6]	-	-	-	0-58,67	0-47,54	-	-

[1]: Bu Çalışma; [2]: Duman vd. (2007); [3]: Ok (2008); Isleyen vd. (2019); [4]: Dundar vd. (2012); [5]: Isen vd. (2013); [6]: Sisman vd. (2002)

Pb açısından dere sedimanı örneklerinden 1 adedi şeyl (22 ppm), 3 adedi ise üst kıtasal kabuk ve dünya toprak ortalama değerlerine (17 ppm) göre daha yüksek değerlere sahiptir (Şekil 2). Örnekler içerisindeki en yüksek Pb içeriği (DS-17: 37 ppm) sırasıyla şeyl ve üst kıtasal kabuk-dünya toprak ortalama değerlerine göre yaklaşık 1,7 ve 2,2 kat zenginleşme göstermiştir. Şeyl ortalama değerine göre en yüksek Pb içeren örnek çalışma alanının kuzeydoğusunda Yanık Tepe'nin güneydoğusunda Cu-Pb-Zn içeren cevherli zuhurlara yakın bir lokasyonda Abant Formasyonu ve granitlerin içerisinde geçtiği drenaj sisteminden alınmıştır. Üst kıtasal kabuk ve dünya toprak ortalama değerlerine göre daha yüksek olan iki örnek (DS-97 ve 130) ise benzer litolojik ilişkilerle birlikte Yayla Mahallesi-Yamaç Tepe çevresinde bulunmaktadır (Şekil 3e ve 3h). Dere sedimanı örneklerinin Pb içerikleri literatürdeki bazı toprak ve dere sedimanı içerikleriyle büyük ölçüde uyumlu olup (Duman vd., 2007; Ok, 2008; Isleyen vd., 2019), Dundar vd. (2012) ve Sisman vd. (2002)'nin sediman ve toprak örneklerinde rapor ettiği değerlere göre nispeten biraz daha düşük, ancak Isen vd. (2013)'nin karayolu kenarından alınan topraklara ait Pb içeriklerinden ise önemli ölçüde daha düşük değerlere sahiptir (Tablo 3).

Dere sedimanı örneklerinin tamamı V içerikleri açısından şeyl (130 ppm) ve dünya toprak (90 ppm) ortalama değerlerinin altında değerlere sahip iken, 2 adet örnek (DS-17 ve 125) üst kıtasal kabuk ortalama değerine (53 ppm) göre daha yüksek değerlere sahiptir (Şekil 2). Örnekler içerisindeki en yüksek V içeriğine sahip örnek (DS-125: 61 ppm) üst kıtasal kabuk ortalama değerine göre yaklaşık 1,2 kat zenginleşme göstermiştir. Bahse konu olan iki örnek çalışma alanında birbirlerinden farklı lokasyonlarda Abant Formasyonu ve granitlerin içerisinde geçtiği drenaj sisteminden alınmıştır (Şekil 3f ve 3h). Bunlara ek olarak dere sedimanı örneklerinden 116 adedi Isen vd. (2013)'nin topraklarına ait V değerinin üzerinde değerlere sahiptir (Tablo 3).

Zn açısından dere sedimanı örneklerinden 2 adedi şeyl (100 ppm), 17 adedi dünya toprak (70 ppm) ve 46 adedi üst kıtasal kabuk ortalama değerine (52 ppm) göre daha yüksek değerlere sahiptir. Örnekler içerisindeki en yüksek Zn içeriğine sahip örnek (DS-128: 170 ppm) sırasıyla üst kıtasal kabuk, şeyl ve dünya toprak ortalama değerlerine göre yaklaşık 3,3, 1,7 ve 2,4 kat zenginleşme göstermiştir. Şeyl ortalama değerine göre 2 örnekte (DS-55 ve 128) gözlenen en yüksek Zn içerikleri çalışma alanında birbirlerinden farklı lokasyonlarda Abant Formasyonu ve granitlerin içerisinde geçtiği drenaj sisteminden alınmıştır. Bununla birlikte dünya toprak ortalama değerine göre zenginleşen örnekler ise benzer litolojik-drenaj ilişkisinde özellikle çalışma alanının batısı ve doğu-kuzeydoğusunda bulunmaktadır (Şekil 3g ve 3h). Dere sedimanı örneklerinin Zn içerikleri literatürdeki bazı toprak ve dere sedimanı içerikleriyle büyük ölçüde uyumlu iken (Isleyen vd., 2019; Dundar vd., 2012; Ok, 2008; Duman vd., 2007), Isen vd. (2013)'nin karayolu kenarından alınan topraklara ait Zn içeriklerinden önemli ölçüde daha küçük değerlere sahiptir (Tablo 3).

Igeo İndeksi


Çalışma alanından derlenen 133 adet dere sedimanı örneğinin ağır metal içerikleri baz alınarak hesaplanan Igeo indeks sonuçlarına ait tanımlayıcı istatistiksel bilgiler Tablo 4'de sunulmaktadır. Igeo hesaplamalarının sonuçları As için -3,7 ile -1,1, Co için -3,6 ile 0,8, Cu için -2,9 ile 0,7, Ni için -3,4 ile 2,8, Pb için -3,7 ile 0,2, V için -4,4 ile -1,7

ve Zn için -4,9 ile 0,2 arasında değişmektedir. Igeo indeks sınıflarına göre dere sedimanı örnekleri As ve V açısından kirlilik göstermemektedir (Tablo 1; Şekil 4).

Igeo'ya göre Co açısından 1 örnek (DS-42) kirlenmemiş-orta derecede kirlenmiş sınıfında yer alırken, aynı zamanda nikel açısından orta-yüksek derecede kirlenmeye sahiptir. Bu örnek çalışma alanında Celaller Mahallesi kuzeydoğusu-Rüzgârlı Tepe kuzeybatısında Abant Formasyonuna ait sedimanter ve 1 metreye kadar blok boyutlarına ulaşan serpantinitle ait kayaların gözlemlendiği dereden alınmıştır (Şekil 5a ve 5h). Örnek lokasyonu çevresinde antropojenik girdileri sağlayacak unsurların olmayışı ve Co'nun yanında Ni kirliliğinin varlığı, gerçekleşen zenginleşmelerin serpantinitle ilişkili olarak jeojenik kökenli olduğunu düşündürmektedir.

Tablo 4. Dere Sedimanı Örneklerinin Igeo İndeks Hesaplamalarına ait Tanımlayıcı İstatistikler

	Igeo As	Igeo Co	Igeo Cu	Igeo Ni	Igeo Pb	Igeo V	Igeo Zn
Minimum	-3,7	-3,6	-2,9	-3,4	-3,7	-4,4	-4,9
Maksimum	-1,1	0,8	0,7	2,8	0,2	-1,7	0,2
Ortalama	-2,8	-1,2	-1,5	0,0	-2,3	-2,7	-1,8
Standart Sapma	0,95	0,66	0,59	1,14	1,02	0,51	0,69
Çarpıklık	0,15	-1,28	0,69	-0,89	-0,31	-0,60	-0,73
Basıklık	-1,70	3,99	1,41	1,01	-1,22	0,40	2,68
Örnek Sayısı	133						



Şekil 4. Dere Sedimanı Örneklerinin Igeo Sınıfları

Igeo Cu sonuçları 2 örnek (DS-86 ve DS-130) için kirlenmemiş-orta derecede kirlenme gösterirken, bu örneklerden DS-130 aynı zamanda Ni açısından kirlenmemiş-orta derecede kirlenmeye de sahiptir. DS-86 numaralı örnek Kamışlı Mahallesi güneyinde-Avlukaya Tepe batısındaki Abant Formasyonuna ait sedimanter ve kireçtaşı mostralının gözlemlendiği dere içerisinde alınmıştır. DS-130 numaralı örnek ise Yayla Mahallesi güneybatısında Abant Formasyonu ve granit birimleri içerisinde geçen dere yatağından alınmış olup, örnek lokasyonunun yakın çevresinde evsel ve tarımsal faaliyetler sürdürülmektedir (Şekil 5b ve 5h). Dolayısıyla DS-130 numaralı örnek lokasyonunda ortaya çıkan Cu zenginleşmesi, evsel atıklar ve çevredeki tarım alanlarında kullanılan bakırlı tarım ilaçları ile fosforlu gübrelerden ve/veya bakır katkılı yem ile beslenen hayvanların dışkılarının ortama bırakılması sonucu olmuş olabilir (Ok, 2008; Duman vd., 2007). Bununla birlikte organik ve inorganik materyaller ile kirlenen Sakarya Nehri'nin tarımsal sulama da kullanımı da yüksek Cu seviyeleri ile sonuçlanabilir ve bu da Cu içeriklerini arttırmış olabilir (Isleyen vd., 2019).

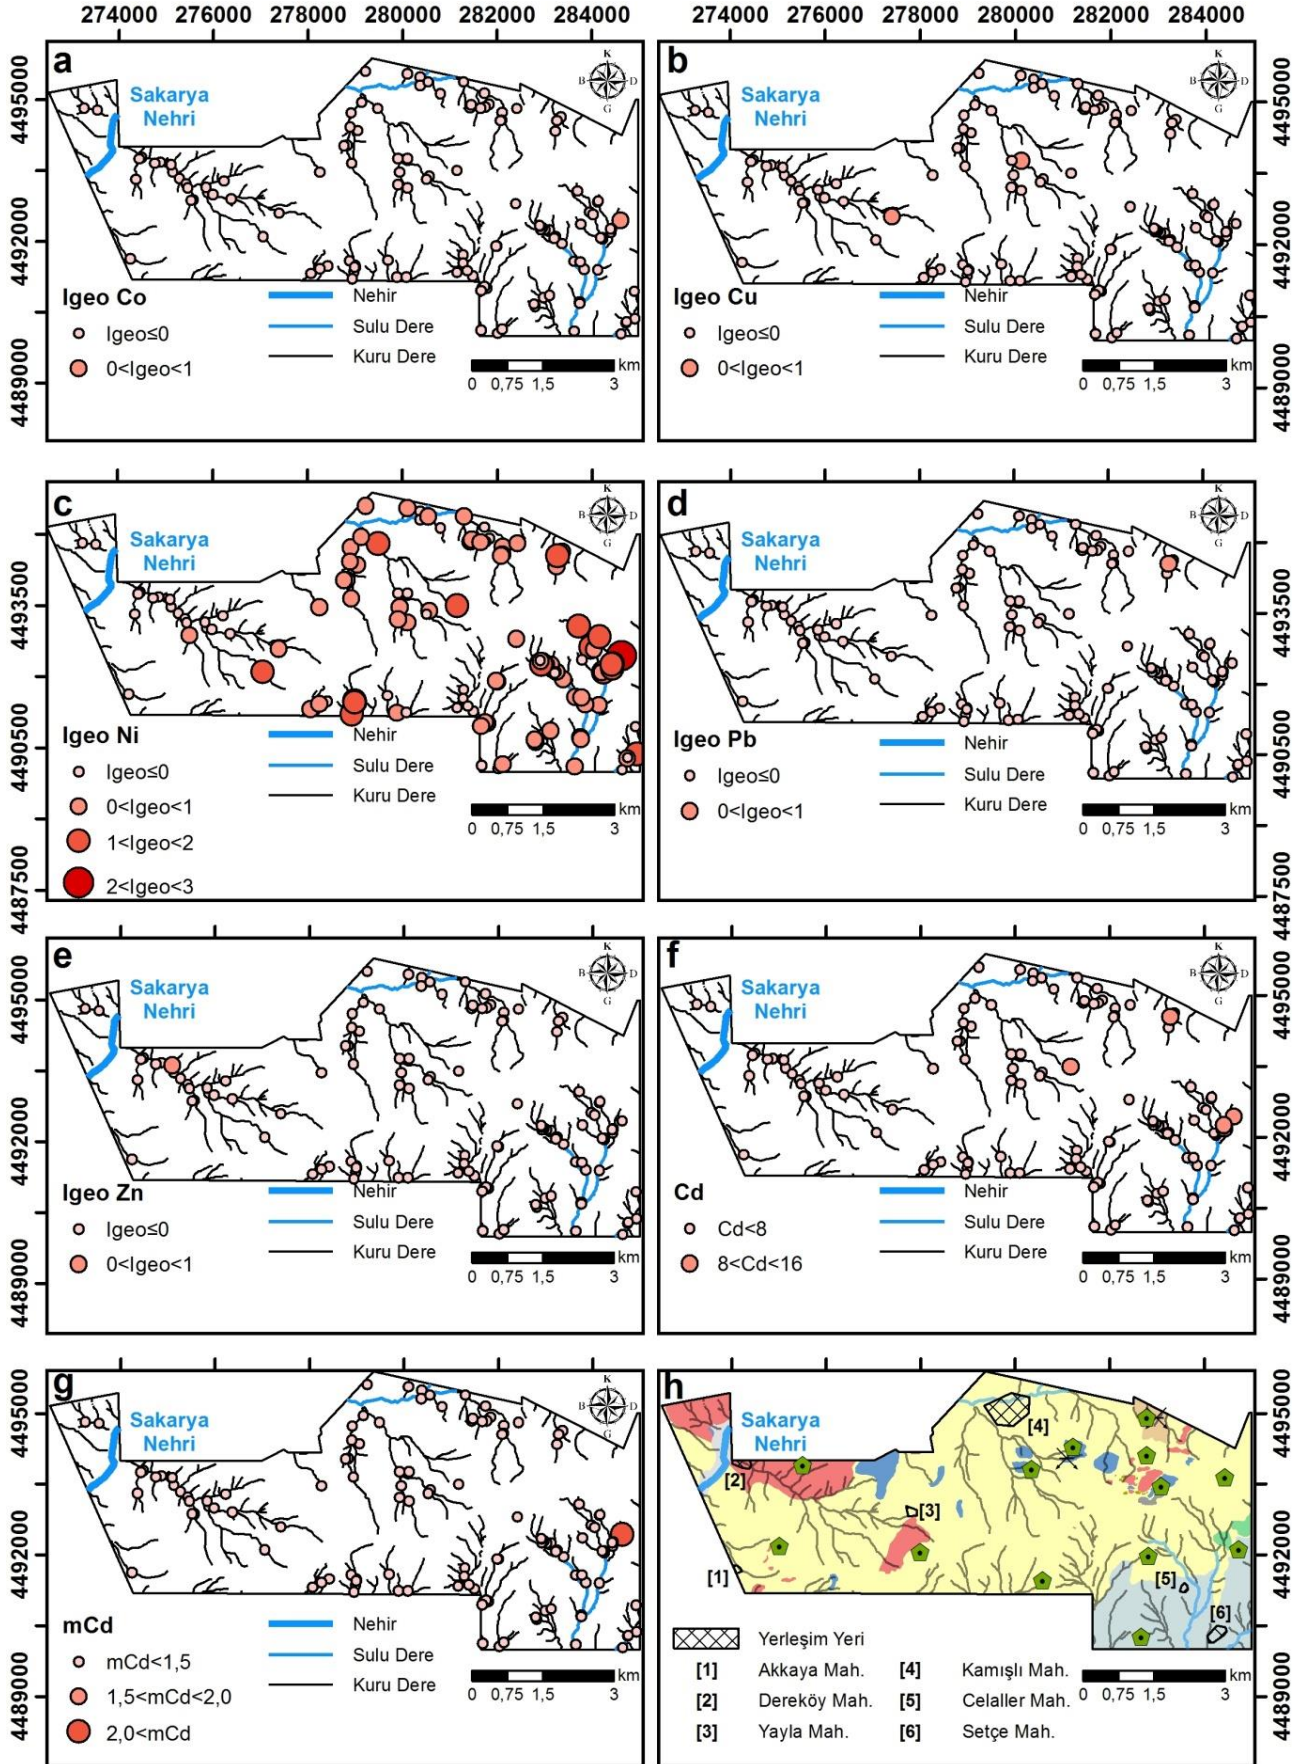
Igeo Ni sonuçlarında kirlenmemiş-orta seviyeden orta-yüksek derecede kirlenmiş seviyeye kadar toplam da 81 örneğin farklı seviyelerde kirlilik gösterdiği belirlenmiştir. Bunların 62 adedi kirlenmemiş-orta, 18 adedi orta (DS-1, 7, 10, 17, 39, 41, 43, 44, 45, 46, 52, 67, 93, 95, 100, 101, 129 ve 133) ve 1 adedi (DS-42) orta-yüksek derecede kirlenmiş seviyeye sahiptir (Şekil 4). Çalışma alanında Igeo Ni açısından farklı seviyelerde kirlenme ile karakteristik olarak gözlenen örneklerin büyük çoğunluğu drenaj sistemlerinin içerisinden geçtiği Abant Formasyonu ve serpantin birimleri ile ilişkili olarak gözlenmektedir (Şekil 5c ve 5h). Bazı dere sedimanı örneklerinin (DS-10, 17, 41, 42, 43, 44, 45, 46, 52, 93, 95, 100, 101 ve 133) alındığı lokasyonlar antropojenik kökenli bir zenginleşmeye neden olabilecek insan faaliyetlerine uzak olmakla birlikte çoğunlukla ormanlar ile kaplıdır. Dolayısıyla bu türden Ni zenginleşmeleri antropojenik faaliyetlerden ziyade Abant Formasyonu içerisinde haritalanabilir ve/veya haritalanamaz ölçekteki serpantin türü kayaçların günlenerek ayrışması ile ilişkili olmalıdır. Çalışma alanının güneybatı sınırına yakın bir konumdan Ok (2008) ve İşleyen vd. (2019) tarafından alınan toprak örneklerinde tespit edilen, sınır değerleri aşan krom içerikleri Ni zenginleşmelerinin jeojenik kökenli olarak serpantinlerin ayrışması ile ortaya çıkışını destekler niteliktedir. Çünkü bu iki ağır metal jeolojik olarak serpantin türü kayaçların içerisinde oluşum koşulları gereği yüksek değerlerde bulunabilmektedir. Söz konusu örnekler ek olarak çalışma alanında orta ve orta-yüksek derecede kirlilik gösteren örneklerden bazılarının (DS-1, 7, 39, 67 ve 129) bulunduğu lokasyonların en fazla 250 metre uzağında yerleşim yeri, köy yolları ve tarım arazilerinin bulunması, tespit edilen zenginleşmelerin jeojenik kökenli süreçler yanında antropojenik kökenli süreçlerle de ilişkili olduğuna işaret etmektedir. Bölgede tarım araç ve makinelerinde kullanılan dizel yakıtlar ve yağlar (Kalkan & Terzi, 2023; Özkan, 2017) ile fosforlu gübrelerin kullanımı (Ok, 2008) antropojenik kökenli artışı desteklemiş olmalıdır. İşleyen vd. (2019) çalışma alanının güneydoğu sınırına yakın ve Geyve ilçesinin kuzey-kuzeydoğusundan derlediği toprak örneklerindeki yüksek Ni içeriklerinin fabrikalardan kaynaklandığını ifade etse de çalışma alanının konumunun sanayi alanlarına uzaklığı böylesi bir ihtimali sınırlamaktadır.

Igeo Ni açısından orta seviyede kirlenme gösteren 1 adet örnek (DS-17) aynı zamanda Igeo Pb açısından da kirlenmemiş-orta seviyede kirliliğe sahiptir. Bu örnek çalışma alanında Cu-Pb-Zn cevher oluşumlarına ev sahipliği yapan Yanık Tepe'nin güneydoğusundaki Abant Formasyonu ve granitlerin içerisinden geçen dereden alınmıştır (Şekil 5d ve 5h). Lokasyonda antropojenik katkıları sağlayacak bir unsur tespit edilememiştir. Dolayısıyla tespit edilen Pb zenginleşmesi hidrotermal süreçlerle ilişkili olarak ortaya çıkmış Pb'ca zengin altere kayaç kesimleri içeren granitik kayaçların ayrışmasıyla ilgili olabileceği daha geçerli bir olasılık olarak belirginleşmektedir.

Igeo'ya göre hesaplanan Zn sonuçları ise 1 adet örnek (DS-128) için kirlenmemiş-orta seviyede kirliliğin varlığına işaret etmektedir (Şekil 4). Kuşkayası Tepe güneybatısından alınan bu örneğin çevresinde tarım arazilerinin ve tarım araçlarının kullandığı köy yolunun varlığı gerçekleşen Zn zenginleşmesinin antropojenik kökenli olabileceğini önermektedir (Şekil 5e ve 5h). Bununla birlikte literatürde bölge için Zn artışlarının araç emisyonları ile ilişkili olarak ortaya çıktığı da ifade edilmektedir (Isen vd., 2013).

C_d, mC_d, ESPI ve PLI İndeksleri


Çalışma alanından derlenen 133 adet dere sedimanı örneğinin ağır metal içerikleri baz alınarak hesaplanan C_d, mC_d, ESPI ve PLI indeks sonuçlarına ait tanımlayıcı istatistiksel bilgiler Tablo 5'de sunulmaktadır. Hesaplama sonuçları C_d'nin 1,2 ile 15,1, mC_d'nin 0,2 ile 2,2, ESPI'nin 0,003 ile 0,5 ve PLI'nın 0,2 ile 0,9 arasında indeks skor değerlerine sahip olduğunu göstermektedir. Bu sonuçlar ESPI ve PLI indeks sınıfları açısından dere sedimanı örneklerinin kirlenme göstermediklerine işaret etmektedir (Tablo 1; Şekil 6). C_d indeks sonuçları 5 adet örnek (DS-17, 42, 43, 46 ve 133) için orta derecede kirlilik varlığını gösterirken, geri kalan örnekler düşük derecede kirlilik sınıfında yer almaktadır. Bu örneklerden DS-42 aynı zamanda mC_d indeksi için orta derecede kirlenme sergilemekte iken, geri kalan örnekler mC_d için kirlenmemiş-çok düşük kirlilik sınıfında yer almaktadır (Şekil 6). Bu örnekler ayrıca Igeo Ni açısından da orta-yüksek derecede kirlilik göstermektedir. Bununla birlikte DS-17 ve 42 örnekleri sırasıyla Igeo Pb ve Igeo Co açısından da düşük seviyede kirliliğe sahiptir. C_d ve mC_d indekslerine göre kirliliğe sahip örnekler çalışma alanında Avlukaya ve Yanık Tepelerinin güneydoğusunda ve Rüzgârlı Tepe kuzeybatısında yüzeyleyen Abant Formasyonu ve serpantinlerinin yüzeylediği alanlar ile örtüşmektedir. Bu veriler Igeo sonuçlarıyla korele edildiğinde bu örnek lokasyonlarında tespit edilen kirliliğin jeojenik kökenli olarak ortaya çıkışı çok daha belirgin hale gelmektedir (Şekil 5f ve 5g).



Şekil 5. Dere Sedimanı Örneklerine ait İndeks Sonuçlarının Mekânsal Dağılım Haritaları: a. Igeo Co, b. Igeo Cu, c. Igeo Ni, d. Igeo Pb, e. Igeo Zn, f. Cd ve g. mCd, ve h. Çalışma Alanının Jeoloji Haritası (Lejant için Şekil 1'e Bakınız)

Tablo 5. Dere Sedimanı Örneklerinin C_d , mC_d , ESPI ve PLI İndeks Hesaplamalarına ait Tanımlayıcı İstatistikler

	C_d	mC_d	ESPI	PLI
Minimum	1,2	0,2	0,003	0,2
Maksimum	15,1	2,2	0,5	0,9
Ortalama	4,6	0,7	0,047	0,5
Standart Sapma	1,90	0,27	0,05	0,15
Çarpıklık	1,49	1,49	6,12	0,27
Basıklık	6,22	6,18	52,50	0,18
Örnek Sayısı	133			

**Şekil 6.** Dere Sedimanı Örneklerinin C_d , M_{Cd} , ESPI ve PLI Sınıfları

SONUÇLAR

Bu çalışmada Geyve kuzeydoğusundaki çalışma alanındaki drenaj sistemlerinden alınan 133 adet dere sedimanı örneğinin ağır metal (As, Co, Cu, Ni, Pb, V ve Zn) içerikleri belirlenmiş ve zenginleşme/kirlenme anomalisi gösteren alanlar tespit edilmiştir. En yüksek ağır metal içerikleri As için 9 ppm, Co için 51 ppm, Cu için 106 ppm, Ni için 750 ppm, Pb için 37 ppm, V için 61 ppm ve Zn için 170 ppm'dir. Bazı örnekler As açısından üst kıtasal kabuk ve dünya toprak, V açısından üst kıtasal kabuk, diğer ağır metaller açısından üst kıtasal kabuk, şeyl ve dünya toprak ortalama değerlerine göre zenginleşme sergilemiştir.

Igeo indeks hesaplamalarına göre dere sedimanı örnekleri As ve V açısından günümüz için bir kirlilik göstermemiştir. Co, Pb ve Zn açısından 1'er adet örnekte, Cu açısından 2 adet örnekte kirlenmemiş-orta, Ni açısından 62 adet örnekte kirlenmemiş-orta, 18 adet örnekte orta ve 1 adet örnekte orta-yüksek seviyede kirlenmelerin olduğu belirlenmiştir. Tüm ağır metal etkilerini birlikte değerlendirerek hesaplama yapan indekslerden C_d 'ye göre 5 adet örnekte ve mC_d 'ye göre ise 1 adet örnekte orta derecede kirlenme tespit edilmiştir. Değerlendirmeler Co ve Ni zenginleşmelerinin serpantinlerin, Pb zenginleşmelerinin ise granitik kayaların ve cevherli zonların ayrışmasıyla ilişkili olarak jeojenik kökenli olduğunu göstermiştir. Ni açısından bazı örneklerde ise jeojenik etkilerin yanında tarımsal faaliyetler sonucunda ortaya çıkan antropojenik girdilerin varlığı da tespit edilmiştir. Çalışma alanındaki Cu ve Zn zenginleşmelerinin ise ağırlıklı tarımsal faaliyetler ile ilişkili olarak antropojenik kökenli olarak geliştiği ortaya konulmuştur.

Çalışma alanında dere sedimanlarında biriken ağır metaller, drenaj sistemlerini kullanarak Türkiye'nin en önemli nehirlerinden Sakarya Nehri'ne ulaşacaktır. En nihayetinde ağır metallerce zenginleşerek kirlenecek suların tarımsal faaliyetlerde kullanılması kaçınılmaz hale gelecektir. Böylesi bir durum öncelikle besin zinciri döngüsünü tehdit

edecektir. Bu türden riskleri kontrol altına almak ve insan sağlığını korumak için sediman, toprak, yüzey ve yeraltı sularının sistematik ve periyodik olarak izlenmesi, kirletici kaynaklarının belirlenmesi ve kontrol altına alınması zorunludur. Çalışma alanı özelinde jeojenik ve antropojenik kökenli ağır metal zenginleşmelerinin ekolojik risklerinden korunmak için ise dere sedimanı jeokimyası çalışmaları ile tespit edilen anomali alanlarında daha kapsamlı toprak jeokimyası çalışmaları yürütülmelidir. Bu sayede ağır metallere ait zenginleşme/kirlilik alanlarının sınırları çok daha kesin olarak ortaya konulabilecektir.

TEŞEKKÜR

Bu çalışma, Mehmet Barış Durgun'un diğer iki yazarın danışmanlığında Aksaray Üniversitesi'nde hazırlamış olduğu Yüksek Lisans tezinin bir parçasıdır. Yazarlar, Maden Tetkik ve Arama Genel Müdürlüğü Maden Etüt ve Arama Dairesi Başkanlığı ve Doğu Marmara Polimetallik Maden Aramaları projesi (Proje No: 2022-32-13-04-2) kapsamında çalışmalara katılan proje ekibine veri desteği ve katkıları için teşekkür eder ve şükranlarını sunarlar.

KAYNAKLAR

- Abraham, G.M.S., & Parker, R.J. (2008). Assessment of heavy metal enrichment factors and the degree of contamination in marine sediments from Tamaki Estuary, Auckland, New Zealand. *Environmental Monitoring and Assessment*, 136:227–238. <https://doi.org/10.1007/s10661-007-9678-2>
- Ateş, A., Çalışkan, N., & Demirel, H. (2017). Evaluation of soil quality in Sapanca Lake basin. *Periodicals of Engineering and Natural Sciences*, 5(1). <https://doi.org/10.21533/pen.v5i1.90>
- Bai, Z., Wu, F., He, Y., & Han, Z. (2023). Pollution and risk assessment of heavy metals in Zuoxiguo antimony mining area, southwest China. *Environmental Pollutants and Bioavailability*, 35(1):2156397. <https://doi.org/10.1080/26395940.2022.2156397>
- Chen, T., Liu, X., Li, X., Zhao, K., Zhang, J., Xu, J., Shi, J., & Dahlgren, R.A. (2009). Heavy metal sources identification and sampling uncertainty analysis in a field-scale vegetable soil of Hangzhou, China. *Environmental Pollution*, 157:1003–1010. <https://doi.org/10.1016/j.envpol.2008.10.011>
- Çelenk, F., & Kızıloğlu, T. (2015). Distribution of lead accumulation in roadside soils: a case study from D 100 highway in Sakarya, Turkey. *International Journal of Research in Agriculture and Forestry*, 2(5):1-10.
- Çelik, Ö.F., Gürer, Ö.F., & Öz, İ. (2009). Geyve Boğazı ve Pamukova Arasında Yer Alan Granitoyitik Kayaçların Petrografik ve Jeokimyasal Özellikleri. *Uygulamalı Yerbilimleri Dergisi*, 8(1):61-75.
- Demirela, G., Yılmaz, E., & Kavurmacı, M.M. (2020). Hydrogeochemical, geotechnical and soil geochemistry characteristics of Aksaray University campus area, Aksaray. *Aksaray University Journal of Science and Engineering*, 4(1):90-112. <https://doi.org/10.29002/asujse.712844>
- Duman, F., Aksoy, A., & Demirezen, D. (2007). Seasonal variability of heavy metals in surface sediment of Lake Sapanca, Turkey. *Environmental Monitoring and Assessment*, 133:277-283. <https://doi.org/10.1007/s10661-006-9580-3>
- Durgun, M.B. (2024). Geyve (Sakarya) civarında ağır metal zenginleşmeleri: toprak ve dere sedimanı jeokimyası çalışmaları. Yüksek Lisans Tezi. Aksaray Üniversitesi Fen Bilimleri Enstitüsü, Aksaray.
- Durgun, M.B., Demirela, G., & Terzi, M.H. (2024a). Heavy metal contamination in soils: Kamışlı (Geyve/Sakarya), NW Türkiye. In AGRO International Conference on Agriculture-II, June 05-07, 2024, Azerbaijan State Agricultural University, Ganja (Azerbaijan), Proceedings Book, p. 312-313.
- Durgun, M.B., Demirela, G., & Terzi, M.H. (2024b). The Origin of heavy metal enrichments in soils; Celaller region (Geyve/Sakarya), NW Türkiye. In 4th International Graduate Studies Congress (IGSCONG'24), June 5-8, 2024, Proceedings Book, p. 1006-1007.
- Durgun, M.B., Terzi, M.H., & Demirela, G., (2024c). Geyve (Sakarya, Türkiye) dere sedimanlarındaki ağır metal zenginleşmelerinin kökeni. 10. Jeokimya Sempozyumu, 17-19 Ekim 2024, Antalya (Türkiye), Bildiri Özleri Kitabı, s. 90-91.
- Dundar, M.S., Altundag, H., Eyupoglu, V., Keskin, S.C., & Tutunoglu, C. (2012). Determination of heavy metals in lower Sakarya river sediments using a BCR-sequential extraction procedure. *Environmental Monitoring and Assessment*, 184:33-41. <https://doi.org/10.1007/s10661-011-1944-7>

- Erturaç, M.K. (2018). Sakarya'nın jeolojik özellikleri. C. İkiel (Ed.), Sakarya'nın Fiziki, Beşeri ve İktisadi Coğrafya Özellikleri, Sakarya Üniversitesi Yayınları, s. 96-116.
- Esmaili, A., Moore, F., Keshavarzi, B., Jaafarzadeh, N., & Kermani, M. (2014). A geochemical survey of heavy metals in agricultural and background soils of the Isfahan industrial zone, Iran. *Catena*, 121:88-98. <https://doi.org/10.1016/j.catena.2014.05.003>
- Geyve Belediyesi, 2024. <https://www.geyve.bel.tr/icerik/geyve-tarihi>, Erişim Tarihi: 07.10.2024.
- Gopal, V., Krishnamurthy, R.R., Indhumathi, A., Sharon, B.T.X., Priya, T.S.D., Rathinavel, K., Bharath, K.M., Magesh, N.S., & Ayyamperumal, R. (2024). Geochemical evaluation, ecological and human health risk assessment of potentially toxic elements in urban soil, southern India. *Environmental Research*, 248:118413. <https://doi.org/10.1016/j.envres.2024.118413>
- Göllü, E. (2019). Aşağı Sakarya havzası jeotermal alanının hidrojeoloji ve hidrojeokimyasal incelenmesi. Yüksek Lisans Tezi. Konya Teknik Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- Hakanson, L. (1980). An ecological risk index for aquatic pollution control, a sedimentological approach. *Water Research*, 14(8):975-1001. [https://doi.org/10.1016/0043-1354\(80\)90143-8](https://doi.org/10.1016/0043-1354(80)90143-8)
- Isen, H., Altundag, H., & Keskin, C.S. (2013). Determination of heavy metal contamination in roadside surface soil by sequential extraction. *Polish Journal of Environmental Studies*, 22(5):1381-1385.
- Isleyen, M., Akpınar, A., Eren, B., & Ok, G. (2019). Heavy metal profiles of agricultural soils in Sakarya, Turkey. *Environmental Engineering Research*, 24(3):427-433. <https://doi.org/10.4491/eer.2018.274>
- Kalkan, M., & Terzi, M.H. (2023). Assessment of heavy metal pollution of the soils in the southwest of Aksaray city. *Recep Tayyip Erdogan University Journal of Science and Engineering*, 4(2):219-231. <https://doi.org/10.53501/rteufemud.1360204>
- Ketin, İ. (1966). Anadolu'nun tektonik birlikleri (Tectonic units of Anatolia). *Bulletin of the Mineral Research and Exploration*, 66:20-37.
- Kızıloğlu Algan, F.T., & Bilen, S. (2005). Toprak kirlenmesi ve biyolojik çevre. *Atatürk Üniversitesi Ziraat Fakültesi Dergisi*, 36(1): 83-88.
- Koljonen, T. (1992). Geochemical Atlas of Finland, Part 2: Till. Geological Survey of Finland, Espoo, Finland, 218 pp.
- Muller, G. (1969). Index of geo-accumulation in sediments of the Rhine River. *GeoJournal*, 2(3):108-118.
- Ochiagha, K.E., Okoye, P.A.C., & Eboagu, N.C. (2020). The geo-accumulation index of some heavy metals in the roadsides soils of Onitsha south local government area Anambra state, Nigeria. *Science Journal of Chemistry*, 8(3):42-47. <https://doi.org/10.11648/j.sjc.20200803.11>
- Ok, G. (2008). Sakarya bölgesindeki topraklardaki inorganik kirleticilerin araştırılması. Yüksek Lisans Tezi. Sakarya Üniversitesi Fen Bilimleri Enstitüsü, Sakarya.
- Okay, A.I., Bozkurt, E., Satır, M., Yiğitbaş, E., Crowley, Q.G., & Shang, C.K. (2008). Defining the southern margin of Avalonia in the Pontides: geochronological data from the Late Proterozoic and Ordovician granitoids from NW Turkey. *Tectonophysics*, 461(1-4):252-264. <https://doi.org/10.1016/j.tecto.2008.02.004>
- Özer, C., Çevikbaş, A., & Eyüpoğlu, M. (2013). Çamyurdu (Mudurnu-Bolu), Örencik, Kirpiyen (Geyve-Sakarya) ruhsat sahaları maden jeolojisi ve prospeksiyon çalışmaları. *MTA Doğal Kaynaklar ve Ekonomi Bülteni*, 16:205-214.
- Özer, C., Turan-Altunsoy, A., Durgun, M. B., Yalçın, Ç., Baran, G., & Kaplan, H. (2021). Celaller (Geyve-Sakarya) sahası jeoloji haritası, Maden Tetkik ve Arama Genel Müdürlüğü, Ankara.
- Özkan, A. (2017). Antakya-Cilvegözü karayolu etrafındaki tarım arazilerinde ve bitkilerdeki ağır metal kirliliği. *Çukurova Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 32(3):9-18. <https://doi.org/10.21605/cukurovaummfd.357176>
- Özkul, C., Acar, R.U., Köprübaşı, N., Er, A.E., Kızılkaya, H.İ., Metin, M., & Şenel, M.N. (2018). Altıntaş (Kütahya-Türkiye) ovası tarım topraklarında ağır metal kirliliğinin araştırılması, öncel çalışma. *Journal of Applied Earthsciences*, 17(1):13-26. <https://doi.org/10.30706/uybd.426408>

- Parlak, M., Çıkılı, Y., & Çiçek, G. (2020). Kereviz tarlalarının verimlilik durumları ile ağır metal kapsamının toprak ve yaprak analizleriyle belirlenmesi: Sakarya-Geyve Örneği. *COMU Journal of Agriculture Faculty*, 8(1):173-185. <https://doi.org/10.33202/comuagri.686369>
- Ravankhah, N., Mirzaei, R., & Masoum, S. (2017). Determination of heavy metals in surface soils around the brick kilns in an arid region, Iran. *Journal of Geochemical Exploration*, 176:91-99. <https://doi.org/10.1016/j.gexplo.2016.01.005>
- Reimann, C., & De Caritat, P. (1998). Chemical elements in the environment: factsheets for the geochemist and environmental scientist. 1st edition, Springer-Verlag Berlin. <https://doi.org/10.1007/978-3-642-72016-1>
- Sakarya İl Tarım ve Orman Müdürlüğü, 2015. <https://sakarya.tarimorman.gov.tr/Menu/27/Geyve-Ilce-Mudurlugu>, Erişim Tarihi: 07.10.2024.
- Sisman, I., Imamoglu, M., & Aydin, A.O. (2002). Determination of heavy metals in roadside soil from Sapanca area highway, Turkey. *International Journal of Environment and Pollution*, 17(4):306-311. <https://doi.org/10.1504/IJEP.2002.000674>
- Stoffers, P., Glasby, G.P., Wilson, C.J., Davis, K.R., & Walter, P. (1986). Heavy metal pollution in Wellington Harbour. *New Zealand Journal of Marine and Freshwater Research*, 20(3):495-512. <https://doi.org/10.1080/00288330.1986.9516169>
- Şener, Ş., & Şener, E. (2015). Kovada Gölü (Isparta) dip sedimanlarında ağır metal dağılımı ve kirliliğinin değerlendirilmesi. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 19(2):86-96.
- Temur, E., & Aksay, A. (2002). 1:100.000 ölçekli Türkiye jeoloji haritaları, Adapazarı G24 paftası, MTA Yayınları, 31.
- Terzi, M.H., & Kalkan, M. (2024). Evaluation of soil pollution by heavy metal using index calculations and multivariate statistical analysis. *Environmental Monitoring and Assessment*, 196(5):443. <https://doi.org/10.1007/s10661-024-12569-3>
- Tomlinson, D.C., Wilson, J.G., Harris, C.R., & Jeffery, D.W. (1980). Problems in the assessment of heavy metals levels in estuaries and the formation of a pollution index. *Helgoländer Meeresuntersuchungen*, 33:566-575. <https://doi.org/10.1007/BF02414780>
- Wedepohl, K.H. (1995). The composition of the continental crust. *Geochimica Et Cosmochimica Acta*, 59(7):1217-1232. [https://doi.org/10.1016/0016-7037\(95\)00038-2](https://doi.org/10.1016/0016-7037(95)00038-2)
- Yılmaz, E., & Terzi, M.H. (2023). Geochemical investigation of soil quality in terms of toxic elements using an AHP-based index. *Environmental Geochemistry and Health*, 45:8271-8294. <https://doi.org/10.1007/s10653-023-01720-7>



Kahramanmaraş Sutcu Imam University

Journal of Engineering Sciences



Geliş Tarihi : 14.10.2024
Kabul Tarihi : 17.01.2025

Received Date : 14.10.2024
Accepted Date : 17.01.2025

INVESTIGATION OF PRECIPITATION DATA OF DİYARBAKIR PROVINCE WITH DIFFERENT TREND ANALYSIS METHODS

DİYARBAKIR İLİNE AİT YAĞIŞ VERİLERİNİN FARKLI TREND ANALİZİ YÖNTEMLERİ İLE İNCELENMESİ

Burak GÜL^{1*} (ORCID: 0009-0005-7735-2455)

¹ Dicle University, Civil Engineering Department, Diyarbakır, Türkiye

*Sorumlu Yazar / Corresponding Author: Burak GÜL, brkg121@gmail.com

ABSTRACT

Global climate change leads to significant alterations in climate systems, affecting natural resource management, agriculture, and water security. As these impacts are also felt at the local level, regional climate analyses are crucial. This study analyzes precipitation data from Diyarbakır province between 1970 and 2022 to examine the local effects of climate change. Trend analyses were conducted using Mann-Kendall, Sen's Slope, Spearman's Rho, and Innovative Trend Analysis (ITA) methods. The Mann-Kendall test assessed the statistical significance of trends, while Sen's Slope estimated the magnitude of these trends. The results indicated no statistically significant trends on an annual or seasonal basis. However, the ITA method revealed decreasing trends in summer precipitation and annual totals, alongside increasing trends in spring and autumn precipitation. No trends were detected for winter precipitation. The Spearman's Rho test identified a positive relationship between annual total precipitation and seasons, but no trends were observed among the seasons themselves. This study highlights the importance of local climate analyses and contributes to preparedness for future changes. Continuous monitoring of climate data plays a critical role in making informed strategic decisions, particularly in water resource management and agricultural policies.

Keywords: Climate change, Diyarbakır, precipitation, trend analysis

ÖZET

Küresel iklim değişikliği, iklim sistemlerinde büyük değişikliklere yol açarak, doğal kaynakların yönetimi, tarım ve su güvenliğini etkilemektedir. Bu etkiler yerel düzeyde de hissedildiği için, bölgesel iklim analizleri büyük önem taşımaktadır. Bu çalışmada, Diyarbakır ilinin 1970-2022 yılları arasındaki yağış verilerini analiz ederek iklim değişikliğinin yerel etkilerini incelenmiştir. Mann-Kendall, Sen's Slope, Spearman's Rho ve Yenilikçi Trend Analizi (ITA) yöntemleri kullanılarak yağış verileri üzerinde trend analizleri yapılmıştır. Mann-Kendall testi trendlerin istatistiksel anlamlılığını, Sen's Slope ise trendlerin eğimini değerlendirmiştir. Sonuçlar, yıllık ve mevsimsel bazda anlamlı bir trend olmadığını göstermiştir. ITA yöntemi, yaz mevsiminde ve yıllık toplam yağışta azalma, ilkbahar ve sonbaharda artış trendleri ortaya koyarken, kış mevsiminde bir trend bulunmamıştır. Spearman's Rho testi, yıllık toplam yağış ve mevsimler arasında pozitif bir ilişki belirlemiş, ancak mevsimler arasında trend görülmemiştir. Bu çalışma, yerel iklim analizlerinin önemine işaret etmekte ve gelecekteki değişikliklere hazırlıklı olma konusunda katkı sağlamaktadır. İklim verilerinin sürekli izlenmesi, stratejik kararlar için kritik bir rol oynamaktadır.

Anahtar Kelimeler: Diyarbakır, iklim değişikliği, trend analizleri, yağış

INTRODUCTION

Global climate change is a significant process causing alterations in climate parameters worldwide, with profound impacts on water resources. Rising temperatures, changes in precipitation patterns, and an increase in the frequency
ToCite: GÜL, B., (2025). INVESTIGATION OF PRECIPITATION DATA OF DİYARBAKIR PROVINCE WITH DIFFERENT TREND ANALYSIS METHODS. *Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences*,28(1), 350-368.

of extreme weather events adversely affect the quantity, distribution, and quality of freshwater resources (Bojago et al., 2024). Water resources, which are utilized in various sectors such as agricultural irrigation, drinking water supply, and energy production, are directly impacted by the effects of climate change. In this context, water resource management and planning must be reevaluated to account for the future impacts of climate change (Sa'adi et al., 2023).

Understanding the impacts of climate change on water resources requires a thorough examination of its causes and mechanisms. Changes in the climate system are associated with various factors, including atmospheric circulations, greenhouse gas accumulations, ocean currents, and evaporation processes. The increase in greenhouse gases in the atmosphere leads to rising global temperatures and alterations in the hydrological cycle (Alemu et al., 2024). This phenomenon results in increased precipitation in some regions and heightened drought conditions in others. Additionally, the frequency and intensity of extreme weather events are increasing, leading to more frequent hydrological disasters such as floods and droughts. These effects complicate the sustainable management of water resources and raise critical questions about how these resources will be preserved amidst growing populations and economic activities in the future (Wubneh et al., 2023).

Some studies analyzing the impacts of climate change on water resources focus on precipitation trend analyses. Identifying changes over time in precipitation amounts, frequency, and seasonal distributions is crucial for understanding potential impacts on water resources (Gül and Kayaalp, 2024). These analyses are typically conducted through long-term examinations of meteorological data and involve statistical methods to develop future precipitation scenarios. Precipitation trend analyses, particularly those conducted at regional scales, provide valuable insights into how local water resources may be affected in the future when correlated with climate models. For example, decreases in precipitation amounts may be observed in some areas, while increases or seasonal shifts may occur in others. These data serve as critical tools for decision-makers in water management planning, offering key guidance for ensuring sustainable resource use.

Precipitation trend analyses are also crucial for examining hydrological events caused by climate change, such as flood risk analyses. In particular, the increase or decrease in extreme precipitation over time aids in predicting future risks in flood-prone areas and planning measures to mitigate these risks. Therefore, precipitation trend analyses are an essential tool in climate change studies, helping to manage climatic uncertainties effectively. (Ceribasi et al., 2021; Kahya and Kalaycı, 2004; Partal and Kahya, 2006; Zhang et al., 2001)

In their study, Modarres and Sarhadi (2009) employed the Mann-Kendall test and Sen's slope estimator method to analyze precipitation data in Iran's arid and semi-arid regions. The study identified significant decreasing trends in precipitation across most regions. It was also revealed that these decreases have become more pronounced over the past 50 years.

Javari, 2016 In the study conducted by him, the trend analysis of precipitation in Iran revealed significant seasonal changes with decreasing precipitation in the eastern and central regions, while increasing trends were observed in the west and north. The trend analysis methods used in the study were the Kruskal-Wallis (KW) Test and the Least Squares Regression (LSR) Test, which were used to examine the nature of monthly and seasonal precipitation series. Pathak and Dodamani (2020) used the Mann Kendal trend analysis method in their study. As a result of the analysis, significant negative trends emerged in annual and seasonal precipitation, and the correlations between precipitation trends and SPI trends varied between 0.91 and 0.97, indicating potential drought conditions. In the study conducted by Singh et al. (2021), the spatial-temporal precipitation trends in India from 1901 to 2019 were analyzed using precipitation data. In the study, an innovative trend analysis (ITA) method was applied to detect trends in seasonal and annual precipitation; The ITA results were compared with conventional methods such as Mann-Kendall (M-K), modified Mann-Kendall (mm-K) and linear regression analysis (LRA). The findings revealed significant trends in increasing monsoon and annual rainfall over most of the peninsular and northwestern India while decreasing trends in rainfall were observed in the central northeastern region and many subdivisions during winter months.

In a study conducted by Shi et al. (2013), precipitation trends in the Shaying River Basin upstream of the Huai River were analyzed for the period 1951 to 2010 using linear regression, the Mann-Kendall test, and R/S analysis. The results indicated that overall precipitation trends were complex, with a slight increase in annual precipitation observed over the past 60 years; however, this increase was not statistically significant. Future projections suggest a non-persistent trend in precipitation, indicating that fluctuations may occur without a clear directional pattern. During the

analysis, among the 38 precipitation stations, predominantly negative trends were observed in the spring and autumn seasons, whereas positive trends were noted during the summer and winter months.

An important analysis by Kundu et al. (2014) examined rainfall trends in India covering the period from 1871 to 2011. The study focused on 306 stations in seven different districts of India which include Homogeneous Indian Monsoon and Core-Monsoon India. The Mann-Kendall test and the Sen slope were used to detect trends, while the Mann-Whitney Pettitt test was applied to identify breakpoints in the precipitation series. With the exceptions noted in the core monsoon and northeast India, five regions have been found to exhibit a decreasing trend in their annual rainfall. Most regions have seen a significant reduction in monsoon rainfall, which has been critical for agricultural water demands. The analysis revealed a variability in precipitation over 141 years; North-West India experienced the highest increase of 5.14%, while core-monsoon India showed an annual decline of 4.45%. The findings highlight the importance of understanding rainfall trends due to their impact on agriculture and water resources management in India. In the study conducted by AlSubih et al. (2021), the Mann-Kendall test was used for trend analysis and the Theil-Sen approach was applied for trend size calculation. Trend analysis revealed a statistically significant downward trend in precipitation at most stations in the Aseer region, especially between 2000 and 2010.

Yükseler et al. (2021) analyzed precipitation data for Bingöl province between 1960 and 2017, identifying decreasing trends of 0-2 mm/year in annual total precipitation at some stations. Furthermore, significant seasonal variations in trends were observed across different stations and seasons. The study particularly highlighted the utility of the Şen Innovative Trend Analysis (Şen-ITA) method in providing detailed evaluations of seasonal transitions and significant changes. Similarly, Çoşkun, 2020 investigated long-term precipitation trends in the Van Lake Closed Basin, located in Turkey's Eastern Anatolia Region. This basin was selected as it provides a suitable area for observing the effects of climate change more distinctly. Using data from seven stations with over 30 years of measurements, the analysis employed the Mann-Kendall Test, Spearman's Rho, and Şen Test. The results revealed decreasing trends in annual precipitation at the Gevaş and Ahlat stations, while the Van-Bölge station exhibited a statistically insignificant increase. On a seasonal basis, significant decreases were observed at Erciş and Ahlat stations, whereas no discernible trends were identified at other stations.

In a study conducted by Gümüş et al. (2021), trend analyses revealed that values in the extreme drought class (-3 and below) show a decreasing trend, indicating a decline in the frequency of extreme droughts in recent years. However, a slight increasing trend has been observed in the categories of severe drought and very severe drought for medium and long-term droughts. During wet periods, a generally weak decreasing trend is observed. In the SYI-12 analysis, particularly in the medium-humid class, a declining trend of over 5% was detected.

Overall, drought trends show limited variation, but there is a tendency for an increase in drought severity for medium and long-term periods. These findings provide critical information for water resource management in Diyarbakır and future drought risk planning. The use of the ITA method has enabled more detailed and effective analyses compared to traditional methods.

In a study conducted by Özdel, 2020 study, the changes in temperature and precipitation parameters in the Diyarbakır Basin from 1965 to 2019 were analyzed. Data from meteorological stations in Batman, Çermik, Diyarbakır, Ergani, and Siirt were used, examining average temperature, maximum temperature, minimum temperature, and total precipitation in detail. Statistical methods such as Mann-Kendall, Spearman's Rho, and Sen's slope trend test were applied, and homogeneity tests indicated that time series generally had a homogeneous structure.

According to the findings, statistically significant warming trends were observed in all stations except Diyarbakır for annual average temperatures, with the strongest warming trends identified in Ergani and Siirt stations. A notable warming trend was observed in all stations, especially during the summer months. In precipitation analyses, no significant decreasing trends were found in annual total precipitation, with only Çermik station showing a statistically significant decrease in November.

Overall, there was an increase in temperature values and a decreasing trend in precipitation. These results highlight the impacts of global climate change on the Diyarbakır Basin. The detailed methods used in the study provide valuable insights into understanding regional climate change impacts and assessing measures for related sectors, particularly in agriculture and water resource management.

In a study conducted by Alashan, 2018 study, daily temperature data for July from 1972 to 2005 were analyzed for Diyarbakır. The time series was divided into two halves for innovative trend analysis (ITA) and change box (ITA-CB) methods, evaluating temperature trends in low, medium, and high-value groups. Results showed a clear increasing trend in July temperatures in all groups. For the low group, a minimum -0.84%, maximum 6.30%, and average 2.04% changes were observed. For the medium group, minimum -0.55%, maximum 2.45%, and average 1.13% increases were recorded. In general, a minimum of -0.84%, a maximum of 6.30%, and an average increase of 1.51% were noted across all groups.

In a study conducted by Şen, 2017 study, annual total precipitation records from Diyarbakır meteorological station to the Tigris River were analyzed. The dataset was evaluated under a broad application of innovative trend significance testing. According to the analysis, a statistically significant decreasing trend was detected in annual total precipitation in Diyarbakır. The trend slope value falling outside the confidence intervals indicates that this decrease is not due to random fluctuations and is statistically significant.

In a study conducted by Bahadır, 2011 Diyarbakır's central region, where despite showing a more stable character compared to other stations in terms of temperature, there was a decreasing trend. The magnitude of average deviations leaned towards a decrease, which continued steadily from 1975 to 1985. After 1985, stability persisted until 2006. From that point onward, a decreasing trend in precipitation reached its lowest levels in 2007 and 2008. Trend analyses suggest a decrease in precipitation by 35 mm from 2009 to 2023. Yürekli (2015), Gümüş et al. (2023), and other studies mentioned a decline in precipitation trends in Diyarbakır.

These studies show that trend analyses are important and widely used methods in the literature to predict future precipitation trends. This study aimed to conduct trend analyses on precipitation data recorded for Diyarbakır province between 1970 and 2022. The analyses employed Mann-Kendall, Sen's Slope, Spearman's Rho, and Innovative Trend Analysis (ITA) methods, offering a multidimensional perspective on potential trends in precipitation data. The Mann-Kendall test was used to evaluate the statistical significance of precipitation trends, while the Sen's Slope method was applied to estimate the slope of these trends. Additionally, Spearman's Rho test was used to examine the relationships between seasonal and annual precipitation, and the ITA method provided an innovative perspective.

The findings revealed that the Mann-Kendall and Sen's Slope methods did not indicate the presence of statistically significant trends on an annual or seasonal basis. However, ITA analysis identified a decreasing trend in annual total precipitation and summer precipitation, along with increasing trends in spring and autumn. No trends were observed for winter precipitation. According to Spearman's Rho test, significant positive relationships were found between annual total precipitation and seasons, although no clear trends were detected among the seasons themselves. This study provides a multidimensional approach to understanding the dynamics of long-term precipitation data for Diyarbakır province.

STUDY AREA

Diyarbakır is a city that receives an average annual rainfall of 493 mm and experiences more rainfall in winter and a very dry climate in summer. The average annual temperature in the city is 22.7°C, with temperatures reaching 40°C in summer and dropping below 0°C in winter (TSMS, 2024). Diyarbakır city center is located at an altitude of about 675 meters above sea level, and as of 2024, its population is around 1.8 million. Geographically, it is located at 37.9144° north latitude and 40.2306° east longitude.

The data used in this study were provided by the Turkish State Meteorological Service and include precipitation records for the years 1970-2022. The data were obtained in their entirety, without any missing values, from the Diyarbakır Regional Meteorological Station (Station No: 17281) located at coordinates 37.8104° latitude and 40.3078° longitude. An analysis of the annual average precipitation data for the Diyarbakır region, presented in Table 1, revealed a minimum precipitation amount of 280.9 mm, a maximum of 846.2 mm, and an average annual precipitation of 536.3 mm. The variability in precipitation across years is expressed by a standard deviation of 124.9 mm, indicating an unpredictable variation in precipitation levels. A skewness coefficient of 0.15 suggests that the precipitation distribution is slightly positively skewed, with extreme precipitation events above the mean occurring more frequently. The relative variability of the precipitation is expressed by a coefficient of variation of 23.3%, highlighting the region's potential to experience both dry and wet years (Table 1).




Figure 1. Workspace Location Map

DATA

Table 1. Statistical Analysis of the Data of the Meteorological Station No. 17281

Minimum	280.90
Maximum	846.20
Standard Deviation	124.86
Skewness	0.15
Mean	536.28
Coefficient of Variation	0.23

METHODS

To analyze the trend of the data in the study, Mann-Kendall, Sen's slope, Spearman's rho, and innovative trend analysis (ITA) methods were selected and applied. There are some reasons why these methods are chosen in the analysis. Since the Mann-Kendall test works independently of data distribution as a non-parametric method, it is resistant to seasonal or extreme distributions frequently encountered in hydrological and meteorological data and is widely preferred to determine the statistical significance of monotonous trends in time series. The Sen's Slope method, on the other hand, allows for a robust calculation of the direction and magnitude of the trend without being affected by noise in the data and can be used in conjunction with the Mann-Kendall test for comprehensive analysis. As a nonparametric correlation method, Spearman's rho draws attention with its capacity to reveal ordered connections, especially in nonlinear relationships, and is effective in detecting trends in hydrological variables. Innovative Trend Analysis (ITA), on the other hand, offers the flexibility to examine trends at different scales by segmenting data, producing reliable results even in non-linear data sets without relying on any statistical assumptions. The combination of these four methods enables precipitation trends to be analyzed from different aspects, contributing to a more comprehensive, reliable, and meaningful interpretation of the results.

Mann Kendal Test

Mann-Kendall trend analysis is a nonparametric statistical method often used in hydrology and climate sciences to test for the existence of trends in time series. This analysis has a wide range of uses, as it provides reliable results in cases where the data are not based on the assumption of seasonality or normal distribution.

Steps:

Preparation of Data Series: The test runs on a time series of data with n observations. The observation sequence is defined as x_1, x_2, \dots, x_n .

Calculation of S-Statistic: From the data, the S , which is the Mann-Kendall test statistic, is calculated. This statistic is calculated by taking the sign of the difference of the two values for each pair of data, respectively. The formula is as follows.

$$s = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sgn}(x_j - x_i) \quad (1)$$

Here:

$$\text{sgn}(x_j - x_i) = \begin{cases} 1, & \text{if } (x_j - x_i) > 0 \\ 0, & \text{if } (x_j - x_i) = 0 \\ -1 & \text{if } (x_j - x_i) < 0 \end{cases} \quad (2)$$

That is, if the next observation is greater than the previous observation, a positive value is taken, if it is smaller, a negative value is taken, and if it is equal, a zero value is taken.

Interpretation of the S Statistic:

- If S is positive, there is an increasing trend in the time series.
- If S is negative, there is a downward trend.
- If S is close to zero, there is no meaningful trend.

Calculation of Variance: The variance evaluates the distribution of the statistic S and is calculated as:

$$\text{Var}(S) = \frac{n(n-1)(2n+5) - \sum t_i(t_i-1)(2t_i+5)}{18} \quad (3)$$

Where " t_i " indicates the number of equal values. This is taken into account because the presence of equal data can affect the test.

Z-Statistic Calculation: Z-statistic is used to standardize results. This statistic approximates the normal distribution in large sample numbers. The calculation is as follows:

$$Z = \begin{cases} \frac{S-1}{\sqrt{\text{Var}(S)}}, & \text{if } S > 0 \\ 0, & \text{if } S = 0 \\ \frac{S+1}{\sqrt{\text{Var}(S)}} & \text{if } S < 0 \end{cases} \quad (4)$$

The Z statistic is then compared to a critical Z value based on the α significance level. Generally, a significance level of 5% is used, and according to this level, the Z value should be in the range of ± 1.96 .

Identifying the Presence of the Trend: If $|Z|$ is greater than the specified critical value (e.g. 1.96), it is concluded that there is a significant trend in the time series.

If Z is positive, this is an increasing trend. If it is negative, it means that there is a decreasing trend (Kundu et al., 2014).

Sen's Slope Test

Sen's Slope method determines the overall trend by calculating the slope between two data points in a time series. The slope between both data points is calculated, and the median of these slopes is considered as the trend ratio.

Slope Calculation: If the data series contains n time-series observations, the slope between each pair of data points is calculated by the following formula:

$$Q_i = \frac{x_j - x_i}{j - i} \quad (5)$$

Here:

- x_j and x_i , j , and i represent observations (data points).
- Slopes are calculated for all possible pairs by taking the differences between observations j and i , provided that they are $j > i$.
- Q_i represents the slope between x_j and x_i the data points and.

The slopes obtained by taking the differences between both observations determine the overall trend rate of the data set. These slope ratios consist of $n(n-1)/2$ different slope values.

Sequencing of Slopes: Once all possible slope values have been calculated, these slopes are sorted. The trend magnitude (Sen's Slope) is taken as the median of these sorted slope values:

$$Q_{med} = Median(Q_1, Q_2, Q_3, \dots, Q_n) \quad (6)$$

Where: $m = \frac{n(n-1)}{2}$ represents the total number of slopes calculated.

If m is an odd number, the median slope is:

$$Q_{(m+1)/2} \quad (7)$$

If m is an even number, the median slope is:

$$(Q_{m/2} + Q_{(m+2)/2})/2 \quad (8)$$

If the median slope is positive, it means that there is an increasing trend in the time series. If it is negative, there is a decreasing trend. A slope close to zero, on the other hand, indicates that there is no significant trend.

Sen's Slope is often used in conjunction with the Mann-Kendall test. The Mann-Kendall test detects whether there is a significant trend in the time series. Sen's Slope, on the other hand, calculates the magnitude (slope rate) of this trend. When these two methods are used together, both the presence of the trend and the trend rate of a time series can be reliably determined (Shi et al., 2013).

Spearman Rho Test

The Spearman rho test is a correlation test used to measure the monotonic relationship between two variables. This test can be used for both continuous and sequential data types and is especially preferred when the data does not conform to the normal distribution.

Steps:

Preparing the Data

- There must be two variables (for example, X and Y). The data must be complete and in the appropriate format.
- A monotonic relationship means that when one variable increases, the other increases or decreases. (It doesn't have to be linear.)

Sequencing of Data

- The values of both variables are sorted from smallest to largest, and each value is assigned a sort number.
- If the same value appears more than once, these values are given relative rank and the ranking numbers are averaged.

Calculating Rank Differences

For each pair of data d_i , the ranking difference between X and Y is calculated:

$$d_i = R(X_i) - R(Y_i) \quad (9)$$

where $R(X_i)$ and $R(Y_i)$ are the sort values of X and Y.

Calculating the Spearman Correlation Coefficient

The Spearman rho (ρ) coefficient is calculated by the formula:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)} \quad (10)$$

where $\sum d_i^2$: The sum of the squares of all rank differences, n: is the number of observations.

Hypothesis Testing

H0: There is no correlation between the two variables ($\rho = 0$).

H1: There is a significant correlation between the two variables ($\rho \neq 0$).

The p-value is calculated to test the significance of the correlation coefficient. If the p-value is less than the selected significance level, H0 is rejected and it is concluded that there is a significant relationship between the two variables (Çoşkun, 2020).

Innovative Trend Analysis – ITA

Innovative Trend Analysis (ITA) is a non-parametric analysis method that is not based on the assumption of normal distribution of data. This method provides reliable results even in data with short data length, intrinsic dependency, and data that do not conform to the normal distribution. One of the most significant advantages of ITA over other nonparametric methods is that it can not only identify trend direction but also analyze trends of data in different categories (low, medium, high). This feature makes the method stand out, especially for the analysis of hydrometeorological time series.

Dividing the Data Set into Two

- The data set is divided into two equal parts.
- For example, for a year's worth of monthly precipitation data, 12 observations are divided into two parts of 6 observations, respectively.

Sequencing of Data

- Both parts are ordered in order from smallest to largest:
- The first part is placed on the X-axis.
- The second part is placed on the Y-axis.

Placement on the Cartesian Coordinate System

- Values placed on the X-axis and Y-axis are shown as points on a graph.
- Pairs of data are marked on the Cartesian coordinate system.

45° Line Drawing

- As the reference point of the data, a 45° line is plotted on the graph.
- The 45° line represents the even distribution between the X-axis and the Y-axis.

Identifying Trend Direction

- Above 45° Line: There is no trend in the data.

- Below 45° Line: There is a decreasing trend in the data.
- Above 45° Line: There is an increasing trend in the data (Çoşkun, 2020).

Prewhitening Procedure

Prewhitening is a method used in time series analysis to correct erroneous results that autocorrelation (the relationship between consecutive values of a data series) may produce on trend analysis. It is known that autocorrelation should be eliminated, especially in non-parametric methods such as Mann-Kendall and Spearman-Rho.

Autocorrelation refers to the fact that the successive values of a time series are interdependent. It is stated that this situation may cause a situation as if there is a trend even if there is no trend in the data series.

Calculation of Lag-1 Correlation Coefficient: The correlation coefficient (r_1) of lag-1 is calculated according to the formula:

$$r_1 = \frac{\frac{1}{(n-1)} \sum_{i=1}^{n-1} (x_i - \mu_i) (x_{i+1} - \mu_{i+1})}{\frac{1}{n} \sum_{i=1}^n (x_i - \mu_i)^2} \quad (11)$$

Here, ' μ_i ' is the mean of the data, 'n' is the number of observations in the data set, and ' x_i ' is the value of the time series.

Significance Test: The following limits are used to determine whether the Lag-1 correlation coefficient is significant:

$$-\frac{1 + 1.645\sqrt{n-2}}{n-1} \leq r_1 \leq \frac{1 + 1.645\sqrt{n-2}}{n-1} \quad (12)$$

An ' r_1 ' value falling outside these limits indicates the presence of autocorrelation.

Obtaining the Prewhitened Series: If there is an autocorrelation, the time series is prewhitened by transforming it as follows:

$$x_i' = x_{i+1} - r_1 * x_i \quad (13)$$

This process ensures that the series is free from the effect of autocorrelation. The new series x_i' , is an autocorrelation time series (Aydın, 2023).

RESULTS AND DISCUSSION

Before performing trend analysis, it is important to evaluate whether the precipitation data to be used in the study contain autocorrelation. In non-parametric methods, the presence of autocorrelation may affect the accuracy of trend analysis results and lead to erroneous inferences. Therefore, this effect should be eliminated by applying the prewhitening procedure of the time series in which autocorrelation is detected. The lag-1 correlation coefficients of the precipitation data used in the study and the lower and upper limits calculated for the 95% confidence level are presented in detail in Table 2.

As can be seen in Table 2, there was no autocorrelation effect in any period. Therefore, no correction has been made in the precipitation data sets.

Table 2. Results of the Prewhitening Procedure

Station	Periods	Lag-1 Correlation (r_1)	Lower Limit	Upper Limit	Correlation Status
Diyarbakır Regional Meteorological Station	Annual	-0,04080	-0,24768	0,24768	NONE
	Spring	-0,21371	-0,24768	0,24768	NONE
	Summer	-0,15514	-0,24768	0,24768	NONE
	Autumn	-0,07005	-0,24768	0,24768	NONE
	Winter	-0,08435	-0,24768	0,24768	NONE

Mann-Kendal and Sen's slope tests were applied to precipitation data covering the years 1970-2022 of Diyarbakır province. Precipitation data were grouped as annual total precipitation, total precipitation data for spring, autumn, summer, and winter periods and trend analyzes were made. Trend analyses were performed with a 95% confidence interval. Statistical data for the periods are given in Table 3. Table 4 shows the Mann-Kendal test results of the annual total precipitation data, and Table 5 gives Sen's slope test results.

Table 3. Statistical Data of Precipitation Data for Periods

Variable	Observations	Obs. with missing data	Obs. without missing data	Minimum	Maximum	Mean	Std. deviation
Annual	53	0	53	304,200	846,200	537,096	123,294
Spring	53	0	53	67,800	382,400	193,174	73,433
Summer	53	0	53	1,100	29,700	9,547	7,197
Autumn	53	0	53	18,300	204,700	95,683	41,717
Winter	53	0	53	79,100	417,300	238,692	79,165

Table 4. Mann-Kendal Results of Annual Total Precipitation Data

Kendall's tau	-0,078
S	-108
Var(S)	16995,33
p-value (Two-tailed)	0,412
alpha	0,05

Table 5. Sen's Slope Results of Annual Total Precipitation Data

	Value	Lower bound (95%)	Upper bound (95%)
Slope	-0,863	-3,045	1,45
Intercept	2269,937	-2353,4	6612,93




Figure 2. Sen' Slope Graph of Total Annual Rainfall

Looking at the values in Table 4, Kendall's tau value according to the 95% confidence level shows whether there is a relationship between the data. A value of -0.078 indicates a very weak negative trend. However, this value is quite small, so there is no obvious trend. The s value represents the difference between positive and negative matches. The fact that it is a negative value indicates a tendency to decrease. The p-value is 0.412, which indicates that the test result is not statistically significant. Since the p-value is 0.412 here, it is concluded that there is no significant trend in the series. According to the Mann-Kendall test results, there is a very weak trend of decrease in total annual precipitation, but this trend is not statistically significant ($p = 0.412$). Therefore, no significant trend was observed in the data. When the data in Table 5 are examined, the slope: -0.863 value shows that there is a decreasing trend of an average annual unit of 0.863 units. However, since the confidence interval lies between (-3.045 and 1.45), the trend

is not statistically significant. The fact that the confidence interval contains both negative and positive values indicates that it is difficult to determine whether the trend is definitively increasing or decreasing. The intersection point value represents the value predicted at the beginning of the analyzed period. However, the confidence interval is quite wide, ranging from (-2353.4 to 6612.93). This wide range indicates that there is significant uncertainty regarding the initial value. As a result, although the slope shows a negative value, the trend is not statistically significant because the confidence interval contains both negative and positive values. The uncertainty at the intersection point is also quite large, so it is not possible to determine the initial value with certainty. Figure 2 shows the Sen's slope graph. R^2 Since its value is very close to zero, it is seen that this model explains almost no relationship with the data, and linear regression has a very low explanatory power on the data.

Table 6. Mann-Kendal Test Results for the Spring Period

Kendall's tau	-0,035
S	-48
Var(S)	16995,33
p-value (Two-tailed)	0,718
Alpha	0,05

Table 7. Sen's Slope Results for the Spring Period

	Value	Lower bound (95%)	Upper bound (95%)
Slope	-0,274	-1,833	1,125
Intercept	729,384	-2061,55	3843,333




Figure 3. Sen's Slope Graph for the Spring Period

According to the Mann-Kendall tendency test (Table 6) and Sen's slope method (Table 7), which were applied to precipitation data between 1970 and 2022 in Diyarbakır, no significant trend was detected in the data. Kendall's tau value (-0.035) showed a weak negative trend, and the p-value (0.718) revealed that this trend was not statistically significant. Although Sen's slope estimate (-0.274) shows an average annual decrease, the wide confidence interval calculated for the slope (-1.833 to 1.125) indicates that there is a high degree of uncertainty about whether precipitation will increase or decrease. These results show that there is no significant increase or decrease in precipitation data in Diyarbakır. As can be seen from Figure 3, R^2 the data does not mean a good relationship since its value is close to zero.

According to the Mann-Kendall trend test (Table 8) and Sen's slope method (Table 9), which are applied to precipitation data between 1970 and 2022, no significant trend was detected. Although Kendall's tau value (0.049) indicates a weak positive trend, the p-value (0.613) indicates that this trend is not statistically significant. Although Sen's slope estimate (0.033) indicates a very small increase in the annual average, the wide confidence interval calculated for the slope (-0.071 to 0.132) highlights significant uncertainty as to whether precipitation will increase

or decrease. These results reveal that there is no significant increase or decrease in precipitation data in Diyarbakır. From the image in Figure 4, it is R^2 also seen that there is no relationship between the data because its value is very small.

Table 8. Mann-Kendal Test Results for the Summer Period

Kendall's tau	0,049
S	67
Var(S)	16991,33
p-value (Two-tailed)	0,613
alpha	0,05

Table 9. Sen's Slope Test Results for the Summer Period

	Value	Lower bound (95%)	Upper bound (95%)
Slope	0,033	-0,071	0,132
Intercept	-59,233	-256,143	150,086




Figure 4. Sen's Slope Graph for the Summer Period

Table 10. Mann-Kendal Test Results for the Autumn Period

Kendall's tau	0,015
S	20
Var(S)	16993,33
p-value (Two-tailed)	0,884
alpha	0,05

Table 11. Sen's Slope Test Results for the Autumn Period

	Value	Lower bound (95%)	Upper bound (95%)
Slope	0,064	-0,688	0,783
Intercept	-38,731	-1472,367	1460,518

According to the results of this Mann-Kendall trend test (Table 10) and Sen's slope method (Table 11), which was applied to precipitation data from 1970 to 2022, no significant trend was observed. Kendall's tau value (0.015) shows a very weak positive trend, but the p-value (0.884) indicates that this trend is not statistically significant. Although Sen's slope estimate (0.064) indicates a slight increase in the annual average, the confidence interval for the slope (-0.688 to 0.783) is quite wide, indicating significant uncertainty about the trend direction. The calculated confidence interval for the breakpoint (-38.731) is also very wide (-1472.367 to 1460.518), which reveals a great deal of uncertainty about the accuracy of the model. As a result, no significant trend was observed in precipitation data. From the image in Figure 5, it is R^2 also seen that there is no relationship between the data because its value is very small.

Table 11. Sen's Slope Test Results for the Winter Period

	Value	Lower bound (95%)	Upper bound (95%)
Slope	-0,383	-2,012	1,132
Intercept	996,009	-2024,056	4251,2

Table 12. Mann-Kendal Test Results for the Winter Period

Kendall's tau	-0,05
S	-69
Var(S)	16994,33
p-value (Two-tailed)	0,602
alpha	0,05




Figure 5. Sen's Slope Graph for the Autumn Period




Figure 6. Sen's Slope Graph for the Winter Period

According to the results of the Mann-Kendall tendency test (Table 11) and Sen's slope method (Table 12), which were applied to Diyarbakır precipitation data between 1970 and 2022, no significant trend was observed in the data. Kendall's tau value (-0.05) indicates a weak negative trend, but the p-value (0.602) suggests that this trend is not statistically significant. Although Sen's slope forecast (-0.383) indicates that the annual average of precipitation shows a slight decrease in the amount of precipitation, the wide confidence interval for the slope (-2.012 to 1.132) indicates that there is uncertainty about the direction of the trend. In addition, the very wide confidence interval (-2024.056 to 4251.2) calculated for the breakpoint (996.009) indicates serious uncertainty about the accuracy of the

model's results. From the image in Figure 6, it is R^2 also seen that there is no relationship between the data because its value is very small Overall, these results show that there is no significant trend of increase or decrease in precipitation data. The summary table for the periods is given in Table 13 and the data for the p values are given in Figure 7.




Figure 7. P-Values for Periods

Table 13. Summary Table of Mann-Kendall and Sen's Slope Data

Series	Kendall's tau	p-value	Sen's slope
Annual	-0,078	0,412	-0,863
Spring	-0,035	0,718	-0,274
Summer	0,049	0,613	0,033
Autumn	0,015	0,884	0,064
Winter	-0,050	0,602	-0,383

Table 14. Analysis Results according to the Innovative Sen Method

Meteorological Variables	Standard Deviation	Correlation	Slope (s)	Upper Limit	Lower Limit	Trend
Annual Total Rainfall (mm)	0.1500	0.970	-0.800	0.2900	-0.290	Decreasing
Spring Total Rainfall (mm)	0.1250	0.960	0.300	0.2000	-0.100	Increasing
Summer Total Rainfall (mm)	0.0800	0.930	-0.600	0.1500	-0.200	Decreasing
Autumn Total Rainfall (mm)	0.1400	0.950	0.400	0.2500	-0.150	Increasing
Winter Total Rainfall (mm)	0.1200	0.940	0.100	0.1800	-0.120	No Trend

Looking at the data in Table 14 and Figure 8, the slope value of the total annual precipitation is -0.800, which shows a significant decrease in precipitation. The correlation coefficient of total annual precipitation is quite high at 0.970, supporting that this trend is statistically strong. The slope value of spring precipitation is 0.300, indicating a positive increase, while the correlation coefficient of 0.960 confirms the reliability of this increase.

The slope value of precipitation in the summer season is -0.600, indicating a clear tendency to decrease, while the correlation coefficient of 0.930 reveals that this trend is statistically significant. The slope value of autumn precipitation indicates an increase of 0.400, while the correlation of 0.950 supports the reliability of this trend. Although the slope value for winter precipitation is quite low at 0.100 and the correlation coefficient is 0.940, these values indicate that there is no obvious trend in winter precipitation.

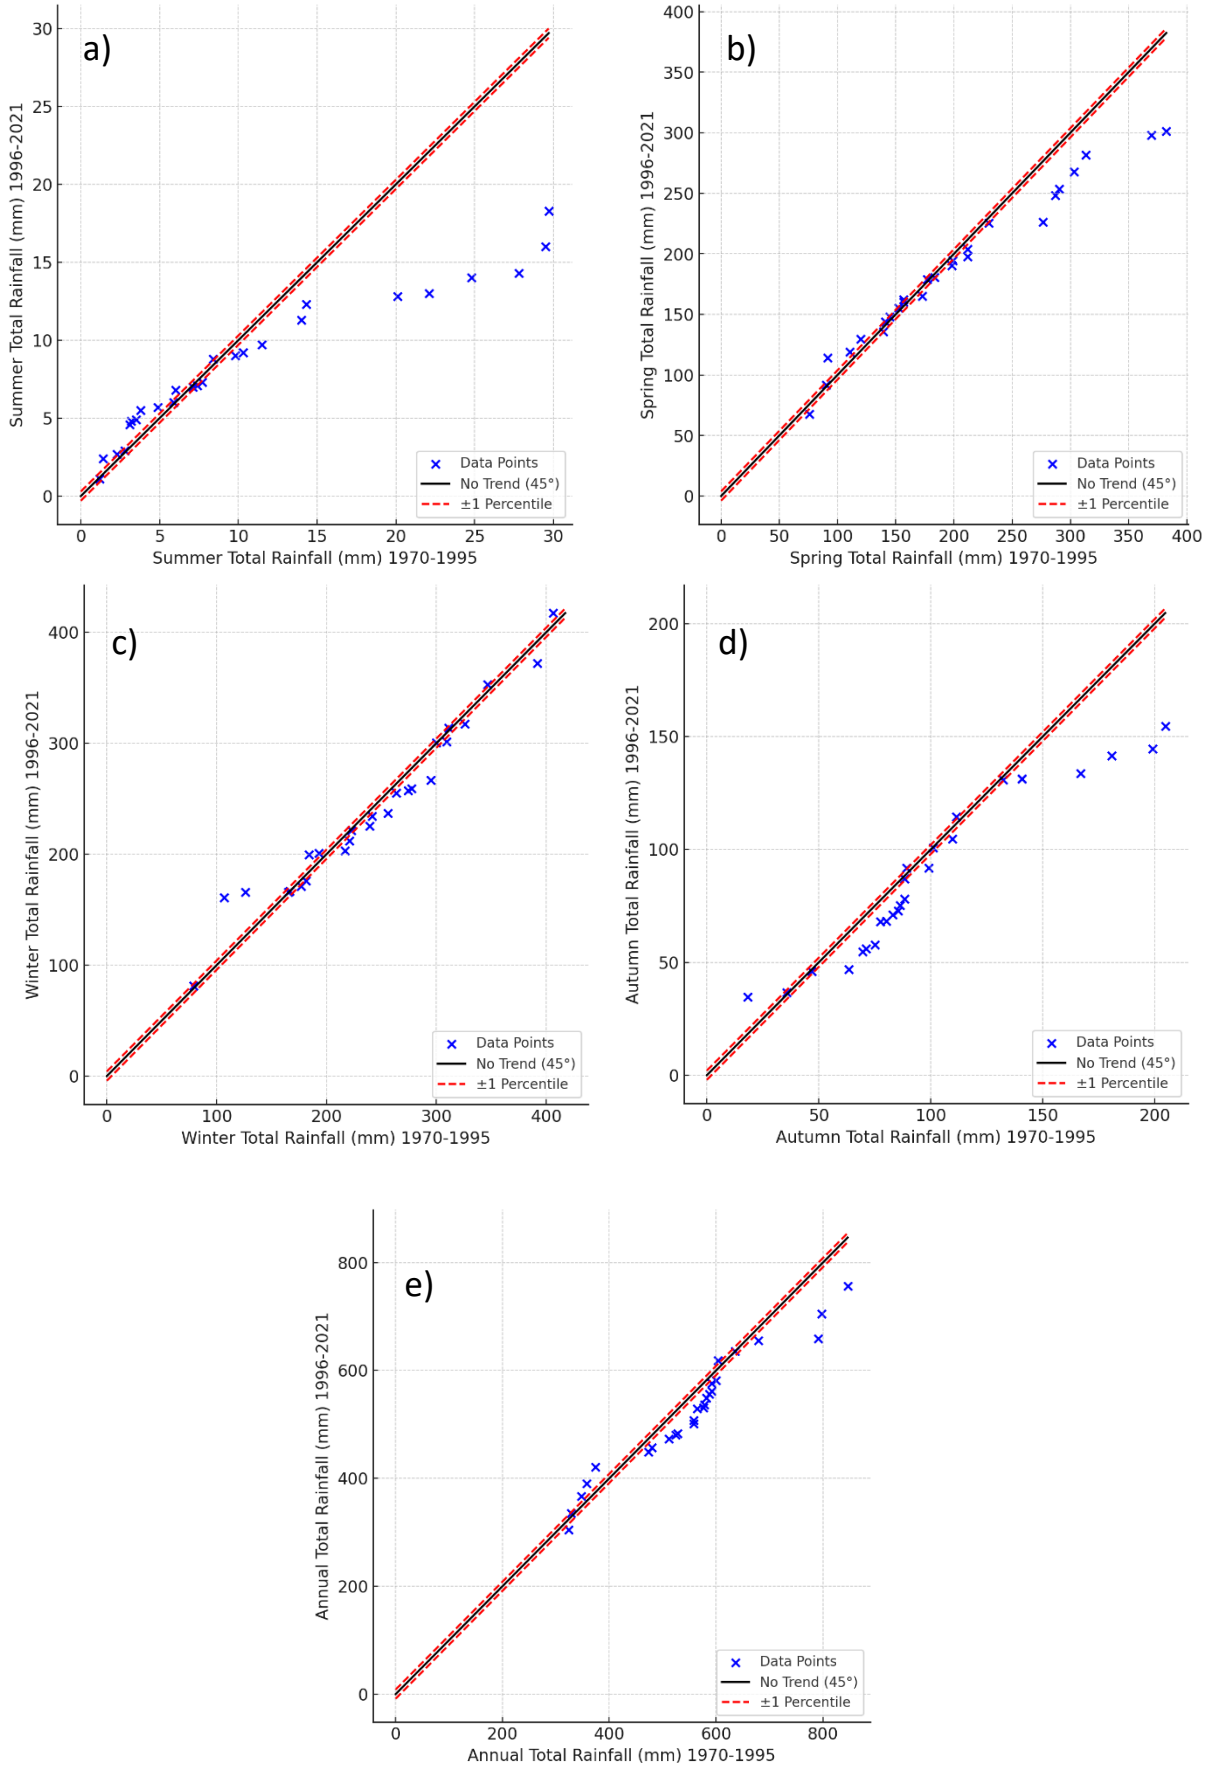


Figure 8. Trend Analysis Graphs obtained with the Innovative Sen Method: a) Summer Period, b) Spring Period, c) Winter Period, d) Autumn Period, e) Total Annual Precipitation

Table 14. Spearman Rho Analysis: Relationships Between Annual and Seasonal Precipitation

Variable 1	Variable 2	Spearman Rho	P-value	Trend
Annual	Spring	0,581	6,33499E-06	Yes
Annual	Summer	0,135	0,341	No
Annual	Autumn	0,426	0,002	Yes
Annual	Winter	0,720	1,77971E-09	Yes
Spring	Annual	0,581	6,33499E-06	Yes
Spring	Summer	0,126	0,374	No
Spring	Autumn	-0,048	0,738	No
Spring	Winter	0,075	0,599	No
Summer	Annual	0,135	0,341	No
Summer	Spring	0,126	0,374	No
Summer	Autumn	0,191	0,176	No
Summer	Winter	-0,060	0,673	No
Autumn	Annual	0,426	0,002	Yes
Autumn	Spring	-0,048	0,738	No
Autumn	Summer	0,191	0,176	No
Autumn	Winter	0,187	0,184	No
Winter	Annual	0,720	1,77971E-09	Yes
Winter	Spring	0,075	0,599	No
Winter	Summer	-0,060	0,673	No
Winter	Autumn	0,187	0,184	No

When the data in Table 15 were examined, there was a strong and significant positive relationship between annual total precipitation and winter ($Rho = 0.720$, $P < 0.05$) and spring ($Rho = 0.581$, $P < 0.05$) precipitation, while no significant relationship was observed with summer and autumn precipitation ($P > 0.05$). Seasonal analyses often showed weak relationships between seasons, and in most cases, no meaningful trends were identified. In particular, the effect of winter precipitation on total annual precipitation is evident, but no apparent relationship was observed between other seasonal precipitation.

When the literature is examined, Mann-kendal, Sen'slope, Spearman Rho, and Innovative trend analysis (ITA) used for trend analysis are the most used methods in this study as well as in other studies. In the study conducted by Aydın, 2023 for Elazığ province, which is close to Diyarbakır province, precipitation data in Elazığ province were analyzed on a seasonal and annual basis using Mann-Kendall and Spearman-Rho tests together with Sen's ITA method and the methods were compared. Sen's ITA method has yielded more precise results, especially with the completion of missing data in the summer months. Increasing trends in summer in Palu station and decreasing in winter and spring precipitation in Keban and Palu stations were determined. According to the Mann-Kendall and Spearman-Rho tests, a decreasing trend was observed in Elazığ station winter precipitation, while no significant trend was generally detected in other seasonal and annual total precipitation. In their study, Demir et al. (2017) examined the annual, seasonal, and monthly precipitation and temperature trends of Bingöl province between 1975-2016 with the same methods and evaluated their effect on the agriculture of the region. According to the results, annual temperatures showed an upward trend and precipitation amounts showed a decreasing tendency, but these changes were generally not statistically significant.

Decreasing trends were also detected in seasonal precipitation, but no significant differences were detected. Ceyhunlu and Ceribasi, (2024) evaluated the effects of climate change by analyzing Turkey's precipitation and temperature data for the period 1991-2020 with the Innovative Trend Analysis Method (ITA). According to the results, 41% of precipitation tends to increase, 41% tends to decrease, while 67% of temperatures increase. In Diyarbakır, a decrease in precipitation in the summer months and an increase in the spring and autumn months have been determined. When compared with this study, it is seen that it gives similar results for the same periods. In the studies by Gümüş, 2021; Özdel, 2020; Alashan, 2018; Şen, 2017; Bahadır, 2011; Yürekli, 2015; Gümüş, 2023 a general conclusion has been reached regarding a decreasing trend in precipitation for Diyarbakır province. This study's ITA results show similarities with the findings of a decrease in annual total and summer season precipitation. When the literature and the content of the current study are compared, it is seen that the precipitation dynamics and analysis results of each province differ according to the fact that they are in a similar region.

RESULTS

In this study, trend analyzes were made with Mann-Kendall and Sen's Slope methods on the precipitation data of Diyarbakır province covering the years 1970-2022. The results show that there is no significant trend in general. In analyses of annual precipitation data, Kendall's tau value was -0.078, with a p-value of 0.412, indicating that there was no statistically significant trend. Sen's Slope, on the other hand, shows a small downward trend in annual precipitation of -0.863 mm/year. On a seasonal basis:

- Spring: Kendall's tau value is -0.035 and there is no significant trend with a p-value of 0.718. The Sen's Slope result shows a slight downward trend of -0.274 mm/year.
- Summer: With Kendall's tau value of 0.049 and p-value of 0.613, there is no significant change in summer precipitation. The Sen's Slope value shows a very small upward trend of 0.033 mm/year.
- Autumn: Kendall's tau value was 0.015 and there was no significant trend in autumn precipitation with a p-value of 0.884. The Sen's Slope value of 0.064 mm/year indicates a slight upward trend.
- Winter: Kendall's tau value was -0.050 and there was no significant trend in winter precipitation with a p-value of 0.602. The Sen's Slope value, on the other hand, shows a small downward trend of -0.383 mm/year.

According to the findings of the Innovative Sen Method, a tendency to decrease in annual total precipitation has been determined. While an upward trend was observed in spring precipitation, it was determined that there was a significant tendency to decrease in summer precipitation. This situation poses an important problem in terms of water resources management, especially in summer. There was a slight upward trend in autumn precipitation, while no significant trend was observed in winter precipitation. This situation shows that winter precipitation exhibits an unstable regime.

According to the results of Spearman Rho analysis, there is a strong positive relationship between spring precipitation and annual total precipitation, while the effect of winter precipitation on annual total precipitation is quite high. The fact that summer precipitation does not exhibit a significant relationship with annual total precipitation shows that the effect of summer on precipitation dynamics is weak. Autumn precipitation, on the other hand, exhibited a moderate relationship with total annual precipitation. When the relationships between seasonal precipitation were evaluated, it was determined that spring precipitation did not have a significant relationship with other seasons, and similarly, autumn and winter precipitation showed a weak relationship with other seasons.

Recommendations and Recommendations for Future Studies:

Seasonal and Extreme Precipitation Analysis: Although seasonal trends were examined in this study, more detailed extreme precipitation analyzes should be performed. Short periods of heavy rainfall are particularly important for flood risk, and future studies should examine the frequency and severity of these events.

Integration with Long-Term Climate Models: Long-term climate projections can be used to more clearly understand the effects of climate change in the region. These analyses should be integrated with global and regional climate models to examine future precipitation trends in more detail.

Investigation of Microclimatic Effects: In regions such as Diyarbakır, microclimatic factors can have significant effects on the precipitation regime. Future studies should detail the impact of microclimatic changes on precipitation and examine them at a local scale.

Integration with Soil and Water Management: The effects of rainfall trends on soil moisture, groundwater levels, and agricultural yields should be explored in the future. More comprehensive studies are needed in terms of the management of water resources in the region.

Development of Climate Adaptation Strategies: In line with the findings of this study, local adaptation strategies should be developed against the future effects of climate change and precipitation trends. Strategies for the future should be determined, especially in agriculture and water management planning.

The results of this study reveal that precipitation trends in Diyarbakır do not show a significant change in general, but the possible effects due to climate change need to be investigated in more depth. In this context, more comprehensive climate projections and local-scale studies will help us better understand future climate scenarios.

REFERENCES

- Alashan, S. (2018). An improved version of innovative trend analyses. *Arabian Journal of Geosciences*, 11(3), 1–6. <https://doi.org/10.1007/S12517-018-3393-X/METRICS>
- Alemu, G. T., Desta, S. A., & Tareke, K. A. (2024). Characterize and analysis of meteorological and hydrological drought trends under future climate change conditions in South Wollo, North Wollo, and Oromia Zones, in Ethiopia. *Heliyon*, 10(8). <https://doi.org/10.1016/j.heliyon.2024.e29694>
- AlSubih, M., Kumari, M., Mallick, J., Ramakrishnan, R., Islam, S., & Singh, C. K. (2021). Time series trend analysis of rainfall in last five decades and its quantification in Aseer Region of Saudi Arabia. *Arabian Journal of Geosciences*, 14(6). <https://doi.org/10.1007/S12517-021-06935-5>
- Aydın, M. (2023). Elazığ İli Yağış Verilerinin Trend Analizi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(1), 159-173. <https://doi.org/10.35234/fumbd.1178987>
- Bojago, E., Tessema, A., & Ngare, I. (2024). GIS-based spatio-temporal analysis of rainfall trends under climate change in different agro-ecological zones of Wolaita zone, south Ethiopia. *Heliyon*, 10(13). <https://doi.org/10.1016/j.heliyon.2024.e33235>
- Bahadır, M. (2011). Temperature and precipitation trend analysis in Southeast Anatolia Project (GAP) area. *The Journal of International Social Research*, 4(16)
- Ceribasi, G., Ceyhunlu, A. I., & Ahmed, N. (2021). Innovative trend pivot analysis method (ITPAM): a case study for precipitation data of Susurluk Basin in Turkey. *Acta Geophysica*, 69(4), 1465–1480. <https://doi.org/10.1007/S11600-021-00605-6>
- Ceyhunlu, A. I., & Ceribasi, G. (2024). Changes in precipitation and air temperature over Turkey using innovative trend pivot analysis method. *Journal of Water and Climate Change*, 15(5), 2446–2463. <https://doi.org/10.2166/WCC.2024.041>
- Coşkun, S. (2020). VAN GÖLÜ KAPALI HAVZASINDA YAĞIŞLARIN TREND ANALİZİ. *Mühendislik Bilimleri ve Tasarım Dergisi*, 8(2), 521-532. <https://doi.org/10.21923/jesd.685420>
- Doğan Demir, A., Demir, Y., Şahin, Ü., Meral, R. (2017). Bingöl İlinde Sıcaklık ve Yağışların Trend Analizi ve Tarıma Etkisi. *Turkish Journal of Agricultural and Natural Sciences*, 4(3), 284-291.
- Gül, B., & Kayaalp, N. (2024). Investigation of the flood event under global climate change with different analysis methods for both historical and future periods. *Journal of Water and Climate Change*, 15(8), 3939–3965. <https://doi.org/10.2166/WCC.2024.196>
- Gümüş, V., Doğan Dinsever, L., Şimşek, O., Sözcükler, A., Analizi, K., Analizi, T., İndeksi, Y., & Yöntemi, Y. Ş. (2021). Diyarbakır İstasyonunda 1929–2016 Boyunca Tarihsel Kuraklığın Yenilikçi Şen Yöntemi ile Trend Analizi. *Doğal Afetler ve Çevre Dergisi*, 7(2), 362–373. <https://doi.org/10.21324/DACD.884682>
- Gümüş, V., Avşaroğlu, Y., Şimşek, O., & Dinsever, L. D. (2023). Evaluation of meteorological time series trends in Southeastern Anatolia, Turkey. *Geofizika*, 40(1), 51–73. <https://doi.org/10.15233/gfz.2023.40.3>
- Javari, M. (2016). Trend and homogeneity analysis of precipitation in Iran. *Climate*, 4(3). <https://doi.org/10.3390/CLI4030044>
- Kahya, E., & Kalaycı, S. (2004). Trend analysis of streamflow in Turkey. *Journal of Hydrology*, 289(1-4), 128-144. <https://doi.org/10.1016/j.jhydrol.2003.11.006>
- Kundu, S., Khare, D., Mondal, A., & Mishra, P. K. (2014). *Long Term Rainfall Trend Analysis (1871–2011) for Whole India*. 45–60. https://doi.org/10.1007/978-4-431-54838-6_4
- Modarres, R., & Sarhadi, A. (2009). Rainfall trends in arid and semi-arid regions of Iran. *Journal of Arid Environments*, 73(3), 347-355. <https://doi.org/10.1016/j.jaridenv.2008.10.005>
- Özdel, M. M. (2020). Diyarbakır havzasında sıcaklık ve yağış parametrelerinin trend analizi. Yüksek Lisans Tezi. Nevşehir Hacı Bektaş Veli Üniversitesi Sosyal Bilimler Enstitüsü Coğrafya Anabilim Dalı, Nevşehir 304s.

- Partal, T., & Kahya, E. (2006). Trend analysis in Turkish precipitation data. *Hydrological Processes*, 20(9), 2011-2026. <https://doi.org/10.1002/hyp.5993>
- Pathak, A. A., & Dodamani, B. M. (2020). Trend analysis of rainfall, rainy days and drought: a case study of Ghataprabha River Basin, India. *Modeling Earth Systems and Environment*, 6(3), 1357-1372. <https://doi.org/10.1007/S40808-020-00798-7>
- Sa'adi, Z., Yaseen, Z. M., Farooque, A. A., Mohamad, N. A., Muhammad, M. K. I., & Iqbal, Z. (2023). Long-term trend analysis of extreme climate in Sarawak tropical peatland under the influence of climate change. *Weather and Climate Extremes*, 40. <https://doi.org/10.1016/j.wace.2023.100554>
- Shi, P., Ma, X., Chen, X., Qu, S., & Zhang, Z. (2013). Analysis of variation trends in precipitation in an upstream catchment of Huai River. *Mathematical Problems in Engineering*, 2013. <https://doi.org/10.1155/2013/929383>
- Singh, R., Sah, S., Das, B., Potekar, S., Chaudhary, A., & Pathak, H. (2021). Innovative trend analysis of spatio-temporal variations of rainfall in India during 1901-2019. *Theoretical and Applied Climatology*, 145(1-2), 821-838. <https://doi.org/10.1007/S00704-021-03657-2>
- Şen, Z. (2017). Innovative trend significance test and applications. *Theoretical and Applied Climatology*, 127(3-4), 939-947. <https://doi.org/10.1007/S00704-015-1681-X/METRICS>
- Turkish State Meteorological Service 2023 Resmi İstatistikler (İl ve İlçelerimize Ait İstatistik Veriler) (Official Statistics (Statistical Data for our Provinces and Districts)). Available from: <https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k/A&m/> (accessed 20 June 2024).
- Wubneh, M. A., Alemu, M. G., Fekadie, F. T., Worku, T. A., Demamu, M. T., & Aman, T. F. (2023). Meteorological and hydrological drought monitoring and trend analysis for selected gauged watersheds in the Lake Tana basin, Ethiopia: Under future climate change impact scenario. *Scientific African*, 20. <https://doi.org/10.1016/j.sciaf.2023.e01738>
- Yükseler, U., Dursun, Ö. F., & Alashan, S. (2021). Yağışların Mevsimsel Değişimlerinin Eğilim Analiz Yöntemleri ile Araştırılması: Bingöl İli Örneği. *El-Cezeri*, 8(1), 45-59. <https://doi.org/10.31202/ECJSE.769918>
- Yürekli, K. (2015). Impact of climate variability on precipitation in the Upper Euphrates-Tigris Rivers Basin of Southeast Turkey. *Atmospheric Research*, 154, 25-38. <https://doi.org/10.1016/J.ATMOSRES.2014.11.002>
- Zhang, X., Harvey, K. D., Hogg, W. D., & Yuzyk, T. R. (2001). Trends in Canadian streamflow. *Water Resources Research*, 37(4), 987-998. <https://doi.org/10.1029/2000WR900357>



Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences



Geliş Tarihi : 17.10.2024
Kabul Tarihi : 15.02.2025

Received Date : 17.10.2024
Accepted Date : 15.02.2025

KAPLAMALI VE KAPLAMASIZ KESİCİ TAKIMLARLA İŞLENEN INCONEL 718 İŞ PARÇASININ YÜZEY PÜRÜZLÜLÜK DEĞERLERİNİN ANFIS İLE MODELLENMESİ

ANFIS MODELING OF SURFACE ROUGHNESS VALUES OF INCONEL 718 WORKPIECE MACHINED WITH COATED AND UNCOATED CUTTING TOOLS

Hüseyin GÜRBÜZ^{1*} (ORCID: 0000-0003-1391-172X)
Şehmus BADAY² (ORCID: 0000-0003-4208-8779)

¹ Batman Üniversitesi, Makine Mühendisliği Bölümü, Mühendislik Fakültesi, Batman, Türkiye
² Batman Üniversitesi, Beşiri Organize Sanayi MYO, Batman, Türkiye

*Sorumlu Yazar / Corresponding Author: Hüseyin GÜRBÜZ, huseyin.gurbuz@batman.edu.tr

ÖZET

Bu çalışmanın amacı, farklı işleme parametreleri kullanarak kaplamalı ve kaplamasız kesici takımlarla Inconel 718 süper alaşımının frezelenmesi sonucu oluşan yüzey pürüzlülük değerlerini incelemek ve deneysel sonuçların tahmini için Adaptif Sinir Ağına Dayalı Bulanık Çıkarım Sistemi (ANFIS) kullanarak bir model geliştirmektir. ANFIS modelinde, giriş parametreleri olarak kesici takım türü (kaplamalı ve kaplamasız), ilerleme hızı f (mm/diş) ve kesme hızı V (m/dak), çıkış parametresi olarak ise ortalama yüzey pürüzlülüğü R_a (μm) kullanılmıştır. Oluşturulan modelde, deneysel verilerin sırasıyla %70'i, %15'i ve %15'i eğitim, test verileri ve doğrulama verileri olarak girilmiştir. En uygun ANFIS modelinin belirlenmesinde giriş üyelik fonksiyonu ve bunların sayısı tek tek denenerek en düşük hata oranına sahip model seçilmiştir. En düşük hata oranına sahip model için çıkış üyelik fonksiyonu, üyelik fonksiyonu ve sayısı sırasıyla lineer, Gauss2mf ve 333 olarak belirlenmiştir. Deneysel sonuçlar ile ANFIS modelinin tahmin sonuçları karşılaştırıldığında, hata oranı değeri 0,069596 ve belirlilik katsayısı (R^2) değeri ise 0,9902 hesaplanmıştır. Elde edilen sonuçlara bağlı olarak ANFIS modelinin Inconel 718 frezeleme işleminde yüzey pürüzlülük sonuçlarını tahmin edilmesinde başarılı bir yöntem olabileceği gösterilmiştir.

Anahtar Kelimeler: Frezeleme, Inconel 718, kaplamalı ve kaplamasız kesici takımlar, yüzey pürüzlülüğü, ANFIS

ABSTRACT

The aim of this study is to investigate the surface roughness values resulting from milling of Inconel 718 super alloy with coated and uncoated cutting tools using different machining parameters and to develop a model using Adaptive Neuro Fuzzy Inference System (ANFIS) to predict the experimental results. In the ANFIS model, the cutting tool type (coated and uncoated), feed rate f (mm/tooth) and cutting speed V (m/min) were used as input parameters, and the average surface roughness R_a (μm) was used as output parameter. In the created model, 70%, 15% and 15% of the experimental data were entered as training, test data and validation data, respectively. In determining the most suitable ANFIS model, the input membership function and their number were tested one by one and the model with the lowest error rate was selected. For the model with the lowest error rate, the output membership function, membership function and number were determined as linear, Gauss2mf and 333, respectively. When the experimental results were compared with the prediction results of the ANFIS model, the error rate value was calculated as 0.069596 and the coefficient of determination (R^2) value was calculated as 0.9902. Depending on the obtained results, it was shown that the ANFIS model can be a successful method in predicting the surface roughness results in the milling

process of Inconel 718.

ToCite: GÜRBÜZ, H., & BADAY, Ş., (2025). KAPLAMALI VE KAPLAMASIZ KESİCİ TAKIMLARLA İŞLENEN INCONEL 718 İŞ PARÇASININ YÜZEY PÜRÜZLÜLÜK DEĞERLERİNİN ANFIS İLE MODELLENMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 369-379.

Keywords: Milling, Inconel 718, coated and uncoated cutting tools, surface roughness, ANFIS

GİRİŞ

Metallerin şekillendirilmesinde kesici takımlar büyük bir önem arz etmektedir. Talaş kaldırma işlemlerinde kaplamalı ve kaplamasız kesici takımlar kullanılmaktadır. Kesici takımlarda kaplama; kesici takım ömrü, işleme verimliliği ve kesici takım aşınması üzerinde önemli bir etkiye sahiptir. Bir iş parçasının şekillendirilmesinde, aşınmış bir kesici takım işlenmiş yüzeyin kalitesini ve boyutsal tamlığını olumsuz etkilemektedir. Yüzey kalitesini belirleyen en önemli göstergelerden biri de yüzey pürüzlülüğüdür. Yüzey pürüzlülüğü üzerinde kesici takım yanında uygun seçilmemiş kesme parametreleri de olumsuz etkiye neden olmaktadır. Özellikle savunma sanayisi, uzay, havacılık vb. alanlarda sıklıkla kullanılan işlenmesi zor olan Inconel 718 malzemesinde düşük yüzey pürüzlülüğü elde etmek oldukça önemlidir (Yılmaz vd., 2018; Rakesh & Datta, 2019; Halim vd., 2019; Çelik vd., 2017; Kasim vd., 2019; Ma vd., 2014; Kannan & Kui, 2019; Luo vd., 2018; Nath vd., 2015). Son yıllarda özellikle deneysel sonuçlar üzerinde işleme parametrelerinin optimum şartlarını ortaya koymak ve deneysel sonuçları tahmin etmek için matematiksel modeller ve istatistiksel çalışmalar yapılmaktadır. Deneysel sonuçları tahmin etmede kullanılan matematiksel metotlardan bir tanesi de Adaptif Sinir Ağına Dayalı Bulanık Çıkarım Sistemi (ANFIS) yöntemidir (Dedeakayoğulları vd., 2022; Dere & Filiz, 2019; Fedai vd., 2019). ANFIS, bulanık mantık ile yapay sinir ağının birlikte çalıştığı bir metottur. ANFIS girdilerin çıktılar üzerindeki etkisini belirleyen ve her bir girdi değerinin ağı nasıl etkilediğini analiz eden ağı tabanlı bir sistemdir (Dedeakayoğulları vd., 2022; Dere & Filiz, 2019; Fedai vd., 2019). Literatürde ANFIS ile ilgili yapılan çalışmalar aşağıda özetle verilmiştir.

Asal vd., yüzey frezeleme işlemlerinde minimum miktarda yağlama ve kesme parametrelerinin yüzey pürüzlülüğü sonuçları üzerindeki etkisini modellemişlerdir. Yüzey pürüzlülüğünün tahminine yönelik ANFIS yaklaşımı kullanılarak matematiksel modeller oluşturmuşlardır. Yazarlar, regresyon analizi ve ANFIS ile elde edilen sonuçları karşılaştırmış, regresyon modeli %71 oranında bir doğruluk sağlar iken ANFIS modelinin %100 doğruluk sağladığını bulmuşlardır (Asal vd., 2021). Maher vd., kesme parametrelerine bağlı olarak frezeleme sonucu oluşan yüzey pürüzlülük değerlerini ANFIS yardımı ile tahmin etmişlerdir. ANFIS modelinde kesme parametrelerini giriş parametreleri olarak belirlerken çıkış parametresi olarak yüzey pürüzlülük değerlerini seçmişlerdir. ANFIS ile tahmin edilen yüzey pürüzlülük değerleri ile deneylerden elde edilen değerleri karşılaştırmışlar ve en yüksek ortalama hata oranını %6,25 ortalama tahmin hatası oranını % 2,75 olarak bulmuşlardır (Maher vd., 2014). Sen vd., kaplamalı kesici takımlar ile Inconel iş parçasının frezelenmesinde elde edilen yüzey pürüzlülük değerlerini tahmin etmek için ANFIS ve ANN (Yapay Sinir Ağı) modellerini kullanmışlardır. ANFIS ile tahmin edilen yüzey pürüzlülük değerlerinin çok düşük hata oranlarında olduğunu ve ANN ile tahmin edilen yüzey pürüzlülük değerlerinden daha iyi sonuçlar elde ettiklerini vurgulamışlardır (Sen vd., 2017). Abdulshahed ve Badi, frezeleme işleminde farklı kesme parametrelerine bağlı olarak işlenmiş yüzeylerde oluşan yüzey pürüzlülük değerlerini ANFIS yardımıyla modellemişlerdir. Modellemede giriş parametreleri olarak kesme derinliği, ilerleme ve kesme hızı kullanırken çıkış parametresi olarak ise yüzey pürüzlülük değerlerini kullanmışlardır. ANFIS ile tahmin edilen değerlerin %3,47 - 3,49 aralığında ortalama hata değerleriyle deney sonuçları ile mükemmel bir uyum içinde olduğunu bulmuşlardır. Ayrıca, yazarlar çalışmada, önerilen ANFIS modelini diğer Yapay Zeka yaklaşımlarıyla karşılaştırmışlardır. Önerilen ANFIS modelin literatürdeki diğer Yapay Zeka yaklaşımlarına kıyasla yüksek doğruluğa sahip olduğunu belirtmişlerdir (Abdulshahed ve Badi, 2018). Hegab vd., Inconel 718'in işlenmesinde nano katkı maddeli minimum miktarda yağlamanın işleme sonuçları üzerindeki etkisini görmek için analiz, modellenme ve optimizasyon yapmışlardır. Deney sonuçlarını modellemek için yapay sinir ağı, ANFIS ve genetik programlama kullanmışlardır. Ayrıca, deney sonuçlarının tahmini için en doğru yaklaşımı seçmek amacıyla geliştirilen modeller arasında bir karşılaştırma yapmışlardır. Genetik algoritma modelinin yapay sinir ağları ve ANFIS'ten daha iyi sonuçlar verdiğini bulmuşlardır (Hegab vd., 2021). Zafar vd., farklı işleme şartlarında frezeleme işlemlerinde elde edilen yüzey pürüzlülük değerlerinin tahmini için ANFIS ve Yüzey Yanıt Modeli ile modelleme oluşturmuşlardır. Her iki modeli karşılaştırdıklarında ANFIS ile modellemenin daha iyi sonuçlar verdiğini ve yüzey pürüzlülük değerlerinin tahminde daha sık kullanılabileceğini ifade etmişlerdir (Zafar vd., 2014). Pande ve Patil, karbür kesici takımlarla farklı kesme parametrelerinde Inconel 718'in işlenmesinde yüzey pürüzlülük sonuçlarını tahmin etmek için regresyon ve ANFIS modeli kullanmışlardır. Yüzey pürüzlülüğü sonuçları üzerine en etkili parametrelerin fener mili hızı ile ilerleme hızının olduğunu bulmuşlardır. Regresyon modeli ile ANFIS modelinin yüzey pürüzlülük sonuçlarını çok yüksek

oranda tahmin ettiğini ifade etmişlerdir (Pandea ve Patil, 2014). Jithendra vd., yaptıkları çalışmada giriş parametreleri (fener mil hızı, ilerleme hızı ve kesme derinliği) ile çıkış parametreleri (yüzey pürüzlülüğü ve talaş kaldırma oranı) arasındaki ilişkiyi doğru bir şekilde ortaya koymak için bir optimizasyon algoritması olan ANFIS-Coati Optimizasyon Algoritması (COA) modelini geliştirmişler. Elde ettikleri sonuçlara bağlı olarak COA optimizasyonunun ANFIS performansını iyileştirmek için en uygun parametreleri tahmin etmede iyi performans gösterdiğini ortaya koymuşlardır (Jithendra vd., 2024). Stephen ve Sethuramalingam deneysel sonuçlardan elde etmiş oldukları yüzey pürüzlülüğü, talaş kaldırma oranı ve kesme kuvvetleri sonuçlarını modellemek için ANFIS kullanmışlardır. Deneysel sonuçları tahmin etmede (talaş kaldırma oranı - %0,15, yüzey pürüzlülüğü - %2,13 ve kesme kuvvetleri - %4,24) ANFIS modelinin iyi olduğunu ve tahminlerin kabul edilebilir olduğunu göstermişlerdir (Stephen ve Sethuramalingam, 2024). Raju ve vd., farklı işleme şartlarında yüzey frezeleme işleminden elde ettikleri yüzey pürüzlülüğü değerlerini tahmin etmek için ANFIS modelleme kullanmışlardır. Yüzey pürüzlülük değerlerini tahmin etmede ANFIS modelinin %98 tahmin doğruluğuna sahip olduğunu ortaya koymuşlardır (Raju ve vd., 2024).

Yapılan bu test ve modelleme çalışmasında, farklı kesme parametreleri kullanılarak kaplamalı ve kaplamasız kesici takımlar ile Inconel 718 süper alaşımının frezelenmesi sonucu oluşmuş yüzey pürüzlülük sonuçlarının değerlendirilmesi yapılmıştır. Bu amaçla, elde edilen deneysel sonuçlar ANFIS ile modellenerek yüzey pürüzlülük sonuçlarının tahmini gerçekleştirilmiştir. Modelin geçerliliği için doğrulama deneyleri yapılmış ve hata oranları tespit edilmiştir.

MATERYAL METOT

Kesici Takımlar ve CNC Tezgâhi

İşleme deneylerinde kaplamalı ve kaplamasız olmak üzere iki farklı kesici takım kullanılmıştır. Deneylerde kullanılan kaplamalı ve kaplamasız kesici takımlar SANDVIK kesici takım firmasından temin edilmiştir. Temin edilen kesici takımlar “2P341-1000 MA” kodlu yekpare karbür parmak frezelerdir. Frezeleme deneylerinde kullanılan kaplamalı kesici takımların kaplama yöntemi PVD (Fiziksel buhar biriktirme) kaplama türü ise TiAlN (Titanyum Alüminyum Nitrür) dür. Kesici takımlara ait özellikler ise kesme çapı 10 mm, aksenal talaş açısı 13,5°, radyal talaş açısı 15°, kesici kenar sayısı 4 ve helis açısı 41° şeklindedir. Inconel 718 iş parçasının frezeleme deneyleri kuru işleme şartlarında “Hummer VMC-1000” markalı dik işleme merkezi CNC tezgahta gerçekleştirilmiştir. Deneylerin tümünde aynı şartları oluşturmak için, her bir deneyde hiç kullanılmamış yeni bir kesici takım kullanılmıştır.

İş Parçası Malzemesi

Bu deneysel çalışmada iş parçası malzemesi olarak yüksek mekanik dayanımlı nikel bazlı bir süper alaşım olan Inconel 718 seçilmiştir. Bu süper alaşıma ait üstün özellikler, bu malzemenin havacılık, uzay araştırmaları ve nikel hidrojen pilleri gibi birçok alanda kullanılmasını sağlamaktadır. Harald Phil firmasından satın alınan Inconel 718 iş parçası 100 × 100 × 12,7 mm boyutlarındadır. Inconel 718'e ait kimyasal bileşim Tablo 1'de verilmiştir.

Tablo 1. Inconel 718 İş Parçasının Kimyasal Bileşimi

C	Si	Ni	S	Fe	Mn	Cu	Cr	Al
0,03	0,065	53,45	0,001	17,64	0,09	0,22	18,55	0,56
Mo	TA	Co	Nb	Ti	B	P	Pb	Se
2,92	0,004	0,23	5,17	0,98	0,002	0,008	0,00002	<,000001


Kesme Parametreleri

İşleme deneylerinde kullanılan kesme parametreleri, Inconel 718 iş parçasının frezelenmesi için üretici kesici takım firmasının tavsiye etmiş olduğu değerler göz önünde bulundurularak belirlenmiştir. Frezeleme deneylerinde kesme parametreleri olarak sabit kesme derinliğinde (a=0,2 mm) üç farklı kesme hızı (V= 35 - 45 - 55 m/dak) ve üç farklı ilerleme miktarı (f= 0,02 - 0,03 - 0,04 mm/diş) kullanılmıştır.

Yüzey Pürüzlülüğü

Frezeleme sonucu işlenmiş yüzeylerde oluşan ortalama yüzey pürüzlülük (Ra) değerleri “TR 200” yüzey pürüzlülük ölçüm cihazı kullanılarak ölçülmüştür. Yüzey pürüzlülük değerleri, her bir deney için işlenmiş yüzeyden 4 (8x0,5) mm ölçme boyunda beş ayrı yerden mikron (µm) cinsinden ölçülerek alınmıştır. Ortalama yüzey pürüzlülük

değerleri ölçülen yüzey pürüzlülük değerlerinin aritmetik ortalamaları alınarak ISO 4287 standardına göre hesaplanmıştır. Test ve modelleme çalışmalarının şematik gösterimi Şekil 1’de verilmiştir.




Inconel 718’in Frezelenmesi Yüzey Pürüzlülük ölçümleri ANFIS ile Modelleme

Şekil 1. Test ve Modelleme Çalışmalarının Şematik Gösterimi

BULGULAR

ANFIS Modelinin Oluşturulması ve Sonuçların Değerlendirilmesi

ANFIS, genelde melez öğrenme algoritmasını kullanarak modeller oluşturmaktadır. ANFIS, hem bulanık mantık çıkarım yöntemlerini hem de sinir ağlarını entegre ettiği için bu yapıların her ikisinden de faydalanmaktadır (Asal vd., 2021). Yüzey pürüzlülük değerlerinin tahmini için ANFIS modeli Matlab programlama dilinde yer alan araç kutusundan faydalanılmıştır. ANFIS araç kutusu, bir geri yayılım algoritması (a back propagations algorithm) ve/veya en küçük kareler (least squares) yöntemiyle beraber kullanılarak bulanık sistemleri oluşturur (Çakir vd., 2013). Oluşturulan ANFIS modelinde, deneysel verilerin, %70’i eğitim ve %15’i test verileri ve geriye kalan %15’i doğrulama verileri olarak seçilmiş ve Matlab programına yüklenmiştir. ANFIS’te girdi parametreleri olarak; kesici takım türü (kaplamalı ve kaplamasız), kesme hızı V (m/dak) ve ilerleme f (mm/diş) alınmıştır. Çıktı parametresi olarak ise ortalama yüzey pürüzlülüğü Ra (μm) belirlenmiştir. ANFIS girdi parametrelerinde kesici takım türü sayısal değer olarak girilebilmesi için kaplamalı kesici takım “1” ve kaplamasız kesici takım ise “2” şeklinde tanımlanmıştır. Kesme parametrelerine ve kesici takım türüne bağlı olarak elde edilen ortalama yüzey pürüzlülük değerleri Tablo 2’de verilmiştir. ANFIS modelinde kullanılan üyelik fonksiyonları ve bunlara ait özellikler Şekil 2’de gösterilmiştir.

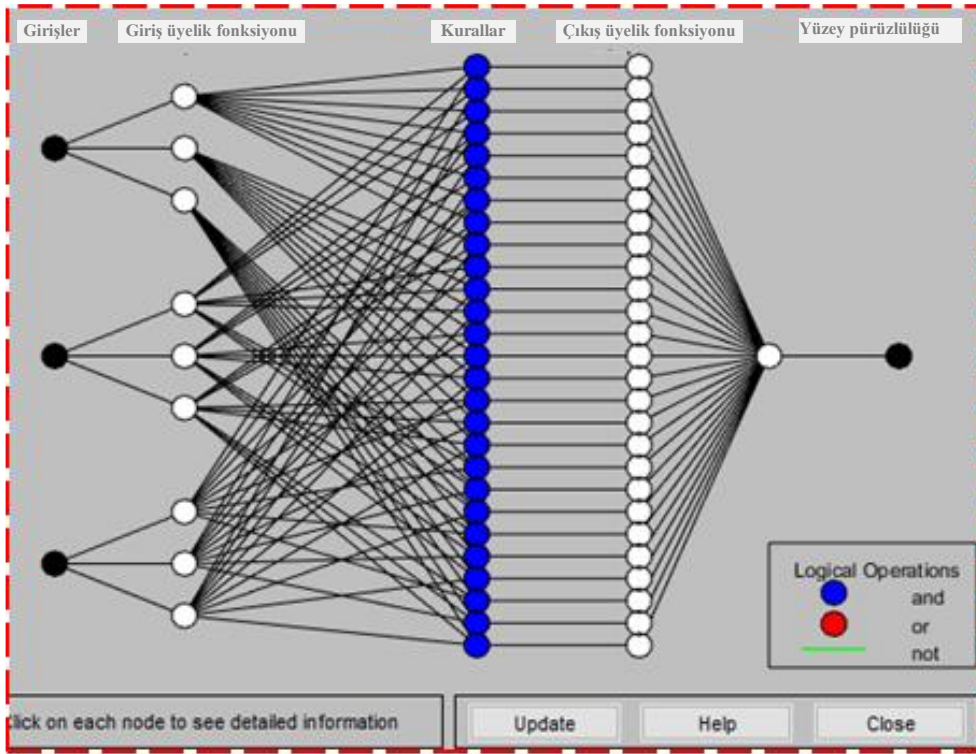


Şekil 2. ANFIS Üyelik Fonksiyonları ve Özellikleri

Tablo 2. Deney şartlarına bağlı olarak elde edilen ortalama yüzey pürüzlülük değerleri

Kesici takım türü, (Kaplama ve kaplamasız)	Kesme hızı, (m/dak)	İlerleme, (mm/diş)	Ortalama yüzey pürüzlülük değerleri, (μm)
Kaplama (1)	35	0,02	0,241
Kaplama	35	0,03	0,2736
Kaplama	35	0,04	0,3358
Kaplama	40	0,02	0,24876
Kaplama	40	0,03	0,31673
Kaplama	40	0,04	0,3847
Kaplama	45	0,02	0,265
Kaplama	45	0,03	0,3438
Kaplama	45	0,04	0,4162
Kaplama	50	0,02	0,33964
Kaplama	50	0,03	0,40761
Kaplama	50	0,04	0,47558
Kaplama	55	0,02	0,3836
Kaplama	55	0,03	0,4554
Kaplama	55	0,04	0,5456
Kaplamasız (2)	35	0,02	0,288
Kaplamasız	35	0,03	0,3184
Kaplamasız	35	0,04	0,3814
Kaplamasız	40	0,02	0,29996
Kaplamasız	40	0,03	0,36793
Kaplamasız	40	0,04	0,4359
Kaplamasız	45	0,02	0,334
Kaplamasız	45	0,03	0,392
Kaplamasız	45	0,04	0,4622
Kaplamasız	50	0,02	0,39084
Kaplamasız	50	0,03	0,45881
Kaplamasız	50	0,04	0,52678
Kaplamasız	55	0,02	0,4288
Kaplamasız	55	0,03	0,5006
Kaplamasız	55	0,04	0,6148

Şekil 2’de giriş parametreleri olarak verilen üyelik fonksiyonları türü, sayısı ve çıkış parametreleri üyelik fonksiyonu türleri ve bunların kombinasyonları alınarak ANFIS modelleri oluşturulmuştur. Bu modeller tek tek denenerek en düşük hata oranı aranmıştır. ANFIS ağ yapısının şematik gösterimi Şekil 3’te verilmiştir.



Şekil 3. ANFIS Ağ Yapısı

Şekil 3'teki giriş parametreleri (Input) kesici takım türü, ilerleme ve kesme hızı olarak seçilmiştir. Çıkış parametresi (Output) olarak ise ortalama yüzey pürüzlülüğü değerleri seçilmiştir. ANFIS giriş ve çıkış kuralları Şekil 4'te verilmiştir. ANFIS ve ANN yapıları birbirine benzemektedir, fakat ANFIS'te bulanıklaştırmak için Şekil 4'te verilen kurallar ve bu kurallarda kullanılan üyelik fonksiyonları yer almaktadır. Bu çalışmada Matlab programında yer alan üyelik fonksiyonlarının tümü tek tek denenerek en uygun ANFIS modeli araştırılmıştır.




Şekil 4. ANFIS Giriş ve Çıkış Kuralları

Optimum yüzey pürüzlülüğü değerlerini belirlemek için ANFIS ile oluşturulan modellerde, en uygun üyelik fonksiyonu tek tek seçilmiş ve her bir üyelik fonksiyonu için hesaplanan eğitim ve test verilerinin hata oranı sonuçları incelenmiştir. Programın sunmuş olduğu tüm üyelik fonksiyonları (member function) denenmiş olup en düşük hataya sahip ANFIS modeli belirlenmiştir. Çıkış parametresi için doğrusal (lineer), tüm üyelik fonksiyon tiplerinde denemeler yapılmıştır. Üyelik fonksiyon sayıları 3-3-3'ten 5-5-5'e kadar değiştirilerek denedikten sonra kabul edilebilir hata değeri ve en iyi tahmin sonuçlarına ulaşıldığında seçilmiştir. Bu doğrultuda elde edilen ANFIS mimarileri ve parametreleri Tablo 2'de verilmiştir.

Tablo 2. Farklı ANFIS Modellerinin Yapısındaki Üyelik Fonksiyon Tipleri ve Sayıları için Elde Edilen Eğitim Hataları

Giriş Üyelik Fonksiyonları	Üyelik Fonksiyon Sayısı	Test Sonucu Hata Oranları
Gauss2mf	333	0,089337
Trimf	333	0,10051
Trapmf	333	0,079613
Gbellmf	333	0,099666
Gaussmf	333	0,08182
“Gauss2mf”	“333”	“0,069596”
Pimf	333	0,079665
Dsigmf	333	0,080013
Psigmf	333	0,089062
Gauss2mf	444	0,096422
Gauss2mf	555	0,10683

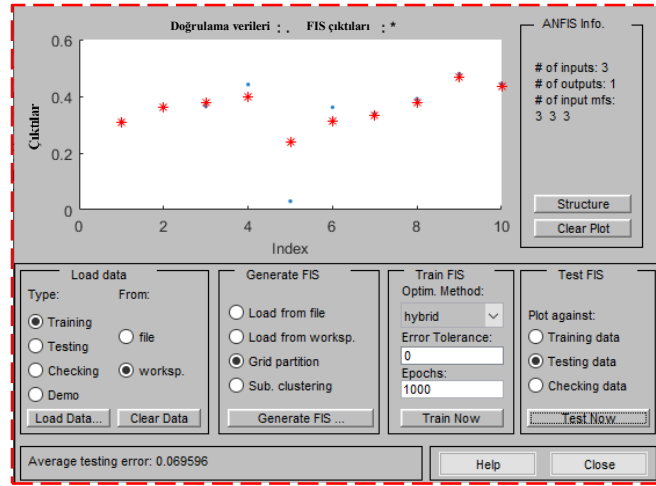
Yüzey pürüzlülüğü değerlerinin eğitilmesi ile ilgili parametreler ve bunların çıktısı Şekil 5'te verilmiştir. Şekil 5'te verilen grafik incelendiğinde mavi daireler yüzey pürüzlülüğü, kırmızı yıldızlar ise eğitilen deney değerlerini ifade etmektedir. İki değer dışında geriye kalan deney değerlerinin birbiri ile örtüştüğü ve oluşturulan modelin değerleri düşük hata oranlarında tahmin ettiği anlaşılmaktadır.




Şekil 5. Yüzey Pürüzlülüğü Değerlerinin Eğitilmesi

Eğitimin geçerliliğini test etmek için test edilen deney sonuçları Şekil 6'da verilmiştir ve bunlara ait sonuçlar Tablo 2'de verilmiştir. Şekil 6'daki grafik incelendiğinde test için ayrılan yüzey pürüzlülüğü değerlerinin büyük bir çoğunluğunun birbiri ile örtüştüğü görülmektedir. Bu durum oluşturulan ANFIS modelinin geçerliliğini ve hata oranlarının düşük olduğunu göstermektedir. Farklı giriş üyelik fonksiyonları ve sayılarına ve sabit alınan lineer çıkış fonksiyonuna göre oluşturulan ANFIS modelleri ve bunların hata oranları değerleri Tablo 2'de verilmiştir.

Tablo 2 incelendiğinde en düşük hata oranı “0,069596”, giriş üyelik fonksiyonu “Gauss2mf” ve sayısının “333” olarak elde edildiği tespit edilmiştir. En düşük hata oranları seçilerek elde edilen giriş ve çıkış parametrelerine bağlı olarak oluşan grafikler Şekil 7'de verilmiştir. Burada: output, yüzey pürüzlülüğünü; input1, kesici takım türünü; input2, kesme hızını; input3, ilerlemeyi ifade etmektedir.



Şekil 6. Yüzey Pürüzlülüğü Değerlerinin Test Edilmesi




a)

b)

Şekil 7. Yüzey Pürüzlülüğü İçin a) Kesme Hızı ve İlerleme b) Kesici Takım 1 ve Kesici Takım 2 Grafikleri

Şekil 7'deki grafiğe bakılırsa ilerleme ve kesme hızının artması iş parçası yüzey pürüzlülük değerlerini olumsuz etkilemektedir. Genel olarak kesme hızının artması ile yüzey pürüzlülüğü değerlerinin düştüğü literatürde ifade edilmektedir. Fakat işlenmesi güç olan Inconel 718 gibi iş parçalarında kesme hızının artması ile iş parçası ve takım arasındaki sıcaklık artışı ve Inconel 718'in yüksek afinitesinden dolayı talaş, kesici takıma yapışmakta ve bu da kesici takımın daha hızlı aşınmasına ve işlenmiş yüzeylerin daha kötü olmasına sebebiyet vermektedir (Gürbüz ve Baday, 2021). Kesici takım türüne göre, kaplamalı kesici takımlarla işlenmiş yüzeylerden elde edilen yüzey pürüzlülük değerleri, kaplamasız kesici takımlarla olanlara göre daha düşük çıkmıştır. Elde edilen ANFIS modelinin hassasiyeti ve doğruluğu belirlilik katsayısı ile (R^2) değerlendirilmiştir. ANFIS modeli tarafından elde edilen değerler ile deney sonuçlarının karşılaştırılması grafiksel olarak Şekil 8'de verilmiştir.

Şekil 8'deki grafik incelendiğinde, doğrusal kırmızı çizgi etrafında, ANFIS ile tahmin edilen değerlerin yoğunlaştığı görülmektedir. Belirlilik katsayısı R^2 değeri 0,9902 olarak hesaplanmıştır. Belirlilik katsayısının 1'e yakın olması modelin geçerliliğinin yüksek olmasını ifade etmektedir. Bu durum deneysel sonuçların tahmin edilmesinde oluşturulan modelin geçerliliğini göstermektedir.



Şekil 8. Deneyisel ve ANFIS ile Tahmin Edilen Yüzey Pürüzlülük Değerleri

SONUÇLAR

Bu çalışmada, işlenmesi güç olan Inconel 718 iş parçasının kaplamalı ve kaplamasız kesici takımlarla frezelenmesi sonucu oluşan yüzey pürüzlülük değerleri ANFIS modeli kullanılarak incelenmiştir. En uygun ANFIS modelini belirlemek için üyelik fonksiyonları tipleri ve sayıları denenerek en düşük hata oranı seçilmiştir. Elde edilen test ve modelleme sonuçları aşağıda özetle verilmiştir.

- İlerleme ve kesme hızı değerinin artmasıyla yüzey pürüzlülük değerlerinin arttığı tespit edilmiştir.
- Yüzey pürüzlülük değerleri üzerinde kaplamalı kesici takımların kaplamasız kesici takımlara göre daha etkili olduğu bulunmuştur.
- En düşük hata oranını veren ANFIS modeli için çıkış üyelik fonksiyonu, üyelik fonksiyonu ve sayısı sırasıyla lineer, Gauss2mf ve 333 olarak tespit edilmiştir.
- ANFIS modelinin tahmin sonuçları ile deneysel sonuçlar karşılaştırıldığında, belirlilik katsayısı (R^2) değeri 0,9902 ve hata oranı değeri ise 0,069596 hesaplanmıştır.
- Oluşturulan ANFIS modelinin, deneysel sonuçları yüksek doğrulukta tahmin edebilme kapasitesine sahip olduğu ve imalat endüstrisinde işlenmesi güç olan parçalarda düşük yüzey pürüzlülük değerleri elde etmede işleme parametrelerinin uygun ve doğru seçiminde yardımcı olabileceği görülmüştür. Bu durum, çalışmada kullanılan $a=0,2$ mm sabit kesme derinliği, $V=35 - 55$ m/dak kesme hızı ve $f=0,02 - 0,04$ mm/diş ilerleme miktarı için doğrulanmıştır.

TEŞEKKÜR

Bu çalışmada, Batman Üniversitesi Bilimsel Araştırma Projeleri Birimi (BTÜBAP) tarafından “18.004” numaralı projeye sunulmuş olan finansal destek için BTÜBAP'a teşekkür ederiz.

KAYNAKLAR

Abdulshahed, A., & Badi, I. (2018). Prediction and control of the surface roughness for the end milling process using ANFIS. *Operational Research in Engineering Sciences: Theory and Applications*, 1(1), 1-12. <https://doi.org/10.31181/oresta1901201011a>

Asal, Ö., Dilipak, H., Yalçınkaya, A., & Ünal, Ş. (2021). Minimum Miktarda Yağlama Tekniği ile Frezeleme İşleminde Yüzey Pürüzlülüğünün Anfis ile Modellenmesi. *International Journal of Innovative Engineering Applications*, 5(2), 162-170. <https://doi.org/10.46460/ijiea.952306>

Cakir, M. V., Eyercioglu, O., Gov, K., Sahin, M., & Cakir, S. H. (2013). Comparison of soft computing techniques for modelling of the EDM performance parameters. *Advances in Mechanical Engineering*, 1-15. <https://doi.org/10.1155/2013/392531>

- Çelik, A., Alağaç, M. S., Turan, S., Kara, A., & Kara, F. (2017). Wear behavior of solid SiAlON milling tools during high speed milling of Inconel 718. *Wear*, 378, 58-67. <https://doi.org/10.1016/j.wear.2017.02.025>
- Dedeakayoğulları, H., Kaçal, A., & Keser, K. (2022). Modeling and prediction of surface roughness at the drilling of SLM-Ti6Al4V parts manufactured with pre-hole with optimized ANN and ANFIS. *Measurement*, 203, 112029. <https://doi.org/10.1016/j.measurement.2022.112029>
- Dere, M., & Filiz, I. H. (2019). Experimental investigation of the effects of workpiece diameter and overhang length on the surface roughness in turning of free machining steel and modelling of surface roughness by using ANFIS. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34(2), 676-686. <https://doi.org/10.17341/gazimmfd.416524>
- Fedai, Y., Ünüvar, A., Akın, H. K., & Başar, G. (2019). 316L Paslanmaz çeliklerin frezeleme işlemindeki yüzey pürüzlülüğünün ANFIS ile modellenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 7(2), 98-110. <https://doi.org/10.29130/dubited.466629>
- Gürbüz, H., & Baday, Ş. (2021). Milling Inconel 718 workpiece with cryogenically treated and untreated cutting tools. *The International Journal of Advanced Manufacturing Technology*, 116, 3135-3148. <https://doi.org/10.1007/s00170-021-07688-x>
- Halim, N. H. A., Haron, C. H. C., Ghani, J. A., & Azhar, M. F. (2019). Tool wear and chip morphology in high-speed milling of hardened Inconel 718 under dry and cryogenic CO₂ conditions. *Wear*, 426, 1683-1690. <https://doi.org/10.1016/j.wear.2019.01.095>
- Hegab, H., Salem, A., Rahnamayan, S., & Kishawy, H. A. (2021). Analysis, modeling, and multi-objective optimization of machining Inconel 718 with nano-additives based minimum quantity coolant. *Applied Soft Computing*, 108, 107416. <https://doi.org/10.1016/j.asoc.2021.107416>
- Jithendra, T., Basha, S. S., Divya, A., & Rajyalakshmi, G. (2024). Machine learning technique ANFIS-COA for enhancing micro-milling performance by investigating the surface roughness and material removal rate. *International Journal on Interactive Design and Manufacturing*, 1-22. <https://doi.org/10.1007/s12008-024-02061-0>
- Kannan, S., & Kui, L. (2019). Experimental investigation of surface integrity during abrasive edge profiling of nickel-based alloy. *Journal of Manufacturing Processes*, 39, 40-51. <https://doi.org/10.1016/j.jmapro.2019.01.052>
- Kasim, M. S., Hafiz, M. S. A., Ghani, J. A., Haron, C. H. C., Izamshah, R., Sundi, S. A., & Othman, I. S. (2019). Investigation of surface topology in ball nose end milling process of Inconel 718. *Wear*, 426, 1318-1326. <https://doi.org/10.1016/j.wear.2018.12.076>
- Luo, M., Luo, H., Zhang, D., & Tang, K. (2018). Improving tool life in multi-axis milling of Ni-based superalloy with ball-end cutter based on the active cutting edge shift strategy. *Journal of Materials Processing Technology*, 252, 105-115. <https://doi.org/10.1016/j.jmatprotec.2017.09.010>
- Ma, J. W., Wang, F. J., Jia, Z. Y., Xu, Q., & Yang, Y. Y. (2014). Study of machining parameter optimization in high speed milling of Inconel 718 curved surface based on cutting force. *The International Journal of Advanced Manufacturing Technology*, 75(1-4), 269-277. <https://doi.org/10.1007/s00170-014-6115-x>
- Maher, I., Eltaib, M. E. H., Sarhan, A. A., & El-Zahry, R. M. (2014). Investigation of the effect of machining parameters on the surface quality of machined brass (60/40) in CNC end milling - ANFIS modeling. *The International Journal of Advanced Manufacturing Technology*, 74, 531-537. <https://doi.org/10.1007/s00170-014-6016-z>
- Nath, C., Brooks, Z., & Kurfess, T. R. (2015). Machinability study and process optimization in face milling of some super alloys with indexable copy face mill inserts. *Journal of Manufacturing Processes*, 20, 88-97. <https://doi.org/10.1016/j.jmapro.2015.09.006>
- Pandea, P. P., & Patilb, N. G. (2014). Investigations into Machining of Inconel 718 By Using Adaptive Fuzzy Based Inference System. *International Journal of Engineering Research*, 3(5).

- Raju, R. U., Kottala, R. K., Varma, B. M., Barmavatu, P., & Aepuru, R. (2024). Precision enhancement in CNC face milling through vibration-aided AI prediction of surface roughness. *International Journal on Interactive Design and Manufacturing*, 1-15. <https://doi.org/10.1007/s12008-024-01948-2>
- Rakesh, M., & Datta, S. (2019). Effects of Cutting Speed on Chip Characteristics and Tool Wear Mechanisms During Dry Machining of Inconel 718 Using Uncoated WC Tool. *Arabian Journal for Science and Engineering*, 1-18. <https://doi.org/10.1007/s13369-019-03785-y>
- Sen, B., Mandal, U. K., & Mondal, S. P. (2017). Advancement of an intelligent system based on ANFIS for predicting machining performance parameters of Inconel 690—A perspective of metaheuristic approach. *Measurement*, 109, 9-17. <https://doi.org/10.1016/j.measurement.2017.05.050>
- Stephen, D. S., & Sethuramalingam, P. (2024). ANFIS prediction modeling of surface roughness and cutting force of titanium alloy ground with carbon nanotube grinding wheel. *Multiscale and Multidisciplinary Modeling, Experiments and Design*, 1-16. <https://doi.org/10.1007/s41939-024-00411-9>
- Yılmaz, B., Karabulut, Ş., & Güllü, A. (2018). Performance analysis of new external chip breaker for efficient machining of Inconel 718 and optimization of the cutting parameters. *Journal of Manufacturing Processes*, 32, 553-563. <https://doi.org/10.1016/j.jmapro.2018.03.025>
- Zafar, R. R., Karim, M., & Rahman, K. B. (2014). Neuro-fuzzy inference system (ANFIS) for ball end milling operation. *International Research Journal of Mechanical Engineering*, 2(6),174-190.



Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences



Geliş Tarihi : 17.10.2024
Kabul Tarihi : 06.01.2025

Received Date : 17.10.2024
Accepted Date : 06.01.2025

STRUCTURAL INVESTIGATION OF PNEUMATIC GRIPPERS FOR HANDLING AUTOMOTIVE PARTS USING FINITE ELEMENT ANALYSIS AND TOPOLOGY OPTIMIZATION

OTOMOTİV PARÇALARININ TAŞINMASINDA PNÖMATİK TUTUCULAR: YAPISAL İNCELEME, SONLU ELEMANLAR ANALİZİ VE TOPOLOJİ OPTİMİZASYON

Ömer ARAT¹ (ORCID: 0009-0008-9894-9631-0000)
Ahmet DURAN¹ (ORCID: 0009-0005-4094-9514)
Barış ERMAN¹ (ORCID: 0009-0009-2127-8259)
Ali KİBAR^{2*} (ORCID: 0 000-0002-2310-1088)

¹ Erha Engineering Industrial Machinery & Equipment, Sancaktepe, İstanbul, Türkiye
² Kocaeli University, Department of Mechanical and Material Technologies, Kocaeli, Türkiye

*Sorumlu Yazar / Corresponding Author: Ali KİBAR, alikibar@kocaeli.edu.tr

ABSTRACT

Robotic grippers are widely used in the automotive industry for material handling processes. The lightweight, durable, and efficient design of these grippers is a critical factor for optimizing production operations. This study investigates the structural performance of a pneumatic gripper mechanism designed for a 500 kg material handling system, specifically for handling automotive parts. Finite element analysis (FEA) was used to evaluate the gripper's ability to withstand applied loads without compromising its structural integrity. The initial analysis revealed a safety factor of 5.16, confirming the design's safety under an applied pressure of 5 bar. Following topology optimization, the gripper's mass was reduced by 35%, resulting in a slight increase in the stress concentration and a decrease in the safety factor to 4.72. To better understand the benefits of topology optimization, a dimensionless SF/M ratio was introduced, which compares the relative safety factor per unit mass for both designs. The initial design served as the baseline with an SF/M ratio of 1.0, while the optimized design achieved a ratio of 1.42, indicating a 42% improvement in structural efficiency. This research demonstrated the effectiveness of FEA and topology optimization in optimizing gripper designs for material handling applications, emphasizing the importance of maintaining a sufficient safety factor. While the optimized design results in higher stress, it maintains structural integrity and reduces the mass, ensuring that the gripper can securely handle loads. These improvements ultimately enhance the functionality and efficiency of robotic grippers in industrial environments.

Keywords: Gripper, finite element analysis, topology optimization

ÖZET

Robotik kavrayıcılar, otomotiv sektöründe malzeme taşıma işlemlerinde yaygın olarak kullanılmaktadır. Bu kavrayıcıların hafif, dayanıklı ve verimli tasarımı, üretim süreçlerinin optimize edilmesi açısından büyük öneme sahiptir. Bu çalışma, otomotiv parçalarının taşınması için tasarlanmış 500 kg kapasiteli bir malzeme taşıma sistemi için pnömatik kavrayıcı mekanizmasının yapısal performansını araştırmaktadır. Sonlu elemanlar analizi (SEA), kavrayıcının dayanım şartlarını karşılayarak uygulanan yükleri güvenle taşıyabilme yeteneğini değerlendirmek amacıyla kullanılmıştır. İlk analizde, 5 bar basınç altında sistemin güvenli olduğunu gösteren 5,16 güvenlik faktörü hesaplanmıştır. Daha sonra yapılan topoloji optimizasyonu ile sistemin kütlesi %35 oranında azaltılmış, bu süreçte güvenlik faktörü çok az bir düşüşle 4,72 olmuştur. Topoloji optimizasyonunun faydalarını daha iyi anlayabilmek için, her iki tasarım için güvenlik faktörünün birim kütle başına göre karşılaştırılmasını sağlayan boyutsuz bir SF/M

ToCite: ARAT, O., DURAN, A., ERMAN, B., & KİBAR, A., (2025). STRUCTURAL INVESTIGATION OF PNEUMATIC GRIPPERS FOR HANDLING AUTOMOTIVE PARTS USING FINITE ELEMENT ANALYSIS AND TOPOLOGY OPTIMIZATION. *Kahramanmaraş Sutcu Imam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1),

oranı tanıtılmıştır. İlk tasarım, 1.0 SF/M oranı ile referans alınırken, optimize edilmiş tasarım 1.42 oranına ulaşmış ve bu, yapısal verimlilikte %42'lük bir iyileşmeyi göstermektedir. Bu çalışma, SEA ve topoloji optimizasyonunun malzeme taşıma uygulamaları için kavrayıcı tasarımlarını optimize etmedeki etkinliğini göstermekte olup, güvenlik faktörünün yeterli seviyede tutulmasının önemini vurgulamaktadır. Optimize edilmiş tasarım, kütleyi azaltırken gerilme seviyesinde bir artışla birlikte yapısal dayanımı korumuş ve kavrayıcının yükleri güvenli bir şekilde taşımamasını sağlamıştır. Böylece, endüstriyel ortamlarda robotik kavrayıcıların işlevselliği ve verimliliği artırılmıştır.

Anahtar Kelimeler: Kavrayıcı, sonlu elemanlar analizi, topoloji optimizasyonu

INTRODUCTION

Automation systems are commonly used in contemporary industrial applications, especially in the automotive sector, to handle and assemble parts. These systems efficiently grasp and manipulate parts with the help of grippers. The grippers are driven by hydraulic or pneumatic actuators. They can be designed in a variety of ways to serve different parts of the body. Productivity and operational reliability depend on the efficiency and accuracy of material handling systems.

Grippers are essential parts of robotic and automated systems. They provide the interface between the machine and the target material. These devices must be sufficiently precise and powerful to handle all kinds of materials, from fragile electronic parts to heavy industrial parts with different geometries. As the primary functional component at the end of most robots, grippers play a crucial role in system performance. Since grippers perform the majority of the actual handling, system performance is affected by both design and functionality, which can affect speed, accuracy, and quality.

Grippers must withstand a variety of operational environments and interface with many types of materials and products. Having a secure hold over material that does not harm it is important, particularly within sectors that value accuracy, including electronics, pharmaceuticals, and automobile manufacturing. Using grippers with high-end control systems allows for precise manipulation and placement of materials on the assembly line, thereby improving the process efficiency and reducing downtime. There are different grippers for capturing various types of workpieces, thus making production lines more flexible. Finger grippers are the most popular, followed by vacuum and magnetic grippers. Each type has advantages and disadvantages, depending on the particular case. The grippers must meet the strength requirements of the static, dynamic load, and fatigue load. Grippers are required to withstand static loads, which include the weight of the parts and the forces applied by pneumatic or hydraulic actuators. The stress and strain limits must also be checked. The gripper components have to be designed with consideration of stresses and deformations.

Grippers also need to withstand dynamic forces such as vibrations and impacts. Their strength is assessed by considering the fatigue and fracture limits. Fatigue occurs when a material weakens over time due to repeated stresses, whereas fracture refers to the breaking of the material. The grippers must stay within these limits. Grippers should be able to endure long-term use. This durability is checked against fatigue and wear boundaries; therefore, it is crucial for the design of gripper components to meet these requirements. An analysis of grippers' strengths is necessary to ensure that they adhere to these standards. This can be achieved using various techniques, such as Finite Element Analysis (FEA). FEA helps determine the stress and deformation patterns by considering the geometry and material properties of the gripper.

Topology optimization is now used to improve gripper functionality and performance. Optimized grippers are useful for grasping and repositioning objects of various weights, sizes, and shapes. Applying topology optimization to gripper design involves outlining the requirements and limitations of the gripper system, including its ability to withstand loads and maintain stability during operation. To optimize the stiffness and strength while reducing the stress concentration, the material distribution within the gripper's design space must be adjusted. This approach not only enhances the gripper's capability to handle diverse objects but also reduces energy consumption, and improves the overall efficiency of robotic applications. Topology optimization design is a valuable tool for developing high-performance grippers. By optimizing the material distribution, it is possible to methodically design grippers. This method can generate innovative holder designs with high performance and lighter mass. Thus, gripper design can provide more effective gripper systems for robots and machines.

The design and optimization of robotic grippers have seen substantial advancements in recent years, with various approaches addressing the limitations of structural strength, adaptability, and efficiency. Bhatt and Chauhan, (2016) introduced a two-finger friction gripper for a wheel mobile robot, focusing on pick-and-place tasks and exploring mechanical design parameters like von Mises stress, deformation, and torque. This foundational study demonstrated the significance of gripper design for industrial applications requiring precise object manipulation. Building on this, Bhagawati et al., (2022) employed finite element analysis (FEA) to enhance the structural understanding of mechanical grippers. The study used SolidWorks and ANSYS to focus on the static structural properties of mating gears, claws, and the overall gripper model, offering a more in-depth exploration of how these components withstand stress during operation.

Gürkal et al., (2021) then expanded the discussion by analysing autonomous mobile robot chassis designs, emphasizing the importance of ensuring load capacity independence. This work underscores the broader need for durability and robustness in robotic systems, laying the groundwork for further optimization efforts. More recent studies have introduced innovative approaches. Wang et al., (2024) proposed a reconfigurable gripper with rigid-flexible states, thus addressing the limitations of existing rigid and flexible grippers. The proposed design demonstrated the versatility of switching between states, which improves task adaptability. Similarly, Trinh et al., (2024) developed a gripper that combines rigid and soft components, enabling the safe handling of diverse objects under harsh vibration conditions. The combination of structural stiffness and flexibility in these grippers represents a novel frontier in robotic manipulation technology.

Soft robotics was further advanced using R. Wang et al., (2020) utilized topology optimization and FEA to design a cable-driven soft robotic gripper. This study addressed complex contact nonlinearities, enabling finer manipulations and adaptive grasping. The use of novel boundary conditions and hyperelasticity techniques improved the gripper's ability to handle various tasks. Dörterler et al., (2021) optimized robot gripper designs using multi-objective metaheuristic algorithms to improve the force transmission and minimize the force differences at the gripper ends. The performance of these algorithms demonstrates the value of computational optimization in enhancing gripper efficiency. Yıldırım and Akay, (2024) proposed a Multi-Strategy Arithmetic Optimization Algorithm (MSAOA), which enhances the AOA by introducing a modified update mechanism and a self-adaptive multi-strategy framework. MSAOA demonstrated superior gripper design optimization, allowing for minimal manipulation and secure object handling without damage. Their algorithm outperformed other contemporary methods, offering a more balanced exploration-exploitation trade-off, which is essential for designing industrial grippers that require precision and care.

The present study focuses on the static strength analysis and topology optimization of a gripper driven by a pneumatic cylinder. This gripper is designed to hold automotive parts at three points under 5 bar pressure. By employing FEA, this study investigates the stress and deformation distributions based on the gripper's geometry and material properties, ensuring that the components stay within safe operational limits.

The key objective of this study is to enhance the gripper's design through topology optimization, aiming at reducing its weight while maintaining its structural integrity. First, a static strength analysis of the initial design is conducted to determine the maximum von Mises stress and safety factor. Then, topology optimization is performed to minimize the weight by redistributing the material in regions of low stress. A comparison between the initial and optimized designs is carried out based on the stress distribution, displacement, and safety factors to evaluate the trade-offs.

Unlike previous research, which has primarily focused on either stress reduction or displacement control, this study addresses the critical trade-off between increased stress and structural displacement in gripper design. By applying topology optimization, this study aims to balance mass reduction with sufficient safety margins, ensuring that grippers can reliably handle automotive parts without compromising performance under operational loads. The novelty of this research lies in the integration of mass reduction strategies with FEA and topology optimization, offering new insights into achieving lightweight and robust gripper designs.

NUMERICAL STUDIES

The structural performance of the pneumatic gripper system was analysed using SolidWorks simulations. The methodology involved creating a detailed 3D model, performing static strength analysis under appropriate boundary conditions and loads, and conducting topology optimization to reduce weight while maintaining structural integrity. Alloy steel, with a yield strength of 620 MPa, was used as the material for the gripper. The analyses compared initial and optimized designs based on stress distribution, displacement, safety factors, and mass reduction.

Topology Optimization Methodology

In this study, the topology optimization of the pneumatic gripper was conducted using a detailed and problem specific approach aimed at improving structural performance while minimizing material usage. The focus of the optimization process was to maximize the gripper's stiffness, minimize its weight, and ensure the structure could safely handle automotive parts under operational loads.

Problem Definition and Design Setup

The design space for the gripper was defined based on the operational requirements of handling automotive parts. The allowable design space was determined by the geometric constraints of the gripper's design, such as the attachment points and the gripper arms' structural limits. The primary goals were set to minimize the gripper's weight while maintaining sufficient structural integrity, as measured by the von Mises stress distribution and the safety factor (Larsson et al., 2022).

The constraints were established to reflect the real-world operating conditions of the gripper, including:

- **Maximum allowable stress:** The material's yield strength was set as the upper limit for von Mises stress.
- **Displacement constraints:** The displacement of critical points, particularly at the gripper arms where contact with automotive parts occurs, was constrained to ensure proper handling.
- **Manufacturing constraints:** Given the application, the final design had to be manufacturable using conventional processes, ensuring that complex geometries did not exceed feasible limits.

Topology Optimization Process

The topology optimization was performed using the Solid Isotropic Material with Penalization (SIMP) method. This method iteratively redistributes material within the design space to maximize stiffness while reducing unnecessary mass. The following steps were followed during the optimization process:

- **Initial Material Distribution:** The entire design space was filled with material at the beginning of the optimization process.
- **Objective Function:** The optimization algorithm aimed to minimize the gripper's mass while ensuring that the stiffness and strength were maintained. The objective function was set to maximize stiffness under the applied loads while minimizing the overall material usage.
- **Optimization Algorithm:** The SIMP method, which penalizes intermediate density values, was used to ensure the design converged towards a structure made of either solid material or voids, thereby avoiding inefficient material distribution.

Constraints and Iterative Refinement

The optimization was subject to constraints that prevented the stress from exceeding the yield strength of the material and kept the displacement within allowable limits. The optimization algorithm iteratively adjusted the material layout, removing material from low stress regions while reinforcing high stress areas. The convergence criteria for the optimization were based on:

- **Stability of the objective function:** The optimization stopped when the changes in the objective function value (i.e., stiffness and mass) between iterations became negligible.
- **Satisfaction of constraints:** The process ensured that all stress, displacement, and manufacturability constraints were satisfied before concluding.

In addition to evaluating traditional metrics such as stress, displacement, and Safety Factors (SF), a dimensionless SF/M ratio was introduced to quantify the efficiency improvements achieved through topology optimization. This ratio compares the relative safety factor per unit mass for both the initial and optimized designs, as defined in Equation (1).

$$SF/M = \frac{SF_{\text{optimised}}/M_{\text{optimised}}}{SF_{\text{initial}}/M_{\text{initial}}} \quad (1)$$

where SF/M is a dimensionless ratio representing the structural efficiency of the gripper design, defined as the safety factor per unit mass. $M_{\text{optimised}}$ represents the mass of the optimized design, and M_{initial} represents the mass of the initial

design. This ratio provides a comparative metric to evaluate the trade-offs between safety and weight reduction achieved through topology optimization.

Computational Model and Boundary Conditions

Figure 1a illustrates the gripper mechanism when lifting a material weighing around 500 kg. The grippers hold the material via a pneumatic cylinder, which applies a pressure of 5 bar to ensure a secure grip and prevent rotation around the axis due to the resulting moment. Thus, with the designed mechanism, the material is held in three different zones with rubber, as shown in Figure 1b. For the analysis, a single gripper was simplified by retaining only the parts affected by the load (Figure 1b).




Figure 1. a) Material to be Lifted by a Gripper; b) Single Gripper used for Analysis

Figure 2 shows the motion mechanism of the gripper. When the gripper is fully open, there is a gap of 170.81 mm between the cylinder piston and an aperture of 57.81 mm. The diameter of the material to be held in the grip area is 120 mm. When the piston was opened to 115.92 mm, the grippers collided with each other. As shown in Figure 2, when the piston was approximately 94 mm open, it fully gripped the 120 mm diameter material. The length may vary slightly due to the rubber material in the grip area.




Figure 2. Gripper Motion Mechanism

An initial force must be applied to grasp the material. A pneumatic cylinder with a piston diameter of 44 mm was used to apply an initial force to hold the material. For this purpose, a pressure of 5 bar was applied, resulting in an initial force of approximately 760 N for the piston. This force, when divided among the two arms of the gripper, was 122.7 N per arm, as shown in the free body diagram in Figure 3. This force is further divided into vertical and horizontal components, exerting 91 and 82.3 N, respectively. The gripper's two arms move closer and further apart simultaneously during the piston's vertical movements.




Figure 3. Free Body Diagram Showing the Forces Acting on the Gripper Arms

Figure 4 illustrates the boundary conditions applied to the gripper mechanism designed for a 500 kg load handling system. The following forces and constraints are applied:

Fixed Boundary Conditions: A fixed support is applied at the piston connection point to simulate the real-world attachment.

Piston Force: The gripper is actuated by a piston applying a total force of 750 N to the system.

Vertical Forces: Each arm of the gripper handles half of the 500 kg load (250 kg per gripper), resulting in a force of 2452.2 N. This force is divided between the two arms, leading to a vertical force of 1317.25 N per arm.

Horizontal Forces: The gripping action introduces a horizontal force of 82.3 N on each arm. This represents the lateral interaction with the cylindrical part being handled. The forces applied to the other two gripping surfaces were separately defined as vertical and horizontal components, as shown in Figure 4.




Figure 4. Boundary Conditions

Mesh Generation for Finite Element Analysis

This section details the mesh-generation process employed for the static strength analysis and topology optimization of the pneumatic gripper design. SolidWorks software was used to create high-quality meshes suitable for accurate finite element analysis (FEA). Figure 5a and Figure 5b show the mesh used for strength analysis and topology optimization, respectively.




Figure 5. Mesh Structures a) Strength and b) Topology Analysis

A solid mesh was used for both analyses to ensure an accurate representation of the gripper’s geometry and material behaviour. The static analysis employed a curvature-based mesh to capture the curvature variations in the gripper design. The topology optimization was performed using a blended curvature-based mesh. The proposed mesh combines curvature-based refinement with additional considerations to optimize the material distribution during the optimization process.

Mesh Quality and Refinement

Table 1 summarizes the key mesh statistics of both analyses. The mesh generation process ensured high-quality meshes for both analyses. The use of solid meshes and appropriate mesh refinement strategies facilitated an accurate representation of the gripper geometry and material behaviour. The finer mesh employed in the TO analysis matched the specific requirements of optimizing the material distribution. The minimal presence of distorted elements in both meshes ensured reliable results for static analysis and topology optimization.

Both analyses prioritize high-quality meshes with minimal distortion. This was achieved using 16 Jacobian points during element generation. The static analysis employed a mesh with a maximum element size of 11.091 mm and a minimum element size of 2.218 mm to balance the computational efficiency while capturing geometric details. The TO utilized a finer mesh than the static analysis, with a maximum element size of 2.644 mm and a minimum size of 1.586 mm, which were necessary to accurately capture the detailed material distribution patterns that emerged during the optimization process.

Table 1. Mesh Details

Property	Static Analysis	Topology Optimization
Mesh Type	Solid	Solid
Mesher	Curvature-based	Blended curvature-based
Mesh Quality	High/Draft	High
Maximum Aspect Ratio	43.885	3.267
Min Element Size (mm)	2.218	1.586
Total Elements	187743	49195
Maximum element size (mm)	11.091	2.644
Jacobian Points	16	16
Total Nodes	187035	74248
% Elements with Aspect Ratio > 10	0.0703%	0%
% Elements with Aspect Ratio < 3	95.7%	100%
Distorted Elements	0	0

RESULTS AND DISCUSSION

The static strength analysis of the gripper mechanism reveals a maximum von Mises stress of 105 MPa, which is well below the yield stress of the material (620.4 MPa, as shown in Figure 6). This indicates that the gripper can safely withstand the applied loads without exceeding the material yield point, thereby ensuring structural integrity during operation. Additionally, the gripper arms exhibit a displacement of approximately 0.402 mm at the point where the rubber pads are attached, as shown in Figure 7.




Figure 6. Von Mises Stress Distribution in the Gripper




Figure 7. Displacement of the Gripper Arms

The finite element analysis reveals a safety factor of 5.16. The safety factor is calculated by dividing the material yield stress by the maximum von Mises stress experienced during operation. A safety factor greater than 1 indicates that the design can withstand the applied loads without exceeding the material yield point, thereby ensuring structural integrity. In this case, a safety factor of 5.16 provides a significant margin against failure, demonstrating the gripper's ability to safely handle the intended loads.

To further enhance the gripper's performance and efficiency, a topology optimization analysis is conducted. This optimization process redistributes the material within the gripper to minimize its overall mass while maintaining or improving the structural integrity. As illustrated in Figure 8, topology optimization successfully reduces the stress concentration in the gripper arm. The maximum von Mises stress increases slightly from 105 to 131.5 MPa. The observed insignificant increase in stress demonstrates the effectiveness of topology optimization in improving the gripper's structural performance.




Figure 8. Topology Optimization Stress Distribution

Figure 9 shows the modified geometry of the gripper after topology optimization. This figure highlights the areas where material has been strategically removed to achieve the desired stress reduction without compromising structural integrity. The optimization process redistributes the material within the gripper focusing on creating a more efficient load path while minimizing the overall mass. The effectiveness of topology optimization can be further observed in Figure 10, which depicts the displacement experienced by the gripper arm in the designated region at the end of the gripper arms. While the optimization process primarily aimed to reduce stress concentrations, it also yields a displacement of 0.446 mm at this specific location. This result demonstrates the ability of topology optimization to simultaneously improve both the strength and displacement characteristics of gripper designs.




Figure 9. Material Mass Distribution after Topology Optimization




Figure 10. Displacement Distribution after Topology Optimization

The initial FEA analysis of the gripper mechanism under a 5 bar pressure demonstrates a safety factor of 5.16, confirming that the design could safely handle the applied loads. However, to improve the overall efficiency of the system, a topology optimization process is implemented to reduce the mass of the gripper while maintaining its structural integrity. As a result of this optimization, the gripper's mass is reduced by 35%, significantly lightening the overall structure. After topology optimization, the safety factor of the gripper remains at a satisfactory level of 4.72, indicating that the design continues to meet the safety standards. Table 1 summarizes the critical parameters of the initial and topology-optimized gripper designs. Notably, the optimized design achieves a higher maximum von Mises stress of 131.5 MPa than the initial design (105 MPa, suggesting a slight increase in the stress concentration. Additionally, this optimization comes with a trade-off the optimized design exhibits a marginally higher displacement of 0.446 mm compared to the initial design of 0.402 mm.

Although the safety factor shows a minor decrease from 5.16 in the initial design to 4.72 in the optimized design, these changes underscore the balance between weight reduction and structural performance. Despite these variations, the overall performance improvement and material savings validate the effectiveness of topology optimization in enhancing the gripper's design. The increase in stress concentrations after optimization is within acceptable limits, ensuring that the gripper can continue to handle the necessary loads without compromising its structural integrity. These findings highlight the effectiveness of combining FEA and topology optimization to achieve more efficient designs while balancing safety and performance requirements.

The SF/M ratio (Equation (1)), defined as the ratio of the safety factor to the mass of the gripper, was calculated for both the initial and optimized designs. For the initial design, the SF/M ratio was 1.0, serving as the baseline. After optimization, the SF/M ratio improved by 42%, reaching a value of 1.42. This indicates that the optimized design achieved a better balance between safety and mass, demonstrating a significant improvement in structural efficiency.

Table 2. Comparison of Initial and Optimized Design Parameters

Parameter	Initial Design	Optimized Design
Maximum von Mises Stress (MPa)	105	131.5
Displacement (mm)	0.402	0.446
Safety Factor	5.16	4.72
Mass Reduction	-	%35
Gripper Mass (kg)	23.3	15.1

CONCLUSION

This study investigates the structural performance of a pneumatic gripper mechanism designed for a 500 kg material handling system using finite element analysis (FEA) and topology optimization. The FEA results demonstrate that the initial gripper design could safely withstand the applied loads with a maximum von Mises stress of 105 MPa, which is well below the material yield stress of 620 MPa. This ensures structural integrity during operation with a safety factor of 5.16.

The topology optimization further improves the gripper design by reducing the stress concentration. The optimized design achieves a maximum von Mises stress of 131.5 MPa. However, a slight trade-off exists between stress reduction and displacement. The optimized design exhibits a marginally higher displacement of 0.446 mm compared to the initial design's displacement of 0.402 mm.

The initial design has an SF/M ratio of 1.0, while the optimized design achieves a ratio of 1.42, demonstrating a 42% improvement in structural efficiency. This indicates a better balance between safety and mass reduction, with the optimized design showing an improvement in overall performance.

This study demonstrates the effectiveness of FEA and topology optimization in optimizing gripper designs for material handling applications. By optimizing the material distribution, gripper performance can be improved while minimizing weight. In this case, the optimized design achieves a stress reduction while maintaining a sufficient safety factor, even with a slight increase in displacement. These improvements ultimately enhance the functionality and efficiency of robotic and mechanical gripping systems in the automotive industry and beyond.

REFERENCES

- Bhagawati, M., Asaduz Zaman, M., Deka, R., Bora, K. P., Gogoi, P. P., Das, M., & Arora, N. (2022). Design and Finite Element Analysis of a Mechanical Gripper. *Smart Innovation, Systems and Technologies*, 292, 411–426. https://doi.org/10.1007/978-981-19-0836-1_32
- Bhatt, N., & Chauhan, N. R. (2016). Design of a Two Fingered Friction Gripper for a Wheel Mobile Robot. *Advanced Computing and Communication Technologies*, 452, 195–203. https://doi.org/10.1007/978-981-10-1023-1_20
- Dörterler, M., Atila, U., Durgut, R., & Sahin, I. (2021). Analyzing the performances of evolutionary multi-objective optimizers on design optimization of robot gripper configurations. *Turkish Journal of Electrical Engineering and Computer Sciences*, 29(1), 349–369. <https://doi.org/10.3906/elk-2003-140>
- Gürkal, A. E., Burak İner, A., Özer, E., & Kibar, A. (2021). Design and Strength Analysis of an Autonomous Mobile Robot Chassis Structure Independent of the Load Capacity. *Mühendis ve Makina*, 62(704), 607–619. <https://doi.org/10.46399/MUHENDISMAKINA.897322>
- Larsson, J., Wennhage, P., & Göransson, P. (2022). Mass minimization with conflicting dynamic constraints by topology optimization using sequential integer programming. *Finite Elements in Analysis and Design*, 200, 103683. <https://doi.org/10.1016/J.FINEL.2021.103683>
- Trinh, H. X., Nguyen, H. H., Pham, T. D., & My, C. A. (2024). A novel rigid-soft gripper for safe and reliable object handling. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 46(4), 1–20. <https://doi.org/10.1007/S40430-024-04757-6>
- Wang, H., Gao, B., Hu, A., Xu, W., Shen, H., & He, J. (2024). Design of a Reconfigurable Gripper With Rigid-Flexible Variable Fingers. *IEEE/ASME Transactions on Mechatronics*, 1–12. <https://doi.org/10.1109/TMECH.2024.3402357>
- Wang, R., Zhang, X., Zhu, B., Zhang, H., Chen, B., & Wang, H. (2020). Topology optimization of a cable-driven soft robotic gripper. *Structural and Multidisciplinary Optimization*, 62(5), 2749–2763. <https://doi.org/10.1007/s00158-020-02619-y>
- Yıldırım, M., & Akay, R. (2024). Robot Tutucu Problemi için Çok Stratejili Aritmetik Optimizasyon Algoritması. *Gazi Üniversitesi Fen Bilimleri Dergisi Part C: Tasarım ve Teknoloji*, 12(1), 108–116. <https://doi.org/10.29109/GUJSC.1383797>

Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences



Geliş Tarihi :21.10.2024
Kabul Tarihi :27.12.2024

Received Date : 21.10.2024
Accepted Date : 27.12.2024

FARKLI KAT ADETLERİNE SAHİP BETONARME YAPILARIN BURULMA DAVRANIŞININ DEĞERLENDİRİLMESİ

EVALUATION OF TORSIONAL BEHAVIOUR OF REINFORCED CONCRETE STRUCTURES WITH DIFFERENT STORY NUMBERS

*Dilara TURSUN*¹ (ORCID: 0009-0003-1501-6961)

Ömer Faruk TAŞ^{2*} (ORCID: 0000-0002-1431-5316)

*Erkut SAYIN*³ (ORCID: 0000-0003-0266-759X)

^{1,2,3} Fırat Üniversitesi, İnşaat Mühendisliği Bölümü, Elazığ, Türkiye

*Sorumlu Yazar / Corresponding Author: Ömer Faruk TAŞ, oftas@firat.edu.tr

ÖZET

Bu çalışmada farklı kat adetlerine sahip (3, 5, 7 ve 9) konut tipi betonarme binalar incelenmiştir. Türkiye Bina Deprem Yönetmeliği (TBDY-2018) esas alınarak doğrusal olmayan zaman tanım alanında analiz yöntemi ile analizler gerçekleştirilmiştir. 4 tip kat planı esas alınarak kat adetleri ve perde elemanların yerleşim düzenleri ve sayıları değiştirilerek toplam 16 tip modelin burulma davranışı üzerindeki etkisi irdelenmiştir. Dikkate alınan binalar perde duvar + çerçeve sistemlidir. ETABS programından yararlanılarak tasarım ve analiz yapılmıştır. Analizlerde kullanılmak üzere esas alınan 1999 Kocaeli depremi ivme kayıtları olup bu kayıtlar tüm binalara x ve y yönlerinde uygulanmıştır. Uygulanan analizler sonucunda periyot ve burulma düzensizliği katsayıları elde edilerek kat adedi değişimine etkisi irdelenmiştir. Periyot değerlerinin kat sayısının artışıyla arttığı gözlenmiştir. İncelenen yapılarda perde sayısının minimum olduğu Tip-1 binasında en yüksek periyot değerleri tespit edilmiştir. Tip-1, 3 katlı bina modelinde en yüksek burulma düzensizliği katsayıları, Tip-2, 7 katlı bina modelinde ise en düşük burulma düzensizliği katsayıları görülmüştür.

Anahtar Kelimeler: Betonarme yapılar, zaman tanım alanında analiz, ETABS, burulma davranışı, TBDY-2018

ABSTRACT

This study analyzes residential reinforced concrete buildings with different numbers of stories (3, 5, 7, and 9). A nonlinear time history analysis method was used based on the Turkish Building Earthquake Code (TBEC-2018). Based on four types of story plans, the number of stories and the layout number of shear wall elements were changed, and the effect of 16 models on torsional behaviour was examined. The buildings considered are a shear wall + frame system. ETABS program was used for design and analysis. The acceleration records of the 1999 Kocaeli earthquake were taken as the basis for the analysis, and these records were applied to all buildings in the x and y directions. As a result of the applied analyses, period and torsional irregularity coefficients were obtained, and their effect on the change in the number of stories was examined. It is observed that the period values increase with the increase in the number of storeys. The highest period values were found in the Type-1 building, where the number of shear walls was minimal. The highest torsional irregularity coefficients were observed in Type-1, 3-storey building model, and the lowest torsional irregularity coefficients were observed in Type-2, 7-storey building model.

Keywords: Reinforced concrete structures, time history analysis, ETABS, torsional behaviour, TBEC-2018

GİRİŞ

ToCite: TURSUN, D., & TAŞ, Ö. F., & SAYIN, E., (2025). FARKLI KAT ADETLERİNE SAHİP BETONARME YAPILARIN BURULMA DAVRANIŞININ DEĞERLENDİRİLMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 391-402.

2023 yılı şubat ayında Pazarcık ve Elbistan ilçelerinde meydana gelen 7.8 Mw ve 7.5 Mw büyüklüklerindeki depremler, ciddi yıkımlara ve kayıplara neden olmuştur. Depremlerin ardından yapılan çalışmalarda betonarme binalarda perde elemanların işlevsel ve doğru kullanılmaması sonucunda yapıların yeterli rijitliğe sahip olmadığı ve bu yapıların ciddi hasarlar aldığı tespit edilmiştir (Taş vd., 2022; Tursun vd., 2023; Atar vd., 2024; İnce 2024; Özmen vd. 2024). Tasarımda ve uygulamada yapılan bu kusurlar nedeniyle Kahramanmaraş depremlerinde az katlı hatta çok katlı yapılarında yıkıldığı gözlemlenmiştir. Bu depremlerde oluşan burulma düzensizlikleri sonucunda oluşan kayıpları azaltmak, daha güvenli binalar inşa etmek için tasarım aşamasında bazı tedbirler alınması önem arz etmektedir.

Burulma etkisine maruz betonarme binalar ile ilgili çalışmalar araştırmacıların ilgisini çekmektedir. Demir & Dönmez (2008) yaptıkları çalışmada çok katlı binalarda burulma düzensizliğine etki eden unsurları incelemek için farklı perde yerleşimleri olacak şekilde kat sayıları 6, 8, 10 ve 12 olan 6 farklı bina modeli tasarlamışlardır. Bu çalışma sonucunda simetrik binalar için burulma düzensizliği katsayısının değerlerinin 1.20'den daha düşük olduğu görülürken, simetrik olmayan yapılarda 2.00'ye yakın değerlere ulaştığı gözlenmiştir. Uçar & Merter (2009) çalışmalarında perde yerleşim düzenlerini değiştirerek deprem performansına etkisini irdelemişlerdir. Deprem Bölgelerinde Yapılacak Yapılar Hakkında Yönetmelik-2007 (DBYYHY-2007) esas alınarak eşdeğer deprem yükü yöntemi ile performans analizlerini yapmışlardır. Bu amaç doğrultusunda, SAP2000 programı kullanılarak 8 katlı 2 tip yapı modelinde perdeler yapının iç ve dış akslarına koyulacak şekilde tasarlanmıştır. Yapılan çalışma neticesinde yapıda dış akslara perde konulmasının burulma rijitliğini artırdığı belirlenmiştir. Derdiman & Mirkelam (2011) çalışmalarında 10, 15 ve 20 kat adedine sahip binaları modelleyerek zaman tanım alanında analiz yöntemi ile farklı deprem kayıtları altında analizlerini gerçekleştirmişlerdir. Planda düzensiz binalarda burulmanın yapı davranışına etkisini belirlemek için viskoz sönümleyici kullanılmıştır. 10, 15 ve 20 katlı binaları modelleyerek zaman tanım alanında analizlerini yapmışlardır. Sonuçları değerlendirerek viskoz sönümleyici kullanımının düzensizlik nedenli burulma olumsuzluklarını azalttığını tespit etmişlerdir. Sağlıyan vd. (2012) çalışmalarında çok katlı sürekli tablalı kirişsiz döşemeli ve kirişli döşemeli yapıları ele alarak burulma davranışını nasıl etkilediğini incelemişlerdir. Yapılan analizler sonucunda sürekli tablalı kirişsiz döşemeli binaların burulma düzensizliğinden daha fazla etkilendiği saptanmıştır. Baral & Yajdani (2015) yapmış oldukları çalışmada perde yerleşim yerleri farklı kat sayısı 10 olan 5 tip binayı ele almışlardır. Hindistan Standardı IS-1893 (2002) dikkate alınarak ETABS programı ile eşdeğer statik ve tepki spektrum yöntemleri kullanılarak analizler yapılmıştır. Perde konumunun deprem davranışına etkisi irdelenmiştir. Uygulanan analiz sonuçlarına göre kütle katılım oranı, yer değiştirme, kat ötelemesi ve periyotlar elde edilerek mukayese edilmiştir. Betonarme perde duvarların köşelere yerleştirildiği durumda kat ötelemesi ve yer değiştirme değerlerinin en iyi neticeler verdiği sonucuna varılmıştır. Mallika & Nagesh (2016) çalışmalarında seçtiği farklı perde yerleşimine sahip T şeklindeki 20 katlı betonarme binaya ETABS programından yararlanılarak eşdeğer statik kuvvet yöntemini uygulamışlardır. Çalışmada IS-1893 (2002)'e göre yapının taban kesme kuvveti, kat yer değiştirmeleri ve periyot değerleri iki farklı zemin sınıfı ve deprem bölgesi için elde edilerek incelenmiştir. İncelemeler sonucunda yapıda deprem bölgesinin ikisinde de perdelerin köşelerde yer aldığı sert zemin sınıfı için minimum yer değiştirme değerleri gözlenirken, yumuşak zemin sınıfında taban kesme kuvveti değerlerinde önemli bir artma elde edilmiştir. Erdem (2016) çalışmasında betonarme binalarda burulma düzensizliğinin meydana gelmediği ve gelebileceği farklı rijitliklere sahip sekiz taşıyıcı sistemi İdeCAD programı ile tasarlamıştır. Farklı kolon boyutları kullanılarak çözümler yapılmıştır. Taşıyıcı sistem tercihinden kaynaklı A1 ve B2 düzensizlikleri oluşmuştur. Komşu katlar arası rijitlik düzensizliğinin burulma düzensizliğine çok fazla etki etmediği tespit edilmiştir. Kolonların konumlarına göre yapıda burulmaların görüleceği sonucuna ulaşılmıştır. Yapının rijitliğine bağlı olarak periyot değerlerinin farklılaşacağı gözlenmiştir. Işık & Öztürk (2017) çalışmalarında, farklı kat yükseklikleri ve kat adedine sahip betonarme yapıların deprem performansları analiz edilmiş, kat yüksekliğinin yapı taban kesme kuvveti, tepe yer değiştirme ve periyot değerleri üzerindeki etkileri incelenerek ideal kat yüksekliği için öneriler sunulmuştur. Hussain & Tengli (2018) yaptıkları çalışmada simetrik olmayan yapılarda burulma davranışının etkilerini değerlendirmişlerdir. 14 katlı bina modellerinin tasarımı düzenli ve düzensiz olarak yapılmıştır. Çözümler IS 1893:2002 (Bölüm 1)'e göre tepki spektrum yöntemi kullanılarak ETABS programı ile elde edilmiştir ve sonuçlar mukayese edilmiştir. Düzensiz binada burulma kaynaklı kolonlardaki kesme kuvvetlerinde önemli bir artış gözlenmiştir. Deprem etkisinin fazla olduğu bölgelerde düzensiz binalarda kat ötelemesi ve yer değiştirmeler daha büyük değerler verdiği için hasarların daha fazla olduğu gözlenmiştir. Kaya & Özbay (2019) çalışmalarında perdeleri farklı boyut ve konumlarda olan 10 farklı tip yapının deprem analizlerini yapmışlardır. Analizler sonucunda periyot değerleri, taban kesme kuvvetleri, kat yer değiştirmeleri ve göreceli kat ötelemeleri için kıyaslamalar yapılmıştır. Perdelerin yapının yatay rijitliğini ve taban kesme kuvvetini artırdığını yapının periyodunu ise azalttığını saptamışlardır. Döker (2020) çalışmasında taban yalıtımlı yapılarda burulma düzensizliğinin deprem davranışına etkisini belirlemeyi hedeflemiştir. Bu amaçla incelenen yapı simetrik hale getirilmiş ve karşılaştırmalar farklı zemin

profilleri için yapılmıştır. Taban yalıtımlı sistemlerin burulmanın etkilerini artırdığını tespit etmiştir. Çetin vd. (2020) yaptıkları çalışmada farklı perde kombinasyonları ve farklı yapı geometrisi olan 5 tip yapının, farklı yerel zemin sınıfları seçerek burulma düzensizliğini nasıl etkilediğini incelemiştir. Deprem hesabı için mod birleştirme yöntemi ve eşdeğer deprem yükü yöntemini seçmişlerdir. Elde edilen analiz sonuçları güncel ve önceki Türk deprem yönetmeliklerine göre kıyaslanmıştır. Düzenli yapılardaki burulma düzensizliği katsayısının düzenli yapılarda TBDY-2018'de TDY-2007'e göre azaldığı sonucuna varılmıştır. Düzensiz yapılarda ise bu katsayıda önemli bir artış olduğu gözlemlenmiştir. Haskılıç (2022) tez çalışmasında kirişsiz döşeme sistemli yapıları yeni yönetmeliğe göre ETABS programı ile modellemiştir. Perde oranı ve uzunlukları değiştirilerek 48 model oluşturulmuştur ve analizler uygulanmıştır. Uygulanan analizler neticesinde kesme kuvvetleri, deplasmanlar ve periyot değerleri elde edilerek karşılaştırılmıştır. Mohammed (2023) yaptığı tez çalışmasında ETABS programını kullanarak 16 modelin tasarımını perde duvarların yerlerini değiştirerek yapmıştır. TBDY-2018 ve Amerikan yönetmeliği ASCE 7-16 analizler uygulanırken kullanılmıştır. Burulma düzensizliği her iki yönetmelikte de kontrol edilerek elde edilen sonuçlar kıyaslanmıştır.

Bu çalışmada, betonarme yapılarda kat sayısı ve perde yerleşim düzenlerinin burulma davranışı üzerindeki etkileri detaylı bir şekilde analiz edilmiştir. Literatürde genellikle yalnızca kat sayısına veya perde yerleşimine odaklanan sınırlı sayıda modelleme çalışması mevcut olup, bu araştırmada dört farklı kat planı ve kat sayısı temel alınarak toplam 16 model üzerinde analizler gerçekleştirilmiştir. 1999 Kocaeli Depremi'ne ait ölçeklendirilmiş ivme kayıtları ile gerçekleştirilen analizler, yerel koşulları ve güncel yönetmelik gerekliliklerini dikkate alarak özgün bir yaklaşım sunmuştur. Çalışmada burulma modunun ilk modlarda ortaya çıkmasının yapı güvenliği üzerindeki olumsuz etkileri detaylı bir şekilde ele alınmış ve simetrik perde yerleşim düzeninin burulma düzensizliğini azaltmadaki kritik rolü vurgulanmıştır. Farklı kat adedine sahip yapılar (3, 5, 7 ve 9 katlı) arasındaki burulma davranışları üzerindeki etkisi analiz edilmiş ve tasarım sürecinde rijitlik merkezi ile kütle merkezi uyumunun sağlanmasının gerekliliği somut önerilerle vurgulanmıştır.

İZLENEN YÖNTEM

Bu çalışma kapsamında, Türkiye Bina Deprem Yönetmeliği-2018 (TBDY-2018)'e göre toplam 16 farklı tip modelden oluşan 4 farklı kat planı incelenmiştir. Bu modeller, kat sayıları farklı olan (3, 5, 7 ve 9) konut tipi betonarme binaları içermektedir. Kolon ve kiriş elemanları, çubuk sonlu eleman olarak modellenmiştir. Tasarım ve analizler, ETABS sonlu elemanlar programı kullanılarak gerçekleştirilmiştir. İlgili yönetmelik kapsamında, kat adedi, perde sayısı ve yerleşim düzenleri değiştirilerek burulma davranışına olan etkisi detaylı bir şekilde incelenmiştir. 16 farklı tip binanın güncel dinamik analizleri yönetmelikte belirtilen, zaman tanım alanında analiz yöntemi kullanılarak yapılmıştır. Bu modellerin uygulanması için ETABS programı kullanılmıştır. Deprem ivme kayıtlarının seçimi, AFAD veri tabanı (Afet ve Acil Durum Yönetimi Başkanlığı, 2023) dikkate alınarak yapılmıştır ve ölçeklendirme işlemi TBDY-2018 tasarım spektrumuna uygun olarak gerçekleştirilmiştir.

SAYISAL ÇALIŞMA



Bu çalışmada güncel yönetmelik dikkate alınarak deprem etkisi altındaki betonarme yapıların kat adetleri ve perdelerin plandaki konumları değiştirilerek bu parametrelerin burulma davranışını nasıl etkilediğini araştırmak amaçlanmıştır. Perde elemanlar planda düzensiz konumlandırılırsa kütle ve rijitlik merkezinin çakışmasını engellemektedir. Dış merkezlik kütle ve rijitlik merkezi arasında oluşmakta ve yapıda deprem yönüne bağlı kalınarak ötelenme meydana gelmekte, rijitlik merkezi çevresinde burulma kaynaklı dönme hareketi olmaktadır. Bu olay yapıda burulmaya sebep olmaktadır. Bu çalışmada, kat adetleri 3, 5, 7 ve 9 olan farklı perde kombinasyonlarının olduğu toplam 16 tip model ETABS sonlu elemanlar programı ile tasarlanmıştır. Bütün modellerde normal kat ve zemin kat yükseklikleri sırasıyla 2.8 m ve 5 m olarak seçilmiştir. İncelenen binalarda kat planları x ve y doğrultuları için 3 açıklıklı ve tasarımları simetriktir. Tasarımı yapılan binaların plandaki boyutları 18 m x 18 m, aks aralıkları her iki doğrultuda 6 m olarak ele alınmıştır. Toplam bina taban alanları 324 m² dir. Modellerin tamamında kolonlar 0.55 m x 0.55 m, kirişler ise 0.25 m x 0.50 m, perdelerin kalınlığı 0.25 m olarak dikkate alınmıştır. Katların tamamına rijit diyafram ataması yapılmıştır. Döşeme kalınlıkları 0.15 m kabul edilmiştir. Kesitlerin tümü için beton sınıfı C30, donatı çeliği ise B420C, yerel zemin sınıfı ZC esas alınmıştır. Deprem tasarım sınıfı (DTS) 1 olarak dikkate alınmıştır. Tablo 1'de incelenen bina modellerinin özellikleri özetlenmiştir. Betonarme binalar TBDY-2018 deprem yönetmeliğine göre zaman tanım alanında analiz yöntemine tabi tutulmuşlardır. Analizler, 1999 Kocaeli Depremi'nin doğu-batı ve kuzey-güney doğrultularındaki ivme kayıtları kullanılarak gerçekleştirilmiştir (Şekil 1-2).


Bu çalışmada, analiz edilen model sayısının fazlalığı ve kapsamlı veri setleriyle çalışmanın gerektirdiği yüksek zaman ve hesaplama gücü nedeniyle, Kocaeli Depremi'nin kuzey-güney ve doğu-batı doğrultularına ait iki temsil

gücü yüksek ivme kaydı tercih edilmiştir. Bu yaklaşım, hem kaynakların verimli kullanılması hem de analiz sürelerinin makul seviyede tutulması açısından uygun görülmüş; seçilen kayıtların, yapıların burulma davranışını değerlendirmek için yeterli temsiliyeti sağladığı düşünülmüştür. Bu bağlamda, 1999 Kocaeli Depremi'ne ait Düzce İvme İstasyonu'ndan kaydedilen deprem verileri kullanılmıştır. Şekil 3'te tasarım spektrumu ve ölçeklendirme işlemi yapılmış ivme kayıtlarının tepki spektrumları verilmiştir. Doğrusal olmayan zaman tanım alanında gerçekleştirilen analizlerde kullanılan deprem kayıtları, Türk Deprem Yönetmeliği 2018 (TBDY-2018) esaslarına uygun olarak ölçeklendirilmiştir. Tip-1, Tip-2, Tip-3 ve Tip-4 kalıp planları sırasıyla Şekil 4-7'de verilmiştir. Tip-1, Tip-2, Tip-3 ve Tip-4'e ait 3, 5, 7 ve 9 katlı binaların ilk üç mod şekli ve periyot değerleri sırasıyla Tablo 2-5'te verilmiştir. Şekil 8-11'de ise bu 4 farklı tip yapının periyot değerlerinin binaların kat adetlerine göre değişimi verilmiştir.


Tablo 1. İncelenen Bina Modellerinin Özellikleri

Binaların kat sayıları	3, 5, 7 ve 9
Binanın boyutları	18 m * 18 m
Normal kat yüksekliği	2.8 m
Zemin kat yüksekliği	5 m
Döşeme kalınlığı	0.15 m
Perde kalınlığı	0.25 m
Beton sınıfı	C30
Donatı sınıfı	B420C
Kolon boyutları	0.55 m * 0.55 m
Kiriş boyutu	0.25 m * 0.50 m
Zemin sınıfı	ZC
S_{DS}	1.0
S_{D1}	0.35


**Şekil 1.** Kocaeli Depremi Kuzey-güney Doğrultusu İvme Kaydı (Afet ve Acil Durum Yönetimi Başkanlığı, 2023)**Şekil 2.** Kocaeli Depremi Doğu-batı Doğrultusu İvme Kaydı (Afet ve Acil Durum Yönetimi Başkanlığı, 2023)




Şekil 3. Tasarım Spektrumu ve Ölçeklendirme İşlemi Yapılmış Deprem İvme Kayıtlarının Tepki Spektrumları




Şekil 4. Tip-1 Planı



Şekil 5. Tip-2 Planı

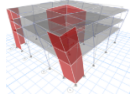
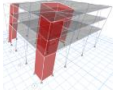
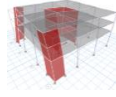
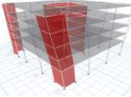
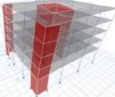
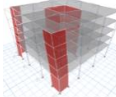
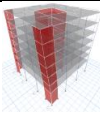
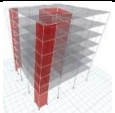
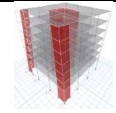
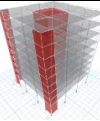
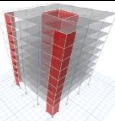
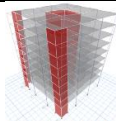


Şekil 6. Tip-3 Planı

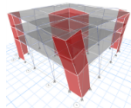
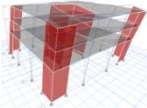
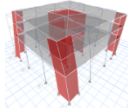
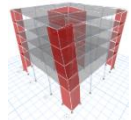
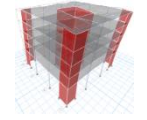
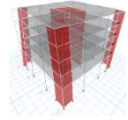
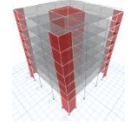
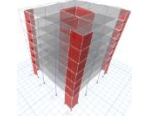
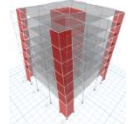
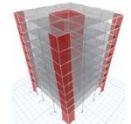
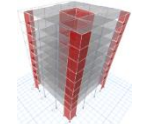
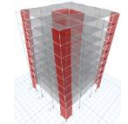


Şekil 7. Tip-4 Planı

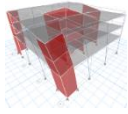
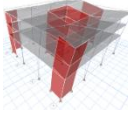
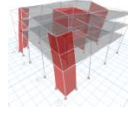
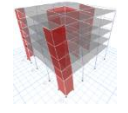
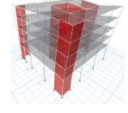
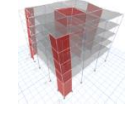
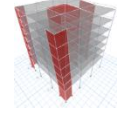
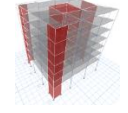
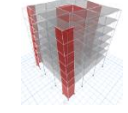
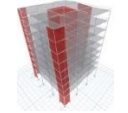
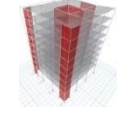
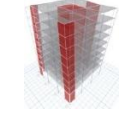
Tablo 2. Tip-1'e ait 3,5,7 ve 9 Katlı Binaların İlk Üç Mod Şekli ve Periyot Değerleri

Kat Plan Tipi	Kat Adedi	Mod 1	Mod 2	Mod 3
Tip-1	3	 $T_b = 0.251$ s (burulma)	 $T_y = 0.173$ s (y)	 $T_b = 0.15$ s (burulma)
Tip-1	5	 $T_b = 0.449$ s (burulma)	 $T_y = 0.319$ s (y)	 $T_b = 0.266$ s (burulma)
Tip-1	7	 $T_b = 0.668$ s (burulma)	 $T_y = 0.495$ s (y)	 $T_b = 0.404$ s (burulma)
Tip-1	9	 $T_b = 0.903$ s (burulma)	 $T_y = 0.692$ s (y)	 $T_b = 0.558$ s (burulma)

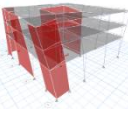
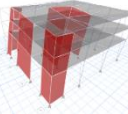
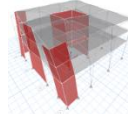
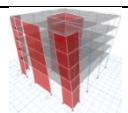
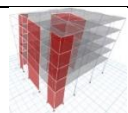
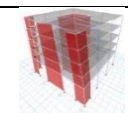
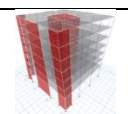
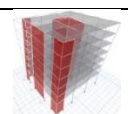
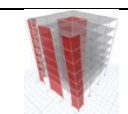
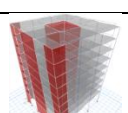
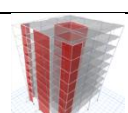
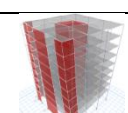
Tablo 3. Tip-2'ye ait 3,5,7 ve 9 Katlı Binaların İlk Üç Mod Şekli ve Periyot Değerleri


Kat Plan Tipi	Kat Adedi	Mod 1	Mod 2	Mod 3
Tip-2	3	 $T_x = 0.197$ s (x)	 $T_y = 0.167$ s (y)	 $T_b = 0.149$ s (burulma)
Tip-2	5	 $T_x = 0.358$ s (x)	 $T_y = 0.311$ s (y)	 $T_b = 0.265$ s (burulma)
Tip-2	7	 $T_x = 0.539$ s (x)	 $T_y = 0.484$ s (y)	 $T_b = 0.4$ s (burulma)
Tip-2	9	 $T_x = 0.735$ s (x)	 $T_y = 0.676$ s (y)	 $T_b = 0.552$ s (burulma)

Tablo 4. Tip-3'e ait 3,5,7 ve 9 Katlı Binaların İlk Üç Mod Şekli ve Periyot Değerleri


Kat Plan Tipi	Kat Adedi	Mod 1	Mod 2	Mod 3
Tip-3	3	 $T_x = 0.217$ s (x)	 $T_y = 0.154$ s (y)	 $T_b = 0.146$ s (burulma)
Tip-3	5	 $T_x = 0.393$ s (x)	 $T_y = 0.292$ s (y)	 $T_b = 0.259$ s (burulma)
Tip-3	7	 $T_x = 0.591$ s (x)	 $T_y = 0.461$ s (y)	 $T_b = 0.393$ s (burulma)
Tip-3	9	 $T_x = 0.809$ s (x)	 $T_y = 0.655$ s (y)	 $T_b = 0.547$ s (burulma)

Tablo 5. Tip-4'e ait 3,5,7 ve 9 Katlı Binaların İlk Üç Mod Şekli ve Periyot Değerleri


Kat Plan Tipi	Kat Adedi	Mod 1	Mod 2	Mod 3
Tip-4	3	 $T_b = 0.241$ s (burulma)	 $T_x = 0.168$ s (x)	 $T_b = 0.128$ s (burulma)
Tip-4	5	 $T_b = 0.433$ s (burulma)	 $T_x = 0.302$ s (x)	 $T_b = 0.23$ s (burulma)
Tip-4	7	 $T_b = 0.65$ s (burulma)	 $T_x = 0.461$ s (x)	 $T_b = 0.348$ s (burulma)
Tip-4	9	 $T_b = 0.884$ s (burulma)	 $T_x = 0.643$ s (x)	 $T_b = 0.478$ s (burulma)




Şekil 8. Tip-1 Binasında Katlara Göre Periyot Değerlerinin Değişimi



Şekil 9. Tip-2 Binasında Katlara Göre Periyot Değerlerinin Değişimi



Şekil 10. Tip-3 Binasında Katlara Göre Periyot Değerlerinin Değişimi



Şekil 11. Tip-4 Binasında Katlara Göre Periyot Değerlerinin Değişimi

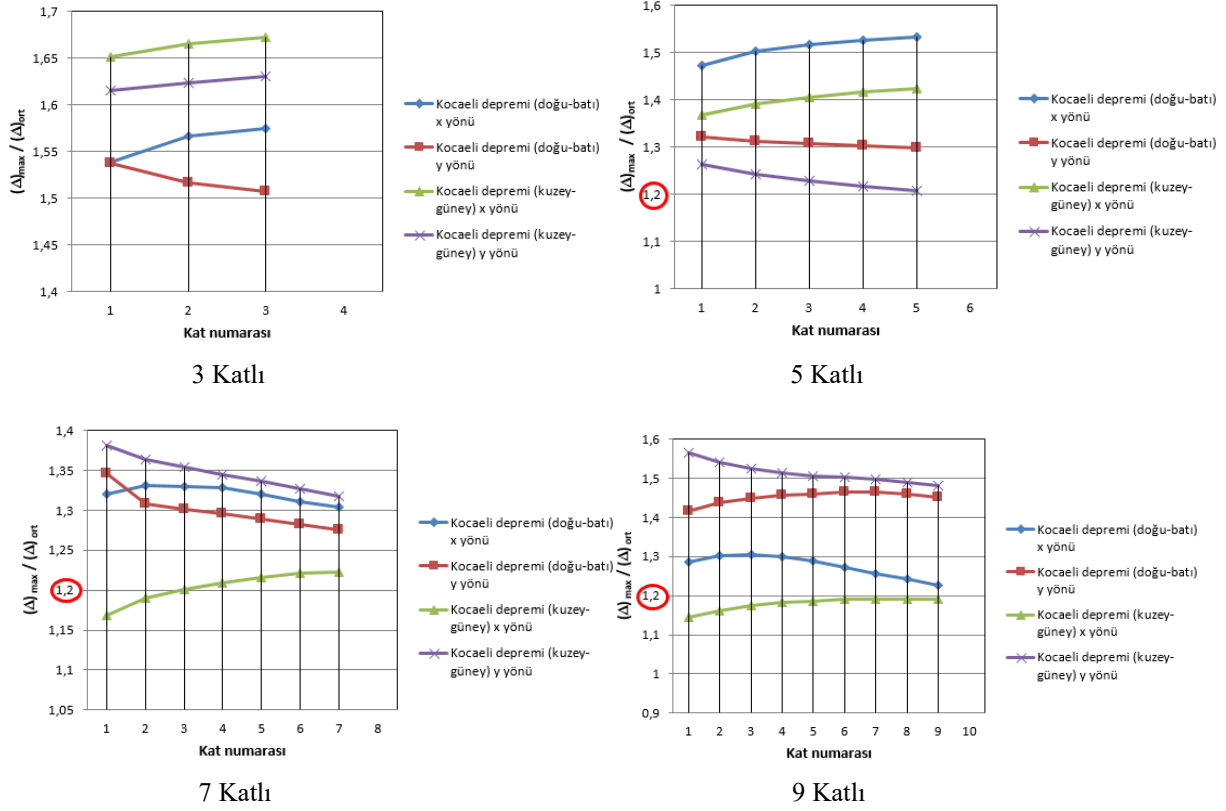
Kat sayılarının farklı olduğu 4 tip modelde ulaşılan periyot değerleri irdelendiğinde kat adedinin artışıyla birlikte periyot değerlerinde artış meydana gelmiştir. Tip-1, 9 katlı binada en büyük periyot değeri gözlenmiştir. Kat sayıları farklı olan betonarme binalarda perdelerin planda farklı yerleşiminin burulma düzensizliğini nasıl etkilediği irdelenerek yönetmelikte ifade edilen değerle kıyaslanmıştır. Tasarımı yapılan modellerin burulma düzensizliği katsayılarındaki değişimi incelemek amacıyla Kocaeli depreminin ivme kayıtları kullanılmıştır. İkinci bir parametre olarak burulma modunun ilk modlarda ortaya çıkması istenilmemektedir. Tip-1 ve Tip-4 modellerde 1. ve 3. modun burulma modu, Tip-2 ve Tip-3'te ise 3. modun burulma modu olduğu belirlenmiştir. Burulma modunun ilk modlarda çıkması binaların burulma davranışını ortaya koymak açısından önemli bir parametredir. TBDY-2018'de yüksek yapılar için verilen taşıyıcı sistemin hâkim burulma modu periyodunun hâkim öteleme modunun periyodundan daha uzun olmaması koşulu sağlanmalıdır (Türkiye Bina Deprem Yönetmeliği, 2018).

Bu çalışmada, farklı bina modelleri üzerinde yapılan analizlerde, Kocaeli depremi doğu-batı ve kuzey-güney doğrultularındaki ivme kayıtlarının etkileri detaylı bir şekilde değerlendirilmiştir. Analizler, tüm bina tiplerinde burulma düzensizliği katsayılarının (η_{bi}), TBDY-2018 yönetmeliğinde belirtilen 1.2 sınır değerini çoğu durumda aştığını ortaya koymuştur. Doğru-batı doğrultusundaki ivme kayıtları, çoğunlukla her iki yön için sınır değerlerin üzerinde bulunmuş, kuzey-güney doğrultusundaki ivme kayıtları ise özellikle y yönünde yüksek değerler göstermiştir. Bu durum, burulma düzensizliğinin, incelenen bina modellerinin yapısal özelliklerine ve doğrultulara bağlı olarak değişiklik gösterdiğini ortaya koymaktadır.

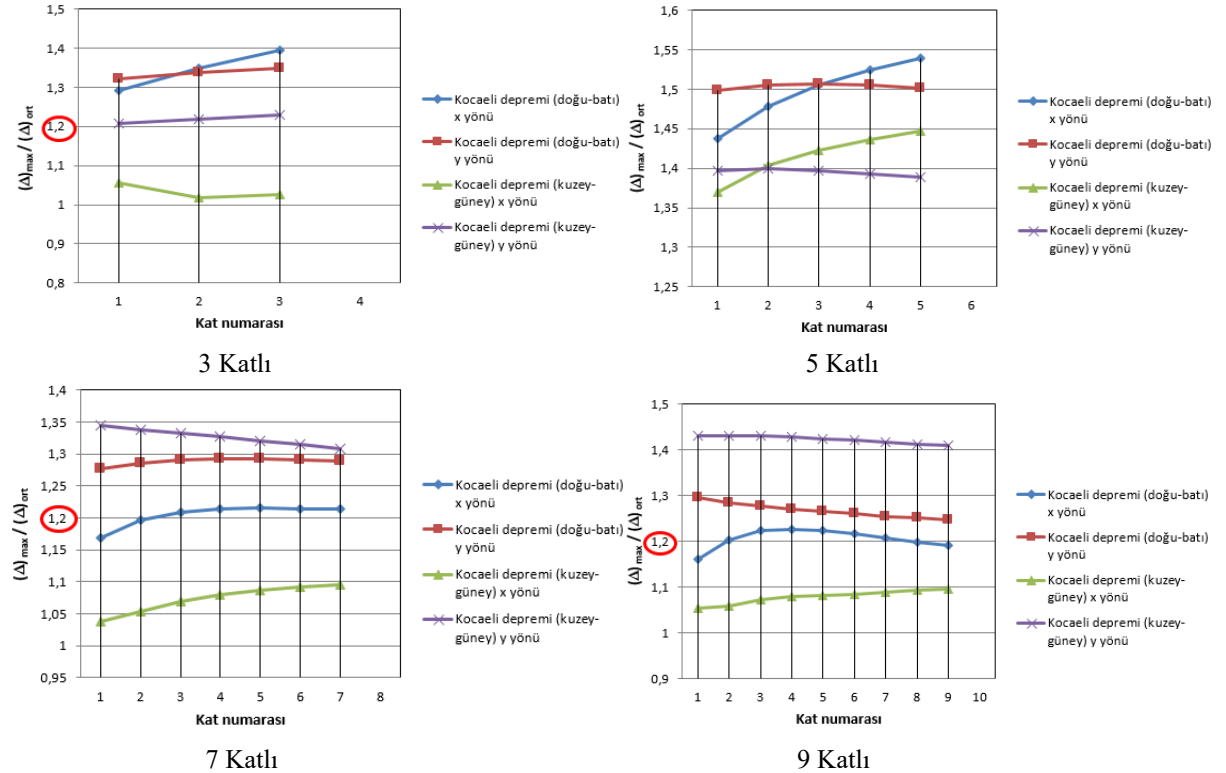
Düşük katlı bina modellerinde burulma düzensizlikleri genellikle tüm katlarda görülürken, yüksek katlı binalarda bu düzensizlikler belirli katlarla sınırlı kalmıştır. Üç ve beş katlı modellerde η_{bi} değerleri tüm katlarda 1.2 sınırını aşarken, yedi ve dokuz katlı modellerde bazı alt veya üst katlarda bu sınırın altında kalmıştır. Özellikle kuzey-güney doğrultusundaki ivme kayıtlarının x yönü için alt katlarda düzensizlik oluşmazken, diğer katlarda sınır değerlerin üzerinde olduğu tespit edilmiştir.

Doğru-batı doğrultusundaki ivme kayıtlarının x ve y yönlerinde, yüksek katlı modellerde bile η_{bi} değerlerinin 1.2'yi sıklıkla aştığı görülmektedir. Bu durum, bu doğrultunun binalardaki yapısal düzensizliklere daha fazla etki ettiğini göstermektedir. Öte yandan, kuzey-güney doğrultusunda y yönünde kaydedilen ivme etkilerinin ise çoğu durumda sınır değerleri aşarak binalarda önemli bir burulma etkisi oluşturduğu belirlenmiştir. Bu bulgular, farklı bina

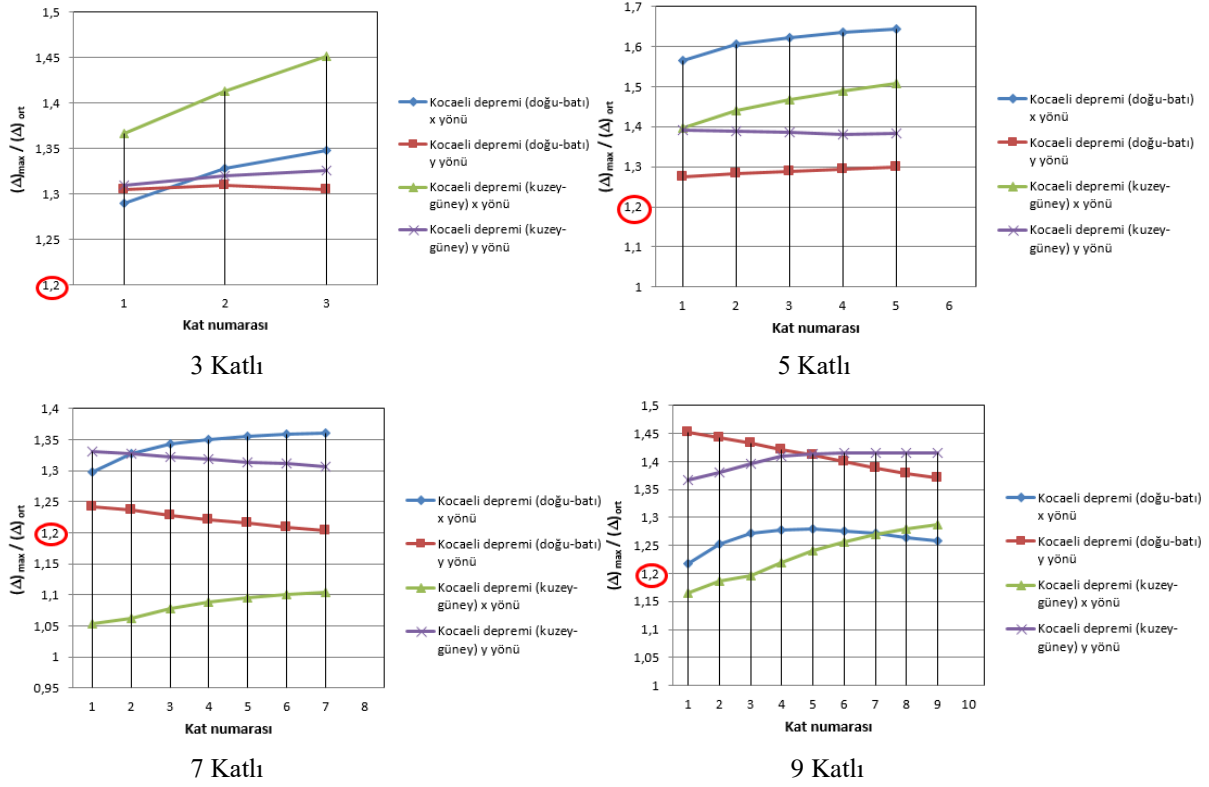
modelleri için doğrultu ve yükseklik değişkenlerinin etkisinin göz ardı edilmemesi gerektiğini ortaya koymaktadır. Sonuçlar, burulma düzensizliğinin düzenli bir örüntü sergilediğini, ancak kat yükseklikleri ve doğrultular arasında farklılıklar olduğunu göstermektedir. η_{bi} değerlerine ait grafikler Şekil (12-15)'te sunulmuştur.



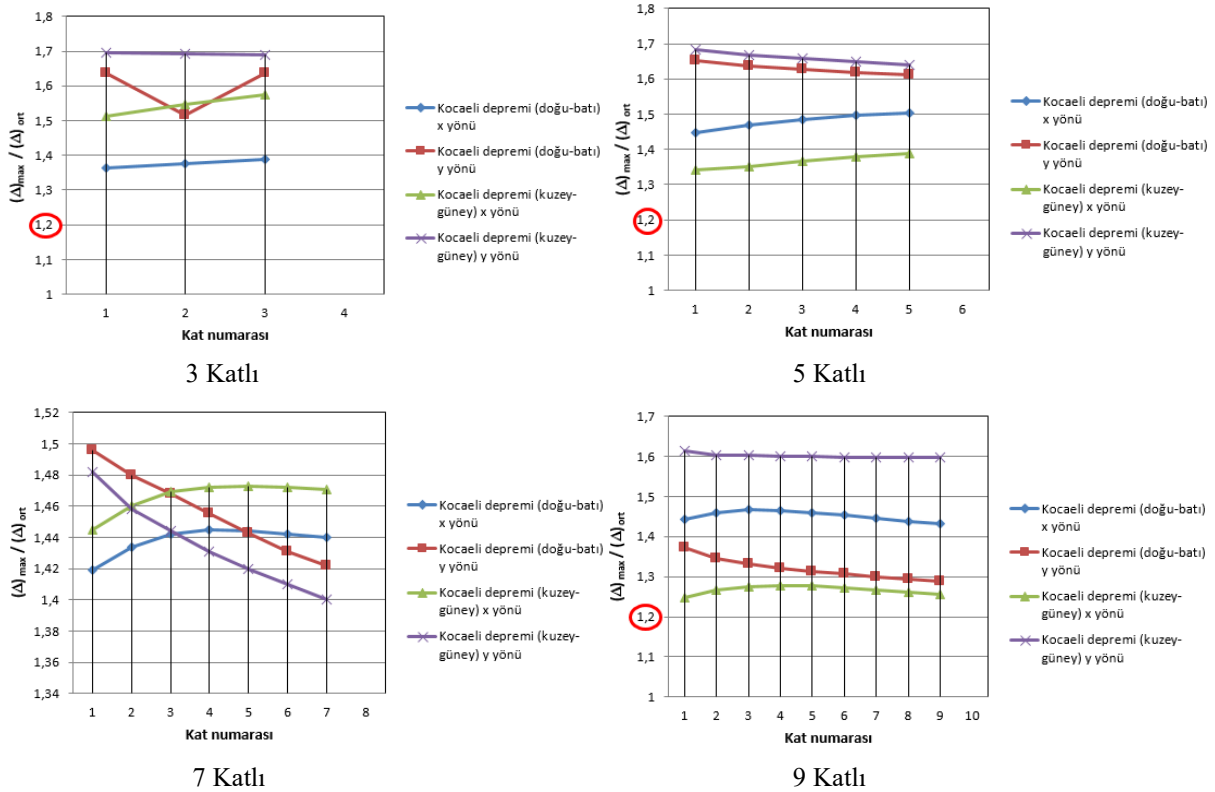
Şekil 12. Tip-1, 3,5,7 ve 9 Katlı Bina Modelleri İçin Elde Edilen η_{bi} Değerleri



Şekil 13. Tip-2, 3,5,7 ve 9 Katlı Bina Modelleri İçin Elde Edilen η_{bi} Değerleri



Şekil 14. Tip-3, 3,5,7 ve 9 Katlı Bina Modelleri İçin Elde Edilen η_{bi} Değerleri



Şekil 15. Tip-4, 3,5,7 ve 9 Katlı Bina Modelleri İçin Elde Edilen η_{bi} Değerleri

SONUÇLAR VE ÖNERİLER

Bu çalışmada, farklı kat sayılarına ve perde konumlarına sahip betonarme binaların burulma davranışları TBDY-2018 yönetmeliği kapsamında incelenmiştir. Bu amaçla, 3, 5, 7 ve 9 katlı betonarme binaların 4 farklı kat planı üzerinden perde konumları değiştirilerek toplam 16 model oluşturulmuş ve dinamik analizleri doğrusal olmayan zaman tanım alanında analiz yöntemi ile yapılmıştır. Analizlerde 1999 Kocaeli depremine ait ivme kayıtları kullanılarak periyot değerleri ve burulma düzensizliği katsayıları hesaplanmıştır. Çalışmanın bulguları ve önerileri aşağıda sunulmuştur:

- Bina tipleri ve perde yerleşim düzenleri burulma davranışını doğrudan etkilemiştir. Perdelerin rijitlik ve kütle merkeziyle olan uyumsuzluğu, burulma düzensizliği katsayısını artırmaktadır.
- Özellikle Tip-1 ve Tip-4 binalarında burulma modunun ilk modlarda olduğu tespit edilmiştir. Bu durum, rijitlik dağılımındaki dengesizliklerin bir sonucu olarak değerlendirilebilir.
- Kat sayısının artmasıyla periyot değerlerinde artış gözlenmiş, ancak burulma düzensizliği katsayıları genellikle düşüş eğilimi göstermiştir. Bu durum, perde yerleşim geometrisinin az katlı yapılarda daha kritik bir rol oynadığını göstermektedir.
- Kocaeli depremi ivme kayıtlarına dayalı analizler, maksimum burulma düzensizliğinin deprem yönüne ve perde konumlarına bağlı olarak değişiklik gösterdiğini ortaya koymuştur. Y yönündeki burulma düzensizlikleri üst katlarda azalma eğilimi gösterirken, x yönünde artış eğilimi tespit edilmiştir.
- Perdelerin rijitlik merkezine yakın ve simetrik olarak yerleştirilmesi, burulma davranışını olumlu etkilemiştir. Tip-2 binasının daha düşük burulma düzensizliği katsayılarına sahip olması, bu yerleşim düzeninin önemini vurgulamaktadır.
- Az katlı binalarda maksimum burulma genellikle üst katlarda, yüksek katlı binalarda ise alt katlarda yoğunlaşmıştır. Bu durum, bina yüksekliği ve perde yerleşim geometrisinin birlikte değerlendirilmesi gerektiğini göstermektedir.

Sonuçların analizinden elde edilen bulgular ışığında, burulma düzensizliğini azaltmaya ve yapı performansını iyileştirmeye yönelik tasarım ve uygulama stratejilerini içeren öneriler aşağıda sunulmuştur:

- Perdelerin iki yönlü simetrik ve rijitlik merkeziyle uyumlu şekilde yerleştirilmesi sağlanmalıdır.
- Yönetmelik kapsamında belirtilen burulma düzensizliği kriterlerine uygun olarak taşıyıcı sistem tasarımı yapılmalıdır. Burulma modunun ilk modlarda oluşmasının önlenmesi için rijitlik dağılımı optimize edilmelidir.
- Burulma düzensizliğini azaltmak için perde alanlarının az katlı yapılarda aşırı büyük seçilmemesi ve rijitlik dağılımının optimize edilmesi gerekmektedir.
- Doğrusal olmayan zaman tanım alanında yapılan analizlerin farklı ivme kayıtları ile tekrarlanarak burulma davranışı daha kapsamlı incelenebilir.

KAYNAKLAR

Afet ve Acil Durum Yönetimi Başkanlığı (AFAD) Veri Tabanı. <https://deprem.afad.gov.tr/home-page/> Erişim tarihi: 2024.

Atar, M., İnce, O., Taş, Ö. F., Özmen, A., & Sayın, E. (2024). 6 Şubat 2023 Kahramanmaraş depremleri sonrası Malatya ilinde bulunan betonarme binaların ve çelik yapıların hasar durumlarının incelenmesi. *Türk Deprem Araştırma Dergisi*, 6(1), 60-80. <https://doi.org/10.46464/tdad.1394039>

Baral, A., & Yajdani, S. K. (2015). Seismic analysis of RC framed building for different position of shear wall. *International Journal of Innovative Research in Science, Engineering and Technology*, 4(5), 3346-3353. <https://doi.org/10.15680/IJIRSET.2015.0405055>

Çetin, K., Demir, A., & Altıok, T. Y. (2020). 2007 ve 2018 Türk Deprem Yönetmeliklerine göre yerel zemin sınıflarının yapılardaki burulma düzensizliğine etkisi. *Konya Mühendislik Bilimleri Dergisi*, 8(2), 282-290. <https://doi.org/10.36306/konjes.578184>

DBYBHY. (2007). Deprem Bölgelerinde Yapılacak Binalar Hakkında Yönetmelik. Ankara: Bayındırlık ve İskân Bakanlığı.

- Demir, A., & Dönmez, D. (2008). Çok katlı yapılarda burulma düzensizliğine etki eden faktörler. C.B.Ü. Fen Bilimleri Dergisi, 4(1), 31-36.
- Derdiman, M. K., & Mirkelam, Z. A. (2011). Planında asimetrik betonarme yapıların deprem davranışının enerji sönmüleyicilerle iyileştirilmesi. Yapı Teknolojileri Elektronik Dergisi, 7(2), 15-30.
- Döker, A. T. (2020). Burulma düzensizliğine sahip taban izolasyonlu yapıların deprem davranışının incelenmesi. Yüksek Lisans Tezi. Uludağ Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı, Bursa 106s.
- Erdem, H. (2016). Burulma Düzensizliğinin Betonarme Yapı Davranışına Etkileri. Çukurova Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 31(1), 459-468. <https://doi.org/10.21605/cukurovaummfd.319360>
- ETABS Version 18.1.1, Computers and Structures, Inc. Berkeley, California, 2020.
- Hussain, S. M., & Tengli, S. K. (2018). Study on torsional effects of irregular buildings under seismic loads. International Journal of Applied Engineering Research, 13(7), 55-60.
- Haskılıç, S. (2022). TBDY-2018'e göre kirişsiz döşeme sistemli betonarme yapıların deprem davranışının perde oranına göre incelenmesi. Yüksek Lisans Tezi. Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı, Konya 143s.
- Işık, E., & Öztürk, G. (2017). Betonarme binalarda kat yüksekliğinin yapı performansına etkisi. Karaelmas Fen ve Mühendislik Dergisi, 7(1), 299-305.
- İnce, O. (2024). Structural damage assessment of reinforced concrete buildings in Adıyaman after Kahramanmaraş (Türkiye) Earthquakes on 6 February 2023. Engineering Failure Analysis, 156, 107799. <https://doi.org/10.1016/j.engfailanal.2023.107799>
- Kaya, G., & Özsoy Özbay, A. E. (2019). Perde ve çerçevesiz betonarme yapılarda perde konumunun planda düzenlenmesi ve yapısal davranışa etkisi. Mühendislik Bilimleri ve Tasarım Dergisi, 7(1), 7-17. <https://doi.org/10.21923/jesd.429880>
- Mallika, K., & Nagesh Kumar, G. (2016). Analysis of shear wall in high rise unsymmetrical building using ETABS. International Journal of Innovative Research in Science, 5(11), 19951-19960. <https://doi.org/10.15680/IJRSET.2016.0511056>
- Mohammed, B. H. (2023). Burulma düzensizliği bulunan binaların deprem performanslarının değerlendirilmesi. Yüksek Lisans Tezi. Dicle Üniversitesi Fen Bilimleri Enstitüsü İnşaat Mühendisliği Anabilim Dalı, Diyarbakır 145s.
- Özmen, A., İnce, O., Taş, Ö. F., Atar, M., Özbulut, O. E., & Sayın, E. (2024). Seismic performance assessment of structures in Malatya Province after 6 February 2023 Turkey earthquake sequences. Natural Hazards, 1-34. <https://doi.org/10.1007/s11069-024-07017-x>
- Sağlıyan, S., Yön, B., & Sayın, E. (2012). Burulma düzensizliğinin çok katlı sürekli tablalı kirişsiz ve kirişli döşemeli yapılara etkisinin incelenmesi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Fen Bilimleri Dergisi, 28(2), 73-87.
- Taş, Ö. F., Sayın, E., & Öncü, M. E. (2022). Yeni betonarme binalar için etkin kesit rijitlikleri ve statik itme analizleri. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 34(2), 505-516. <https://doi.org/10.35234/fumbd.1074221>
- TBDY. (2018). Türkiye Bina Deprem Yönetmeliği. Ankara: Afet ve Acil Durum Yönetimi Başkanlığı.
- Tursun, D., Taş, Ö. F., & Sayın, E. (2023). Türkiye Bina Deprem Yönetmeliği 2018'e (TBDY-2018) göre betonarme bir binanın perde elemanlarının hasar sınır bölgelerinin tespit edilmesi. Fırat Üniversitesi Mühendislik Bilimleri Dergisi, 35(2), 581-595. <https://doi.org/10.35234/fumbd.1287311>
- Uçar, T., & Merter, O. (2009). Planda perde yerleşiminin betonarme perde-çerçevesiz binaların deprem davranışına etkisi. Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi, 11(2), 11-18.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 24.10.2024
Kabul Tarihi : 10.12.2024

Received Date : 24.10.2024
Accepted Date : 10.12.2024

DALGACIK DÖNÜŞÜMÜ TABANLI NAİVE BAYES SINIFLANDIRICI İLE TÜRKİYE’NİN TAMAMINI İÇEREN BÖLGELERDEKİ LİNYİT KÖMÜRÜNÜN KALİTE TESPİTİ

QUALITY DETERMINATION OF LIGNITE COAL IN THE REGIONS INCLUDING THE WHOLE OF TURKEY USING WAVELET TRANSFORM BASED NAIVE BAYES CLASSIFIER

Sevcan AYTAÇ^{1*}(ORCID: 0000-0001-6689-2337)

¹ Fırat Üniversitesi, Elektronik ve Otomasyon, Elazığ, Türkiye

*Sorumlu Yazar / Corresponding Author: Sevcan AYTAÇ, sevcanaytackorkmaz@gmail.com

ÖZET

Günümüzde Türkiye sondaj sahalarından elde edilen karmaşık linyit kömürünün kabul edilebilir kalite ve nispeten zayıf kalitede olduğunun tespiti işlemi enerji santrallerinde, diğer alanlarda ve enerji üretiminde hayati öneme sahiptir. Özellikle, birden fazla karmaşık parametrelerinin doğru bir şekilde kalitelerine göre belirlenmesi yatırım kararlarında büyük ölçüde önem kazanmıştır. Bu makalede, Türkiye Kömür İşletmeleri Genel Müdürlüğünden alınan, MTA tarafından yayınlanan linyit envanterinde Türkiye'nin tamamını içeren 96 linyit kömürünün 96 sondaj bölgesine ait nem, kül, kükürt ve kalori içerikleri ele alınmıştır. Belirtilen nem, kül ve kükürt gibi 3 parametre, bağımlı değişken olan kalori değeri üzerinde etkili olmaktadır. Kalori ne kadar yüksekse kömür kalitesi o kadar iyidir. İlk olarak verilere K-Ortalamalar kümeleme algoritması uygulanarak kömürünün kalori değerleri 2 gruba ayrılmıştır. 2 gruba ayrılan bu değerler doğrulama verisi olarak kullanılmıştır. Dalgacık katsayılarından elde edilen özellik değerleri Naive Bayes sınıflandırıcısı ile sınıflandırılmıştır. Sınıflandırma performansları kıyaslandığında Daubechies dalgacık ailesinden olan db4'ün diğer dalgacık ailelerine ve CA dalgacık katsayılarının CH, CV ve CD katsayılarına göre daha yüksek performans sergilediği tespit edilmiştir. Nem, kül ve kükürt içeriklerinin Dalgacık Dönüşümü katsayıları hesaplanarak, Naive Bayes yöntemi ile sınıflandırma performansları kıyaslanmıştır. Daubechies ailesinden olan db4'ün yaklaşık katsayıları ile elde edilen kömürün kalite tespit oranının en yüksek olduğu ve %100 olarak bulunduğu tespit edilmiştir.

Anahtar Kelimeler: Linyit kömür, k-ortalamalar, dalgacık dönüşümü, naive bayes sınıflandırıcı

ABSTRACT

Today, the process of determining whether the complex lignite coal obtained from Turkey's drilling fields is of acceptable quality or relatively poor quality is of vital importance in power plants, other areas and energy production. In particular, the accurate determination of multiple complex parameters according to their quality has gained great importance in investment decisions. In this article, the moisture, ash, sulfur and calorie contents of 96 drilling regions of 96 lignite coals covering the whole of Turkey in the lignite inventory published by MTA, received from the General Directorate of Turkish Coal Enterprises, are discussed. The 3 parameters mentioned, such as moisture, ash and sulfur, affect the caloric value, which is the dependent variable. The higher the calories, the better the coal quality. First, by applying the K-Means clustering algorithm to the data, the caloric values of coal were divided into 2 groups. These values, divided into 2 groups, were used as validation data. Feature values obtained from wavelet coefficients were classified with the Naive Bayes classifier. When the classification performances were compared, it was determined that db4, which is from the Daubechies wavelet family, showed higher performance than other wavelet families and CA wavelet coefficients compared to CH, CV and CD coefficients. Wavelet Transform coefficients of moisture, ash and sulfur contents were calculated and classification performances were compared with the Naive Bayes method.

ToCite: AYTAÇ, S., (2025). DALGACIK DÖNÜŞÜMÜ TABANLI NAİVE BAYES SINIFLANDIRICI İLE TÜRKİYE’NİN TAMAMINI İÇEREN BÖLGELERDEKİ LİNYİT KÖMÜRÜNÜN KALİTE TESPİTİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 403-413.

It has been determined that the quality detection rate of coal obtained with the approximation coefficients of db4, which is from the Daubechies family, is the highest and is 100%.

Keywords: Lignite coal, k-means, wavelet transform, naive bayes classifier

GİRİŞ

Nem, kül ve kükürt gibi linyit kalitesini etkileyen değişkenler enerji santrallerinde, diğer alanlarda ve enerji üretiminde hayati öneme sahiptir. Bu nedenle bu değişkenlerin modellenmesi yatırım kararlarında yararlıdır (Moon vd., 2006; Tutmez vd., 2013; Korkmaz ve Esmeray, 2018). Dünya projeksiyonuna benzer şekilde, Türkiye'de bilinen linyit yataklarının çoğu düşük kalori değerine, yüksek oranda kül, uçucu madde, nem ve kükürt içeriklerine sahiptir. Bu nedenle, teknik ve ekonomik olarak işletmeler için uygulanabilir olan bu türdeki linyitlerin çoğunun, pazarlamadan önce yıkanarak zenginleştirilmesi gerekir (Korkmaz ve Esmeray, 2018; Senguler, 2010). Linyit, kömürün alt kademesi olmasına rağmen dünyanın birçok yerinde geniş rezervler edinilebilir. Türkiye dünyanın en önemli linyit üreticilerinden biridir (Korkmaz ve Esmeray, 2018; IEA, 2000). Linyit kömürü, Türkiye ulusal ürününün büyümesine önemli ölçüde katkıda bulunduğu için, linyit alanlarında genel bir değerlendirme yaparak, genel bir bakış açısı sağlamak ve nispeten teknik ve ekonomik değerlendirmeler yapma olanağı sağlamaktadır. Linyit kalitesine ilişkin parametreler arasındaki ilişkiyi sınıflandırmak ve modellemek için, literatürde birçok deneysel ve matematiksel / istatistiksel teknikler kullanılmıştır (Korkmaz ve Esmeray, 2018; Galetakis vd., 2002).

Bir çalışmada, Hindistan kömürlerini sınıflandırmak için, ilk kez "Kendini Düzenleyen Harita (Self Organization Map-SOM)" olarak bilinen klasik denetimsiz bir kümeleme tekniği olan "K-Ortalama Kümeleme" ve Yapay Zeka Tabanlı (Artificial Intelligence-AI) doğrusal olmayan kümeleme yöntemi kullanılmıştır. Bu çalışma ile K-Ortalama ve SOM tabanlı sınıflandırma sonuçlarının %75 kömür numunelerinde benzerlik sergilediği bulunmuştur (Korkmaz ve Esmeray, 2018; Pandit vd. 2011).

Başka bir araştırma çalışmasında, Hindistan'ın tüm büyük kömür alanlarından spontan yanmaya karşı yüksek ve düşük duyarlılığa sahip farklı safhalardan 51 kömür numunesi toplanmıştır. Toplanan bu kömürlerin damarlarının sınıflandırılması için bulanık K-Ortalama yönteminin kullanıldığı bir yaklaşım sunulmaktadır. Bu yaklaşımla, kömür numunelerinin nemi, uçucu maddesi, kül içeriği ve geçiş noktası sıcaklığını parametreler olarak kullanarak önerilen algoritma kömür damarlarını üç farklı kategoriye ayırmak için uygulanmıştır. Bu sınıflandırma, saha mühendislerine maden yangınlarının oluşmasını önlemek için önceden iyileştirici tedbirler almak için yararlı olacağı bilgisini vermektedir (Korkmaz ve Esmeray, 2018; Sahu vd., 2012).

Başka bir makalede, Hindistan'ın tüm büyük kömür alanlarından kendiliğinden yanmaya karşı yüksek ve düşük duyarlılık derecelerine sahip olan çeşitli derecelerde 29 kömür numunesi toplanmıştır. Bu makale, kümeleme probleminin doğrusal bir tayin modeli haline getirilmesini ve spontan yanmaya yol açan kömür damarlarının sınıflandırılması için ayırık parçacık sürüsü optimizasyon yaklaşımının uygulanmasını sunmaktadır (Korkmaz ve Esmeray, 2018; Sahu vd., 2011).

Ayrıca, literatürde kömürün nem, kül, kükürt ve kalori değerlerinin sınıflandırılması için çok farklı yaklaşımlar bulunmaktadır. Bu çalışmalardan biri olan makalede Yapay Sinir Ağları, Bulanık Çıkarım Sistemleri, Genetik Algoritmalar ve bunların melez biçimleri gerekli kömür parametrelerin tahmin edilmesi ve öngörülen modellerin geliştirilmesi için kullanılmıştır (Yılmaz vd., 2010).

Kömürlerin Brüt Kalori Değerinin (Gross Calorific Value-GCV) belirlenmesi, kömür karakterizasyonu için çok önemlidir; zor, pahalı, zaman alıcı ve tahrip edicidir. Bu çalışmada GCV'nin öngörülmesi için Yapay Sinir Ağlarının farklı öğrenme algoritmaları olan Çok Katmanlı Algılayıcı (Multi-Layered Perceptron-MLP), Radyal Tabanlı Fonksiyon (Radial Basis Function-RBF)-(tam), RBF (K-Ortalama) ve RBF (Kendini Düzenleyen Harita (Self Organization Map-SOM) gibi modelleri kullanılmıştır. Bu makalenin bir sonucu olarak, tüm modeller GCV'yi tahmin etmek için yüksek performans sergilemiştir. Yapay Sinir Ağları (Artificial Neural Network-ANN)'nin dört farklı algoritması neredeyse aynı tahmin etme kabiliyetine sahip olmuş olsa da, MLP'nin doğruluğunun diğer modellerden nispeten daha yüksek olduğu belirtilmiştir (Korkmaz ve Esmeray, 2018; Yılmaz vd., 2010).

Bir çalışmada linyit kömür numunelerinde, Yakın Kızıl Ötesi (Near-infrared-NIR) spektrumlarını kullanarak nem tespiti yapılmıştır. Çalışmadaki model, kısmi En Küçük Kareler Regresyonu (Least Squares Regression-PLS) ve Ayırık Dalgacık Dönüşümü (Discrete Wavelet Transform-DWT) uygulanarak geliştirilmiştir. Öncelikle, NIR

spektrumu, montaj ve sıkıştırma için DWT ile önceden işlendi. Daha sonra, sıkıştırılmış veriler, kömür örneklerinde nem belirlenmesi için PLS ile regresyon modeli oluşturmak için kullanılmıştır. Farklı çözünürlük ölçeklerinde sıkıştırma performansı araştırılmıştır. Sıkıştırılmış veriyi kullanarak, PLS ham spektrumlarından daha doğru sonuç elde edildiği belirtilmiştir. Ayrıca, PLS modelinde de ana bileşen sayısı araştırılmıştır. Sonuçlar, DWT-PLS'nin bitümlü kömür ve linyit kömürün nem analizi için tatmin edici bir tespit performansı elde edebildiğini göstermektedir (Korkmaz ve Esmeray, 2018; Yang vd., 2014).

Başka bir çalışmada, çevrimiçi kömür kalori değer tahmin yöntemine dayalı bir Destek Vektör Regresyonu (Support Vector Regression-SVR) modellenmesi yapılmıştır. Dalgacık Dönüşümü ve PCS işlemi ile kömür alevi radyasyon özellikleri çıkarılmıştır. SVR modellenmesi ile radyasyon karakteristik değişkenleri ile kömür kalori değeri arasındaki ilişki modeli oluşturulmuştur. Doğru SVR yapım parametreleri, Grid hesaplaması ile seçilmiştir. Deney sonuçlarının, SVR modeli tahmini ile kömür kalori değerinin laboratuvar sonuçları arasında iyi bir tutarlılık gösterdiği belirtilmiştir (Korkmaz ve Esmeray, 2018; Cheng vd., 2012).

Bununla birlikte, genel olarak jeosistemlerde kullanılan problem yapılarından bazıları, lineer regresyonda aşına olunan sürekli cevaplar yerine sonuç değişkenleri farklılıklar içerebilir. Bu nedenle, bazı durumlarda, konvansiyonel yaklaşımlar yerine, sonuç çıktılarını için bazı analizler yapılmalıdır. Literatürde şimdiye kadar Linyit Kömürünün kalite tespiti için K-Ortalamlar, Dalgacık Dönüşümü ve Naive Bayes sınıflandırma yöntemleri birlikte kullanılmamıştır. Bu makalede, verilerin arasındaki ilişki ve güçlü yönleri hakkında sınıflandırma yapmak için K-Ortalamlar, Dalgacık Dönüşümü ve Naive Bayes sınıflandırma yöntemleri birlikte kullanılmıştır. Ayrıca, bu makalede Naive Bayes sınıflandırıcısının kullanılmasının nedenlerinden birincisi bu yöntemin tahmine dayalı modelleme yapmak için basit ve bunun yanında güçlü bir algoritma olmasıdır. İkinci ise az sayıdaki verilerle güçlü tahmin kabiliyetine sahip kullanışlı ve avantajlı bir yöntem olmasıdır. Üçüncüsü ise, diğer sınıflandırıcılara göre daha iyi performans sağladığı için bu makalede kullanılmıştır.

Bu çalışmada, linyitin nem, kül ve kükürt içeriği ve tepki değişken kalori değeri gibi belirleyici kalite parametreleri arasındaki ilişkinin modellenmesine odaklanılmıştır. İlk olarak Türkiye'de linyit bölgelerinden elde edilen tüm ortalama kalori değerleri K-Ortalamlar yöntemi ile iki kategoriye ayrılmıştır. İkinci olarak kalori değerlerine göre iki kategoriye ayrılan nem, kül ve kükürt gibi özelliklere Dalgacık Dönüşümü yöntemi uygulanmıştır. Son olarak ise Naive Bayes sınıflandırıcısı yöntemiyle iki kategoriye ayrılan nem, kül ve kükürt değerlerine göre sınıflandırılma başarımları karşılaştırılmıştır. Bu makalenin literatüre katkıları aşağıdaki gibi sıralanmaktadır:

Türkiye Kömür İşletmeleri Genel Müdürlüğünden alınan, MTA tarafından yayınlanan lintit envanterinde Türkiye'nin tamamını içeren 116 bölgede linyit değerleri elde edilmiş olup bu çalışmada eksik veriler çıkarılarak 96 linyit kömürünün 96 sondaj bölgesine ait nem, kül, kükürt ve kalori içerikleri ele alınmış olup daha önceden K-ortalamlar kümeleme algoritması kullanılmamış olup bu makalede, K-ortalamlar kümeleme algoritması ile kalori değerleri 2 gruba ayrılarak bu değerler sınıflandırmada doğrulama verisi olarak kullanılmıştır.

1- Bugüne kadar, Türkiye'nin tamamını içeren bölgelerde bulunan karmaşık nem, kül, kükürt ve kalori gibi linyit kömürü verilerin kabul edilebilir kalite ve nispeten zayıf kalite diye iki sınıfa ayrılması için K-Ortalamlar, Dalgacık Dönüşümü ve Naive Bayes sınıflandırıcı yöntemleri birlikte kullanılmamıştır. Bu yöntemler birlikte kullanılarak bugüne kadar literatürde yapılmayan çok modaliteli farklı bir yöntemle sınıflandırma yapılmıştır.

2- Belirtilen nem, kül ve kükürt gibi 3 parametre, bağımlı değişken olan kalori değeri üzerindeki etkisine bakılarak kömürün bu kalori değerlerine göre çok modaliteli bir yöntemle “kabul edilebilir kalite” ve “nispeten zayıf kalite” olmak üzere 2 kategoriye ayrılmıştır. Kalori ne kadar yüksekse kömür kalitesinin o kadar iyi olduğu tespit edilmiştir.

Problem Belirleme

Linyit kalitesinin değerlendirilmesinde önemli parametrelerden biri olan kalori değeri, santrallerde yakılan kaliteli kömürün önemli bir ölçüsüdür. Kalori değeri genellikle yüksek ısıtma değeri veya brüt kalori değeri olarak belirtilir. Genel olarak, linyit belirsizdir ve bazı bölgelerde büyük rezervler olmasına rağmen, kalori değerleri düşük olarak kaydedilebilir (Korkmaz ve Esmeray, 2018; Chelgani vd. 2010). Nem, kül ve kükürt gibi linyit kalitesini etkileyen değişkenler enerji santrallerinde, diğer alanlarda ve enerji üretiminde hayati öneme sahiptir. Bu nedenle adı geçen değişkenlerin modellenmesi yatırım kararları için yararlıdır.

Türkiye Kömür İşletmeleri Genel Müdürlüğünden alınan, MTA tarafından yayınlanan lintit envanterinde Türkiye'nin tamamını içeren 116 bölgede linyit değerleri elde edilmiş olup bu çalışmada eksik veriler çıkarılarak 96 linyit kömürünün 96 sondaj bölgesi için linyit kömürü kalite sınıflandırma yapılması amaçlanmıştır. Bu bölgeler için elde edilen kalori değerleri, K-Ortalamalar kümeleme yöntemiyle, kabul edilebilir kalite ve nispeten zayıf kalite olmak üzere 2 kategoriye ayrılmıştır. Bu kategorilere 2200 kcal / kg ile 5574 kcal / kg arasındaki kalori değerlerinin kabul edilebilir kalite seviyesinde olduğu ve 868 kcal / kg ile 2196 kcal / kg arasındaki kalori değerlerinin nispeten zayıf

Tablo 1. Türkiye Kömür İşletmeleri Genel Müdürlüğünden Alınan, 96 Bölgenin Nem, Kül, Kükürt ve Kalori Değerleri (MTA Tarafından Yayınlanan Linyit Envanteri Verileri)

No	Nem	Kül	Kükürt	AID (kcal/kg)	No	Nem	Kül	Kükürt	AID (kcal/kg)
1	41,00	28,00	2,10	1298	49	25,73	30,90	2,51	2539
2	49,72	21,34	1,16	1385	50	19,67	35,74	3,29	2832
3	38,66	14,79	3,39	2820	51	25,00	22,61	2,41	2800
4	10,25	40,52	1,25	3500	52	27,50	36,57	2,02	1908
5	14,53	10,31	1,81	5574	53	32,50	22,50	1,50	2300
6	21,71	34,35	4,04	2557	54	48,00	25,00	1,10	1150
7	14,83	48,70	3,39	1988	55	25,00	25,00	5,40	2250
8	26,44	25,36	2,79	2839	56	50,00	11,00	1,10	2180
9	10,00	36,11	5,20	3000	57	41,70	20,25	1,54	1344
10	35,36	28,69	1,46	2004	58	45,57	25,00	1,10	1155
11	36,83	22,63	1,64	2232	59	48,88	27,00	1,66	1430
12	41,06	23,34	1,19	1470	60	22,90	15,30	4,42	4063
13	15,25	20,16	2,75	4020	61	4,41	25,54	6,51	5200
14	20,46	27,24	0,98	3120	62	32,00	43,00	1,20	2080
15	16,00	22,00	3,16	3800	63	15,00	41,00	1,60	2560
16	20,00	8,00	2,00	3260	64	13,00	33,00	1,30	3150
17	16,70	39,80	1,67	2700	65	15,00	28,00	0,70	2070
18	47,00	24,00	0,60	1460	66	18,00	45,00	0,70	2310
19	10,09	20,98	9,00	4755	67	15,00	36,00	1,20	2940
20	9,00	28,00	6,91	4100	68	18,00	40,00	1,20	2080
21	23,00	31,00	1,80	2340	69	30,90	17,43	5,80	3600
22	53,00	10,73	2,50	1754	70	52,00	19,00	2,00	1143
23	34,00	26,00	1,50	1900	71	48,07	24,08	0,92	1063
24	31,00	26,00	4,20	2100	72	29,00	25,00	3,20	2196
25	11,67	27,05	3,71	3840	73	31,00	27,00	3,30	1642
26	24,00	24,00	2,00	2500	74	32,00	29,00	2,20	1775
27	37,00	11,00	1,00	3190	75	30,00	31,00	1,30	1863
28	23,00	25,00	4,20	3000	76	30,00	22,00	4,50	2229
29	26,00	16,00	4,00	3678	77	27,00	25,00	4,30	4200
30	28,40	21,30	4,85	2960	78	34,00	22,00	3,00	2185
31	21,61	52,62	1,09	1278	79	29,00	28,00	3,10	2356
32	48,47	28,59	0,71	868	80	26,00	24,00	2,80	2670
33	23,00	23,00	1,60	3150	81	25,58	24,33	2,72	2671
34	23,00	46,00	1,40	1470	82	33,00	27,00	2,30	2168
35	31,30	42,55	0,76	976	83	42,00	22,00	1,30	1903
36	20,42	43,11	4,54	1878	84	42,24	29,69	2,51	1231
37	40,00	34,00	2,60	3000	85	41,20	32,80	1,01	1244
38	38,00	20,00	2,00	2500	86	50,00	21,00	2,02	1300
39	19,20	23,29	0,71	3500	87	41,06	19,11	2,07	2120
40	31,61	26,97	1,33	2200	88	42,40	16,56	1,70	2194
41	17,07	35,73	4,07	2754	89	42,06	20,30	1,12	1699
42	34,53	34,12	1,30	1484	90	22,13	37,38	1,56	2266
43	5,66	36,44	3,74	4500	91	33,28	27,33	1,41	2359
44	11,76	40,89	1,94	2500	92	28,28	31,14	1,57	2277
45	28,59	30,39	1,60	2304	93	32,46	28,90	1,90	2075
46	35,00	19,00	0,20	2570	94	26,96	36,37	0,50	2089
47	21,00	45,00	0,50	971	95	5,32	31,46	4,10	4926
48	8,00	44,00	1,10	3100	96	13,76	43,80	4,09	2502


kalitede olduğu kabul edilmiştir. Bulunan bu kritik değerlere dayanarak, bu çalışmada linyit kalite parametreleri olan nem, kül ve kükürt içeriklerine göre sınıflandırma tahmini yapılması amaçlanmıştır. Bu çalışmada ifade edilen problemde, yanıt değişkeni olan linyit kalitesi, kabul edilebilir (1) ve nispeten zayıf (0) gibi sadece iki değer alabilir. İki hedef değişken kategorisinin üyeliğini tahmin etmek için çoklu öngörücü değişkenlerin etkisini tanımlayan bir sınıflandırma düşünülmüştür.

Veri Seti

Tablo 1’de, Türkiye Kömür İşletmeleri Genel Müdürlüğünden alınan, 96 bölgenin nem, kül, kükürt ve kalori değerlerini yani MTA tarafından yayınlanan linyit envanteri verilerini göstermektedir. 96 bölgenin verileri vardır. Sınıflandırmada, 48 bölgenin verileri eğitim amaçlı, 48 bölgenin verileri test amaçlı kullanılmıştır.

YÖNTEM

Bu makalede kullanılan linyit kömürü verileri, Türkiye Maden Tetkik ve Arama Genel Müdürlüğü'nün yetkili kamu kuruluşu tarafından yayınlanan Türkiye Linyit Envanterinden elde edilmiştir (Tutmez vd., 2013; MTA, 2010). Bu orijinal veriler, Türkiye'nin tamamını içeren 116 bölge için linyit değerleri elde edilmiş olup bu çalışmada eksik veriler çıkarılarak 96 linyit kömürünün 96 sondaj bölgesine ait nem, kül, kükürt ve kalori içerikleri ele alınmıştır. Bu makalede linyitin kabul edilebilir kalite ve nispeten zayıf kalite olmak üzere kalite sınıfının belirlenmesi için önerilmiş sistem Şekil 1’de görülmektedir.



Şekil 1. Önerilen Sistemin Genel Yapısı

K-Ortalamalar Yöntemi

Çok değişkenli istatistiksel bir teknik olan K-Ortalamalar yöntemi, homojen alt gruplara ayrılması ve benzerliklerine göre sınıflandırılması için kullanılmaktadır. En çok bilinen kümeleme yöntemlerinden biri K-Ortalamalar yöntemidir. Hiyerarşik olmayan bir yapıya sahip olan K-Ortalamalar yöntemi, bir T veri setine ait n adet değişkeni ve B adet özellik vektörünü A adet kümeye ayırma ve sınıflandırma özelliğine sahiptir (Korkmaz ve Esmeray, 2018; Muda vd., 2011).

Bu yöntem, daha önceden seçilmiş A adet kümeye ait merkezlerin tespit edilmesi ile başlar. Ve daha sonra her bir değişken benzerlik ölçütü yardımıyla en yakın küme merkezine atanır (Korkmaz ve Esmeray, 2018; Ozcift vd., 2008). Giriş veri setinde bulunan her bir değişkenin 2 kümeye atanmasından sonra, her bir küme için küme merkezi yeniden hesaplanır. Küme merkezi yeniden hesaplandıktan sonra ise bu değişkenler elde edilen yeni küme merkezlerinin yerleşimine bağlı olarak yeni farklı kümelere atanabilir. Bu işlem küme üyeliklerinde herhangi bir değişim olmayana kadar tekrarlanır. İncelenen bir problemde, K adet özellik vektörüne ve n adet değişkene sahip bir T veri seti $T = \{t_k | k = 1, 2, \dots, A\}$ şeklinde tanımlanabilir. Bu veri setinde k. özellik vektörü $X_k = [x_{k1}, x_{k2}, \dots, x_{kn}]$, $x_k \in R^d$ şeklinde yazılabilir (Korkmaz ve Esmeray, 2018; Muda vd., 2011; Fırat vd., 2012).

Denklem (1)'de, verilen amaç fonksiyonunun veri setinin alt kümelerine ayrıldığıında en küçük küme ayrılması ana hedefdir. Bu denklemde verilen amaç fonksiyonu ile en küçük küme elde edilmesi esas, her bir özellik vektörü ile en yakın küme merkezi arasındaki mesafe ölçütünün ve dolayısıyla benzer yapıya sahip verilerin aynı kümede toplanmasını sağlamaya dayanmaktadır. Mesafe ölçütünün hesaplanması için genellikle Denklem (2)'de verilen öklit mesafe ölçütü kullanılmaktadır (Korkmaz ve Esmeray, 2018; Fırat vd., 2012; Leśniak ve Isakow, 2009).

$$J(S:T) = \sum_{i=1}^A \sum_{k=1}^B n_{ik}^2(t, S_i) \quad (1)$$

Denklem (1)'de verilen n_{ik}^2 aşağıdaki gibi tanımlanmıştır.

$$n_{ik}^2 = \left\| t_k^{(i)} - S_i \right\|^2 \quad (2)$$

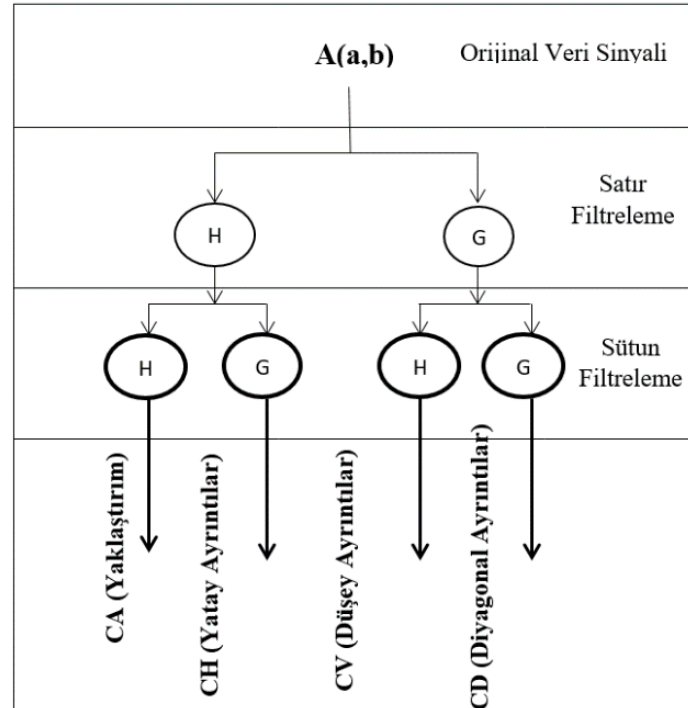
$$S_i = \frac{1}{B} \sum_{k=1}^B t_k^{(i)} \quad (3)$$

Dalgacık Dönüşümü Özellikleri

Ayrık Dalgacık Dönüşümü öznelik çıkartımı için son yıllarda sinyal işleme, biyomedikal işaret işleme, haberleşme gibi birçok değişik alanda yaygın olarak kullanılan bir yöntemdir (Korkmaz ve Esmeray, 2018; Leśniak ve Isakow, 2009). Ayrık Dalgacık Dönüşümü (ADD), tüm zaman boyunca dalgacığın zaman düzleminde ölçeklenmiş ve ötelenmiş değerleriyle çarpılan sinyalin toplamına denir. ADD fonksiyonu, imge ya da işaret için istenilen seviyede kullanılabilir (Korkmaz ve Esmeray, 2018; Leśniak ve Isakow, 2009). ADD alt bantlara ayırma yöntemi verilerin, yüksek frekansa ait bileşenini dar bir aralıkta, düşük frekansa ait bileşenini de daha geniş bir bant aralığında analiz ederek, sinyale ait ayırt edici özelliklerin elde edilmesine olanak sağlar. ADD kullanılarak dördüncü seviyeye kadar alt bant ayrışımının matematiksel ifadesi Denklem (4)'de gösterilmektedir (Korkmaz ve Esmeray, 2018; Leśniak ve Isakow, 2009).

$$I_{BI}(u, v) = ADD\{I(x, y), B \in \{AA, YA, AY, YY\}, 1 < I < 4\} \quad (4)$$

Şekil 2'de işaretin bir seviye alt bantlara ayrılma işlemi gösterilmektedir.



Şekil 2. Orijinal Veri Sinyalinin Bir Seviye ADD Alt Bant Ayrışımı (Korkmaz ve Esmeray, 2018)

Şekil 2'deki $G[b]$ yüksek geçiren filtre ve $H[b]$ alçak geçiren filtreyi temsil etmektedir. Bu alt bantlara ayrıştırma işleminde $H[b]$ işarete ait yaklaşık katsayıları ifade ederken $G[b]$ ise işarete ait detay katsayılarını ifade etmektedir.

(Korkmaz ve Esmeray, 2018; Karhan ve Ergen, 2016; Sengur vd., 2008). İşaret öncelikle satır esasına göre filtrelemeye tabi tutulur. Bu filtreleme sonucunda, alçak ve yüksek geçiren filtrelemeden iki grup veri elde edilir. Elde edilen verilerde örnek azaltması yapılır. Ardından bu iki alt grup veriler sütun esasına göre yine alçak ve yüksek geçiren filtrelerden geçirilir. Bu alt iki grup veriden de yine iki alt veri grubu elde edilir. Sonuçta yaklaşım, yatay, dikey ve diyagonal olmak üzere dört alt veri grubu elde edilmiş olur. Yaklaşım verileri yine benzer şekilde ayrıştırılarak ADD devam ettirilebilir.

Çalışmalarda seçilmesi gereken dalgacık ailesi çeşidinin belirlenmesinde herhangi bir algoritma bulunmamaktadır. Zaman düzleminde ana dalgacık, üzerinde çalışılacak sinyale görsel olarak ne kadar çok benzerse, seçilen Dalgacık Dönüşümü yönteminden o kadar çok verim elde edilir. Fakat bu şekilde bir seçim yapılması hemen hemen olanaksız görünmektedir. Bu sebeple tüm dalgacık çeşitleri denenmelidir. Diğer filtreler kullanıldığında sınıflandırma doğruluk oranları düşük çıkmıştır. Bu yüzden dalgacık dönüşümünde kullanılan wavelet filtreleri diğer filtrelere göre avantajlı olduğu için kullanılmıştır. Genel amaçlı olarak kullanılan dalgacık Daubechies'tir. Diferansiyel bir operatör olan Haar Dalgacığı, Daubechies1, Symlet1, Coiflet1 ve BiorSpline1.1 dalgacık aileleri ile aynıdır (Korkmaz ve Esmeray, 2018; Sengur vd., 2008).

Naive Bayes Sınıflandırıcısı

Naive Bayes sınıflandırıcısı makine öğrenmesi ve veri madenciliği alanında yaygın kullanıma sahip denetimli öğrenme sınıfında bir algoritmadır. Belirli bir veri kümesini belirli bir sınıfa ait olma olasılığını tahmin etmede kullanılır. Sınıflandırmada, Bayes Karar teoremini esas alarak ve olasılık hesaplamalarını kullanarak en yüksek olasılığa sahip kararı seçmeyi hedefler. Bu yöntemde, her bir özelliğin sınıf içerisindeki diğer özelliklerden bağımsız olduğu kabul edilmektedir. Bu sınıflandırıcı basit hesaplamalar yaparak olasılık tabanlı olarak bir olayın gerçekleşme ihtimalini hesaplamaktadır. Naive Bayes sınıflandırıcısı, tahmine dayalı modelleme yapmak için basit ve bunun yanında güçlü bir algoritma olduğu için ve az sayıdaki verilerle güçlü tahmin kabiliyetine sahip kullanışlı ve avantajlı bir yöntem olduğu için tercih edilir. Naive Bayes sınıflandırıcı, Bayes Teoremini temel alan ve bağımsız varsayımlara dayanan olasılıklı bir sınıflayıcıdır. Bayes teoremi koşullu olasılıklar ile marjinal olasılıklar arasındaki ilişkiyi gösteren ve bir rassal değişkeni referans alan sınıflandırıcı yöntemidir (McCallum ve Nigam, 1998).

$$P(X|Y) = \frac{P(Y|X)P(X)}{P(Y)} \quad (5)$$

Denklem (5)'de $P(X|Y)$ Y olayının gerçekleştiği durumda X olayının meydana gelme olasılığıdır. $P(Y|X)$ X olayı gerçekleştiği durumda Y olayının meydana gelme olasılığıdır. $P(X)$ ve $P(Y)$ ise X ve Y olaylarının önsel olasılıklarıdır (Yongkui vd., 2014). Bir sınıflandırma işlemi, birçok özellikten ve bir hedef değişkeninden oluşur.

$$p(T|K_1 \dots K_k) = \frac{p(T)p(K_1 \dots K_k|T)}{p(K_1 \dots K_k)} \quad (6)$$

T verilen hedef ve K özellikleri temsil eder. Naive Bayes sınıflandırıcı genel olarak bütün koşullu olasılıkların çarpımıdır (McCallum ve Nigam, 1998; Yongkui vd., 2014).

SONUÇLAR VE TARTIŞMA

Bugüne kadar makine öğrenme alanında birçok çalışma bulunmaktadır (Tuncer ve Ertam, 2020; Tuncer vd., 2019; Korkmaz, 2021; Korkmaz ve Binol, 2018; Aytaç Korkmaz, 2020; Doğan ve Ergen, 2022; Özdemir ve Türkoğlu, 2022). Bu makalede, makine öğrenme yöntemlerinden K-Ortalamalar, Dalgacık Dönüşümü ve Naive Bayes yöntemleri, Türkiye Maden Tetkik ve Arama Genel Müdürlüğü'nün yetkili kamu kuruluşu tarafından yayımlanan Türkiye Linyit Envanteri'nden elde edilen linyit kömürü verilerine uygulanmıştır. Türkiye Maden Tetkik ve Arama Genel Müdürlüğü'nün yetkili kamu kuruluşu tarafından yayımlanan Türkiye Linyit Envanteri'nden elde edilen linyit kömürü verilerinden olan nem, kül, kükürt ve kalori değerlerinden öncelikle kalori değerleri doğrulama verisi olarak kullanılmıştır. Bu kalori değerlerine göre K-Ortalamalar kümeleme yöntemiyle veriler "kabul edilebilir kalite" ve "nispeten zayıf kalite" olmak üzere 2 kategoriye ayrılmıştır. Bu kategorileşme yöntemi ile 2200 kcal / kg ile 5574 kcal / kg arasındaki kalori değerlerinin kabul edilebilir kalite seviyesinde olduğu ve 868 kcal / kg ile 2196 kcal / kg arasındaki kalori değerlerinin nispeten zayıf kalitede olduğu kabul edilmiştir. K-Ortalamalar yöntemiyle 2 kategoriye ayrılan 96 sondaj lokasyonu bölgesindeki linyit kömürlerinde doğrulama verisi olarak, 54 verinin kabul edilebilir kaliteli, 42'sinin ise nispeten zayıf kaliteli linyit kömürünün olduğu saptanmıştır. Daha sonra bu çalışmada linyit kömürünün kalite parametreleri olan nem, kül ve kükürt içerikleri esas alınarak Dalgacık Dönüşümü yöntemi ile

yaklaşım (CA), yatay (CH), düşey (CV), diyagonal (CD) katsayı değerleri bulunmuştur. Bu katsayılar bulunurken Daubechies, Symlet, Coiflet, Reversebior, Dmey, Biorpline ve Haar dalgacık aile gruplarından faydalanılmıştır. Bu katsayıların değerleri ayrı ayrı Naive Bayes sınıflandırıcısına verilerek “kabul edilebilir kalite” ve “nispeten zayıf kalite” olmak üzere iki sınıfa ayrılarak sınıflandırma doğruluk oranları bulunmuştur. Sınıflandırma yapılırken toplam verilerin 48’i test amaçlı 48’i ise eğitim amaçlı kullanılmıştır. Daha sonra bulunan bu sınıflandırma doğruluk oranı sonuçları karşılaştırılmıştır. Bu sonuçların karşılaştırılması Tablo 2, Tablo 3 ve Tablo 4’de gösterilmektedir.

Tablo 2. Reversebior Dalgacık Türü İçin Dalgacık Katsayılarına Göre Naive Bayes Sınıflandırıcı Performansları

	Dalgacık Katsayılarına göre Naive Bayes Sınıflandırıcı Performansı			
	CA	CH	CV	CD
rbio1.1	86,95	73,91	43,47	34,78
rbio1.3	86,95	60,86	47,82	56,52
rbio1.5	86,95	60,86	47,82	34,78
rbio2.2	91,30	78,26	56,52	47,82
rbio2.4	91,30	78,26	52,17	52,17
rbio2.6	91,30	78,26	52,17	56,52
rbio2.8	91,30	78,26	47,82	47,82
rbio3.1	86,95	69,56	43,47	47,82
rbio3.3	86,95	69,56	43,47	47,82
rbio3.5	86,95	69,56	43,47	47,82
rbio3.7	86,95	69,56	43,47	52,17
rbio3.9	86,95	69,56	47,82	52,17
rbio4.4	86,95	78,26	56,52	47,82
rbio5.5	86,95	73,91	56,52	56,52
rbio6.8	86,95	78,26	52,17	43,47

K-Ortalama kümeleme yöntemiyle kalori değerlerine göre kümelenen linyit kömürünün nem, kül ve kükürt değerleri, Tablo 2’de reversebior dalgacık ailesi türleri için CA, CH, CV ve CD katsayı değerleri kullanılarak Naive Bayes sınıflandırıcısı ile sınıflandırılmıştır. Tablo 2’deki sonuçlar incelendiğinde en yüksek sınıflandırma performansının reverseior dalgacık türlerinden rbio2.2, rbio2.4, rbio2.6 ve rbio2.8’in CA katsayıları ile %91.30 olarak bulunduğu görülmektedir.

K-Ortalama kümeleme yöntemiyle kalori değerlerine göre kümelenen linyit kömürünün nem, kül ve kükürt değerleri, Tablo 3’de Daubechies dalgacık ailesi türleri için CA, CH, CV ve CD katsayı değerleri kullanılarak Naive Bayes sınıflandırıcısı ile sınıflandırılmıştır. Tablo 3’deki sonuçlar incelendiğinde en yüksek sınıflandırma performansının Daubechies dalgacık türlerinden db4’ün CA katsayıları ile % 100 olarak bulunduğu görülmektedir.

Tablo 3. Daubechies Dalgacık Türü İçin Dalgacık Katsayılarına Göre Naive Bayes Sınıflandırıcı Performansları

	Dalgacık Katsayılarına göre Naive Bayes Sınıflandırıcı Performansı			
	CA	CH	CV	CD
db1	86,95	73,91	43,47	34,78
db2	82,60	60,86	56,52	56,52
db3	82,60	73,91	39,13	43,47
db4	100	91,30	39,13	43,47
db5	86,95	86,95	52,17	39,13
db6	78,26	78,26	34,78	34,78
db7	91,30	82,60	47,82	43,47
db8	73,91	78,26	43,47	43,47
db9	82,60	86,95	65,21	65,21
db10	86,95	82,60	47,82	47,82
db11	73,91	78,26	52,17	47,82
db12	91,30	86,95	65,21	60,86
db13	65,21	73,91	47,82	65,21
db14	82,60	78,26	52,17	56,52

K-Ortalama kümeleme yöntemiyle kalori değerlerine göre kümelenen linyit kömürünün nem, kül ve kükürt değerleri, Tablo 4’de Dmey, Haar, Coif, Sym ve Bior dalgacık ailesi türleri için CA, CH, CV ve CD katsayı değerleri kullanılarak Naive Bayes sınıflandırıcısı ile sınıflandırılmıştır. Tablo 4’deki sonuçlar incelendiğinde en yüksek

sınıflandırma performansının Coif3, Bior1.3 ve Bior1.5'in CA katsayıları ile % 91.30 olarak bulunduğu görülmektedir.

Tablo 4. Diğer Dalgacık Türleri İçin Dalgacık Katsayılarına Göre Naive Bayes Sınıflandırıcı Performansları

	Dalgacık Katsayılarına göre Naive Bayes Sınıflandırıcı Performansı			
	CA	CH	CV	CD
dmey	86,95	82,60	56,52	56,52
haar	86,95	73,91	43,47	34,78
coif1	86,95	78,26	52,17	56,52
coif2	69,56	73,91	43,47	39,13
coif3	91,30	91,30	52,17	43,47
coif4	78,26	78,26	39,13	34,78
coif5	86,95	82,60	47,82	43,47
sym1	86,95	73,91	43,47	34,78
sym2	82,60	60,86	56,52	56,52
sym3	82,60	73,91	39,13	43,47
sym4	69,56	65,21	43,47	43,47
sym5	86,95	86,95	56,52	47,82
sym6	69,56	69,56	43,47	39,13
sym7	69,56	69,56	43,47	39,13
sym8	69,56	69,56	43,47	34,78
bior1.1	86,95	73,91	43,47	34,78
bior1.3	91,30	65,21	43,47	34,78
bior1.5	91,30	69,56	43,47	34,78
bior2.2	78,26	69,56	56,52	60,86
bior2.4	82,60	69,56	56,52	60,86
bior2.6	82,60	69,56	56,52	60,86
bior2.8	82,60	69,56	56,52	60,86
bior3.1	86,95	56,52	43,47	60,86
bior3.3	78,26	69,56	43,47	60,86
bior3.5	78,26	69,56	43,47	60,86
bior3.7	78,26	69,56	43,47	60,86
bior3.9	78,26	65,21	43,47	60,86
bior4.4	86,95	69,56	52,17	56,52
bior5.5	86,95	86,95	52,17	52,17
bior6.8	86,95	69,56	52,17	56,52

Bu çalışmada elde edilen sonuçlar ile literatürde önerilen benzer çalışmaların sonuçları arasında aşağıda belirtilen üç nedenden dolayı doğrudan ve ayrıntılı karşılaştırma yapmak mümkün olamamıştır. İlk olarak, her çalışmada farklı veri doğrulama yöntemleri ve farklı makine öğrenmesi yöntemleri ve kullanılmaktadır. İkincisi, her çalışma, analiz türüne göre farklı tahmin edici değişkenleri olan ve farklı sayıda örnek içeren farklı veri kümeleri kullanmaktadır. Son olarak, oluşturulan her veri seti, örneğin kömürün çıkarıldığı bölge ve kömürün kalitesi gibi farklı veri özelliklerine sahip olabilmektedir.

Ancak, literatür çalışmalarından anlaşılacağı üzere günümüzde Türkiye'de bulunan karmaşık nem, kül, kükürt ve kalori gibi linyit kömürü verilerinin kabul edilebilir kalite ve nispeten zayıf kalite diye iki sınıfa ayrılması için K-Ortalamlar, Dalgacık Dönüşümü ve Naive Bayes sınıflandırıcı yöntemleri birlikte kullanılmamıştır. İlk olarak karmaşık olarak Türkiye Kömür İşletmeleri Genel Müdürlüğü tarafından verilen verilere K-Ortalamlar kümeleme algoritması uygulanmıştır. Bu K-Ortalamlar algoritmasının kümelediği kalori değerleri, nem, kül ve kükürt gibi linyit kömürü parametrelerinin sınıflandırılmasında doğrulama verisi olarak kullanılmıştır. Daha sonra nem, kül ve kükürt gibi linyit kömürü parametrelerinin Daubechies, Symlet, Coiflet, Reversebior, Dmey, Biorspline ve Haar gibi dalgacık aileleri yardımıyla CA, CH, CV ve CD dalgacık katsayıları bulunmuştur. Bu dalgacık katsayılarından elde edilen özellik değerleri Naive Bayes sınıflandırıcısı ile sınıflandırılmıştır. Sınıflandırma performansları kıyaslandığında nem, kül ve kükürt linyit kömürü parametrelerine uygulanan Daubechies dalgacık ailesinden olan db4'ün diğer dalgacık ailelerine ve CA dalgacık katsayılarının ise CH, CV ve CD katsayılarına göre daha yüksek performans sergilediği tespit edilmiştir. Kaliteli ve nispeten zayıf kaliteli linyit kömürünün yüksek performansla ayırt edilmesi yatırımcılara yatırım amaçlı fayda sağlarken, linyit kömürü kullanıcılarına da sağlık açısından fayda sağlayacağı düşünülmektedir.

Gelecek çalışmalarda, linyit verilerinin bilinen x, y koordinat sistemleri ve kalori değerleri referans alındığında iki boyutlu olduğu için bazı sınırlamalar olduğu için, 3 boyutlu olarak sondaj vurulmayan farklı x ve y noktalarındaki kalori sonuçları regresyon yöntemleriyle tahmin edilebilir. Bu çalışmada veri sayısı az olduğu için LSTM Derin öğrenme yöntemleri kullanılmamıştır. Bu yüzden, gelecek çalışmalarda, çok fazla sayıda bölgenin nem, kül, kükürt ve kalori değerleri temin edilebilirse, LSTM derin öğrenme tabanlı yöntemlerde kullanılarak analiz yapılabilir.

TEŞEKKÜR

Yazar İnönü üniversitesinde öğretim üyesi olan Prof. Dr. Bülent TÜTMEZ'e teşekkür etmektedir.

KAYNAKLAR

- Aytac Korkmaz, S. (2020). Grade level of lignite coal datas in the different areas with decision tree, random forest, and discriminant analysis methods. *Applied Artificial Intelligence*, **34(11)**, 755-776.
- Cheng, Y., Xu, L., Li, X., & Guo, Z. (2012, July). Online coal calorific value prediction from mutiband coal/air combustion radiation characteristics. In *Instrumentation and Control Technology (ISICT), 2012 8th IEEE International Symposium on*, 309-313, IEEE.
- Chelgani S C, Mesroghli S H, Hower J C. (2010). Simultaneous prediction of coal rank parameters based on ultimate analysis using regression and artificial neural network. *International Journal of Coal Geology*, **83(1)**, 31-34.
- Doğan, G. & Ergen, B. (2022). Karayollarındaki Asfalt Çatlaklarının Tespiti İçin Yeni Bir Konvolüsyonel Sinir Ağı Tabanlı Yöntem . *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, **34 (2)** , 485-494 . DOI: 10.35234/fumbd.1014951.
- Fırat M., Dikbaş F., Koç AC., ve Güngör M. (2012). K-Ortalamalar Yöntemi ile Yıllık Yağışların Sınıflandırılması ve Homojen Bölgelerin Belirlenmesi. *İMO Teknik Dergi*, **383**, 6037-6050.
- Galetakis M J, Theodoridis K, Kouridou O. (2002). Lignite quality estimation using ANN and adaptive neuro-fuzzy inference systems (ANFIS). *APPCOM*: 425-431.
- IEA, (2000). International energy annual. France. *International Journal of Coal Science & Engineering (China) Energy Agency*.
- Karhan Z., Ergen B. (2016). Content based medical image classification using discrete wavelet and cosine transforms. (2015). *23rd Signal Processing and Communications Applications Conference (SIU)*, (pp:1445-1448).
- Korkmaz, S. A. (2021). Classification of histopathological gastric images using a new method. *Neural Computing and Applications*, **33(18)**, 12007-12022.
- Korkmaz, S. A., & Binol, H. (2018). Classification of molecular structure images by using ANN, RF, LBP, HOG, and size reduction methods for early stomach cancer detection. *Journal of Molecular Structure*, **1156**, 255-263.
- Korkmaz, S. A., & Esmeray, F. (2018, March). Quality lignite coal detection with discrete wavelet transform, discrete fourier transform, and ANN based on k-means clustering method. In *Digital Forensic and Security (ISDFS), 2018 6th International Symposium on* (pp. 1-6). IEEE.
- Korkmaz, S. A., & Poyraz, M. (2014). A New Method Based for Diagnosis of Breast Cancer Cells from Microscopic Images: DWEE—JHT. *Journal of medical systems*, **38(9)**, 92.
- Leśniak, A., & Isakow, Z. (2009). Space-time clustering of seismic events and hazard assessment in the Zabrze-Bielszowice coal mine. Poland. *International Journal of Rock Mechanics and Mining Sciences*, **46(5)**, 918-928.
- McCallum, A., & Nigam, K. (1998, July). A comparison of event models for Naive Bayes text classification. In *AAAI-98 workshop on learning for text categorization*, **752**, pp. 41-48.
- Moon C J, Whateley M K G, Evans A M. (2006). "Introduction to mineral exploration" India: Blackwell Publishing.
- MTA, (2010). Lignite inventory of Turkey, general directorate of mineral research and exploration (MTA) in Turkey. Ankara (in Turkish).
- Muda, Z., Yassin, W., Sulaiman, M. N., & Udzir, N. I. (2011, July). Intrusion detection based on K-Means clustering and Naive Bayes classification. In *Information Technology in Asia (CITA 11), 2011 7th International Conference on* (pp. 1-6). IEEE.

- Ozcift, A., & Gulden, A. (2008). Assessing effects of pre-processing mass spectrometry data on classification performance. *European Journal of Mass Spectrometry*, **14(5)**, 267-273.
- Özdemir, E. & Türkoğlu, İ. (2022). Yazılım Güvenlik Açıklarının Evrimsel Sinir Ağları (CNN) ile Sınıflandırılması, *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, **34(2)**, 517-529. DOI: 10.35234/fumbd.1076870.
- Pandit, Y. P., Badhe, Y. P., Sharma, B. K., Tambe, S. S., & Kulkarni, B. D. (2011). Classification of Indian power coals using K-means clustering and Self Organizing Map neural network. *Fuel*, **90(1)**, 339-347.
- Sahu, H. B., Mahapatra, S. S., & Panigrahi, D. C. (2012). Fuzzy c-means clustering approach for classification of Indian coal seams with respect to their spontaneous combustion susceptibility. *Fuel processing technology*, **104**, 115-120.
- Sahu, H. B., Mahapatra, S. S., Sirikasemsuk, K., & Panigrahi, D. C. (2011). A discrete particle swarm optimization approach for classification of Indian coal seams with respect to their spontaneous combustion susceptibility. *Fuel processing technology*, **92(3)**, 479-485.
- Senguler I. (2010). Lignite explorations in Turkey: new projects and new reserves. //17th Annual International Pittsburgh Coal Conference, İstanbul, Turkey.
- Sengur, A., Turkoglu, I., & Ince, M. C. (2007). Wavelet packet neural networks for texture classification. *Expert systems with applications*, **32(2)**, 527-533.
- Sengur, A., Turkoglu, I., & Ince, M. C. (2008). Wavelet oscillator neural networks for texture segmentation. *Neural Network World*, **18(4)**, 275.
- Tuncer, T., & Ertam, F. (2020). Neighborhood component analysis and reliefF based survival recognition methods for Hepatocellular carcinoma. *Physica A: Statistical Mechanics and its Applications*, **540**, 123143.
- Tuncer, T., Dogan, S., & Akbal, E. (2019). A novel local senary pattern based epilepsy diagnosis system using EEG signals. *Australasian physical & engineering sciences in medicine*, **42(4)**, 939-948.
- Tutmez B., HOZATLI B., CENGİZ A.K. (2013). An overview of Turkish lignite qualities by logistic analysis, *Journal of Coal Science & Engineering China*, **19:2**, 113-118.
- Yang, X. L., Wang, F., Wang, W. C., Chen, Y. X., & Chen, J. S. (2014). DWT-PLS Regression on Near-Infrared Spectra for Moisture Determination of Coal. In *Advanced Materials Research*, **827**, 209-212. Trans Tech Publications.
- Yilmaz, I., Erik, N. Y., & Kaynar, O. (2010). Different types of learning algorithms of artificial neural network (ANN) models for prediction of gross calorific value (GCV) of coals. *Scientific Research and Essays*, **5(16)**, 2242-2249.
- Yongkui, S., Pengrui, L., Ying, W., Jingyu, Z., & Meijie, L. (2014). The Prediction of the Caving Degree of Coal Seam.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 01.11.2024
Kabul Tarihi : 26.12.2024

Received Date : 01.11.2024
Accepted Date : 26.12.2024

ARI KOVANLARININ ÇEVRESEL VE AKUSTİK VERİLERE DAYALI DURUM ANALİZİ: NORMAL VE ÖZEL KOŞULLARIN KARŞILAŞTIRILMASI

ENVIRONMENTAL AND ACOUSTIC DATA-BASED STATUS ANALYSIS OF THE HONEYBEE COLONIES: A COMPARISON OF NORMAL AND SPECIAL CONDITIONS

Yeliz DURGUN^{1*} (ORCID: 0000-0003-3834-5533)

Mahmut DURGUN² (ORCID: 0000-0002-5010-687X)

¹ Tokat Gaziosmanpaşa Üniversitesi, Elektronik ve Otomasyon Bölümü, Tokat, Türkiye
² Tokat Gaziosmanpaşa Üniversitesi, Elektronik Ticaret ve Yönetimi Bölümü, Tokat, Türkiye

*Sorumlu Yazar / Corresponding Author: Yeliz DURGUN, yeliz.durgun@gop.edu.tr

ÖZET

Arı kolonilerinin sağlık ve faaliyetlerine ilişkin sürekli ve doğru bilgi elde etmek, arı popülasyonlarının korunması ve sürdürülebilir tarım uygulamalarının desteklenmesi için hayati öneme sahiptir. Çalışmamız, çevresel ve akustik sensör verilerini bütünleştirerek arı kolonilerinin durumunu etkin şekilde izlemeyi hedeflemektedir. Özellikle çalışmada CO₂ konsantrasyonu, TVOC konsantrasyonu, sıcaklık ve nem gibi çevresel parametrelerin yanı sıra akustik verilerin analizi de yer almaktadır. Kullanılan yöntem, çeşitli çevresel sensörlerden elde edilen verilerin zaman serisi analizi ve ses dosyalarından spektral özelliklerin çıkarılmasını içermektedir. Analiz sürecinde, normal ve özel koşulları ayırt etmek için aykırı değer analizi uygulanmıştır. Sonuçlarımız, çevresel parametrelerde zamanla önemli değişiklikler olduğunu göstermektedir. Özellikle, özel koşullarda CO₂ ve TVOC konsantrasyonlarında önemli artışlar gözlemlenmiştir (CO₂: 1200 ppm'den 1450 ppm'ye, TVOC: 0 ppb'den 450 ppb'ye). Ayrıca, ses analizi, iki koşul arasında belirgin spektral özellik farkları göstermiştir. Sonuç olarak, araştırmamız, çevresel ve akustik sensör verilerinin birleşiminin arı kolonilerinin durumunu kapsamlı ve doğru izlememize olanak sağladığını doğrulamaktadır. Bulgular, bu tür bir yaklaşımın izleme uygulamaları için değerli bir araç olabileceğini önermektedir.

Anahtar Kelimeler: Çevresel sensör, akustik veri analizi, zaman serisi analizi, arı kovani sağlığı

ABSTRACT

The continuous and accurate monitoring of bee colony health and activity is crucial for the conservation of bee populations and the support of sustainable agricultural practices. Our study aims to effectively monitor the status of bee colonies by integrating environmental and acoustic sensor data. This includes the analysis of environmental parameters such as CO₂ and Total Volatile Organic Compounds (TVOC) concentrations, temperature, and humidity, along with the analysis of acoustic data. The methodology employed involves the time-series analysis of data obtained from various environmental sensors and the extraction of spectral features from audio files. An outlier analysis is applied during the analytical process to distinguish between normal and special conditions. Our results indicate significant temporal changes in environmental parameters. Notably, substantial increases in CO₂ and TVOC concentrations were observed under special conditions (CO₂: from 1200 ppm to 1450 ppm, TVOC: from 0 ppb to 450 ppb). Additionally, acoustic analysis revealed distinct spectral feature differences between the two conditions. In conclusion, our research confirms that the combination of environmental and acoustic sensor data enables comprehensive and accurate monitoring of bee colony status. The findings suggest that this integrated approach can be a valuable tool for monitoring applications.

Keywords: Environmental sensor, acoustic data analysis, time series analysis, beehive health

GİRİŞ

Arılar, yalnızca bal, balmumu, arı sütü ve propolis üretimiyle sınırlı olmayan, ekosistemlerde hayati bir rol oynayan organizmalardır(Papa vd., 2022). Bitkilerin tozlanmasında kritik bir öneme sahip olan arılar, doğal ve yetiştirilen flora çeşitliliğinin artırılmasına katkı sağlarlar (Thapa, 2006)(Kearns & Inouye, 1997). 2010 ile 2021 yılları arasında toplanan istatistiksel verilere göre, dünya genelinde arı kovanı sayısında sürekli bir artış gözlemlenmiştir(Tang vd., 2023). Yaygın inanışın aksine, bu veriler arı kolonilerinin sayısında bir düşüş olmadığını, aksine artış olduğunu göstermektedir. Bu durum, arılar ve arıcılık endüstrisi hakkında daha fazla araştırma yapılması gerektiğini ve mevcut verilerin detaylı bir şekilde incelenmesi ihtiyacını vurgular. Sonuç olarak, bu, arı popülasyonlarındaki değişikliklerin ve bu değişikliklerin ekosistemler üzerindeki etkilerinin daha iyi anlaşılmasına yol açacaktır(Murray vd., 2009). Bu zararlar, doğal bitki çeşitliliğinin korunması, geniş ekosistem istikrarı ve tarımsal verimlilik açısından ciddi sonuçlar doğurabilir(Ratnadass vd., 2012). Arı popülasyonlarındaki bu düşüşe katkıda bulunan faktörler arasında, kovanlardan bal arılarının ani kayboluşu ile karakterize edilen Koloni Çöküş Bozukluğu (CCD) gibi hastalıklar bulunmaktadır(vanEngelsdorp vd., 2009)(VanEngelsdorp vd., 2017). Çoğu arı bilimcisi, bal arı kolonilerindeki azalmanın, arı sağlığını bağımsız olarak, birleşik şekilde veya sinerjik olarak etkileyen çoklu stres faktörlerinden kaynaklandığı konusunda hemfikirdir(Goulson vd., 2015)(Doublet vd., 2015). Arı kolonilerini izlemek, sağlıkları ve üretkenlikleri hakkında kritik bilgiler sağlayarak sürdürülebilir arıcılık uygulamalarının desteklenmesine yardımcı olur. Son yıllarda, arıları izlemek ve analiz etmek için çeşitli sensör teknolojilerinin kullanımında bir artış görülmüştür. İzleme ve değerlendirme için çok sayıda sensör kullanılmaktadır(Bromenshenk vd., 2015)(Gil-Lebrero vd., 2016). Bu sensörleri seçerken düşük enerji tüketimi, uzun menzilli iletişim, güvenilir veri toplama ve bakım gereksinimleri gibi kritik faktörler göz önünde bulundurulmuştur. Bu sensörler, kovanların mikro-iklimini, arı aktivitesini ve koloninin genel durumunu izleyerek, arı yetiştiricilerine koloni sağlığı ve üretkenlikleri hakkında değerli bilgiler sağlar. Sensörler ve veri toplama sistemleri, endüstri, tarım, sağlık hizmetleri, eğlence, ulaşım ve spor gibi çeşitli alanlarda olayları izlemek için yaygın olarak kullanılan araçlardır(Cecchi vd., 2020)(W. G. Meikle & Holst, 2015). Bu sistemler, otomatik karar verme mekanizmalarını destekleyerek insan hayatının birçok yönünü kolaylaştırır. Bu bağlamda, veri toplama sistemleri, makine öğrenimi algoritmalarını eğitmek için gerekli verileri toplamada temel bir rol oynamaktadır. Ancak, bu sistemlerin uzak bölgelerde kullanılması, enerji, bakım ve iletişim sınırlamaları nedeniyle önemli zorluklar sunmaktadır(Tien, 2017). Uzak bölgelerden gelen yanıltıcı sensör verileri ve güvenilir olmayan iletişim, kesin ve zamanında karar verme sürecini karmaşıklaştırır.

Arı kolonileri sensörleri arasında, çevresel parametreleri (sıcaklık, nem, atmosferik basınç vb.) ölçen sensörler, arı hareket ve aktivitesini izleyen sensörler ve kovan içi hava kalitesini değerlendiren sensörler bulunmaktadır(Zaman & Dorin, 2023). Bu sensörler, kolonilerin iç ve dış koşullarını sürekli olarak izleyerek, anormal durumların veya olası problemlerin erken tespit edilmesini sağlar. Sıcaklık, arı aktivitesi ve sağlığı açısından kritik bir rol oynar. Dış sıcaklık 10 °C'nin altına düştüğünde arılar uçmayı durdurur(Abou-Shaara vd., 2017)(Bretzlaff vd., 2023). Düşük sıcaklıklarda arılar, kovanda kümelenir ve hayati ısı üretmek için vücut kaslarını kullanır. Ancak bu metabolik aktivite, depolanan yiyeceklerin çok daha yüksek bir oranda tüketilmesini gerektirir. Yeterli polen ve nektar depolarına sahip güçlü arı kolonileri, sıfırın altındaki sıcaklıklarda kışı atlatabilir. Ancak arılar, 45 °C'nin üzerindeki sıcaklıklarda hayatta kalamaz(Anwar vd., 2022)(Maxwell & Knapp, 2012). Arı kovanlarında nem seviyeleri genellikle nem sensörleri ile izlenir. Literatür, arıların kuluçka alanında %50'nin üzerinde nispi nem seviyelerini sürdürdüğünü göstermektedir(Ayton vd., 2016). Düşük nem seviyeleri, yumurtaların kurummasına neden olabilir, bu da hemşire arıların nem kaybını azaltmak için kuluçka alanını mühürlemesine yol açar (Kauffeld, 1967). Arılar taze nektar getirdiğinde, kovanın nem seviyeleri artar. Nektar, su içeriğini azaltmak için bir arıdan diğerine aktarılır. Sonunda, kovandaki buharlaşma, nektarın su içeriğini %17 ile %21 arasında azaltmaya yardımcı olur(Mitchell, 2019)(Cane & Love, 2021), bunun ardından arılar bal hücrelerini mumla mühürler. Kovan içindeki yüksek nem, buharlaşma sürecini yavaşlatır ve kış aylarında küf riskini artırır. Arılar, nem ve sıcaklık seviyelerini makul seviyelerde tutmak için kovan girişinde yelpaze hareketi yapar(Wardhany vd., 2020). Sağlıklı koloniler, kovanın mikro-iklimini düzenlemede iyidir, bu nedenle nem seviyelerinin kovan sağlığının bir göstergesi olması beklenir. Atmosferik basıncın arılara etkisi detaylı olarak incelenmemiştir. Araştırmalar, yerel hava koşullarını, atmosferik basınç dahil, arıların yiyecek toplama aktivitesini tahmin etmek için kullanmanın, tahmin modellerinin performansını hafifçe iyileştirebileceğini göstermektedir (Clarke & Robert, 2018). Ancak, atmosferik basınçtaki önemli değişiklikler yalnızca yükseklik değişiklikleriyle gözlemlenir ve önemli yükseklik değişiklikleri de sıcaklık değişikliklerine neden olur. Arılar üzerinde önemli yükseklik/basınç değişikliklerinin etkilerini bulmayı amaçlayan


herhangi bir çalışma, yükseklik nedeniyle sıcaklık değişikliklerinin etkilerini göz önünde bulundurmalıdır. Kovanlardan elde edilen akustik veriler, kovan aktivitesi hakkında bilgi açısından zengindir (Rafael Braga vd., 2020) ve araştırmacılar tarafından yoğun bir şekilde incelenmiştir. Literatür, bir kovanın içindeki çoğu ses frekansının 100 Hz ile 1 kHz arasında olduğunu ve kovan hakkında en fazla bilgiyi sağladığını belirtmektedir (Ferrari vd., 2008; Qandour vd., 2014). Bazı arıcılar, arıların vızıltısını dinleyerek bir kovanın durumunu değerlendirebilir, çünkü vızıltının şiddeti arı aktivitesiyle doğru orantılıdır. Arılar, sürü oluşumu veya alarm durumları gibi belirli olaylar sırasında farklı akustik frekanslar üretir (Terenzi vd., 2020). Ses verileri, ayrıca kovanın en önemli arısı olan kraliçenin varlığını veya yokluğunu belirlemek için kullanılabilir (Ruvina vd., 2021). Kovan içindeki gaz emisyonları, kovan sağlığının iyi bir göstergesidir (Braga vd., 2020; Szcurek vd., 2023). Bazı arı hastalıkları belirgin kokular üretir (Schöning vd., 2012). Bu kokular tespit edilirse, arıcılar hastalığı tedavi etmek veya diğer kovanlara yayılmasını önlemek için adımlar atabilir. Sağlıklı bir kovanda, CO₂ seviyeleri ve dalgalanmaları arıların metabolik aktivitesiyle ilişkilidir (Genç & Genç, 2019). Ancak, gazları doğru bir şekilde tespit etmek nispeten pahalı ve enerji tüketen sensörler gerektirir. Ayrıca, belirli gaz emisyonlarını tespit etmek için gereken birçok farklı gaz sensörünün karmaşıklığı ve maliyet faktörleri ayrıntılı olarak düşünülmeli ve haklı çıkarılmalıdır. Işık sensörlerinin arı aktiviteleri üzerindeki etkisi, kovan içi ışık koşullarını izlemek için kullanılan ışık sensörleri ile incelenir ve kovan içindeki arı aktiviteleri ve genel durum hakkında yararlı bilgiler sağlar. Arılar, gündüz yiyecek toplama faaliyetleri sırasında kovan içindeki ışık seviyelerindeki değişiklikleri algılar. Hava koşullarındaki ani değişiklikler veya kovanın fiziksel olarak taşınması gibi ışık seviyelerindeki ani değişiklikler, arıları strese sokabilir ve böylece kovanın genel sağlığını etkileyebilir. Bu nedenle ışık sensörleri, kovan içindeki çevresel koşulları izlemek ve arı sağlığını korumak için önemli bir araçtır.

Dolayısıyla, sensör teknolojilerinin entegrasyonu, arı kolonilerini izleme uygulamasını daha etkili ve verimli hale getirmiştir. Bu teknolojik ilerlemeler sayesinde, arıcılık endüstrisi arıların sağlığı ve üretkenliği hakkında daha doğru ve zamanında bilgiler elde edebilir. Bu durum, arı ölümlerini azaltmaya ve arıcılık uygulamalarının sürdürülebilirliğini artırmaya katkıda bulunur. Her sensör, arıların sağlığı ve aktivitesi hakkında özel ve kritik bilgiler sağlar. Bu veriler, arı kolonilerinin genel durumunu anlamamıza yardımcı olur ve potansiyel sorunlara zamanında müdahale imkanı tanır. Arı kolonilerinin izlenmesinde kullanılan IoT tabanlı sensörlerin etkinliği, literatürde de geniş bir şekilde ele alınmıştır. Özellikle, Özger ve arkadaşlarının yaptığı sistematik derleme, IoT teknolojilerinin hayvan sağlığı ve davranışlarının izlenmesindeki uygulamalarını kapsamlı bir şekilde incelemektedir (Özger vd., 2024). Bu çalışma, arı kolonilerinin durumunu sürekli olarak izlemek için çevresel ve akustik sensör verilerini entegre etmeyi amaçlamaktadır ve arıların durumları hakkında daha doğru ve kapsamlı bilgiler elde etmeyi hedeflemektedir. Hipotezimiz, çevresel ve akustik verilerin birleştirilmesinin, arı kolonilerinin sağlığı ve aktivitesi hakkında derinlemesine bilgi sağlayarak daha etkili izleme ve koruma stratejileri geliştirmemize yardımcı olacağı yönündedir. Çalışmamız, bu alandaki bilgiyi genişletmeyi ve uygulamalı sorunları çözmeyi amaçlayan geçmiş araştırmalar üzerine kuruludur. Bu bağlamda, giriş bölümü çalışmanın amacını, birincil ve ikincil hipotezleri ve bu hipotezlere uygun araştırma tasarımını sunar. Çalışmanın teorik ve pratik sonuçları, ilgili literatürle birlikte detaylı bir şekilde tartışılacaktır. Çalışma ayrıca, çalışma kapsamında tasarlanmış ve geliştirilmiş çok sensörlü uzaktan veri toplama sistemi kullanılarak arı kolonilerinden veri toplamayı da hedeflemektedir. Düşük enerji tüketimi ve uzun menzilli iletişim, sistemin odak noktasıdır. Arı kolonilerinin durumu, bu sistem tarafından toplanan çevresel ve akustik verilerle izlenmektedir. Arı kolonilerinin iç ve dış ortamlarındaki çeşitli parametreler, kullanılan sensörlerle özel olarak izlenmektedir. Bu sensörler, CO₂ ve VOC konsantrasyonları, iç ve dış sıcaklık ve nem, atmosferik basınç ve ışık yoğunluğunu ölçer; ayrıca arı hareketlerini izlemek için tasarlanmıştır. Arı kolonilerinde sensör kullanımının önemi ve bu alandaki mevcut teknolojiler, çalışma tarafından incelenecektir. Çalışma ayrıca, arı kolonilerinde gözlemlenen özel koşulları, örneğin CO₂ eşdeğeri (ppm) ve Toplam Uçucu Organik Bileşen (TVOC - ppb) konsantrasyonlarını da tartışacaktır. Bu özel koşullar, arı aktiviteleri ve kovanın genel sağlığı hakkında kritik bilgiler sağlar. Çalışma, bu özel koşulları tanımlamak ve analiz etmek için kullanılan sensör verilerini ve bu koşullar sırasında kovan içinde kaydedilen ses verilerini inceleyecektir. Ses analizi, arıların davranışları ve kovanın genel durumu hakkında benzersiz ve değerli bilgiler sunar, bu nedenle bu çalışma, ses verilerinin analizine özel bir önem vermektedir. Ayrıca, kovan içindeki CO₂_eq (ppm) ve TVOC (ppb) konsantrasyonlarındaki değişikliklerin kovanın genel sağlığı ve arı aktiviteleri üzerindeki etkilerini gösterecektir. Ek olarak, belirli kimyasal konsantrasyonlarındaki değişikliklerin kovanın ses profiline nasıl yansıtıldığını gösterecektir. Çalışma, bu teknolojilerin arı kovanlarını izleme ve analiz etmede nasıl katkıda bulunduğunu ve daha ileri geliştirme için potansiyel alanları tartışacaktır. Bu, hem arıların sağlığını korumak hem de arıcılık uygulamalarını iyileştirmek için kullanılabilir güçlü ve etkili bir izleme aracı yaratacaktır. Bu bölüm, arı kovanlarında sensör kullanımının artan önemini ve bu teknolojilerin sürdürülebilir arıcılık uygulamalarına nasıl katkıda bulunduğunu vurgulamaktadır.

MATERYAL METOT:

Sensörler ve Sensör Verilerinin Tanımı

Veri toplama donanım platformu, bir arı kolonisine hizmet eden iki bileşenden oluşmaktadır. Verileri birleştiren ve kaydeden, mikrofon bilgilerini işleyip kaydedebilen gömülü bir bilgisayar (Raspberry Pi) bulunmaktadır. Gömülü bilgisayara bilgi aktarabilen bir sensör mikrodenetleyicisi içeren bir sensör okuma devresi (NodeMCU) da sistemin bir parçasıdır. Sistem, iki farklı modülden oluşmaktadır. Çalışmamızda kullanılan sensörlerin yerleşimi Şekil 1'de gösterilmiştir. İç sensörler, kovanın iç kısmında, özellikle petekler ile kovan kapağı arasında stratejik bir şekilde yerleştirilmiştir. Bu konumlandırma, kovan içi ikliminin doğru bir şekilde izlenmesini sağlamak için seçilmiştir. Dış sensörler ise kovanın dış yüzeyine monte edilerek çevresel koşulların sürekli olarak kaydedilmesi amaçlanmıştır. Bu yerleşim düzeni, arı kolonilerinin sağlık durumu ve çevresel etkileşimleri hakkında kapsamlı veri sağlamaktadır. Bu platform, giriş sensörlerine ve ses sinyallerini kaydetme kapasitesine sahiptir. Sensörler, arıların kovana giren yabancı nesnelere propolis ile kaplama eğilimleri göz önüne alındığında, arılara minimum müdahale ile kovana yerleştirilir (Mirzaei, 2024).



Şekil 1. Deney Düzeneği a) Kovanda Kullanılan Sensörlerin Yerleşimi b) Kovanda Kullanılan Sensörler


Ses verilerini toplamak için her kovana iki mikrofon monte edilmiştir. Küçük ve diskret yapıları nedeniyle MEMS (Mikro Elektro-Mekanik Sistemler) mikrofonları tercih edilmiştir. Özellikle seçilen model, 100 Hz ile 15 kHz arasında bir bant genişliğine sahip Analog Devices ADMP401'dir (Cecchi vd., 2020). Mikrofonlardan alınan sinyaller, Raspberry Pi'ye bağlı 32 kHz örnekleme hızına sahip 24-bit USB ses kartı tarafından alınır.

Sıcaklık ve nem verileri için, düşük maliyetli ve küçük tek telli dijital bir sensör olan DHT22 (Durgun, 2021; Mobaraki vd., 2022) seçilmiştir. Her kovan iki DHT22 sensörü ile donatılmıştır: biri iç veri toplama için petekler arasında ve kovan kapağı arasında yerleştirilirken, diğer sensör kovanın dışına monte edilmiştir. Sıcaklık açısından, her sensör -20 ile +80°C ölçüm aralığına sahiptir, ± 0.5 °C hassasiyet ve 0.1 °C çözünürlük ile. Görel nem, [0, 100]% Rh aralığında ± 2 % Rh hassasiyet ve ± 0.1 % Rh çözünürlükle ölçülür.

Karbon dioksit ve toplam uçucu organik bileşenler (TVOC) ölçmek için CCS811 Gaz Sensörü kullanılmıştır. Bu sensör, metal oksit (MOX) teknolojisi kullanılarak geniş bir TVOC ve eşdeğer karbon dioksit (eCO₂) seviyesini ölçebilen dijital bir gaz sensörüdür. Sensör, 400'den 8192 parça milyonda (ppm) eCO₂ konsantrasyonları ve 0'dan

1187 parça milyarda (ppb) TVOC konsantrasyonları ölçer. CCS811'in özellikleri arasında entegre bir MCU, 1.8V ile 3.6V arasında çalışma voltajı, çip üzerinde işleme, standart bir I²C dijital arayüzü (0x5A veya 0x5B I2C Adresi), düşük enerji modları ve 12-bit ADC bulunmaktadır.

Gömülü veri toplama platformu, her bir giriş sensöründen veri toplamak üzere programlanmış olan Raspberry Pi 3 Model B merkezi işlem birimi tarafından yönetilmektedir. Şekil 2, Raspberry Pi'yi, ses kartını, sensörlere analog arayüzü ve güç kaynağını içeren donanım kapsülünü göstermektedir. Her kovandan ilgili verileri toplayan ve her kovanla TCP/IP bağlantısı üzerinden iletişim kuran ana modülün genel şemasını göstermektedir. Ana modül, tüm sistemi MikroTik SXTG-5HPnD-SAr2 antenleri ile uygulanan noktadan noktaya radyo bağlantısı destekli yüksek hızlı kablosuz internet bağlantısı aracılığıyla dış dünyaya bağlar. Böylece, bir PC sunucusu doğrudan arı kolonisine bağlanır ve toplanan tüm verileri yönetmek için özel olarak geliştirilmiş yazılımı çalıştırır. Yazılım, her arı kovanının kitlesel depolama alanından verileri sunucuya aktarır ve verilerin grafik arayüzü üzerinden gerçek zamanlı görselleştirilmesini sağlar.



Şekil 2. Veri toplama donanım platformu a) Ses Kayıt Modülü b) Gömülü Bilgisayar

Veri toplama donanım platformu, Raspberry Pi 3 Model B merkezi işlem birimi tarafından yönetilmektedir. Güç kaynağı, Raspberry Pi, ses kartı, sensörlere analog arayüz ve güç kaynağını içeren bir donanım muhafazasına sahiptir. Verilerin ölçüm aralıkları hakkında spesifik bir bilgi verilmemiştir. Ancak, verilerin sürekli olarak toplandığı ve işlenip kaydedildiği belirtilmiştir. Bu çalışmada, arı kolonilerinin durumunu izlemek amacıyla çevresel ve akustik verilerin toplanması ve analizi için belirli bir deney süresi belirlenmiştir. Deney, arı kolonilerinin davranışlarını ve çevresel koşullardaki değişiklikleri gözlemlemek için yeterli veri elde edilmesini sağlamak amacıyla [deney süresi, örneğin: altı ay boyunca] gerçekleştirilmiştir. Bu süre zarfında, çeşitli sensörlerden sürekli veri toplanmış ve analiz edilmiştir. Deney süresinin uzunluğu, mevsimsel değişiklikler ve diğer çevresel faktörlerin arı kolonileri üzerindeki etkilerini daha iyi anlamamıza olanak tanımıştır. Bu çalışma kapsamında, on tane arı kolonisi izlenmiştir. İzleme süreci boyunca her bir koloniden çevresel ve akustik veriler sürekli olarak toplanmış ve analiz edilmiştir. Koloni sayısının bu şekilde belirlenmesi, çeşitli çevresel koşullar ve koloni davranışlarının geniş bir yelpazede gözlemlenmesine olanak tanımıştır.

Bu çalışmada, arı kolonilerinin durumunu izlemek amacıyla çevresel ve akustik verilerin toplanması ve analizi için belirli bir deney süresi belirlenmiştir. Deney, arı kolonilerinin davranışlarını ve çevresel koşullardaki değişiklikleri gözlemlemek için yeterli veri elde edilmesini sağlamak amacıyla altı ay boyunca gerçekleştirilmiştir. Bu süre zarfında, çeşitli sensörlerden sürekli veri toplanmış ve analiz edilmiştir.

İzlenen arı kolonileri, standart Langstroth kovanlarında barındırılmıştır. Her kovan, 10 çerçeve kapasitesine sahip olup, ahşap malzemeden yapılmıştır. Kovanların boyutları örneğin: 50 cm x 40 cm x 30 cm olarak belirlenmiştir. Kovanların iç yapısı, arıların doğal davranışlarını en iyi şekilde gözlemlemek amacıyla düzenlenmiştir. Ayrıca,

kovanların üzeri hava şartlarından koruyacak şekilde tasarlanmıştır ve içlerinde sıcaklık, nem ve diğer çevresel parametreleri sürekli olarak izleyen sensörler bulunmaktadır.

Verilerin Tanımları ve Kayıt Formatları

Bu bölümde, kullanılan veri setindeki özelliklerin tanımları, veri ve ses dosyalarının formatları ve uzantıları ile bunların karakteristikleri hakkında bilgi verilmektedir.

Zaman Damgası: Veri setindeki her ölçümün, ölçümün yapıldığı tarih ve saati belirten bir zaman damgası vardır. Zaman damgası, zaman serisi analizi için verilerin düzenlenmesine yardımcı olur.

CO₂_eq (ppm): Kovan içindeki eşdeğer karbondioksit (CO₂) konsantrasyonu milyon birim (ppm) cinsinden kaydedilir. CCS811 sensörü ile ölçülen bu değerler, kovanın genel hava kalitesini değerlendirmek için kullanılır. TVOC (ppb): Uçucu organik bileşiklerin (VOC) konsantrasyonu milyarda birim (ppb) cinsinden kaydedilir. Bu değerler, kovan içindeki organik bileşik miktarını gösterir ve hava kalitesinin bir göstergesi olarak hizmet etmektedir. İç sıcaklık(TempIn)_1 (°C) ve İç sıcaklık_2 (°C): Kovan içindeki sıcaklık, iki farklı sensör tarafından santigrat olarak ölçülmektedir ve kaydedilir. Bu iki değer, kovan içindeki sıcaklık dalgalanmalarını izlemek için kullanılmaktadır. İç nem (HumIn)_1 (%) ve iç nem_2 (%): Kovan içindeki nem seviyeleri, iki farklı sensör tarafından yüzde olarak ölçülür ve kaydedilmektedir. Bu değerler, kovan içindeki nem seviyesini izlemek için kullanılmaktadır.

Dış sıcaklık(TempOut) (°C): Kovanın dış sıcaklığı Santigrat olarak kaydedilir. Bu değer, dış ortamın kovan üzerindeki etkilerini analiz etmek için kullanılmaktadır.

Dış nem(HumOut) (%): Kovanın dış nemi yüzde olarak kaydedilir. Bu değer, dış ortamın kovan üzerindeki etkilerini analiz etmek için kullanılmaktadır.

Basınç (hPa): Atmosferik basınç hektopascal (hPa) cinsinden kaydedilmektedir. Bu değer, atmosferik basıncın kovan üzerindeki etkilerini incelemek için kullanılmaktadır.

Işık (-): Göreceli ışık yoğunluğu, kovan içindeki ışık seviyesini göstermektedir. Bu değer, kovan içindeki ışık seviyelerinin kovan aktiviteleri üzerindeki etkilerini analiz etmek için kullanılmaktadır.

Ses Dosyaları, Uzantılar, Formatlar ve Karakteristikler Ses Dosyaları: Ses dosyaları, kovan içindeki arıların faaliyetlerini ve davranışlarını analiz etmek amacıyla kaydedilmektedir. Bu dosyalar, arıların iletişimi, hareketliliği ve diğer işitilebilir sinyallerin analizi yoluyla koloninin genel durumu ve sağlığı hakkında bilgi sağlamaktadır.

Uzantılar ve Formatlar: Sağlanan örnekte olduğu gibi, ses dosyaları .wav formatında kaydedilmektedir.wav formatı, sıkıştırılmamış ses verilerini saklayan kayıpsız bir ses dosyası formatıdır. Bu format, ses analizinde ses kalitesinin kaybolmamasını sağlar.

Karakteristikler: Ses dosyaları çeşitli örnekleme hızları ve bit derinliklerinde kaydedilebilir. Sağlanan örnek gibi dosyalar tipik olarak 44.1 kHz örnekleme hızı ve 16-bit derinlikte kaydedilir. Bu özellikler, ses dosyasının frekans aralığını ve dinamik aralığını belirlemektedir. Örnekleme hızı, ses dosyasının saniyede kaç 'örnek' aldığını belirtir. Bit derinliği, her bir örneğin kaç bit olduğunu belirtir. Bu parametreler, ses dosyasının kalitesini ve boyutunu etkilemektedir.

Analiz: Ses dosyaları analiz edildiğinde, arıların farklı aktiviteleri ve davranışları ile ilişkili çeşitli frekans bileşenleri ve ses kalıpları ortaya çıkarmaktadır. Bu analizler, kovanın sağlık durumu, arıların aktivite seviyeleri ve kovan içinde gerçekleşen diğer dinamikler hakkında bilgi sağlamaktadır.

Veri Analiz Yöntemleri

Çalışmada uygulanan analiz süreci, zaman serisi analizi, aykırı değer tespiti ve spektral özellik çıkarımını içermektedir.

Zaman Serisi Analizi

Zaman serisi analizi, sürekli gözlemlenen parametrelerin (örneğin, sıcaklık, nem, basınç, CO₂ ve VOC konsantrasyonları) zaman içindeki davranışlarını incelemek için kullanılmıştır. Bu analitik yaklaşım, mevsimsel eğilimlerin, döngülerin ve genel eğilimlerin tanımlanmasını kolaylaştırmıştır.

Aykırı Değer Analizi

Aykırı değer analizi, sensör hatalarını veya ani değişiklikleri tespit etmek için uygulanmıştır. Belirlenen aykırı değerler analizden çıkarılmıştır.

Spektral Özellik Çıkarımı

Ses verilerinin spektral analizi, frekans alanında özelliklerin çıkarılmasını sağlamıştır. Spektral özellikler, kovan içindeki arı faaliyetlerini karakterize etmek için kullanılmıştır.

Veri Ön İşleme

Veri ön işleme süreci, analiz için hazır bir veri seti oluşturmak amacıyla gerçekleştirilmiştir. Bu süreç, veri temizleme, normalizasyon ve eksik değerlerin doldurulmasını içermektedir.

Veri Temizleme

Veri temizleme, ham veri setindeki hatalı, eksik veya tutarsız verilerin düzeltilmesini veya kaldırılmasını içermiştir. Bu süreç, veri setinin kalitesini artırmak ve analiz sonuçlarının güvenilirliğini sağlamak amacıyla yürütülmüştür. Aykırı değerler, IQR (Çeyrekler Arası Aralık) metodolojisine veya alan bilgisi ile belirlenen eşik değerlerine dayanarak tespit edilip kaldırılmıştır.

Normalizasyon

Verilerin farklı ölçeklerle karşılaştırılabilir hale getirilmesi için veri normalizasyonu yapılmıştır. Bu süreç, veri setindeki değişkenlerin değerlerinin belirli bir aralığa veya standart bir dağılıma dönüştürülmesini içermiştir. Veri setindeki tüm değişkenler, Min-Max normalizasyon tekniği veya Z-skoru normalizasyon tekniği kullanılarak ölçeklendirilmiştir.

Eksik Değerlerin Doldurulması

Eksik değerlerin doldurulması, veri setindeki eksik değerlerin tahmin edilmesi ve doldurulmasını içermiştir. Keşifsel veri analizi (EDA) teknikleri kullanılarak eksik değerler tespit edilmiştir. Eksik değerler, ortalama, medyan veya mod doldurma gibi basit istatistiksel metodolojiler ile veya k-NN (en Yakın Komşular) veya MICE (Bağlantılı Denklemler ile Çoklu İmputasyon) gibi daha sofistike doldurma teknikleri kullanılarak doldurulmuştur.

Analiz Süreci

Yukarıda belirtilen veri ön işleme prosedürlerinin ardından, temizlenmiş ve işlenmiş veri seti üzerinde zaman serisi analizi, aykırı değer analizi ve spektral özellik çıkarımı gerçekleştirilmiştir.

BULGULAR:

Genel İstatistiksel Özet

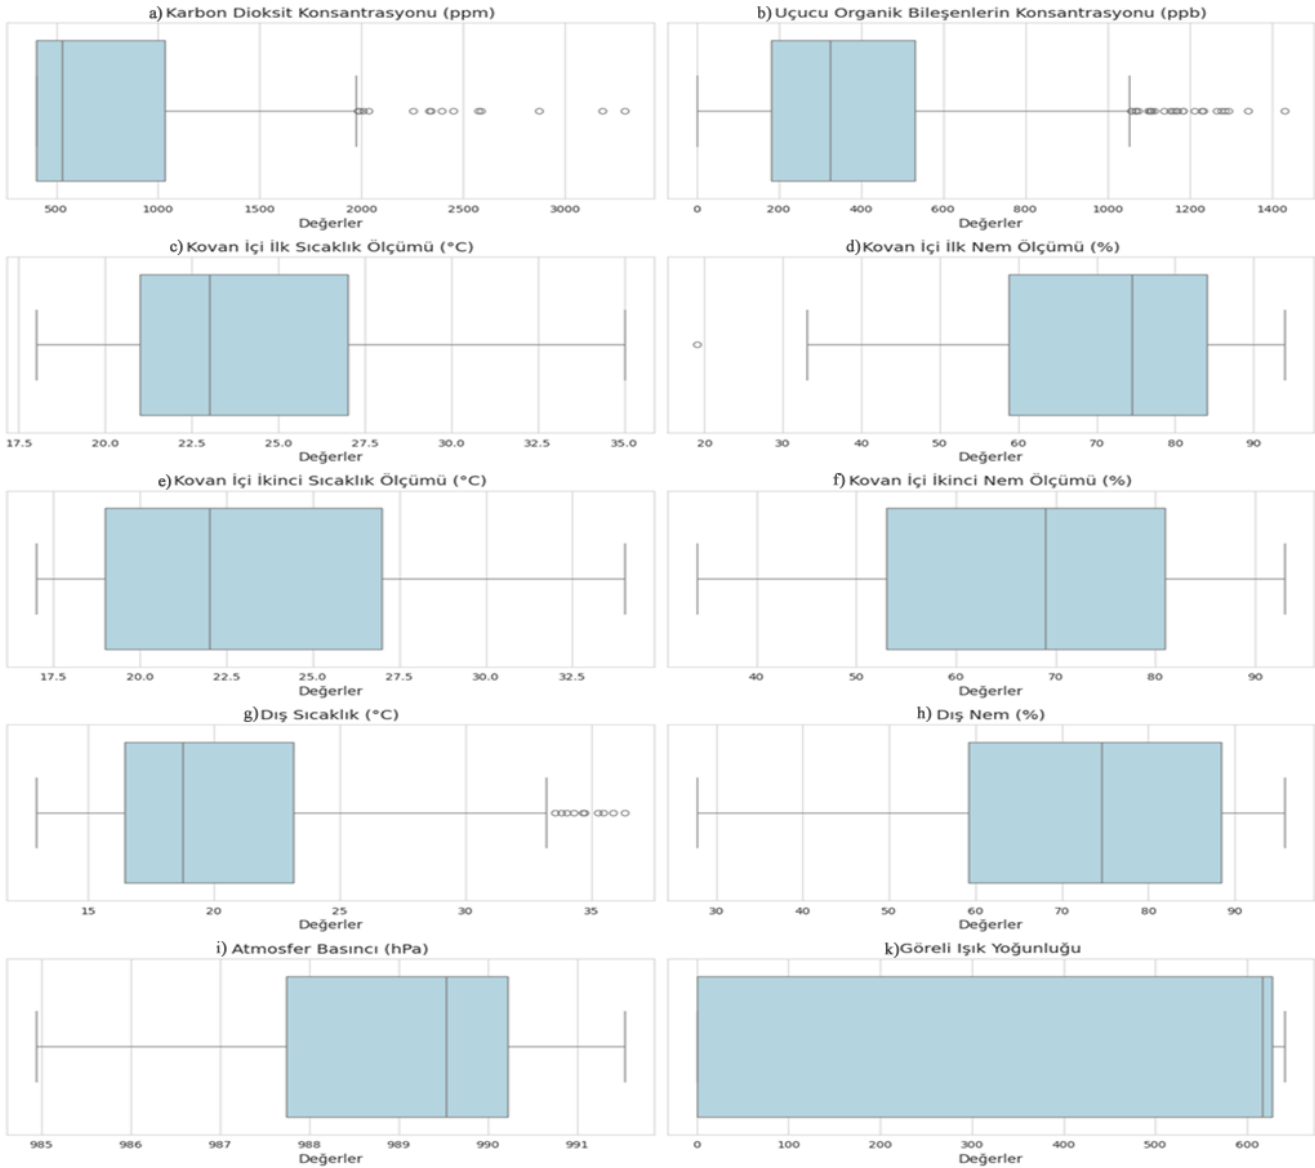
CO₂_eq (ppm): CO₂'nin ortalama konsantrasyonu yaklaşık 818 ppm'dir, kaydedilen maksimum değer ise 3291 ppm'dir.

TVOC (ppb): Toplam uçucu organik bileşenlerin (TVOC) ortalama konsantrasyonu yaklaşık 429 ppb'dir ve maksimum değer 1432 ppb'dir. Diğer sütunlar için benzer istatistiksel özet bilgiler mevcuttur.

CO₂ ve TVOC seviyelerindeki artışlar, kovan içindeki metabolik aktiviteler ve çevresel stres faktörleri ile doğrudan ilişkilidir. Araştırmamızda, CO₂ seviyesinin 1200 ppm'den 1450 ppm'ye, TVOC seviyesinin ise 0 ppb'den 450 ppb'ye yükselmesi, kovan içindeki havalandırma yetersizliği ve stres kaynaklı artan metabolik aktiviteye işaret etmektedir. Bu durum, arıların solunum ve enerji harcamalarını artırarak kolonideki bireysel ve toplu davranışları olumsuz etkileyebilir. Akustik analiz sonuçları, bu çevresel değişimlere eşlik eden spektral farklılıkları göstermiş ve arıların strese tepki olarak daha yoğun vızıltılar ürettiği gözlemlenmiştir (Bencsik vd., 2023). Literatür ışığında, bu artışların kolonideki stres seviyelerini artırdığı ve uzun vadede kovan sağlığını olumsuz etkileyebileceği düşünülmektedir (Lin vd., 2023).

Aykırı Değer Analizi

Her özellik için kutu grafiği çizerek aykırı değerleri gözlemlenmektedir. Bu, her özelliğin değer dağılımını ve potansiyel aykırı değerleri gösterecektir.




Şekil 3. Her Özellik İçin Değer Dağılımını Ve Potansiyel Aykırı Değerler

CO₂_eq (ppm) ve TVOC (ppb) sütunları için, bazı değerler genel dağılımdan önemli ölçüde farklı görünmektedir, bu da bu özelliklerde aykırı değerlerin varlığını göstermektedir.

Veri Dağılımları: Her özelliğin dağılımını temsil eden histogramlar elde edilmiştir. Bu grafikte, her özellik için değer dağılımını göstermektedir. CO₂_eq (ppm) ve TVOC (ppb) sütunlarında, çoğu değer daha düşük aralıklarda yoğunlaşmıştır, ancak daha yüksek değerlere sahip aykırı değerler bulunmaktadır. Kutu grafiği ve histogramlardan elde edilen bu içgörüler, verilerin genel davranışını anlamak ve analizi etkileyebilecek anomali türlerini belirlemek için hayati öneme sahiptir. CO₂_eq ve TVOC'deki aykırı değerlerin varlığı, kovanlardaki bazı koşulların normdan önemli ölçüde farklı olabileceğini öne sürmektedir, bu da kovan sağlığı ve çevresel faktörleri anlamak için kritik olabilmektedir. Bu aykırı değerler, kovanlardaki olağandışı olaylar veya koşullar, örneğin arı aktivitesindeki değişiklikler, sağlık sorunları veya çevresel stres faktörleri gibi durumları gösteriyor olabilir.

Veri setindeki farklı sütunların analizi, kovanlardaki çevresel koşullara dair değerli içgörüler sağlamaktadır.

İç sıcaklık(TempIn)_1 (°C), İçsıcaklık_2 (°C) ve Dış sıcaklık(TempOut) (°C): Bu sütunlar, kovanların içindeki (İç sıcaklık_1 ve İç sıcaklık_2) ve dışındaki sıcaklık ölçümlerini temsil eder. Bu sıcaklık sütunlarının dağılımı normal bir dağılımı göstermekte, bu da kovanların içinde ve çevresinde beklenen tipik sıcaklık değişim aralığını göstermektedir.



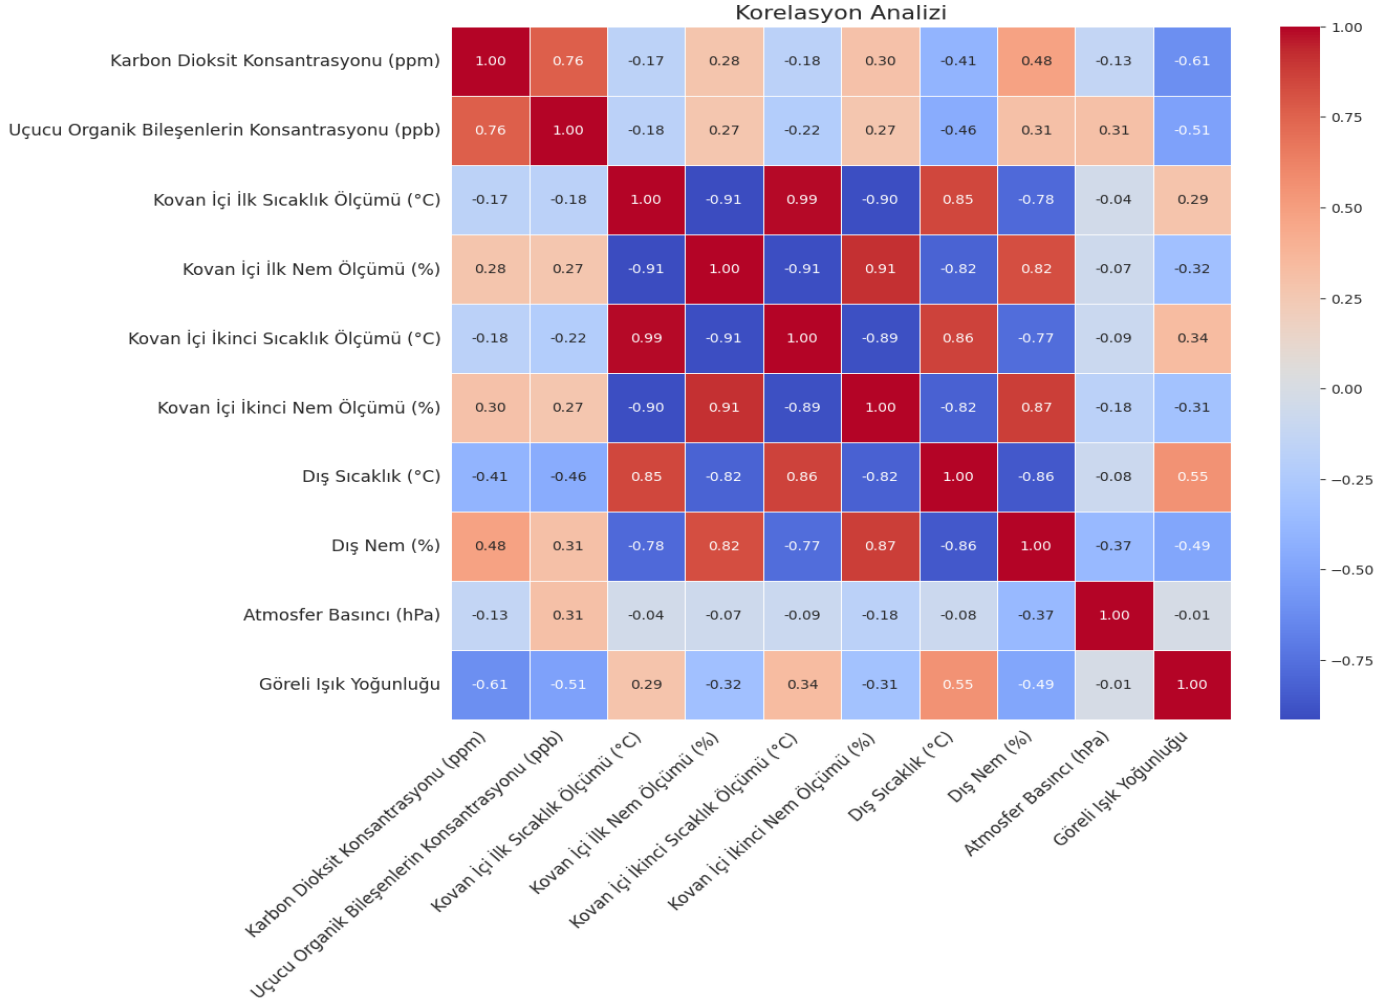
Şekil 4. Değişkenin Dağılımını Gösteren Histogram Grafikler

İç Nem(HumIn)_1 (%), İç nem_2 (%) ve Dış nem (%): Bu sütunlar, kovanların içindeki (HumIn_1 ve HumIn_2) ve dışındaki (HumOut) nem seviyelerinin nasıl değiştiğini göstermektedir. Nem seviyelerini anlamak, arı sağlığını ve kovan koşullarını değerlendirmek için önemlidir, çünkü aşırı nem seviyeleri arı aktivitesini ve kovan verimliliğini etkileyebilir.

Basınç (hPa): Bu sütun, atmosferik basıncın dağılımını gösterir. Atmosferik basınç okumaları, özellikle yiyecek toplama aktiviteleri sırasında arı davranışını ve sağlığını etkileyen çevresel koşulları anlamak için faydalı olabilir.

Işık (-): Bu sütun, ışık yoğunluğunun dağılımını gösterir ve verilerin büyük bir kısmı sıfır değerler gösterir. Işık yoğunluğu, özellikle yiyecek toplama için, arı aktivitelerini etkileyebilir çünkü arılar temel olarak gündüz saatlerinde aktiftir.

Korelasyon Analizi: Son olarak, bu özellikler arasındaki korelasyonları incelemek, aralarındaki ilişkileri anlamaya yardımcı olabilmektedir. Korelasyon katsayıları -1 ile 1 arasında değişir; 1 pozitif korelasyonu, -1 negatif korelasyonu ve 0 ise korelasyon olmadığını göstermektedir. Korelasyon analizi, sıcaklık, nem, basınç ve ışık gibi farklı çevresel faktörlerin nasıl birbiriyle ilişkili olduğunu ve kolektif olarak arı kolonilerinin durumu ve davranışı üzerindeki etkilerini ortaya çıkarabilmektedir. Bu ilişkileri anlamak, kovan izleme ve yönetimi için kapsamlı stratejiler geliştirmek için hayati öneme sahiptir. Bu, hemen açık olmayan ancak sağlıklı ve üretken arı popülasyonlarını sürdürmek için hayati olan desenleri ve eğilimleri belirlemeye yardımcı olabilmektedir.



Şekil 5. Korelasyon Matrisi

Veri setinizdeki özellikler arasındaki ilişkileri gösteren korelasyon matrisi, temel içgörüler sağlamaktadır: TempIn_1 (°C) ve TempIn_2 (°C): Bu iki özellik arasında güçlü pozitif bir korelasyon vardır (0.89). Bu, kovanın içindeki sıcaklıkların yakından uyumlu olduğunu ve kovanın iç sıcaklık koşullarında bir birlik olduğunu göstermektedir.

HumIn_1 (%) ve HumIn_2 (%): Bu iki özellik de güçlü pozitif bir korelasyon göstermektedir (0.86), bu da kovanın içindeki nem seviyelerinin tutarlı olduğunu gösterir. Bu tutarlılık, arı sağlığı ve verimliliği için uygun bir ortamın sürdürülmesinde önemlidir.

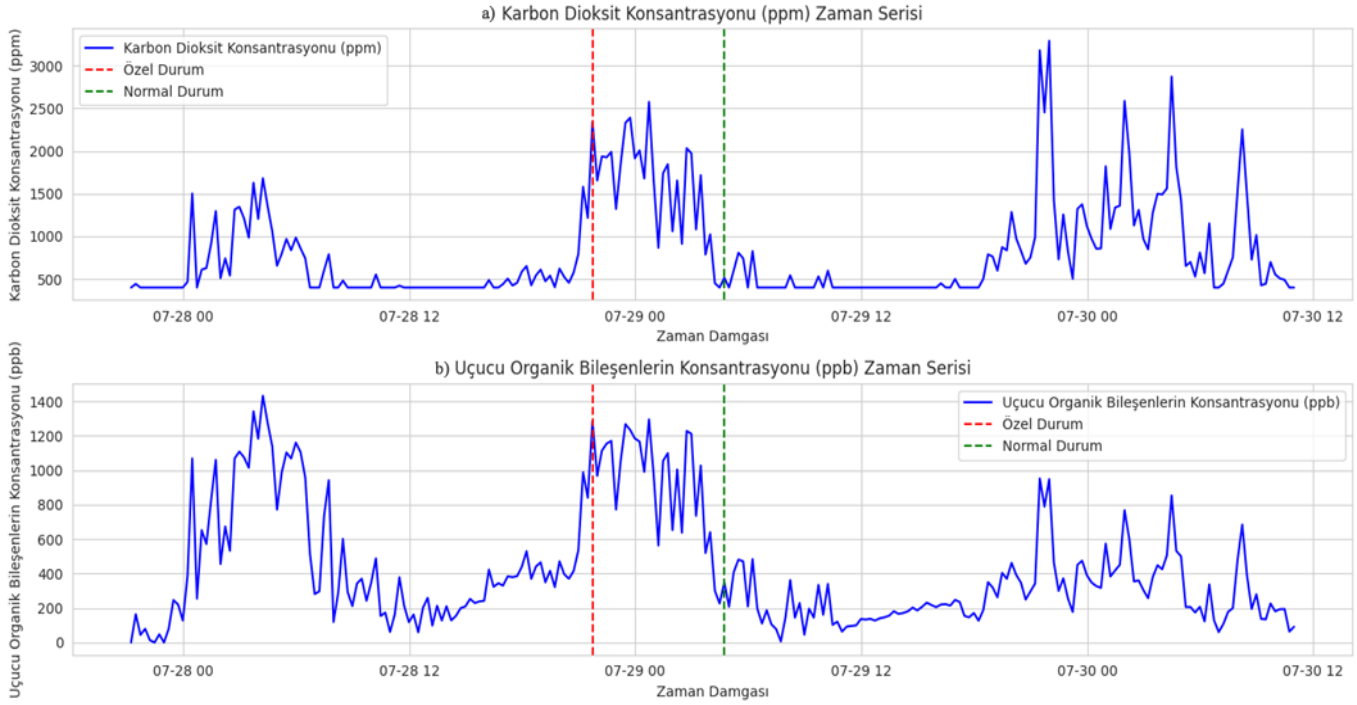
TempOut (°C) ve HumOut (%): Bu iki özellik arasında negatif bir korelasyon vardır (-0.71). Bu, dış sıcaklıklar arttıkça dış nemin azaldığını göstermektedir. Bu ilişki, dış çevresel koşulların kovana nasıl etki ettiğini anlamak için önemli olabilir.

Diğer Korelasyonlar: Diğer korelasyonlar daha düşük, bu da bu belirli özellikler arasında önemli bir ilişki olmadığını önerir.

Aykırı Değer Analizi: Veri setindeki aykırı değerleri belirlemek için Dörtte Birler Aralığı (IQR) yöntemi kullanılmıştır. IQR, bir veri setindeki birinci (Q1) ve üçüncü (Q3) çeyreklikler arasındaki farkı ölçer ve bu fark, aykırı değerleri belirlemek için bir eşik olarak kullanılmıştır.

Genellikle, $Q1 - 1.5IQR$ 'dan küçük veya $Q3 + 1.5IQR$ 'dan büyük olan değerler aykırı olarak kabul edilir. Analiz, "28.07.22 21:43:51" zaman damgasına sahip bir veri noktasını, CO₂_eq (ppm) ve TVOC (ppb) değerleri açısından bir aykırı olarak belirledi. Bu, bu sensörler tarafından kaydedilen değerlerin genel veri dağılımından önemli ölçüde sapma gösterdiği anlamına gelir. Böyle aykırı değerler, sensör hatalarından, veri kaydı sırasında anomalilerden veya kovandaki gerçek, atipik çevresel koşullardan kaynaklanabilmektedir. Buna karşın, "29.07.22 04:43:52" zaman

damgasına sahip veri noktası normal bir durumu temsil eder. Bu zaman damgası için kaydedilen değerler, tüm sensörler için beklenen aralıklarda yer alır ve genel veri dağılımıyla uyumludur. Normal koşullar, kovan için kararlı ve sağlıklı bir çevresel durumu gösterir ve analiz ve modelleme çabaları için güvenilir bir referans noktası sağlamaktadır. Bu detaylı korelasyon ve aykırı değer analizi, kovan içindeki dinamikleri anlamak için hayati öneme sahiptir ve arıcılık uygulamaları ile çevresel izleme stratejilerini önemli ölçüde bilgilendirebilir.




Şekil 6. Sensör Verilerinin Zaman Serisi Grafikleri a) Karbondioksit Konsantrasyonu b) Uçucu Organik Bileşiklerin Konsantrasyonu

Üst Grafik - CO₂eq(ppm) Zaman Serisi: Üst grafik, CO₂eq(ppm) değerlerinin zaman serisini göstermektedir. Bu, eşdeğer karbondioksit konsantrasyonunun zaman içinde nasıl değiştiğini gözlemlememize olanak tanımaktadır. Analiz edilen zaman diliminde önemli dalgalanmalar ve herhangi bir atıpkı (aykırı) değer incelenebilmektedir. Aykırı değer analizi bölümünde belirlenen "28.07.22 21:43:51" zaman damgası bu grafikte özellikle dikkat çekicidir. Bu zaman damgasında, CO₂eq(ppm) değerlerinde normdan bir sapma vardır, bu da bu noktanın daha fazla araştırılmayı gerektirdiğini önermektedir.

Alt Grafik - TVOC(ppb) Zaman Serisi: Alt grafik, TVOC(ppb) değerlerinin zaman serisini göstermektedir. TVOC, havadaki toplam uçucu organik bileşiklerin konsantrasyonunu temsil etmektedir. Grafik, belirli zamanlarda TVOC konsantrasyonlarındaki değişiklikleri göstermektedir. TVOC konsantrasyonu, hava kalitesini değerlendirmek için önemli bir parametredir. "28.07.22 21:43:51" zaman damgasında TVOC değerlerinde bir artış gözlemlenmektedir. Bu, belirli bir dönemde kovan içindeki hava kalitesinde bir değişiklik olduğunu gösterebilir. Ses Dalgalarının görselleştirilmesi akustik verileri daha fazla analiz etmek için, her iki ses dosyasının dalga formlarını görselleştirmek kritik öneme sahiptir. Bu görselleştirme, ses sinyallerinin zaman alanındaki yapısını temsil edecektir. Dalga formu görselleştirmeleri, arıların düzenli vızıltıları gibi desenleri veya kovan içindeki arı aktivitesindeki veya stres seviyelerindeki değişiklikleri gösterebilecek olağandışı gürültü desenleri gibi örüntüleri ortaya çıkarabilir. Bu içgörüler, arı kolonisini anlamak ve sağlığını değerlendirmek için değerlidir. Çevresel faktörlerin zaman serisi analizini akustik verilerle bütünleştirerek, kovanın durumu ve arıların çevresel değişikliklere verdiği tepkiler hakkında daha kapsamlı bir anlayış elde edilebilir. Bu yaklaşım, sürdürülebilir arıcılık ve ekolojik izlemede paha biçilmezdir.


Üstteki Grafik- Özel Durum (28.07.22 21:43:51): Bu ses dosyası, daha yüksek genlikli ve daha karmaşık desenler içeren dalga formlarını göstermektedir. Dalga formunda bu tür özellikler, bu dönemde daha yoğun veya çeşitli ses olaylarının meydana geldiğini gösterebilir. Bu ses olayları, artan arı aktivitesi, kovandaki potansiyel stres faktörleri veya arıları etkileyen diğer önemli çevresel değişikliklerle ilgili olabilir.



Şekil 7. İki Ses Dosyası için Ses Dalga Formlarının Görselleştirilmesi a) Özel Durum b) Normal Durum
Alt Grafik- Normal Durum (29.07.22 04:43:52): Bu zaman damgasından gelen ses dosyası, daha düşük genlikli ve daha düzenli desenler gösteren dalga formlarını içermektedir. Bu daha tutarlı ve daha az yoğun ses deseni, genellikle normal kovan koşullarında düzenli arı aktivitesini temsil etmektedir. Bu iki dalga formu arasındaki karşılaştırma, kritik içgörüler sağlamaktadır. Genlik ve karmaşıklıkta bu kontrast, iki zaman damgası arasındaki arı davranışı ve kovan koşulları arasındaki farkları yansıtabilir. Bu varyasyonları anlamak, kovanın çevresindeki değişiklikleri yorumlamak için esastır ve potansiyel sorunları belirlemede veya kovanın sağlık ve istikrarını doğrulamada önemli bir araç olabilir.

Spektrogramların Görselleştirilmesi

Spektrogramlar, ses sinyallerinin zaman içinde frekans bileşenlerini görselleştirmek için etkili bir araçtır.



Şekil 8. İki Ses Dosyasının Spektrogramları a) Özel Durum b) Normal Durum

İki ses dosyasının spektrogramları, farklı kovan koşulları için frekans bileşenlerinin ve zaman içindeki değişikliklerinin görsel bir temsilini sağlamaktadır.

Üst Grafik - Özel Durum (28.07.28 21:43:51): Bu spektrogramda, zamanla değişen farklı frekanslarda güçlü bileşenler görebiliriz. Bu, özel bir zaman damgasında kovandaki olağandışı aktiviteleri veya rahatsızlıkları belirtebilecek karmaşık ve değişken bir ses profili olduğunu göstermektedir.

Alt Grafik - Normal Durum (29.07.22 04:43:52): Bu spektrogram daha basit olup, az sayıda güçlü frekans bileşeni içermektedir. Böyle bir desen, kovandaki daha istikrarlı ve tipik bir ses ortamını göstermektedir, bu da normal arı aktivitesi ve davranışını yansıtmaktadır. Bu spektrogramlar, farklı koşullar altında kovanın akustik ortamı hakkında bilgiler sağlamaktadır. Özel durumdaki karmaşık desenler, potansiyel stres faktörlerine veya çevresel değişikliklere kovanın tepkisini önerirken, normal durumdaki daha basit desenler, sakin ve istikrarlı bir kovana göstermektedir. Bu tür bir analiz, arıcılar ve araştırmacılar için arı kolonilerinin sağlığını ve aktivitesini izleme paha biçilmezdir.

TARTIŞMA

Bu çalışma, çevresel ve akustik verilerin bütünleştirilmesi yoluyla kovanların sağlık ve davranışlarının çok yönlü bir analizini sunarak, aykırı değer analizi ile tanımlanan normal ve özel koşullar arasındaki farklılıkları vurgulamaktadır. Bu veri türlerinin entegrasyonu, arı sağlığı ve davranışını anlamak için çok yönlü bir perspektif sunar, bu da sürdürülebilir arıcılık uygulamaları için kritik öneme sahiptir.

Özel koşullardaki ses kayıtları (zaman damgası: 28.07.22 21:43:51), normal koşullara kıyasla (zaman damgası: 29.07.22 04:43:52) daha yüksek genlik ve daha karmaşık dalga formları göstermiştir. Bu yüksek genlik ve karmaşık desenler, kovan içinde stres veya olağandışı aktiviteyi belirtebilecek yoğun veya çeşitli ses olaylarına işaret eder. Bu tür akustik sinyaller, artan arı aktivitesi, çevresel stres faktörleri veya kovana etkileyen rahatsızlıklarla ilişkili olabilir. Önceki araştırmalar, akustik verilerin arı aktivitesi ve sağlığını izlemek için kullanılabilirliğini desteklemektedir. Arıların aktivite ve stres durumlarına bağlı olarak değişen ses frekansları, kovanın genel sağlığını değerlendirmek için kullanılmaktadır (Ferrari vd., 2008; Terenzi vd., 2020). Bulgularımız, ses analizinin, kovan içi değişiklikleri belirlemede etkili olduğunu ortaya koymaktadır. Ses kayıtlarının spektrogramları, özel ve normal koşullar arasındaki farkları daha da netleştirmektedir. Özel koşuldan alınan spektrogram, zamanla değişen çeşitli frekanslarda güçlü bileşenler ile dinamik ve karmaşık ses desenleri göstermiştir. Bu karmaşıklık, kovana etkileyen olağandışı aktiviteleri veya çevresel değişiklikleri işaret etmektedir. Buna karşılık, normal koşuldan alınan spektrogram daha basit desenler ve daha az güçlü frekans bileşenleri göstererek stabilite ve düzenli arı aktivitesini ima etmektedir.

Spektrogramlardaki bu zıtlık, kovanın değişen çevresel koşullara tepkisini vurgulamaktadır. Araştırmalar, arıların akustik imzalarının çevresel stres faktörlerine ve iç kovan dinamiklerine tepki olarak değiştiğini göstermiştir (Gorgeva vd., 2023; Sharif vd., 2023). Bu nedenle, bu çalışmadaki spektrogram analizi, akustik izlemenin kovan sağlığını değerlendirmek için etkili bir araç olduğunu pekiştirmektedir. Dörtte Birler Aralığı (IQR) yöntemi kullanılarak yapılan aykırı değer analizi, CO₂ eq (ppm) ve TVOC (ppb) değerlerinde önemli sapmalar gösteren belirli zaman damgalarını tanımlamıştır. Örneğin, "28.07.22 21:43:51" zaman damgası, kovan içindeki olağandışı çevresel koşulları gösteren yüksek CO₂ ve TVOC seviyelerini göstermiştir. Bu aykırı değerler, sensör hatalarından, veri kaydı sırasında meydana gelen anormalliklerden veya kovana etkileyen gerçek atipik koşullardan kaynaklanabilir.

CO₂ ve TVOC seviyelerini izlemek, kovan sağlığını değerlendirmek için kritik öneme sahiptir, çünkü bu parametreler kovan içindeki metabolik aktivite ve hava kalitesinin göstergeleridir (Rigakis vd., 2023; Szczurek vd., 2023). Yüksek seviyeler, havalandırma sorunlarını veya stres nedeniyle artan metabolik aktiviteyi gösterebilir. Dolayısıyla, aykırı değerlerin tanımlanması ve analizi, potansiyel sorunların erken tespiti ve zamanında müdahale için esastır. Çevresel ve akustik sensör verilerinin entegrasyonu, kovan koşullarının bütüncül bir görünümünü sağlamaktadır. Bu veri türlerinin birleştirilmesi, arıcıların kovanın durumu hakkında kapsamlı içgörüler elde etmelerine olanak tanımaktadır ve proaktif izleme ve yönetimi mümkün kılmaktadır. Bu çalışma, bu tür entegre bir yaklaşımın olağandışı koşulları etkili bir şekilde tespit edebileceğini göstererek, arı kolonilerinin sağlığı ve sürdürülebilirliği için katkıda bulunur. Bulgularımız, CO₂ ve TVOC seviyelerindeki artışların arı kolonilerindeki stres seviyelerini artırdığına işaret etmektedir. Literatürle karşılaştırıldığında, bu artışların kolonilerin sağlık durumunu etkilediği birçok çalışmada benzer şekilde rapor edilmiştir. Örneğin, Amsalem ve Grozinger'in 2017 yılında yaptıkları çalışmada, CO₂ seviyelerinin artmasının bireysel arı davranışlarını etkilediğini ve kolonide stres belirtilerini tetiklediğini göstermiştir (Amsalem & Grozinger, 2017). Benzer şekilde, Bahreini ve Currie 2015 yılında, sınırlı havalandırma koşullarında artan CO₂ seviyelerinin varroa akarlarının kontrolüne katkı sağlarken arıların genel sağlığı üzerinde

olumsuz etkilere neden olabileceğini belirtmiştir (Bahreini & Currie, 2015). Meikle ve arkadaşları 2021 yılında ise pestisitlerle ilişkili olarak artan CO₂ seviyelerinin kovan içindeki metabolik aktiviteyi değiştirdiğini ve kolonilerin uzun vadeli performansını olumsuz etkilediğini bulmuşlardır (William G Meikle vd., 2021). Bu çalışmalar, mevcut bulgularımızı destekler niteliktedir ve CO₂ ve TVOC seviyelerindeki artışların arı kolonilerindeki çevresel stres faktörleri ile doğrudan ilişkili olduğunu doğrulamaktadır.

Bu çalışma, arı kovana izleme için entegre ve etkili analiz metodolojilerinin geliştirilmesine katkıda bulunmaktadır. Bulgular, çevresel parametrelerin akustik verilerle birleştirilmesinin, kovan koşullarındaki değişiklikleri tespit etme ve yorumlama yeteneğini artırdığını önermektedir. Gelecekteki araştırmalar, bu metodolojilerin rafine edilmesine ve kovan izleme sistemlerini daha da geliştirmek için ek sensör teknolojilerinin keşfedilmesine odaklanmalıdır.

İleri veri analizi teknikleri ve sensör teknolojilerinin kullanılmasıyla, arıcılık uygulamaları daha verimli ve sürdürülebilir hale gelebilir. Bu çalışma, kovan izleme konusundaki yeniliklerin temellerini atarak, arı popülasyonlarının korunması ve verimliliğinin artırılmasını desteklemektedir.

KAYNAKLAR

- Abou-Shaara, H. F., Owayss, A. A., Ibrahim, Y. Y., & Basuny, N. K. (2017). A review of impacts of temperature and relative humidity on various activities of honey bees. *Insectes Sociaux*, 64(4), 455–463. <https://doi.org/10.1007/s00040-017-0573-8>
- Amsalem, E., & Grozinger, C. M. (2017). Evaluating the molecular, physiological and behavioral impacts of CO₂ narcosis in bumble bees (*Bombus impatiens*). *Journal of Insect Physiology*, 101, 57–65. <https://doi.org/10.1016/j.jinsphys.2017.06.014>
- Anwar, O., Keating, A., Cardell-Oliver, R., Datta, A., & Putrino, G. (2022). Design and development of low-power, long-range data acquisition system for beehives - BeeDAS. *Computers and Electronics in Agriculture*, 201, 107281. <https://doi.org/10.1016/j.compag.2022.107281>
- Ayton, S., Tomlinson, S., Phillips, R. D., Dixon, K. W., & Withers, P. C. (2016). Phenophysiological variation of a bee that regulates hive humidity, but not hive temperature. *Journal of Experimental Biology*, 219(10), 1552–1562. <https://doi.org/10.1242/jeb.137588>
- Bahreini, R., & Currie, R. W. (2015). The Potential of Bee-Generated Carbon Dioxide for Control of Varroa Mite (Mesostigmata: Varroidae) in Indoor Overwintering Honey bee (Hymenoptera: Apidae) Colonies. *Journal of Economic Entomology*, 108(5), 2153–2167. <https://doi.org/10.1093/jee/tov202>
- Bencsik, M., McVeigh, A., Tsakonas, C., Kumar, T., Chamberlain, L., & Newton, M. (2023). A Monitoring System for Carbon Dioxide in Honeybee Hives: An Indicator of Colony Health. *Sensors (Basel, Switzerland)*, 23. <https://doi.org/10.3390/s23073588>
- Braga, A. R., Gomes, D. G., Rogers, R., Hassler, E. E., Freitas, B. M., & Cazier, J. A. (2020). A method for mining combined data from in-hive sensors, weather and apiary inspections to forecast the health status of honey bee colonies. *Computers and Electronics in Agriculture*, 169, 105161.
- Bretzlaff, T., Kerr, J. T., & Darveau, C. A. (2023). High temperature sensitivity of bumblebee castes and the colony-level costs of thermoregulation in *Bombus impatiens*. *Journal of Thermal Biology*, 117, 103710. <https://doi.org/10.1016/j.jtherbio.2023.103710>
- Bromenshenk, J. J., Henderson, C. B., Seccomb, R. A., Welch, P. M., Debnam, S. E., & Firth, D. R. (2015). Bees as biosensors: Chemosensory ability, honey bee monitoring systems, and emergent sensor technologies derived from the pollinator syndrome. İçinde *Biosensors* (C. 5, Sayı 4, ss. 678–711). MDPI. <https://doi.org/10.3390/bios5040678>
- Cane, J. H., & Love, B. G. (2021). Hygroscopic larval provisions of bees absorb soil water vapor and release liquefied nutrients. *Apidologie*, 52(6), 1002–1016. <https://doi.org/10.1007/s13592-021-00883-5>
- Cecchi, S., Spinsante, S., Terenzi, A., & Orcioni, S. (2020). A Smart Sensor-Based Measurement System for Advanced Bee Hive Monitoring. *Sensors 2020, Vol. 20, Page 2726, 20(9)*, 2726. <https://doi.org/10.3390/S20092726>
- Doublet, V., Labarussias, M., de Miranda, J. R., Moritz, R. F. A., & Paxton, R. J. (2015). Bees under stress: Sublethal doses of a neonicotinoid pesticide and pathogens interact to elevate honey bee mortality across the life cycle. *Environmental Microbiology*, 17(4), 969–983. <https://doi.org/10.1111/1462-2920.12426>
- Durgun, Y. (2021). Nesnelerin İnterneti Teknolojisinin Kümes Ortamına Uygulanması ve Etkileri. *European Journal of Science and Technology*. <https://doi.org/10.31590/ejosat.1005685>

- Ferrari, S., Silva, M., Guarino, M., & Berckmans, D. (2008). Monitoring of swarming sounds in bee hives for early detection of the swarming period. *Computers and Electronics in Agriculture*, 64(1), 72–77. <https://doi.org/10.1016/j.compag.2008.05.010>
- Genç, M., & Genç, F. (2019). Stress Factors on Honey Bees (*Apis mellifera* L.) and The Components of Their Defense System Against Diseases, Parasites, and Pests. *Mellifera*, 19(1), 7–20.
- Gil-Lebrero, S., Quiles-Latorre, F. J., Ortiz-López, M., Sánchez-Ruiz, V., Gámiz-López, V., & Luna-Rodríguez, J. J. (2016). Honey Bee Colonies Remote Monitoring System. *Sensors* 2017, Vol. 17, Page 55, 17(1), 55. <https://doi.org/10.3390/S17010055>
- Gorgeva, E., Robertson, J., Voss, S., & Hoogewerff, J. (2023). The potential of bioacoustics for surveying carrion insects. İçinde *Australian Journal of Forensic Sciences* (ss. 1–20). Taylor & Francis. <https://doi.org/10.1080/00450618.2023.2295447>
- Goulson, D., Nicholls, E., Botías, C., & Rotheray, E. L. (2015). Bee declines driven by combined Stress from parasites, pesticides, and lack of flowers. İçinde *Science* (C. 347, Sayı 6229, s. 1255957). American Association for the Advancement of Science. <https://doi.org/10.1126/science.1255957>
- Kauffeld, N. M. (1967). Seasonal colony activity and individual bee development. *Beekeeping in the United States*, 335, 5.
- Kearns, C. A., & Inouye, D. W. (1997). Pollinators, Flowering Plants, and Conservation Biology. *BioScience*, 47(5), 297–307. <https://doi.org/10.2307/1313191>
- Lin, Z., Zheng, M., Li, Z., & Ji, T. (2023). Editorial: Biotic and abiotic stresses on honeybee physiology and colony health. *Frontiers in Physiology*, 14. <https://doi.org/10.3389/fphys.2023.1260547>
- Maxwell, J. T., & Knapp, P. A. (2012). Reconstructed tupelo-honey yield in northwest Florida inferred from Nyssa Ogeche tree-ring data: 1850-2009. *Agriculture, Ecosystems and Environment*, 149, 100–108. <https://doi.org/10.1016/j.agee.2011.11.004>
- Meikle, W. G., & Holst, N. (2015). Application of continuous monitoring of honeybee colonies. *Apidologie*, 46(1), 10–22. <https://doi.org/10.1007/S13592-014-0298-X/TABLES/1>
- Meikle, William G, Adamczyk, J. J., Weiss, M., Ross, J., Werle, C., & Beren, E. (2021). Sublethal concentrations of clothianidin affect honey bee colony growth and hive CO2 concentration. *Scientific Reports*, 11(1), 4364. <https://doi.org/10.1038/s41598-021-83958-8>
- Mirzaei, S. (2024). *Smart Beehive System for Measuring Honey Level and Controlling Temperature*.
- Mitchell, D. (2019). Nectar, humidity, honey bees (*Apis mellifera*) and varroa in summer: A theoretical thermofluid analysis of the fate of water vapour from honey ripening and its implications on the control of Varroa destructor. *Journal of the Royal Society Interface*, 16(156), 20190048. <https://doi.org/10.1098/rsif.2019.0048>
- Mobaraki, B., Komarizadehasl, S., Castilla Pascual, F. J., & Lozano-Galant, J. A. (2022). Application of Low-Cost Sensors for Accurate Ambient Temperature Monitoring. *Buildings*, 12(9), 1411. <https://doi.org/10.3390/buildings12091411>
- Murray, T. E., Kuhlmann, M., & Potts, S. G. (2009). Conservation ecology of bees: Populations, species and communities. İçinde *Apidologie* (C. 40, Sayı 3, ss. 211–236). EDP Sciences. <https://doi.org/10.1051/apido/2009015>
- Ozger, Z. B., Cihan, P., & Gokce, E. (2024). A Systematic Review of IoT Technology and Applications in Animals. *Kafkas Universitesi Veteriner Fakültesi Dergisi*, 411. <https://doi.org/10.9775/kvfd.2024.31866>
- Papa, G., Maier, R., Durazzo, A., Lucarini, M., Karabagias, I. K., Plutino, M., Bianchetto, E., Aromolo, R., Pignatti, G., Ambrogio, A., Pellicchia, M., & Negri, I. (2022). file:///C:/Users/togu/Downloads/scholar (26).ris. *Biology*, 11(2), 233. <https://doi.org/10.3390/biology11020233>
- Qandour, A., Ahmad, I., Habibi, D., & Leppard, M. (2014). Remote beehive monitoring using acoustic signals. *Acoustics Australia*, 42(3), 204–209.
- Rafael Braga, A., G. Gomes, D., Rogers, R., E. Hassler, E., M. Freitas, B., & A. Cazier, J. (2020). A method for mining combined data from in-hive sensors, weather and apiary inspections to forecast the health status of honey bee colonies. *Computers and Electronics in Agriculture*, 169(7), 105161.

<https://doi.org/https://doi.org/10.1016/j.compag.2019.105161>

Ratnadass, A., Fernandes, P., Avelino, J., & Habib, R. (2012). Plant species diversity for sustainable management of crop pests and diseases in agroecosystems: A review. İçinde *Agronomy for Sustainable Development* (C. 32, Sayı 1, ss. 273–303). Springer. <https://doi.org/10.1007/s13593-011-0022-4>

Rigakis, I., Potamitis, I., Tatlas, N. A., Psirofonias, G., Tzagaraki, E., & Alissandrakis, E. (2023). A Low-Cost, Low-Power, Multisensory Device and Multivariable Time Series Prediction for Beehive Health Monitoring. *Sensors*, 23(3), 1407. <https://doi.org/10.3390/s23031407>

Ruvinga, S., Hunter, G. J. A., Duran, O., & Nebel, J. C. (2021). Use of LSTM Networks to Identify “Queenlessness” in Honeybee Hives from Audio Signals. *2021 17th International Conference on Intelligent Environments, IE 2021 - Proceedings*, 1–4. <https://doi.org/10.1109/IE51775.2021.9486575>

Schöning, C., Gisder, S., Geiselhardt, S., Kretschmann, I., Bienefeld, K., Hilker, M., & Genersch, E. (2012). Evidence for damage-dependent hygienic behaviour towards *Varroa destructor*-parasitised brood in the western honey bee, *Apis mellifera*. *Journal of Experimental Biology*, 215(2), 264–271. <https://doi.org/10.1242/jeb.062562>

Sharif, M. Z., Di, N., & Yu, B. (2023). Honeybee (*Apis* spp.) (Hymenoptera: Apidae) Colony Monitoring Using Acoustic Signals from the Beehive: An Assessment by Global Experts and Our Feedback. *Agriculture (Switzerland)*, 13(4), 769. <https://doi.org/10.3390/agriculture13040769>

Szczurek, A., Maciejewska, M., & Batog, P. (2023). Monitoring System Enhancing the Potential of Urban Beekeeping. *Applied Sciences (Switzerland)*, 13(1), 597. <https://doi.org/10.3390/app13010597>

Tang, J., Ji, C., Shi, W., Su, S., Xue, Y., Xu, J., Chen, X., Zhao, Y., & Chen, C. (2023). Survey Results of Honey Bee Colony Losses in Winter in China (2009–2021). *Insects*, 14(6), 554. <https://doi.org/10.3390/insects14060554>

Terenzi, A., Cecchi, S., & Spinsante, S. (2020). On the importance of the sound emitted by honey bee hives. *Veterinary Sciences*, 7(4), 1–14. <https://doi.org/10.3390/vetsci7040168>

Thapa, R. (2006). Honeybees and other Insect Pollinators of Cultivated Plants: A Review. *Journal of the Institute of Agriculture and Animal Science*, 27, 1–23. <https://doi.org/10.3126/jiaas.v27i0.691>

Tien, J. M. (2017). Internet of Things, Real-Time Decision Making, and Artificial Intelligence. *Annals of Data Science*, 4(2), 149–178. <https://doi.org/10.1007/s40745-017-0112-5>

vanEngelsdorp, D., Evans, J. D., Saegerman, C., Mullin, C., Haubruge, E., Nguyen, B. K., Frazier, M., Frazier, J., Cox-Foster, D., Chen, Y., Underwood, R., Tarpy, D. R., & Pettis, J. S. (2009). Colony collapse disorder: A descriptive study. *PLoS ONE*, 4(8), e6481. <https://doi.org/10.1371/journal.pone.0006481>

VanEngelsdorp, D., Traynor, K. S., Andree, M., Lichtenberg, E. M., Chen, Y., Saegerman, C., & Cox-Foster, D. L. (2017). Colony Collapse Disorder (CCD) and bee age impact honey bee pathophysiology. *PLoS ONE*, 12(7), e0179535. <https://doi.org/10.1371/journal.pone.0179535>

Wardhany, V. A., Hidayat, A., Subono, & Jhoswanda, M. (2020). Temperature and Humidity Control of Smart Cage Bee Honey Based on Internet of Things. *2020 3rd International Conference on Computer and Informatics Engineering, IC2IE 2020*, 467–472. <https://doi.org/10.1109/IC2IE50715.2020.9274620>

Zaman, A., & Dorin, A. (2023). A framework for better sensor-based beehive health monitoring. İçinde *Computers and Electronics in Agriculture* (C. 210, s. 107906). Elsevier. <https://doi.org/10.1016/j.compag.2023.107906>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 01.11.2024
Kabul Tarihi : 21.01.2025

Received Date : 01.11.2024
Accepted Date : 21.01.2025

KUM ZEMİNDE KAZIK TAŞIMA KAPASİTESİNİN LABORATUVAR MODEL KAZIK YÜKLEME DENEYLERİ İLE BELİRLENMESİ

DETERMINATION OF PILE BEARING CAPACITY IN SAND SOIL BY LABORATORY MODEL PILE LOADING TESTS

Murat GÜLEN¹* (ORCID: 0000-0003-4143-9266)
Havvanur KILIÇ² (ORCID: 0000-0001-9455-1687)

¹ Siirt Üniversitesi, İnşaat Mühendisliği, Siirt, Türkiye

² Yıldız Teknik Üniversitesi, İnşaat Mühendisliği, İstanbul, Türkiye

*Sorumlu Yazar : Murat GÜLEN, murat.gulen@siirt.edu.tr

ÖZET

Kazık ve kazıklı temellerin taşıma kapasiteleri genellikle arazi kazık yükleme deneylerinden ve ya literatürde kabul gören yaklaşımlardan faydalanılarak belirlenmektedir. Son yıllarda laboratuvar ortamında gerçekleştirilen model kazık yükleme deneylerinden de kazıkların taşıma kapasitelerinin belirlenmesi için çalışmalar devam etmektedir. Özellikle taşıma kapasitelerinin tamamını veya bir kısmını kazık-zemin sürtünmesi ile sağlayan kazıklar için ara yüzey sürtünme mukavemeti parametrelerinin doğru bir şekilde belirlenmesi, daha gerçekçi ve güvenilir tasarımların yapılmasına olanak sağlayacaktır. Bu çalışma kapsamında enstrümante edilen ve eksenel yükleme koşullarına maruz bırakılan alüminyum bir kazığın yük taşıma kapasitesi laboratuvar model kazık yükleme deneyleri ile araştırılmıştır. Deneysel ölçümlerden belirlenen yük-oturma eğrisi dikkate alınarak kazık taşıma kapasitesi literatürde kabul gören yöntemler kullanılarak belirlenmiştir. Elde edilen sonuçlar karşılaştırılarak benzerlikler ve farklılıklar yorumlanmıştır. Laboratuvar ortamında sınırlı bir durumu temsil eden model kazık yükleme deney sonuçlarından genel değerlendirmelerin yapılabilmesi için çalışmaların farklı kazık çapları ve türleri, zemin sınıfları ve yükleme koşulları dikkate alınarak desteklenmesi gerekmektedir. Böylelikle kazıkların taşıma kapasitesinin arazi kazık yükleme deneylerine alternatif bir yöntemle laboratuvar ortamında belirlenebileceği açıktır.

Anahtar Kelimeler: Zemin-kazık etkileşimi, kazık yükleme deneyleri, kazık taşıma kapasitesi

ABSTRACT

The bearing capacities of piles and piled foundations are typically determined through pile loading tests conducted in the field or by applying accepted methodologies from the literature. Recent studies have continued to investigate the potential for determining pile bearing capacity utilising model pile loading tests conducted in laboratory. For piles that derive all or part of their bearing capacity from pile-soil friction, there is a clear necessity for accurately determining the interface frictional strength parameters in developing more realistic and reliable designs. This study investigates the bearing capacity of an instrumented aluminium pile subjected to axial loading conditions using pile loading tests conducted in a laboratory. The pile's bearing capacity was determined from the load-settlement curve derived from measurements, in accordance with accepted methods from the literature. A comparison was subsequently done, with particular attention focused on identifying any similarities and differences in the results. While the results of these model pile loading tests represent a limited situation in laboratory conditions, they highlight the necessity for further experimental studies considering different pile dimensions and types, soils, and loading conditions. These findings indicate the potential for determining pile bearing capacity in laboratory conditions as an alternative to field pile loading tests.

Keywords: Soil-pile interaction, pile loading tests, pile bearing capacity

ToCite: GÜLEN, M., & KILIÇ, H., (2025). KUM ZEMİNDE KAZIK TAŞIMA KAPASİTESİNİN LABORATUVAR MODEL KAZIK YÜKLEME DENEYLERİ İLE BELİRLENMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 430-440.

GİRİŞ


Kazıklar, kazıklı temeller, ankrajlı sistemler, diyafram duvarlar gibi geoteknik yapıların tasarımlarında ara yüzey sürtünme mukavemeti parametreleri (δ , c_a) genellikle kayma mukavemeti parametrelerine (c , ϕ) bağlı olarak Terzaghi ve Peck (1948) tarafından önerilen ampirik eşitliklerden elde edilmektedir. Buna ek olarak, NAVFAC (1986) tarafından önerilen δ ve c_a değerleri de tasarımlarda sıklıkla kullanılmaktadır. Potyondy (1961), farklı yüzey pürüzlülüğüne sahip ara yüzey elemanları ile farklı dane çapı dağılımına sahip zeminler için δ ve c_a değerleri belirlenmiştir. Çalışmalar sonucunda su muhtevasını (w), dane çapını, zemin türünü, farklı yapısal elemanları ve farklı yüzey pürüzlülüğünü dikkate alarak c_a/c ve δ/ϕ oranlarını önermiştir. Kishida ve Yoshimi (1981), farklı kum zeminler ile çelik ara yüzey sürtünme mukavemetini incelemiş ve sürtünme mukavemetinin ara yüzey elemanın pürüzlülüğüne ve zeminin ortalama dane çapına (D_{50}) bağlı olduğunu ifade etmişlerdir. Cerato ve Lutenege (2006), farklı boyuttaki direkt kesme kutusu deney aleti ile farklı sıklıklardaki 5 kumun ϕ değerlerini belirlemişlerdir. Çalışmalarda rölatif sıklığın (Dr) artışına bağlı olarak ϕ değerinin arttığını ve kesme kutusu deney aletinin boyutları büyüdükçe ϕ değerinin azaldığını tespit etmişlerdir. Samanta vd. (2018), farklı dane şekline ve dane boyutuna sahip kumlar ile farklı pürüzlülüğe sahip beton ve çelik ara yüzey etkileşimini incelemişlerdir. Bu etkileşim için Dr (%), yüzey pürüzlülüğü, dane şekli ve D_{50} 'nin en önemli parametreler olduğunu belirtmişlerdir. Tiwari ve Al-Adlath (2014) kum zeminler ile farklı yapısal elemanlar için kuru ve suya doymun olarak hazırlanarak yapılan deneylerde, Dr (%) artışına bağlı olarak ara yüzey sürtünme mukavemetinin arttığını ve kuru hazırlanan numunelerden elde edilen mukavemetin doymun hazırlanan numunelerden daha büyük olduğunu rapor etmişlerdir.

Kazıkların yük altındaki davranışının belirlenmesi için kullanılan en yaygın yöntem arazi kazık yükleme deneyleridir. Yankı (2015), kazık yükleme deneylerinden elde edilen sonuçların statik taşıma gücü formülleri ve sayısal analizlerle birlikte değerlendirilmesi gerektiğini ifade etmiştir. Bu durumun tasarım sonrası oluşacak sorunların minimize edilmesinde önemli rol oynadığını belirtmiştir. Özellikle kazık yükleme deneylerinden belirlenen yük-oturma eğrisi için farklı hesaplama yöntemleri dikkate alınarak taşıma kapasitesi belirlenmektedir [Broms (1981), Tomlinson (2004), Fleming vd. (2009)]. Fellenius (2004) kazık yükleme deneyi sonuçlarının değerlendirilme yöntemlerini üç ana başlıkta gruplandırmıştır (Tablo 1).

Tablo 1. Kazık Taşıma Kapasitesinin Belirlenmesi İçin Kullanılan Yöntemler [Fellenius (2004)]

Yöntemler	Referans	Yükleme yöntemi
Matematiksel	Chin (1970)	CRP-QM-SM
Grafiksel	De Beer (1972)	SM
	Brinch-Hansen (1963)	CRP
	Teğet Yöntemi	-
	Mazurkiewicz (1972)	-
Oturmayı Sınırlandıran	Davissan (1972)	OM-CRP-SM

Tablo 1'deki yöntemlerden sabit penetrasyon oranı ile yükleme deneyi (CRP), yavaş (SM) ve hızlı (QM) kademeli yükleme ile çevrimli yükleme (SC) deney yöntemleri için belirlenen yük-oturma ilişkisi, deneyin yapıldığı yükleme koşullarına bağlı olarak farklılık göstermektedir. Aynı yükleme koşulları için bu yöntemlerden belirlenen yük-oturma eğrileri Şekil 1'de sunulmuştur.



Şekil 1. Farklı Deney Yöntemleri İçin Yük-Oturma İlişkisinin Karşılaştırılması [Toğrol (1970)]

Bir kazığa etki eden düşey yüklerin bir kısmı kazığın uç direnci (Q_p) tarafından taşınırken, bir kısmı da çevre sürtünmesi (Q_s) ile karşılanır. Nihai durumunda kazığın taşıma kapasitesi (Q_{ult}), Q_p+Q_s 'nin toplamı olarak ifade edilir. Özellikle kazıklar Q_p ve Q_s değerlerine farklı oturma miktarlarında ulaşırlar. Bowles (1996), uç direncinin çakma kazıklarda kazık çapının (D) %10'unda ve fore kazıklarda %30'unda; Tomlinson (2004) ve Woodward (2006), kumlu zeminlerde uç direncin kazık çapının %10-%20'sinde; Das (2007), uç direncinin kazık çapının %10-%25'i oturma değerinde ulaştığını ifade etmişlerdir.

Baca vd. (2019), laboratuvar model kazık deneyleri ile çelik bir kazığın taşıma kapasitesini orta sıklıktaki kum için incelemişlerdir. Kazıkların iki farklı statik yükleme durumu için yük-oturma eğrileri belirlenmiştir. Yükleme türünün yük-oturma ilişkisini etkilediğini ve taşıma kapasitesinin yükleme türüne bağlı olduğunu ifade etmişlerdir. Baca ve Rybak (2018), pürüzlü ve pürüzsüz yüzeye sahip çelik dairesel bir kazığın nihai taşıma kapasitesini Brinch Hansen (1963) yöntemini kullanarak belirlemişlerdir. Aynı deney koşulları için pürüzlü kazık yüzeyine sahip kazığın nihai taşıma kapasitesi, pürüzsüz yüzeydeki taşıma kapasitesinden %34 daha büyük hesaplanmıştır. Rybak ve Krol (2018), prefabrik olarak üretilen ve zemine sürülerek yerleştirilen 30 farklı arazi kazık yükleme deneyinden elde edilen yük-oturma ilişkisi için yükleme hızı ve sıklığının kazık taşıma kapasitesini Tablo 1'deki yöntemleri kullanarak hesaplamışlardır. Belirlenen kazık taşıma kapasiteleri için ilk yükleme kademelerindeki noktaların önemli olmadığını ve nihai taşıma kapasitesi için plastik bölgedeki değerlerin belirleyici olduğunu ifade etmişlerdir. Yenginlar (2015), kum tankı içerisinde imal edilen ve farklı boyutlardaki kazıklar için laboratuvar model kazık yükleme deneyleri ile Q_s ve Q_p değerlerini araştırmıştır. Çalışmalar sonucunda kazıklardaki maksimum Q_s ve Q_p değerlerinin sırasıyla kazık çapının %10 ve %15-%20'sinde oluştuğunu belirtmiştir.


Bu çalışma kapsamında alüminyum bir kazığın aksel olarak yüklenmesi sonucunda yük-oturma eğrisi elde edilmiştir. Bu yük-oturma eğrisi dikkate alınarak Tablo 1'deki yöntemler için kazık taşıma kapasiteleri belirlenerek karşılaştırılmıştır. Buna ek olarak farklı D_r (%) değerlerindeki kum-alüminyum ara yüzeyi için δ değerleri kesme kutusu deneyleri ile belirlenerek Q_s değeri hesaplanmıştır. Arazi kazık yükleme deneylerinin yapılamadığı koşullarda laboratuvar kazık yükleme deneylerinin kullanılabilirliği araştırılmıştır.

DENEYSEL ÇALIŞMALAR

Bu çalışma kapsamında kullanılan Şile kumuna ait özellikler, kayma mukavemeti parametreleri ve ara yüzey sürtünme açıları, kazık yükleme deneyi için kullanılan model deney sistemi, alüminyum kazık için gerçekleştirilen kalibrasyon ve enstrümantasyon aşamaları alt başlıklar halinde açıklanacaktır.

Şile Kumunun Özellikleri

DeneySEL çalışma kapsamında kullanılan Şile kumu için yapılan elek analizi ile belirlenen dane çapı dağılımı Şekil 2'de sunulmuştur. Birleştirilmiş Zemin Sınıflandırma Sistemine göre kötü derecelenmiş kum (SP) sınıfında yer alan Şile kumunun laboratuvar ortamında belirlenen fiziksel özellikleri Tablo 2'de özetlenmiştir.



Şekil 2. Şile Kumuna Ait Dane Çapı Dağılımı

Tablo 2. Şile Kumuna Ait Malzeme Özellikleri

Zemin sınıfı	Gs	Cu	Cc	e_{max}	e_{min}
SP	2,65	3	1,33	0,80	0,50

Direkt Kesme Kutusu Deney Sonuçları


Şile kumunun ϕ ve Şile kumu-alüminyum ara yüzey sürtünme açısı (δ), $Dr(\%)=70$ için 50 kPa, 100 kPa ve 200 kPa normal gerilmelerde ve 1 mm/dk kesme hızında küçük ölçekli direkt kesme kutusu deney aleti kullanılarak belirlenmiştir. Tablo 3'te sunulan δ/ϕ oranı farklı yapısal elemanlar-kum ara yüzeyi için ASCE (1993), Kulhawy (1984) ve NAVFAC (1988) ve tarafından önerilen değerlerle uyumludur.

Tablo 3. Şile Kumu İçin Direkt Kesme Kutusu Deney Sonuçları

Dr (%)	ϕ (°)	δ (°)	δ/ϕ
70	36	28	0,78

Model Deney Düzenegi ve Deney Prosedürü

Laboratuvarda model kazık yükleme deneylerinde kullanılan deney düzenegi Şekil 3'te detaylandırılmıştır.

**Şekil 3.** Deneyel Ekipman a) Yağmurlama Düzenegi b) Deney Sistemi Ve Gerinim Ölçerin Konumu


Deneyler sırasında boyu 75 cm ve çapı 2,2 cm olan alüminyum kazık üzerindeki gerilmeleri belirlemek için farklı derinliklere gerinim ölçerler (strain gauge) yerleştirilmiştir. Şile kumunun deney tankında aynı boşluk oranında ve uniform olarak yerleştirilmesi amacıyla yağmurlama sistemi tercih edilmiştir. Şekil 3a'da gösterilen yağmurlama düzeneginde, zeminden 2,1 m yükseklikte tekerlekli bir aksan üzerine monte edilen 0,9 m x 1,0 m x 0,8 m boyutlarındaki tank içinde kontrollü açılıp kapanan iki delikli plaka ve bunların altında 0,15 m aralıklarla yerleştirilmiş iki elek yer almaktadır. 1 mm aralıklı olan bu elekler yardımıyla kumun yerleşmesi sağlanmıştır.

Boyutları 0,70 m x 0,95 m x 0,80 m olan model deney tankı çelik profiller kullanılarak duvarları camdan imal edilmiştir. Kum yağmurlama düzenegi yardımıyla deney tankına yerleştirilmeden önce, alüminyum model kazık yükleme başlığı hizasında ve tank tabanından 90 mm yukarıda askıya alınarak sabitlenmiştir. Akabinde yağmurlama düzenegi ile deney tankı, kazık başında 50 mm kalıncaya kadar $Dr(\%)=70$ ve birim hacim ağırlığı (γ) 19 kN/m³ olacak şekilde kontrollü olarak sıkıştırılarak doldurulmuştur. Yükleme hazır olan deney tankı yükleme başlığı altında konumlandırılmıştır. Kazık yükleme deneyleri için kullanılan sistem kademeli yüklemeye elverişli olarak tasarlanmıştır. Deney başında yükleme adımlarını 0,04 kN, 0,08 kN, 0,12 kN, 0,16 kN ve 0,20 kN olarak

belirlenmiştir. Deney sistemi bu tanımlanan yükleri, model kazık üzerine imal edilen kazık başlığına 0,45 mm/dk olacak şekilde uygular. Her yükleme kademesi için tanımlanan yük değeri kazık başına uygulandıktan sonra yükleme sistemi servo motor yardımıyla bu yükü sabit tutar. Yükleme boyunca kazık başı hareketini ölçmek için kazık başına yer değiştirme ölçer konumlandırılmıştır (Şekil 3b). Uygulanan yük altında kazığın düşey oturması tamamlandıktan sonra kazık başı oturması (Δh) kaydedilmiş ve sonraki yükleme kademesine geçilmiştir. Deney aletinin yükleme aşamaları dikkate alındığında deneylerin gerilme kontrollü gerçekleştirildiğini söylemek mümkündür. Her yükleme kademesinde Omega SGK-B3A-K350U-PC11-E marka gerinim ölçerlerdeki okumalar veri toplama sisteminde kaydedilmiştir. Tüm yükleme kademelerinde uygulanan bu süreç sonunda yükleme adımları tamamlanmış ve yük- oturma eğrisi elde edilmiştir. Model deneylerin tekrarlanabilirliğini kontrol için deneyler tekrarlanmış ve benzer sonuçlar elde edilmiştir. Bu çalışma kapsamında tekrarlanan deney sonuçlarından sadece iki tanesi değerlendirilmiştir. Yapılan her deneyden sonra tank boşaltılarak tekrar doldurulmuş ve bütün deneylerde benzer koşulların oluşturulması sağlanmıştır.

Deneyler sırasında aksel yüklemeye ile birlikte kazıktaki aksel ve teğetsel doğrultudaki şekil değiştirmeleri belirlemek için tek sıra halinde kullanılan gerinim ölçerler (şekil değiştirme ölçerler), et kalınlığı 1,25 mm ve boyu 750 mm olan içi boş kazık üzerine alttan itibaren ilki kazık ucundan 35 mm yukarıda ve diğerleri 100 mm aralıklarla yerleştirilmiştir (Şekil 3b). Yükleme altında elastik olarak uzama ve kısalma hareketi yapan ve bilgisayar destekli veri toplama sistemine bağlı olan bu gerinim ölçerlerin çıktı verisi milivolttur. Yetkili firmadan temin edilen kalibrasyon verileri kullanılarak bu milivolt verileri aksel ve teğetsel şekil değiştirmelere dönüştürülmüştür.

Alüminyum kazık üzerine yapıştırılan gerinim ölçerlerin kalibrasyonu 60 mm çapında ve 1200 mm boyunda dairesel kesitli iki ucu kapalı cam hücre içerisinde gerçekleştirilmiştir (Şekil 4). Kazığın bir ucu cam hücreye sabitlendikten sonra cam hücre içerisine kademeli olarak basınç uygulanarak gerinim ölçerlerden okumalar alınmıştır. Yapılan kalibrasyon deneyleri göz önüne alındığında, gerilme kontrollü yapılan bu işlemler sonucunda kazığın E modülü (E) yaklaşık $4,35 \times 10^7$ kN/m² olarak belirlenmiştir.



Şekil 4. Kalibrasyon Deneylerinin Yapıldığı Cam Hücre Kesiti [Göçek (2001)]

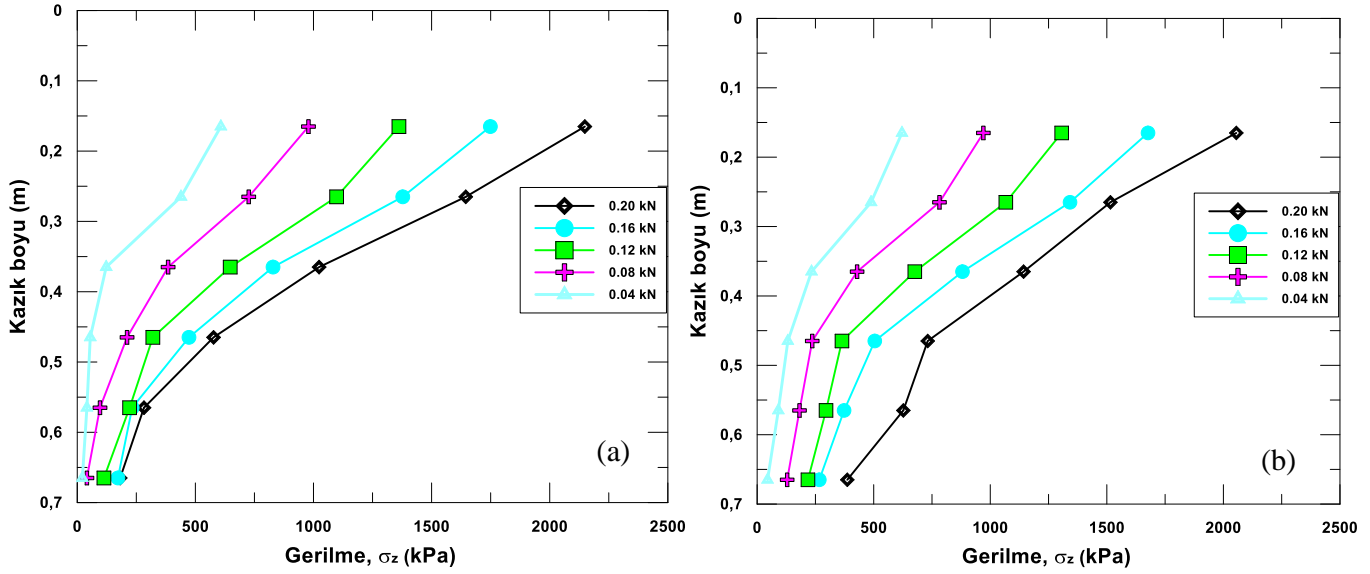
DEĞERLENDİRME VE TARTIŞMA

Model Kazık Boyunca Gerilmelerin Belirlenmesi

Deneyel çalışmalarda deney koşulları ve ölçüm ekipmanından kaynaklanan aksaklıklardan dolayı ölçüm hataları olasıdır. Bu çalışma kapsamında özellikle deneme deneylerinde bu durum açıkça görülmüş ve deneme deneylerinde aksaklıklar giderilerek hata oranı minimize edilmiştir. Bu çalışma kapsamında sunulan sonuçlar üzerinde belirli bir hata payının olduğunu göstermek için aynı koşullarda ve yükleme adımlarında gerçekleştirilen 2 deneye ait sonuçlar sunulmuştur.

E değeri $4,35 \times 10^7$ kN/m² olan bir kazığın gerinim ölçerlerden belirlenen aksel şekil değiştirme (ϵ_z) değerleri kullanılarak aksel gerilme (σ_z) değerleri Model Deney 1 (MD1) ve Model Deney 2 (MD2) için Eşitlik 1'den hesaplanmıştır. Fakat 1 nolu gerinim ölçerden anlamlı veri alınamadığı için sonuçları bu çalışma kapsamında değerlendirilmemiştir. Kademeli olarak 0,20 kN aksel yüke maruz kalan ve detayları Şekil 3b'de sunulan kazık başlık bölgesinden kazık kesitine aktarılan 2454 kPa değerinin derinlikle değişimi Şekil 5'te sunulmuştur. Deneyler sırasında alüminyum kazığa maksimum 0,20 kN yükleme yapılmıştır. Bu yükleme altında kazık yapısal olarak göçmemiş ve kazığın yapısal olarak göçtüğü yük değeri bu çalışma kapsamında belirlenmemiştir. Uygulanan maksimum 0,20 kN yük değeri de deneme deneyleri ve Chin (1970) yöntemi dikkate alınarak belirlenmiştir.

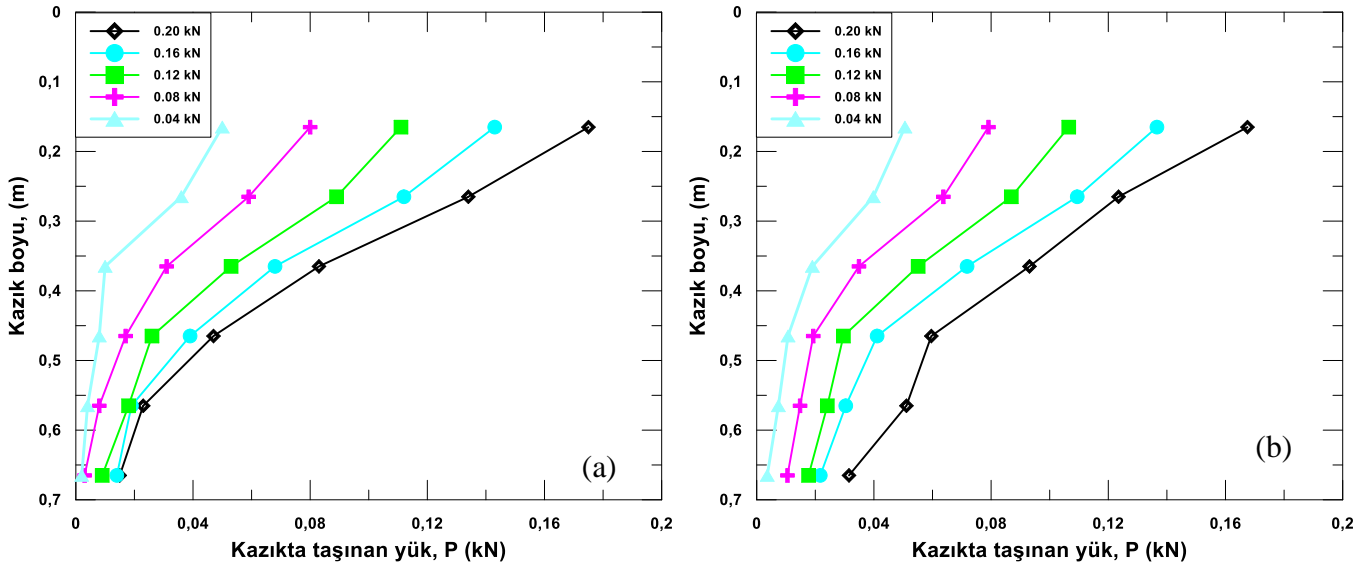
$$E = \frac{\sigma}{\epsilon} \quad (1)$$



Şekil 5. Eksenel Gerilmelerin Kazık Boyunca Değişimi a) MD1 b) MD2

Deneyler sırasında kazığın zemin içerisinde kalan kısmı zemin ile etkileşim halinde olduğundan dolayı kazık taşıdığı yükün bir kısmını bu etkileşim sonucu sürtünme ile zemine aktarır. Kazık-zemin sürtünmesi sonucu zemine aktarılan yük miktarı, sürtünen alan ve yanıl toprak basınçlarına bağlı olarak derinlikte artacaktır. Bu ara yüzey sürtünme mekanizması ile zemine aktarılan yük miktarı artmış ve kazık gövdesinde taşınan yük miktarı azalmıştır (Şekil 5).

Şekil 6'da MD1 ve MD2 için uygulanan yükün kazık boyunca değişimi sunulmuştur. Kazık-zemin ara yüzey sürtünmesi sonucu kazıktan zemine yük aktarımı olacağından kazık gövdesinde taşınan yük değeri kazık üst noktasından alt noktasına doğru azalmaktadır. Bu azalma miktarının derinlikle doğrusal olmayıp belirli bir derinlikten sonra değişimi oldukça sınırlıdır.



Şekil 6. Uygulanan Yükün Kazık Boyunca Değişimi a) MD1 b) MD2


Model Kazık Boyunca Gerilmelerin Belirlenmesi

Model deneylerden ölçülen gerinim değerleri kullanılarak kazık kesitindeki gerilmeler, Eşitlik 2'de ifade edilen ve elastisite teorisinde yer alan silindirik kabukların gerilme-şekil değiştirme ilişkisi kullanılarak hesaplanmıştır. Eşitlikte radyal şekil değiştirmeler ihmal edilirse;

$$\sigma_z = \frac{E}{[(1+\nu) \times (1-2\nu)]} \times [(1-\nu) \times \epsilon_z + \nu \times \epsilon_\phi] \quad (2)$$

Eşitlik 2'de ν poisson oranı, ϵ_z eksenel şekil değiştirme ve ϵ_ϕ teğetsel şekil değiştirmeyi ifade etmektedir.

Alüminyum kazık için v değeri 0,33 ve E değeri $4,35 \times 10^7$ kN/m² alınarak gerilmeler hesaplanmıştır. MD1 ve MD2'ye ait beş farklı yükleme kademesi için Eşitlik 2 kullanılarak elde edilen σ_z değerlerinin kazık boyunca değişimi Şekil 7'de sunulmuştur.



Şekil 7. Ampirik Eşitlikle Belirlenen σ_z 'nin Kazık Boyunca Değişimi a) MD1 b) MD2

Kalibrasyon deneylerinden belirlenen E kullanılarak MD1 ve MD2 için kazık boyunca hesaplanan düşey gerilme ile Eşitlik 2'den hesaplanan düşey gerilmeler Tablo 4'te sunulmuştur.

Tablo 4. Kazık Boyunca Oluşan Düşey Gerilmelerin Kazık Boyunca Değişimi


Yük (kN)	Derinlik (m)	Gerinim Ölçer No	MD1 σ_z (kPa)	MD2 σ_z (kPa)	Eşitlik 2 σ_z (kPa)
0,20	0,065	1	-	-	-
	0,165	2	2149	2055	1441
	0,265	3	1644	1516	965
	0,365	4	1064	1123	595
	0,465	5	597	702	403
	0,565	6	327	283	317
	0,665	7	182	187	271

Kazık tarafından taşınan yük miktarı için MD1 ve MD2'den elde edilen gerilme değerleri (gerinim ölçer 7 dışında) Eşitlik 2'den belirlenenlerden daha büyüktür. Özellikle model deneylerden ölçülen ve Eşitlik 2'den hesaplanan gerilme değerleri arasında %40'lara varan önemli farklılıklar gözlemlenmiştir. Bu durum elastisite teorisindeki silindirik kabukların gerilme-şekil değiştirme ilişkisinin eksenel yüklü kazıklarda anlamlı sonuçlar vermediğini göstermektedir.


Model Kazık İçin Yük-Oturma Eğrisinin Değerlendirilmesi

Laboratuvar model kazık yükleme deneyinde 0,20 kN eksenel yüklemeye maruz kalan MD1 ve MD2 için ortalama değerleri yük-oturma eğrisi Şekil 8'de sunulmuştur. Bu yük-oturma eğrisi için Tablo 1'deki yöntemler kullanılarak kazık taşıma kapasitesi (Q_{ult}) hesaplanmıştır. Davisson yöntemi deplasman kontrollü bir yöntem olduğu için bu çalışma kapsamında hesaplamalara dahil edilmemiştir. Q_{ult} değerinin belirlenmesi için uygulanan tüm yöntemlerin hesaplama adımlarını detaylandırmak yerine, matematiksel yöntemlerden ve grafiksel yöntemlerden sadece biri için hesaplama adımları sunulmuştur.

Chin (1970) yönteminde, sabit yük (Q) kademesinde ölçülen kazık oturmasının o yükleme kademesindeki Q değerine bölünerek $\Delta h/Q$ ve Δh grafiği çizilir. Grafiği oluşturan noktalar, belirli bir kısımdan sonra doğrusallaşır. Bu doğrunun eğiminin (C_1) tersi ($1/C_1$) kazık taşıma kapasitesini verir. Özellikle bu doğrunun eğimi sabit olduğundan yükleme deneyinin tamamlanması beklenilmeden kazık taşıma kapasitesinin hesaplanabilir. Fakat Chin (1970) yönteminin diğer yöntemlere göre daha büyük taşıma kapasiteleri verdiği de bilinmektedir (Dalkılıç 2020). Bundan dolayı deney sonuçlarından belirlenen kazık taşıma kapasitesinin genel kabul gören farklı yöntemlerle kontrol edilmesi gerekir. Şekil 8'deki yük oturma eğrisine Chin (1970) yönteminin uygulanması sonucu belirlenen kazık taşıma kapasitesi Şekil 9'da sunulmuştur.




Şekil 8: Ortalama Değerleri İçin Elde Edilen Yük-Oturma Eğrisi



Şekil 9: Chin (1970) Yöntemi İle Nihai Kazık Taşıma Yükünün Belirlenmesi

SM yükleme türü olan ve De Beer (1972) tarafından önerilen yöntemde yük - oturma grafiği, çift eksenli logaritmik ölçekte olacak şekilde çizilir. Bu egrideki ölçüm noktalarının birleştirilmesi ile eğimleri farklı olan iki doğru elde edilir. Bu iki doğrunun kesiştiği noktaya karşılık gelen yük değeri, kazığın taşıma kapasitesidir. Şekil 8'e De Beer (1972) yönteminin uygulanması ile belirlenen kazık taşıma kapasitesi Şekil 10'da sunulmuştur.



Şekil 10. De Berr (1972) Yöntemine Göre Kazık Taşıma Kapasitesinin Belirlenmesi

0,20 kN eksenel yüklemeye maruz kalan kazık için yük-oturma eğrisi için farklı yöntemler dikkate alınarak belirlenen kazık taşıma kapasiteleri Tablo 5'te özetlenmiştir.

Tablo 5. Farklı Yöntemlerden Belirlenen Nihai Kazık Taşıma Yüğü

Chin (1970)	De Beer (1972)	Brinch-Hansen (1963)	Teğet yöntemi	Mazurkiewicz (1972)
0,256 kN	0,185 kN	0,160 kN	0,170 kN	0,225 kN

Elde edilen sonuçlar karşılaştırıldığında Chin (1970) yöntemi ile belirlenen kazık taşıma kapasitesi en büyük olurken, en düşük değer Brinch-Hansen (%90) yönteminden elde edilmiştir. Bu sonuçların Şekil 1 ve Tablo 1 ile uyumlu olduğu görülmektedir. Benzer sonuçlar farklı araştırmacılar tarafından gerçekleştirilen arazi deneylerinden ve sayısal analizlerden de elde edilmiştir [Ünküp (2024), Pulat (2024)].

Kazık Çevresinde Taşınan Yüğüün Hesaplaması

Model kazık üzerine yerleştirilen gerinim ölçerlerin konumu ve kazığa etkiyen yanal toprak basınç dağılımı için zeminden kazığa etkiyen yanal toprak basınçları 15D kritik derinliği dikkate alınarak çizilmiştir. Bu gerilme dağılımında kazık çevresinde 15D mesafede çevre sürtünmesi ile taşınan yük miktarı Q_{s1} ve 15D mesafesinden sonra taşınan yük miktarı Q_{s2} olarak adlandırılmıştır. Bu değerler Tablo 2'de özetlenen δ değerleri kullanılarak Eşitlik 3'ten hesaplanmıştır. Hesaplamalarda K değeri 1.4 olarak dikkate alınmıştır. Genellikle kazık türü ve kazığın zemine yerleştirilme yöntemine göre değişkenlik gösteren bu K değeri, NAVFAC (1988) tarafından önerilen değerlerle uyumludur.

$$\Sigma p. \Delta L. K. \sigma'_v \tan(\delta) \quad (3)$$

Kritik derinlik kullanılarak hesaplanan kazığın çevresinde taşınan yük değeri $\delta=28^\circ$ $Q_s = Q_{s1} + Q_{s2} = 0,1753$ kN olarak hesaplanmıştır. Bu değer Şekil 6'daki verilerle uyumludur.

SONUÇLAR

Bu çalışma kapsamında küçük boyutlu alüminyum bir kazığın taşıma kapasitesinin laboratuvar model kazık yükleme deneyleri ile belirlenmesine yönelik bir çalışma gerçekleştirilmiştir. Boyut etkisi göz ardı edilerek elde edilen sonuçlar aşağıda özetlenmiştir.

- ❖ Zemin ile yapı arasında sürtünmenin olduğu durumlarda δ değerinin ampirik eşitlikler yerine, laboratuvar deneyleriyle belirlenmesi daha gerçekçi tasarımların yapılmasına olanak sağlayacaktır.
- ❖ Kalibrasyon deneylerinden belirlenen E değeri kullanılarak model deneyler için kazık kesitindeki düşey gerilmeler ile Eşitlik 2'den belirlenen düşey gerilmeler arasında %40'lara varan farklılıklar elde edilmiştir. Kazık-zemin sürtünmesi ile zemine aktarılan gerilmelerden dolayı kazık kesitindeki düşey gerilmeler MD1, MD2 ve Eşitlik 2 için kazık başından kazık alt noktasına doğru azalmıştır. Fakat yükün mobilize olduğu derinlikler arasında farklılıklar tespit edilmiştir.
- ❖ Arazi kazık yükleme deneylerinden elde edilen yük-oturma ilişkisini dikkate alarak kazığın taşıma kapasitesini belirleyen yöntemler laboratuvar model kazık deneyleri için uygulanmış ve Chin (1970) yöntemi dışında yaklaşık birbirine yakın sonuçlar elde edilmiştir.
- ❖ Kesme kutusu deneylerinden belirlenen δ ve kritik derinlik kavramı kullanılarak kazığın çevresinde taşınan yük değeri hesaplanmış ve elde edilen sonuçların MD1 ve MD2 ile uyumlu olduğu görülmüştür.
- ❖ Kazık yükleme deneylerinin yapılamadığı durumlarda kazık davranışını ve kazık-zemin ara yüzey sürtünmesini öngörmek için arazi zemin koşulları ve boyut etkisi dikkate alınarak laboratuvar model kazık deneyleri ile incelenmesi tavsiye edilmektedir.

KAYNAKLAR

American Society of Civil Engineers. (1993). *Design of pile foundations technical engineering and design guides*. ASCE.

Baca, M., & Rybak, J. (2018). A first result of pipe pile static load test in small laboratory scale. *E3S Web of Conferences*, 251. <https://doi.org/10.1051/e3sconf/201825100001>

Baca, M., Lesny, J., Al-Khoury, R., & Wiczorek, M. (2019). Assessing the pile base capacity from a static load test on model piles. *E3S Web of Conferences*, 97. <https://doi.org/10.1051/e3sconf/20199700011>

- Beer, E. E., & Wallays, M. (1972). Franki piles with overexpanded bases. *La Technique des Travaux*, 333.
- Bowles, J. E. (1997). *Foundation analysis and design* (5th ed.). McGraw-Hill.
- Broms, B. B. (1981). *Precast piling practice*. Thomas Telford Ltd.
- Cerato, A., & Lutenegeger, A. (2006). Specimen size and scale effects of direct shear box tests of sands. *Geotechnical Testing Journal*, 29(6), 507–516. <https://doi.org/10.1520/GTJ100486>
- Chin, F. K. (1970). Estimation of the ultimate load of pile not carried to failure. In *Proceedings of the 2nd Southeast Asian Conference on Soil Engineering* (pp. 81–90). Singapore.
- Dalkılıç, B. (2020). *Göçme durumuna ulaşmamış kazık yükleme deneylerinde nihai kazık taşıma kapasitesinin belirlenmesi* [Master's thesis, İstanbul Teknik Üniversitesi / Fen Bilimleri Enstitüsü].
- Das, B. M. (2007). *Principles of foundation engineering* (6th ed.). Thomson Canada Limited.
- Davisson, M. T. (1972). High capacity piles. In *Proceedings of Lecture Series on Innovations in Foundation Construction* (pp. 81–112). American Society of Civil Engineers, Chicago.
- Department of the Navy. (1988). *NAVFAC Design Manuals 7.1 and 7.2: Foundations and earth structures*. Alexandria, VA.
- Fellenius, B. H. (2004). Unified design of piled foundations with emphasis on settlement analysis. In *Geo-Trans Conference Proceedings* (pp. 253–275). Geo-Institute, Los Angeles.
- Fleming, W. G. K., Weltman, A. J., Randolph, M. F., & Elson, W. K. (2009). *Piling engineering* (3rd ed.). Taylor & Francis.
- Göçek, H. (2001). *Kazıkların eksenel yük taşıma kapasiteleri* [Master's thesis, Yıldız Teknik Üniversitesi].
- Hansen, J. B. (1963). Hyperbolic stress-strain response of cohesive soils. *Journal of the Soil Mechanics and Foundations Division, ASCE*, 89(1).
- Kishida, T., & Yoshimi, Y. (1981). A ring torsional apparatus for evaluations of friction between soil and metal surface. *Geotechnical Testing Journal*, 4(4), 145–152. <https://doi.org/10.1520/GTJ10909J>
- Kulhavy, F. H. (1984). Limiting tip and side resistance—Fact or fallacy. In I. R. Meyer (Ed.), *Analysis and design of pile foundation* (pp. 80–88). ASCE.
- Mazurkiewicz, B. K. (1972). Test loading of piles according to Polish regulations. *Royal Swedish Academy of Engineering Sciences Commission on Pile Research*, Stockholm.
- Potyondy, J. G. (1961). Skin friction between various soils and construction materials. *Geotechnique*, 11(4), 339–353. <https://doi.org/10.1680/geot.1961.11.4.339>
- Pulat, Ö. (2024). *Kazık taşıma kapasitesinin statik formüller, nümerik analiz ve yükleme deneyleri kullanılarak belirlenmesi üzerine bir çalışma* [Master's thesis, İstanbul Teknik Üniversitesi / Fen Bilimleri Enstitüsü].
- Rybak, J., & Krol, M. (2018). Limitations and risk related to static capacity testing of pile—Unfortunate case studies. *MATEC Web of Conferences*, 146. <https://doi.org/10.1051/mateconf/201714600001>
- Samanta, M., Hazarika, H., & Yasufuku, N. (2018). Effect of roughness on interface shear behavior of sand with steel and concrete surfaces. *Geomechanics and Engineering*, 14(4), 387–398. <https://doi.org/10.12989/gae.2018.14.4.387>
- Terzaghi, K., & Peck, R. B. (1948). *Soil mechanics in engineering practice*. John Wiley & Sons.
- Tiwari, B., & Al-Adhahd, M. (2014). Influence of relative density on static soil-structure frictional resistance of dry and saturated sand. *Geotechnical and Geological Engineering*, 32(2), 411–427. <https://doi.org/10.1007/s10706-013-9720-4>
- Toğrol, E. (1970). *Kazıklı temeller*. Temel Araştırma A.Ş. Yayınları No. 1. İstanbul.
- Tomlinson, M. J. (2004). *Pile design and construction in practice*. E & FN Spon.
- Tomlinson, M., & Woodward, J. (2006). *Pile design and construction practice* (5th ed.). CRC Press.
- U.S. Department of Navy. (1986). *NAVFAC Engineering Manual (EM 7.02)*.

- Ünküp, L. (2024). *Vida kazık kapasitelerinin arazi deneyleri ve sayısal analizlerle belirlenmesi* [Master's thesis, Yıldız Teknik Üniversitesi].
- Yankı, O. (2015). *İki yönlü statik yükleme deneyi ve nümerik analizlerle kazık davranışının incelenmesi* [Master's thesis, İstanbul Teknik Üniversitesi].
- Yenginar, Y. (2014). *Kazıklı temellerde grup etkisinin model deneylerle araştırılması* [Master's thesis, Selçuk Üniversitesi].



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 07.11.2024
Kabul Tarihi : 31.01.2025

Received Date : 07.11.2024
Accepted Date : 31.01.2025

FORECASTING ENERGY DEMAND IN TURKEY USING DIFFERENT METAHEURISTIC METHODS: A COMPARATIVE STUDY

TÜRKİYE'DE ENERJİ TALEBİNİN FARKLI METASEZGİSEL YÖNTEMLER KULLANILARAK TAHMİNİ: KARŞILAŞTIRMALI BİR ÇALIŞMA

Taner SEVMİŞ¹ (ORCID: 0000-0003-0034-4252)
Rasim ÇEKİK^{1*} (ORCID: 0000-0002-7820-413X)

¹ Şırnak Üniversitesi, Bilgisayar Mühendisliği Bölümü, Şırnak, Türkiye

*Sorumlu Yazar / Corresponding Author: Rasim ÇEKİK, rasimcekik@sirnak.edu.tr

ABSTRACT

Energy demand forecasting plays a crucial role in shaping energy policies, particularly for countries like Turkey that experience rapid industrialization and urbanization. Accurately predicting energy demand helps to ensure energy supply security and to guide strategic investments, especially in transitioning towards renewable energy sources. This study explores the use of modern metaheuristic optimization methods to forecast Turkey's energy demand up to the year 2035, focusing on the effectiveness of various techniques in addressing this complex, multi-dimensional problem. The dataset used spans from 1979 to 2011 and includes economic and demographic indicators such as GDP, population, imports, and exports, which are key drivers of energy demand. Several metaheuristic algorithms, including The African Vultures Optimization Algorithm (AVOA), Grey Wolf Optimizer (GWO), Whale Optimization Algorithm (WOA), and Dynamic Bayesian Optimization (DBO), were applied to this dataset. A comparative analysis of these methods demonstrated that AVOA, GWO, DBO, and other similar approaches yielded the most accurate predictions, with minimum total error rates. The analysis revealed that the AVOA method outperformed other methods in terms of accuracy and computational efficiency by obtaining the lowest total error of 0.2391 and relative error percentage of 0.3565. The study highlights the significant role metaheuristic approaches play in improving the accuracy of energy demand forecasts and informs future policy decisions by identifying critical factors affecting Turkey's energy consumption patterns. The findings are expected to contribute to more effective long-term energy planning and the development of sustainable energy policies.

Keywords: Energy demand, Turkey, metaheuristic, optimization

ÖZET

Enerji talebi tahmini, özellikle hızlı sanayileşme ve kentleşme yaşayan Türkiye gibi ülkelerde enerji politikalarının şekillendirilmesinde kritik bir rol oynamaktadır. Enerji talebinin doğru bir şekilde tahmin edilmesi, enerji arz güvenliğinin sağlanmasına ve yenilenebilir enerji kaynaklarına geçişte stratejik yatırımların yönlendirilmesine yardımcı olur. Bu çalışma, Türkiye'nin 2035 yılına kadar olan enerji talebini tahmin etmek amacıyla modern metasezgisel optimizasyon yöntemlerinin kullanımını araştırmakta ve bu karmaşık, çok boyutlu problemi ele almadaki etkinliklerini incelemektedir. Çalışmada, 1979-2011 yıllarını kapsayan ve GSYH, nüfus, ithalat ve ihracat gibi enerji talebinin temel belirleyicilerini içeren bir veri seti kullanılmıştır. Bu veri seti üzerinde Afrika Akbabalaları Optimizasyon Algoritması (AVOA), Gri Kurt Optimizasyonu (GWO), Balina Optimizasyon Algoritması (WOA) ve Dinamik Bayes Optimizasyonu (DBO) gibi çeşitli metasezgisel algoritmalar uygulanmıştır. Karşılaştırmalı analiz sonuçları, AVOA, GWO, DBO ve benzeri yaklaşımların en düşük toplam hata oranlarıyla en doğru tahminleri sağladığını göstermektedir. Analizler, AVOA metodunun 0,2391 ile en düşük toplam hatayı ve 0,3565 bağlı hata yüzdesini elde ederek doğruluk ve hesaplama verimliliği açısından diğer yöntemlerden daha iyi performans gösterdiğini ortaya koymuştur. Çalışma, enerji talebi tahminlerinde metasezgisel yaklaşımların önemli bir rol oynadığını vurgulamakta ve Türkiye'nin enerji tüketim eğilimlerini etkileyen kritik faktörleri belirleyerek

ToCite: SEVMİŞ, T., & ÇEKİK, R., (2025). FORECASTING ENERGY DEMAND IN TURKEY USING DIFFERENT METAHEURISTIC METHODS: A COMPARATIVE STUDY. *Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences*, 28(1), 441-459.

gelecekteki politika kararlarına ışık tutmaktadır. Bulgular, uzun vadeli enerji planlamasının daha etkili hale getirilmesine ve sürdürülebilir enerji politikalarının geliştirilmesine katkı sağlamayı amaçlamaktadır.

Anahtar Kelimeler: Enerji talebi, Türkiye, metasezgisel, optimizasyon

INTRODUCTION

Energy demand is directly related to economic growth, demographic changes, and the social structure of countries, and it is shaped by the influence of various complex factors. Population growth, urbanization, technological progress, and improvements in living standards are the main factors driving increased energy consumption. In developing countries, rapid population growth and economic development lead to significant increases in energy demand, while in developed countries, technology-based production processes in the industrial and service sectors play a decisive role in energy consumption. In this context, in developing countries such as Turkey, energy demand is continuously increasing alongside urbanization and industrialization processes. Not only is the amount of energy demand changing, but so is the diversity of energy sources. While interest in renewable energy sources is increasing in line with sustainable development goals, the share of fossil fuels in the energy portfolio tends to decrease. However, this transition process occurs at different speeds depending on countries' infrastructure capacities and energy supply security policies. Turkey is accelerating the transition from fossil fuels to renewable resources to meet its energy needs, prioritizing investments in solar, wind, hydroelectric, and nuclear energy. According to World Energy Outlook, global energy demand will continue to rise until 2030 (Agency, 2009; Bilgen, Kaygusuz, and Sari, 2004). The growth rate of energy demand in developing countries is higher than in developed countries. Turkey's young population, rapid urbanization, and industrialization are gradually increasing the country's energy demand, which poses challenges for energy supply security. Therefore, accurately forecasting energy demand and making strategic plans accordingly are fundamental elements of energy policies (Sonmez, Akgüngör, and Bektaş, 2017).

The use of modern methods in energy demand forecasting is of great importance for maintaining the balance between energy supply and demand, as well as achieving high accuracy in long-term planning. In Turkey, official energy demand forecasts have been conducted by institutions such as the Ministry of Energy and Natural Resources, the Turkish Statistical Institute, and the State Planning Organization since 1984 (Ediger and Tatlıdil, 2002). However, the literature on this subject presents various approaches that have been developed and applied to forecast energy demand. Initially, statistical methods were preferred, but over time, more advanced techniques such as artificial neural networks and metaheuristic optimization techniques have emerged in energy demand forecasting. Metaheuristic optimization methods offer effective solutions for complex and multi-dimensional energy demand problems. The problem-independent nature of these methods makes them easily adaptable to various challenges, such as energy demand forecasting. Particularly in Turkey, the use of modern metaheuristic algorithms to accurately predict energy demand plays a strategic role in ensuring the balance between energy supply and demand. Energy demand forecasting is essential for balancing energy supply and demand and achieving sustainable development goals.

This study focuses on the critical application of metaheuristic methods to improve forecasting accuracy for Turkey's energy demand. The main objectives are to evaluate the effectiveness of various modern optimization techniques, identify key influencing factors, and provide actionable insights for sustainable energy policy planning. For example, the transition to renewable energy sources in Turkey highlights the importance of accurate forecasting methods. Moreover, this study aims to analyze the performance of different metaheuristic optimization approaches in forecasting Turkey's energy demand up to the year 2030. By conducting a comparative evaluation of several recently proposed metaheuristic methods, critical parameters that contribute to the accurate prediction of energy demand have been identified. The study is based on energy demand data provided by the Ministry of Energy and Natural Resources (MENR) and the Turkish Statistical Institute (TÜİK), covering the period from 1979 to 2011 (Erdogdu, 2007; Koç, Nureddin, and Kahramanlı, 2018). This dataset serves as a comprehensive resource for analyzing past trends in energy consumption and projecting future scenarios. Various metaheuristic approaches were applied to this dataset to test the accuracy and effectiveness of the forecasting models (Bulut and Yıldız, 2016; Kaur, Awasthi, Sangal, and Dhiman, 2020). The methods included in this study are widely used techniques in optimization problems, yielding successful results in solving multi-dimensional and complex issues. These approaches offer significant advantages in terms of flexibility and accuracy in the modeling process for energy demand forecasting. The results obtained highlight which methods are more effective in energy forecasting and which parameters play a critical role in this process, thereby providing valuable insights to inform future energy policies.

The remainder of this paper is organized as follows: Section 2 offers a comprehensive review of related work. Section 3 discusses existing metaheuristic approaches. Section 4 presents the experimental results. Finally, Section 5 provides conclusions and discusses the implications of the findings.

RELATED WORKS

This section provides a comprehensive review of previous works in energy demand forecasting using metaheuristic techniques, including applications of Genetic Algorithms (GA), Particle Swarm Optimization (PSO), and the Grey Wolf Optimizer (GWO). Comparative analysis of these methods demonstrates their respective strengths and applicability to specific forecasting challenges.

Energy demand forecasting is a critical topic in energy management and planning, essential for balancing energy production and consumption. In addition to traditional methods, the use of metaheuristic optimization techniques has gained significant prominence in this field in recent years. This section reviews key studies from existing literature on the application of metaheuristic methods in energy demand forecasting (Özdemir and Dörterler, 2022; Özdemir, Dörterler, and Aydın, 2022).

Tiris (2005) presents significant findings on Turkey's energy demand forecasts. The study projects that Turkey's annual energy demand will increase by 1.7% between 2002 and 2030. Based on 2012 data, Turkey's total primary energy demand was recorded as 121 MTEP, with the majority of this demand being met by fossil fuels. Turkey meets 70% of its energy demand through imports, a situation that raises concerns regarding energy security. The author emphasizes the importance of accurately forecasting energy demand to mitigate potential issues that may arise during the development and industrialization process. Additionally, various studies demonstrate the need for employing different methods to accurately forecast Turkey's energy demand. References (Dilaver and Hunt, 2011; Ediger and Akar, 2007; Kankal, Akpınar, Kömürcü, and Özşahin, 2011; Yumurtaci and Asmaz, 2004) discuss the use of statistical techniques, while references (Biçer, 2017; Es, Kalender Öksüz, and Hamzacebi, 2014; Sözen, Arcaklioğlu, and Özkaymak, 2005) provide examples of artificial neural networks techniques being applied to energy demand forecasting. References (Kıran, Özceylan, Gündüz, and Paksoy, 2012; Salcedo-Sanz, Muñoz-Bulnes, Portilla-Figueras, and Del Ser, 2015; Sánchez-Oro, Duarte, and Salcedo-Sanz, 2016; Uguz, Hakli, and Baykan, 2015) highlight the use of heuristic techniques, particularly in engineering applications, noting that population-based heuristic algorithms can provide quick solutions through multi-point procedures. Moreover, several modern methods have been proposed in this field. One of them is Genetic Algorithms (GA), introduced by Holland (1992), which is based on a population-driven approach and optimizes solutions through evolutionary processes. Dorigo (2007), inspired by the natural behavior of ant colonies, developed the Ant Colony Optimization (ACO) algorithm, which demonstrates effective performance, particularly in combinatorial optimization problems.

Kennedy and Eberhart (1995) developed Particle Swarm Optimization (PSO), an algorithm that models the social behaviors of swarms to search for solutions. This algorithm is widely used in energy demand forecasting due to its ability to provide quick solutions to complex problems with a low number of parameters.

(Corne et al., 1999; Kunkle et al., 2019) addressed high-dimensional, non-linear, and multi-objective optimization problems, emphasizing their importance in various industries, such as manufacturing, economics, healthcare, and transportation. The authors pointed out that traditional optimization methods fail to meet the complexity of these problems, leading to the broader application of metaheuristic algorithms.

Beheshti and Shamsuddin (2013) noted that nature-inspired metaheuristic algorithms find widespread application across various domains. The authors demonstrated that algorithms based on biological behaviors are particularly effective in solving problems with multiple extremum features.

Agarwal and Kumar (2022) conducted a comprehensive review of the Bat Algorithm (BA) and discussed its use in biological applications and optimization problems. Similarly, (Kar, 2016) evaluated the general principles, development processes, and application areas of biologically inspired algorithms.

Ezugwu et al. (2021) explored the impact of metaheuristic algorithms, particularly on clustering algorithms, and presented trends and advances in the field through a systematic review and bibliometric analysis. Such studies contribute to the growing use of metaheuristic algorithms in energy demand forecasting.

Finally, (Guo, Tang, Niu, and Lee, 2021) conducted a bibliometric review of the Bacterial Foraging Optimization (BFO) algorithm, offering an in-depth analysis of its information structures, research collaborations, and application areas. The study highlights the potential of such algorithms in energy demand forecasting.

Table 1. Characteristics of Commonly Employed Metaheuristic Methods

Article	Method	Population Based	Global Optimization	Local Optimization	Fast Convergence	Parameter Sensitivity	Multi-objective Optimization	Energy Data Utilisation	Description
(Karaboga and Basturk, 2008)	Artificial Bee Colony (ABC)	✓	✓	✓	✓	✓	✓	✓	The artificial bee colony-based algorithm optimizes by direct interaction of the population.
(Guo et al., 2021; Passino, 2012)	Bacterial Foraging Optimization (BFO)	✓	✓	✓	✓	✓	✗	✓	It performs optimization by simulating bacterial movement and feeding processes.
(Agarwal and Kumar, 2022; Yang and He, 2013)	Bat Algorithm (BA)	✓	✓	✓	✓	✓	✗	✓	Based on the bat echolocation principle, it provides fast and flexible analyses.
(Kennedy and Eberhart, 1995)	Particle Swarm Optimization (PSO)	✓	✓	✗	✓	✓	✓	✓	It is based on a social interaction model that optimizes solutions through the movement of particles.
(Sarzaeim, Bozorg-Haddad, and Chu, 2018)	Teaching-Learning-Based Optimization (TLBO)	✓	✓	✓	✓	✗	✓	✓	A parameter-free optimization method based on a learning and teaching process.
(Yang and Slowik, 2020)	Firefly Algorithm (FA)	✓	✓	✓	✓	✓	✗	✓	Optimizes the attractiveness of fireflies according to their light intensity.
(Feoktistov, 2006)	Differential Evolution (DE)	✓	✓	✓	✓	✓	✓	✓	It optimizes by mutation and crossover between different solutions.
(Bertsimas and Tsitsiklis, 1993)	Simulated Annealing (SA)	✗	✓	✓	✗	✓	✗	✓	It seeks global optimization with temperature decrease but has slow convergence.
(Holland, 1992)	Genetic Algorithms (GA)	✓	✓	✓	✓	✓	✓	✓	Based on evolutionary processes, it generates multiple solutions through populations.
(Gendreau, 2003)	Tabu Search (TS)	✗	✓	✓	✗	✓	✗	✓	Guided local search algorithm with memory structures.
(Dorigo, 2007)	Ant Colony Optimization (ACO)	✓	✓	✓	✓	✓	✗	✓	It is based on the discovery of solutions by swarms of ants leaving a trail.
(Resende and Ribeiro, 2016)	GRASP	✓	✓	✓	✓	✓	✗	✓	It uses short-time refinement and a randomized heuristic search strategy.
(Wilson, Pallavi, Ramachandran, Chinnasamy, and Sowmiya, 2022)	Memetic Algorithms (MA)	✓	✓	✓	✓	✓	✓	✓	Combines local research with genetic algorithms; population co-operative resolution.

A comprehensive review by Li et al. (2024) addressed the historical development and fundamental principles of metaheuristic optimization methods. The authors categorized metaheuristic methods and emphasized their ability to enhance problem-solving capabilities. In particular, the applications of popular metaheuristic methods such as

Artificial Bee Colony (ABC), Genetic Algorithms (GA), and Particle Swarm Optimization (PSO) in energy demand forecasting were detailed. The study also compared the performance of these methods and discussed which scenarios they might be more effective for. ABC, for instance, draws inspiration from natural systems and finds solutions based on the interactions between individuals, while GA offers population-based approaches, and PSO optimizes solutions through social interactions. The effectiveness of these methods in energy demand forecasting has been supported by experiments on real-world datasets.

Martí, Sevaux, and Sörensen (2024) examined the applications of next-generation metaheuristic methods in the energy sector. The authors assessed the potential of metaheuristic algorithms to improve energy efficiency, presenting a comparative performance analysis of both classical and innovative hybrid methods. Particular attention was given to the effectiveness of Tabu Search (TS) and Ant Colony Optimization (ACO) in energy demand forecasting. The findings showed ACO's ability to find optimal paths while exploring the solution space, and TS's use of memory structures to optimize solutions based on previously discovered solutions. The authors concluded that these methods play a crucial role in improving the accuracy of energy demand forecasting.

In another comprehensive review, Martín-Santamaría, López-Ibáñez, Stützle, and Colmenar (2024) explored the development of metaheuristic approaches and their application in various fields. The study underscored the problem-independent nature of metaheuristic algorithms and their ability to guide the development of problem-specific heuristic optimization techniques. The authors provided examples of how metaheuristic approaches can be applied to large-scale energy systems and summarized the key contributions from literature. The study also highlighted the strengths and weaknesses of metaheuristic methods, offering recommendations to guide future research in this area. Table 1 presents the comparative characteristics of some commonly used metaheuristics.

In conclusion, while the studies show the effectiveness of metaheuristics in energy demand forecasting, they also suggest that these techniques should be investigated more comprehensively in future research. In particular, combinations of different metaheuristic algorithms and the development of new approaches can contribute to better results in energy management. Moreover, it is important to continuously update and optimize the algorithms considering the current data sets and changing energy dynamics. In this context, the benefits and application potential of metaheuristic optimization techniques in energy demand forecasting have been further reinforced by important studies in the literature. These studies clearly demonstrate the contributions of metaheuristics in achieving energy efficiency and sustainability goals.

METAHEURISTIC METHODS

Metaheuristic algorithms have emerged as a crucial tool for solving complex optimization problems. These nature-inspired methods possess the capability to effectively address high-dimensional and multi-objective problems (Akter et al., 2024; Güven, Yörükeren, Tag-Eldin, and Samy, 2023; Pamuk, 2024). In this section, commonly used metaheuristic approaches in experimental studies. After giving detailed information about AVOA, GWO and BWOA methods, a summary information table is presented for the others.

African Vultures Optimization Algorithm (AVOA)

The African Vultures Optimization Algorithm (AVOA) is a novel metaheuristic algorithm inspired by the behavior of African vultures during their search for food (Abdollahzadeh, Gharehchopogh, and Mirjalili, 2021). The algorithm simulates the vultures' foraging strategies, navigation, and interactions with each other to solve complex global optimization problems. AVOA is designed to balance between exploration (searching new solutions) and exploitation (refining known solutions) by mimicking vultures' ability to navigate large areas and compete for limited resources.

AVOA was tested on 36 benchmark functions and several engineering design problems, and it demonstrated superior performance compared to other algorithms like Genetic Algorithm (GA), Whale Optimization Algorithm (WOA), and Grey Wolf Optimizer (GWO). The performance was evaluated based on various criteria such as the average solution quality, best and worst solutions, and convergence speed.

- **Vulture Movement Equations:** The vultures' movement is based on their proximity to the best solutions found so far. Vultures move towards the best vulture using the following equations:

$$P(i + 1) = R(i) - D(i)x_F \quad (1)$$

where, $P(i + 1)$ is the position of the vulture in the next iteration and $R(i)$ is the current best solution. $D(i) = |X * R(i) - P(i)|$ represents the distance between the vulture and the best solution and F is the satiation factor of the vultures.

- Satiation Factor F : The algorithm transitions between exploration and exploitation based on the vultures' "satiation" levels. The satiation factor F is modeled as:

$$F = (2 * rand1 + 1) * z * \left(1 - \frac{iteration}{max\ iteration}\right) + t \quad (2)$$

where, $rand1$ is a random number between 0 and 1, z is a random number between -1 and 1, t is a disturbance term that helps balance exploration and exploitation.

- Levy Flight Model: The vultures use Levy flights to enhance their exploration capabilities, especially when searching for new solutions. The Levy flight is modeled as:

$$LF(x) = 0.01 * \frac{\mu * \sigma}{|v|^{1/\beta}} \quad (3)$$

where, μ and v are random numbers, β is a constant (usually 1.5), σ is a scaling factor based on β .




Figure 1. (a) Example of Overall Vectors in the case of Competition for Food, (b) Example of Overall Vectors in the case of Aggressive Competition for Food (Abdollahzadeh et al., 2021)

Grey Wolf Optimizer (GWO)

The Grey Wolf Optimizer (GWO) algorithm is a metaheuristic optimization algorithm inspired by the social hierarchy and hunting behavior of grey wolves (Mirjalili, Mirjalili, and Lewis, 2014). The primary inspiration behind GWO is the leadership structure and hunting strategies exhibited by grey wolves. GWO models three main social roles: Alpha (α), Beta (β), and Delta (δ) wolves, which represent the best solutions in the optimization process, while Omega (ω) wolves represent the remaining solutions.

- **Social Hierarchy:** The alpha, beta, and delta wolves represent the top solutions, and the rest of the omega wolves position themselves according to these leaders.
- **Encircling the Prey:** Wolves update their positions based on the positions of the alpha, beta, and delta wolves as they surround the prey.

$$\vec{D} = |\vec{C}\vec{X}_p(t) - \vec{X}(t)| \quad (4)$$

$$\vec{X}(t + 1) = \vec{X}_p(t) - \vec{A}\vec{D} \quad (5)$$

Here, t represents the current iteration, while \vec{A} and \vec{C} are coefficient vectors. \vec{X}_p denotes the prey's position vector, and \vec{X} represents the position vector of a grey wolf. The coefficient vectors \vec{A} and \vec{C} are determined as follows:

$$\vec{A} = 2\vec{a}\vec{r}_1 - \vec{a} \quad (6)$$

$$\vec{C} = \vec{r}_2 \quad (7)$$

where components of \vec{a} are linearly decreased from 2 to 0 over the course of iterations and r_1, r_2 are random vectors in $[0,1]$.




Figure 2. 2D and 3D Position Vectors and Their Possible Next Locations in GWO (Mirjalili et al., 2014).

- **Hunting:** Wolves follow the prey until the best solution is found, ultimately capturing the prey.

$$\vec{D}_\alpha = |\vec{C}_1\vec{X}_\alpha - \vec{X}|, \vec{D}_\beta = |\vec{C}_2\vec{X}_\beta - \vec{X}|, \vec{D}_\delta = |\vec{C}_3\vec{X}_\delta - \vec{X}| \quad (8)$$

$$\vec{X}_1 = \vec{X}_\alpha - \vec{A}_1(\vec{D}_\alpha), \vec{X}_2 = \vec{X}_\beta - \vec{A}_2(\vec{D}_\beta), \vec{X}_3 = \vec{X}_\delta - \vec{A}_3(\vec{D}_\delta) \quad (9)$$

$$\vec{X}(t + 1) = \frac{\vec{X}_1 + \vec{X}_2 + \vec{X}_3}{3} \quad (10)$$

The Black Widow Optimization Algorithm (BWOA)

The Black Widow Optimization Algorithm (BWOA) is a metaheuristic optimization method inspired by the biological behavior of the western black widow spider (*Latrodectus hesperus*) (Peña-Delgado et al., 2020). These spiders exhibit unique strategies in mating, movement, and cannibalistic behavior, which serve as the foundation for the algorithm's design.

- **Movement Strategy:** The movement of the black widow spider is modeled as both linear and spiral. The position of a new search agent ($\vec{x}_1(t + 1)$) is updated based on the position of the best search agent from the previous iteration ($\vec{x}^*(t)$) and the position of a randomly selected search agent ($\vec{x}_{r_1}(t)$).

$$\vec{x}_1(t + 1) = \begin{cases} \vec{x}^*(t) - m\vec{x}_{r_1}(t), & \text{if } \text{rand}() \leq 0.3, \\ \vec{x}^*(t) - \cos(2\pi\beta)\vec{x}_1(t) & \text{otherwise.} \end{cases} \quad (11)$$

Here, m is a random coefficient selected from the interval $[0.4, 0.9]$, and β is a random coefficient from the interval $[-1.0, 1.0]$.

Pheromone Strategy: Pheromones play a critical role in the mating behavior of black widow spiders. Well-fed females produce higher pheromone levels, making them more attractive to males. The pheromone rate is calculated as follows:

$$pheromone(i) = \frac{fitness_{max} - fitness(i)}{fitness_{max} - fitness_{min}} \quad (12)$$

Where, $fitness_{max}$ and $fitness_{min}$ represent the highest and lowest fitness values in the current generation, respectively, while $fitness(i)$ denotes the fitness value of the i th search agent.

Female spiders with low pheromone levels are considered dangerous due to cannibalistic behavior and are thus replaced in the population:

$$\vec{x}_i(t) = \vec{x} * (t) + \frac{1}{2} [\vec{x}_{r_1}(t) - (-1)^\sigma * \vec{x}_{r_2}(t)] \quad (13)$$

In this equation, σ is a binary number randomly chosen from $\{0, 1\}$, and r_1 and r_2 are two different search agents selected randomly.

Time Complexity: The time complexity of the algorithm is defined as $O(tMax * nSp * f)$, where $tMax$ is the maximum number of iterations, nSp is the population size (number of spiders), and f is the computational complexity of the objective function being optimized.

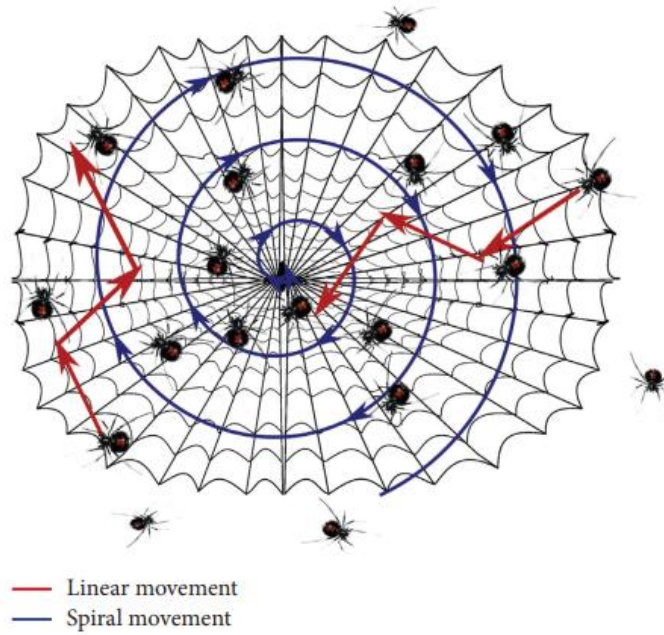


Figure 3. Typical Spider Movement within the Web (Peña-Delgado et al., 2020)

Information regarding the other methods used in experimental studies, aside from those previously discussed, is presented in Table 2. This table summarizes the inspiration sources, key features, and application areas of the methods. It provides a comprehensive comparison of all the methods included in the experiments, offering a broad overview of how each one is applied and utilized in different optimization problems.

EXPERIMENTAL WORKS

In this section, detailed information about the dataset used in the experimental studies is presented. First, the structure, sources, and characteristics of the dataset are explained to clarify the scope of the data forming the foundation of the study. Then, the results obtained by the existing metaheuristic approaches on this dataset are analyzed in detail, and the performance of each method is compared based on various criteria. In this way, the effectiveness of different methods and their success on the dataset are evaluated.

Table 2. Summary of Additional Metaheuristic Methods Used in Experimental Studies

Method	Inspiration Source	Key Features	Application Areas
Arithmetic Optimization Algorithm (AOA)	Mathematical Operators	Based on Addition, Subtraction, Multiplication, and Division; balances exploration and exploitation (Abualigah, Diabat, Mirjalili, Abd Elaziz, and Gandomi, 2021).	Engineering design and various optimization problems.
Blood-Sucking Leech Optimizer (BSLO)	Blood-Sucking Leech Behavior	Five hunting strategies, strong exploration and exploitation capability; can be integrated with ANN (Bai et al., 2024).	Engineering design and melting electrospinning fiber diameter prediction.
Chernobyl Disaster Optimizer (CDO)	Chernobyl Nuclear Explosion	Based on radiation spread; balances exploration and exploitation (Shehadeh, 2023).	Global optimization problems and engineering design.
Dung Beetle Optimizer (DBO)	Dung Beetle Behavior	Fast convergence rate and solution accuracy; applicable to engineering designs (Xue and Shen, 2023).	Complex engineering designs and global optimization problems.
Hybrid Firefly and Particle Swarm Optimization (HFPSO)	Firefly and Particle Swarm Optimization	Combines strengths of firefly and PSO; improved balance of exploration and exploitation (Aydilek, 2018).	Engineering and computationally expensive problems.
Nutcracker Optimizer (NOA)	Clark's Nutcracker Birds	Based on seasonal food-searching strategies, it provides superior performance in engineering designs (Abdel-Basset, Mohamed, Jameel, and Abouhawwash, 2023).	Complex optimization problems and engineering design.
Sinh Cosh Optimizer (SCHO)	Sinh and Cosh Mathematical Functions	Two phases of exploration and exploitation; bounded search strategy (Bai et al., 2023).	Complex optimization problems and engineering designs
Whale Optimization Algorithm (WOA)	Whale Hunting Strategy	Based on bubble-net hunting strategy; superior exploration and exploitation capabilities (Mirjalili and Lewis, 2016).	Structural optimization and engineering designs.
Aquila Optimizer (AO)	Aquila's Prey-Catching Behavior	Optimization procedures include soaring, contour flight, low flight, and swooping attacks; strong exploration and exploitation balance (Abualigah, Yousri, et al., 2021).	Tested on 23 functions, CEC2017 and CEC2019 test functions, and seven real-world engineering problems
Golden Sine Algorithm (Gold-SA)	Sine Function & Golden Section	Math-based algorithm inspired by sine; narrows search space using the golden section, leading to faster convergence with fewer parameters (Tanyildizi and Demir, 2017).	General optimization problems, shows superior performance compared to other population-based methods
Reptile Search Algorithm (RSA)	Crocodile Hunting Behavior	Incorporates unique encircling (high/belly walking) and hunting (coordination/cooperation) behaviors; demonstrated superior performance in benchmark tests and real-world problems (Abualigah, Abd Elaziz, Sumari, Geem, and Gandomi, 2022).	Tested on 23 classical functions, CEC2017 and CEC2019 test functions, and seven real-world engineering problems, achieving better results compared to other algorithms.

Dataset

The analysis of Turkey's energy demand between 1979 and 2011 was conducted using data on imports, population, exports, and GDP. These data are presented in detail in Table 1 and are based on official statistics provided by the Turkish Statistical Institute (TÜİK) and the Ministry of Energy and Natural Resources (ETKB) (Koç et al., 2018). In the scope of the study, the effects of these economic and demographic factors on energy demand were observed, and the findings were evaluated within the framework of the energy supply and demand balance. Detailed information regarding the dataset is provided in Table 3.

Table 3 reveals that Turkey's economic values have continuously increased over the years, reflecting the country's development process. Moreover, based on the data derived from the table, a strong relationship between the rise in economic indicators and energy consumption can be observed. This indicates that economic growth progresses in parallel with the increase in energy demand, positioning energy consumption as a significant indicator of economic development. In this context, linear models have been employed in the study for energy demand forecasting. To accurately analyse the relationship between economic growth and energy demand, the linear models demonstrate how changes in energy consumption align with economic indicators.

Table 3. Turkey's Energy Demand, GDP, Population, Imports and Exports between 1979-2011

Years	GSYİH (\$ 10 ^{^9})	Population (\$ 10 ^{^6})	Imports (\$ 10 ^{^9})	Export (\$ 10 ^{^9})	Energy Demand (TWh)
1979	82	45.53	5.07	2.26	30.71
1980	68	44.44	7.91	2.91	31.97
1981	72	45.54	8.93	4.7	32.05
1982	64	46.69	8.84	5.75	34.39
1983	60	47.86	9.24	5.73	35.7
1984	59	49.07	10.76	7.13	37.43
1985	67	50.31	11.34	7.95	39.4
1986	75	51.43	11.1	7.46	42.47
1987	86	52.56	14.16	10.19	46.88
1988	90	53.72	14.34	11.66	47.91
1989	108	54.89	15.79	11.62	50.71
1990	151	56.1	22.3	12.96	52.98
1991	150	57.19	21.05	13.59	54.27
1992	158	58.25	22.87	14.72	56.68
1993	179	59.32	29.43	15.35	60.26
1994	132	60.42	23.27	18.11	59.12
1995	170	61.53	35.71	21.64	63.68
1996	184	62.67	43.63	23.22	69.86
1997	192	63.82	48.56	26.26	73.78
1998	207	65	45.92	26.97	74.71
1999	187	66.43	40.67	26.59	76.77
2000	200	67.42	54.5	27.78	80.5
2001	146	68.37	41.4	31.33	75.4
2002	181	69.3	51.55	36.06	78.33
2003	239	70.23	69.34	47.25	83.84
2004	299	71.15	97.54	63.17	87.82
2005	361	72.97	116.77	73.48	91.58
2006	483	72.97	139.58	85.54	99.59
2007	531	70.59	170.06	107.27	107.63
2008	648	71.13	201.96	132.03	106.27
2009	730	73.23	140.93	102.14	106.14
2010	615	74.47	185.54	113.88	109.27
2011	731	74.72	240.84	134.91	114.48

Model

Linear models have been employed in this study to predict how energy demand interacts with factors such as economic growth, population increase, and industrialization. The fundamental assumption of these models is that the increase in economic indicators is directly related to the increase in energy demand. Turkey's energy demand data for the period 1979-2011 are used. This data set includes the main determinants of energy demand such as Gross Domestic Product (GDP), population, imports and exports. The mathematical expression of the linear model used in the study is presented in Equation 14, and this model is structured to estimate the effects of economic indicators on energy demand.

$$E_{linear} = w_1 + w_2X_1 + w_3X_2 + w_4X_3 + w_5X_4 \quad (14)$$

The primary goal of energy demand forecasting is to determine the most suitable values in light of the available data. In Equation 14, X_1 , X_2 , X_3 and X_4 represent the Gross Domestic Product (GDP), population, imports, and exports, respectively. Based on these data, the weight values w_1 , w_2 , w_3 , w_4 and w_5 are calculated to obtain the optimal energy demand prediction for specific years. The objective function used is shown in Equation 15, which plays a critical role in determining the optimal weights during the process of energy demand prediction.

$$\min f(x) = \sum_{i=1}^M (E_i^{observed} - E_i^{predicted}) \quad (15)$$

In this case, $E_i^{observed}$ and $E_i^{predicted}$ represent the actual and predicted values for the $i - th$ data point, respectively, and M denotes the total number of data points.

It is also worth noting this point. Evaluation metrics include Root Mean Square Error (RMSE), offering robust measures of forecasting accuracy.

Experimental Results and Analysis

In this section, the performance results of the different metaheuristic algorithms introduced in the previous sections are discussed in detail. These performance evaluations are presented in various tables and figures. Table 4 presents the total error and the weight coefficients obtained for optimal values through the methods for the years 1979-2000.

Table 4. Total Error Values and Weight Coefficients obtained by the Algorithms for the Years 1979-2000

	W_1	W_2	W_3	W_4	W_5	$minf(x)$
GWO	-32.1724	0.0316	1.3161	0.2138	0.2812	23.0204
WOA	-23.9307	0.0480	1.1117	-0.0182	0.7151	33.0276
NOA	-22.6343	0.0279	1.0985	0.1892	0.4671	41.8404
AO	-14.0644	0.0314	0.8984	0.0752	0.8511	31.1919
HFPSO	-32.1827	0.0315	1.3164	0.2115	0.2855	23.0224
AVOA	-32.1518	0.0316	1.3156	0.2136	0.2816	23.0204
DBO	-32.1824	0.0316	1.3163	0.2138	0.2808	23.0204
GoldSA	0.3618	0.0380	0.5725	0.0504	1.0635	44.5907
SCHO	-32.0998	0.0317	1.3143	0.2121	0.2848	23.0220
AOA	0.0193	0.0284	0.5798	-0.0561	1.3288	50.0386
BWOA	-32.1824	0.0316	1.3163	0.2138	0.2808	23.0203
BSLO	-32.1824	0.0316	1.3163	0.2138	0.2808	23.0203
CDO	0.1062	0.0355	0.5785	0.0739	1.0425	44.0240
RSA	-36.1380	0.0092	1.4315	0.3727	0.0448	35.3284

Table 4 presents a diverse set of approaches, including GWO, WOA, NOA, AO, HFPSO, AVOA, DBO, GoldSA, SCHO, AOA, BWOA, BSLO, CDO, and RSA. The fact that each algorithm finds different values for certain weights w_1, w_2, w_3, w_4 and w_5 reveals that different approaches can be used to provide solutions to Turkey's energy demand forecasting problem. The total error value ($\min f(x)$) in the table is an important indicator of the solution quality of the algorithms, and smaller values indicate better solutions. In particular, the algorithms that reached the smallest relative error value of 23.0204-GWO, AVOA, DBO, BWOA and BSLO-performed the best for this problem. These algorithms were successful in minimizing the objective function, which shows their effectiveness. However, some algorithms such as GoldSA, AOA and CDO have larger relative error values compared to other methods. This may indicate that these algorithms are not suitable for this problem or that they may need different parameter settings to perform more effectively. In conclusion, the table presents the comparative performance of various algorithms and clearly shows which methods are more effective for forecasting Turkey's energy demand. However, although this table gives a general idea, a deeper analysis is needed. For this purpose, Table 5 show the estimated energy amounts for the 10 years between 1991 and 2000, the amount of error between the actual energy demand and the estimated energy amount and the relative error percentages according to the weights found by the algorithms (GWO, AVOA, DBO, BWOA and BSLO) which give the best results according to Table 4 and WOA which gives an average result in addition to them. The reason for choosing WOA is to make the details of the analysis more understandable by giving an algorithm that gives an average result along with the algorithms that give good results.

Table 5 presents remarkable results. When the table is analysed, it is seen that the AVOA algorithm exhibits the best performance in terms of prediction accuracy compared to other algorithms. Moreover, the algorithm was able to produce forecasts very close to the actual energy demand values. One of the main reasons why AVOA is so effective in the energy demand forecasting problem is its adaptability to this problem with low computational cost and its ability to work on the problem with high efficiency. In addition, the algorithm's reflexive search mechanisms enable more efficient exploration of the solution space by preventing it from falling into local minimum traps. The most important factor for AVOA to be effective in this problem is the preservation of population diversity by using F coefficient and randomisation techniques and balancing the search process with multiple strategies.

Table 5. Predicted Energy Values (P), Error Rates (E), and Relative Error Percentages (RE) of the Algorithms for the Years 1991-1995

Year		1991	1992	1993	1994	1995	1996	1997	1998	1999	2000
OED		54.2700	56.6800	60.2600	59.1200	63.6800	69.8600	73.7800	74.7100	76.7700	80.5000
GWO	P	54.6417	56.8093	60.2536	59.4907	65.5045	69.2506	72.5976	76.2010	75.4121	80.5016
	E	0.3717	0.1293	-0.0064	0.3707	1.8245	-0.6094	-1.1824	1.4910	-1.3579	0.0016
	RE	0.6850	0.2282	0.0106	0.6270	2.8650	0.8724	1.6027	1.9958	1.7687	0.0020
WOA	P	54.8860	57.0548	59.4008	60.3274	65.3972	68.0185	71.4816	77.2847	76.9787	79.5002
	E	0.6160	0.3748	-0.8592	1.2074	1.7172	-1.8415	-2.2984	2.5747	0.2087	-0.9998
	RE	1.1350	0.6613	1.4257	2.0423	2.6966	2.6359	3.1153	3.4463	0.2718	1.2420
AVOA	P	54.2700	56.6800	60.1641	59.1083	63.6713	69.8600	73.7800	74.7100	76.6523	80.4949
	E	0.000	0.000	-0.0959	-0.0117	-0.0087	0.000	0.000	0.000	-0.1177	-0.0051
	RE	0.002	0.002	0.1592	0.0198	0.0137	0.000	0.000	0.000	0.1534	0.0064
DBO	P	4.6374	56.8049	60.2470	59.4882	65.5013	69.2459	72.5939	76.1982	75.4097	80.4955
	E	0.3674	0.1249	-0.0130	0.3682	1.8213	-0.6141	-1.1861	1.4882	-1.3603	-0.0045
	RE	0.6770	0.2203	0.0215	0.6228	2.8600	0.8790	1.6076	1.9920	1.7720	0.0056
BWOA	P	54.6394	56.8070	60.2506	59.4889	65.5023	69.2479	72.5952	76.1989	75.4103	80.4986
	E	0.3694	0.1270	-0.0094	0.3689	1.8223	-0.6121	-1.1848	1.4889	-1.3597	-0.0014
	RE	0.6807	0.2240	0.0156	0.6240	2.8617	0.8762	1.6059	1.9930	1.7712	0.0018
BSLO	P	54.6394	56.8070	60.2506	59.4889	65.5023	69.2479	72.5952	76.1989	75.4103	80.4986
	E	0.3694	0.1270	-0.0094	0.3689	1.8223	-0.6121	-1.1848	1.4889	-1.3597	-0.0014
	RE	0.6807	0.2240	0.0156	0.6240	2.8617	0.8762	1.6059	1.9930	1.7712	0.0018

The total error amounts and relative error percentages of the algorithms are summarized in Table 6 in order to provide a more comprehensive comparison. This additional table provides an important reference point to analyze and compare the performance of different algorithms in more detail.

Table 6. Total Error Values and Total Relative Error Percentages obtained by the Algorithms for 1991-2000

Method	Total Error	Total Relative Error (%)
GWO	7.3449	10.6574
WOA	12.6977	18.6722
AVOA	0.2391	0.3565
DBO	7.3480	10.6578
BWOA	7.3439	10.6541
BSLO	7.3439	10.6541

In Table 6, the total error and total relative error percentages are calculated as the sum of the absolute values of the results found by the algorithms. According to the table, the AVOA method's lowest 'Total Error' and 'Total Relative Error (%)' values indicate that it outperforms the other methods. This result suggests that the AVOA method yields predictions closer to the actual values. Additionally, the similar results of the DBO, BWOA, and BSLO methods suggest comparable performance among these approaches, while the higher error values of the WOA method suggest relatively lower accuracy compared to the others. To examine each method's annual performance in energy demand forecasting, data from Table 5 were used to create Figure 4, enabling an assessment of the reliability of the results and visualization of significant differences and error margins across methods.

Upon examining Figure 1, it is evident that the AVOA method consistently yields the lowest error values across all years. In contrast, the GWO method exhibits fluctuating error values between 1995 and 1999, reaching a peak in 1995. The figure also indicates that the DBO, BWOA, and BSLO methods display similar behaviors. Meanwhile, the WOA method shows higher error values compared to the other methods, indicating a broader range of error values; notably, it peaked in 1998. Overall, the AVOA method provides stable results that are closer to the actual values, while the WOA method presents more erratic and higher errors. The other approaches, on the other hand, yield comparable and similar results.

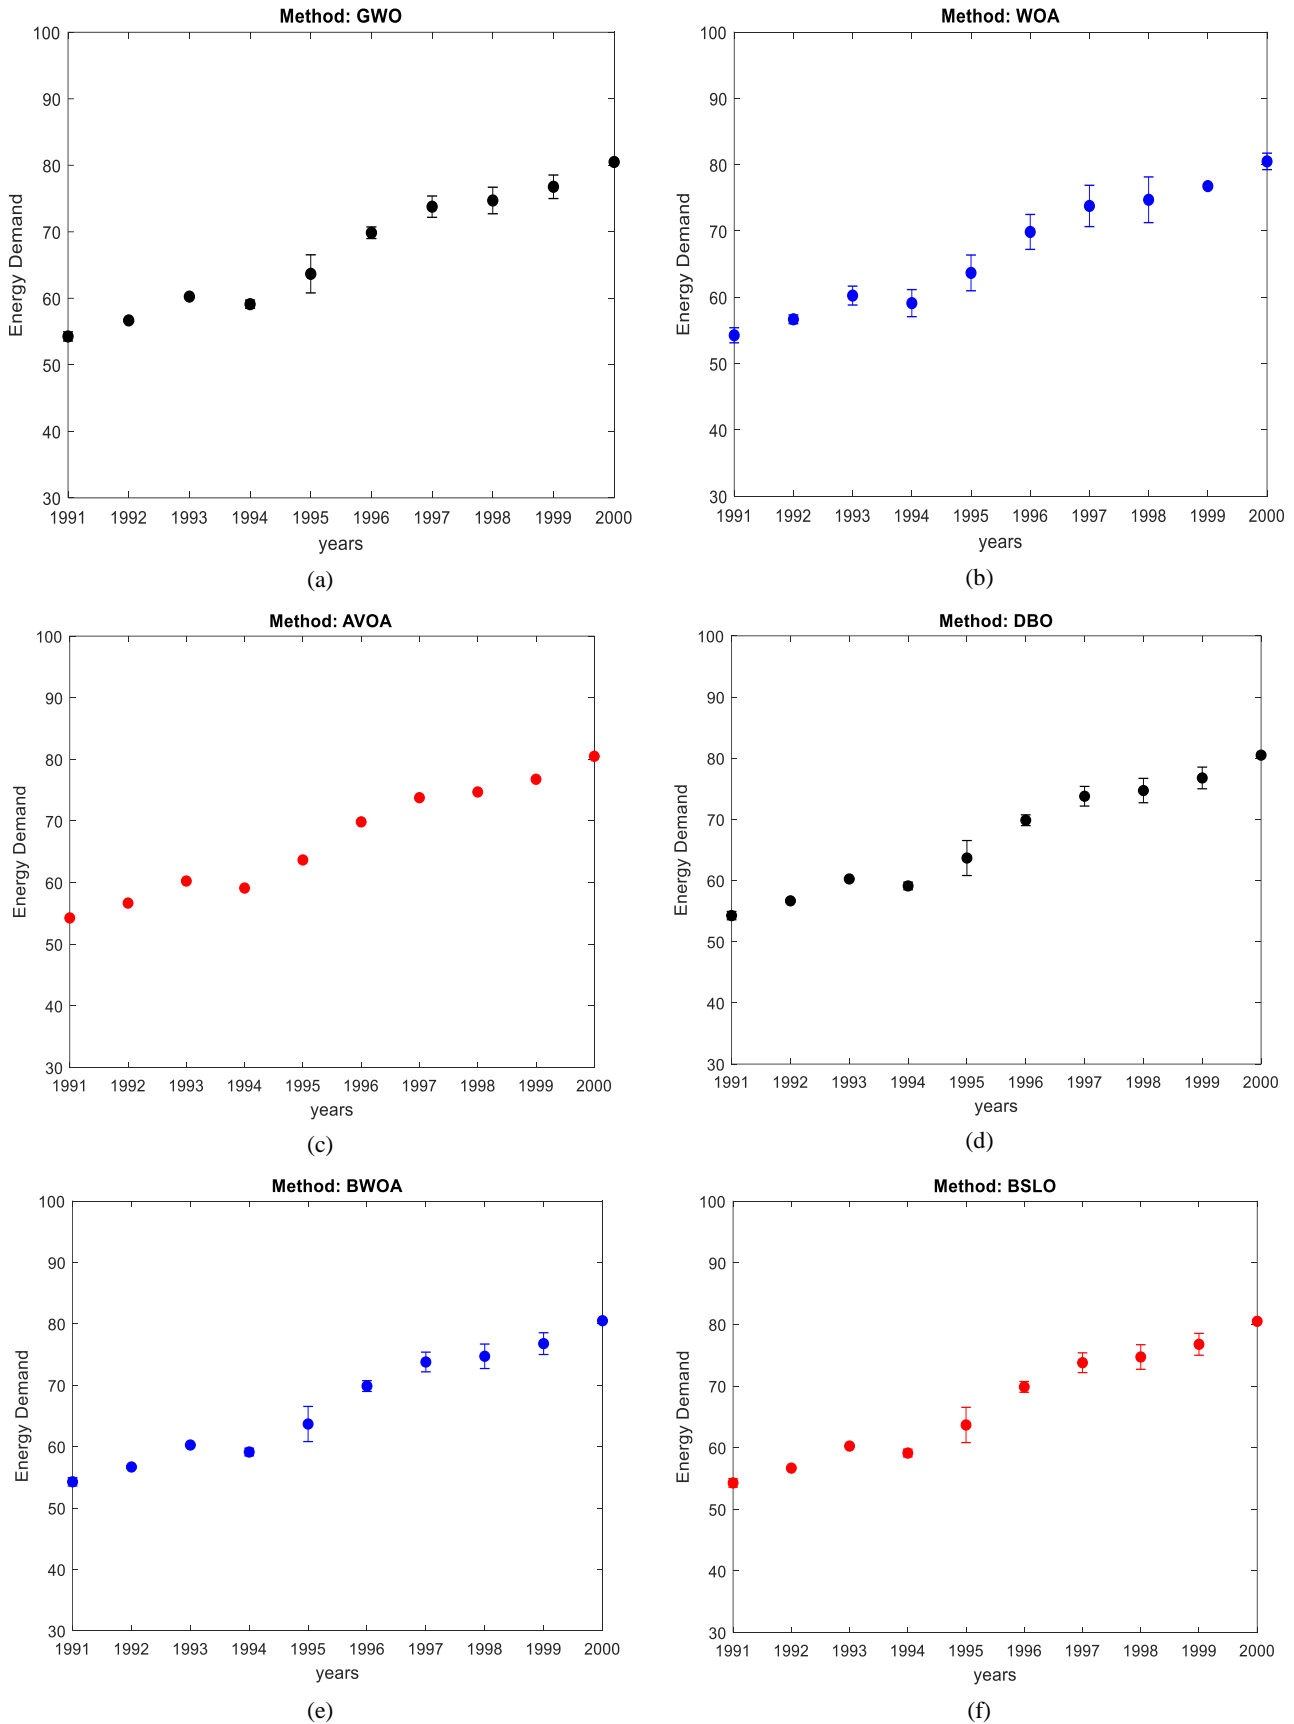


Figure 4. Error Values of Methods in Annual Energy Demand Forecasting (1991-2000)

Prediction of Turkey's Future Energy Demand for the Period 2012-2030: To enable the methods to predict Turkey's energy demand for the period 2012-2030, optimal coefficients were first determined using the complete

data from 1979-2011. Accordingly, coefficient values that optimize the predictive performance of each method were calculated, and the results are presented in Table 7.

Table 7. Total Error Values and Weight Coefficients obtained by the Algorithms for the Years 1979-2011

	W_1	W_2	W_3	W_4	W_5	$minf(x)$
GWO	-64.6293	0.0476	2.0569	0.0011	-0.0895	134.3387
WOA	-57.9652	0.1023	1.8814	-0.1918	-0.0757	243.9200
AVOA	-65.0584	0.0445	2.0682	0.0370	-0.1312	132.4312
DBO	-65.0595	0.0455	2.0682	0.0372	-0.1322	132.5312
BWOA	-65.0593	0.0463	2.0682	0.0375	-0.1343	133.4312
BSLO	-65.1585	0.0453	2.0682	0.0372	-0.1331	132.6312

When examining Table 7, it is observed that AVOA yields better results compared to the other algorithms. Following this, future energy demand predictions were conducted based on the scenarios presented in Table 8, using the data from Table 7. These scenarios aim to evaluate the predictive performance of the methods under different conditions.

Table 8. Possible Scenarios for the Years 2012-2030

Data	Scenario I	Scenario II	Scenario III
Average GDP growth rate (%)	4.0	5.0	6.0
Population growth rate (%)	0.5	0.6	0.6
Growth rate of imports (%)	2.5	3.5	3.0
Growth rate of exports (%)	3	3.5	3.0

The scenarios presented in Table 8 were compiled from updated data by Koç et al. (2018). to forecast Turkey's energy demand for the period 2012-2030. The results obtained by the methods according to these scenarios are shared in two parts. In the first part, the methods' results for 2012-2020 are presented in tabular form, while the results for 2021-2030 are illustrated graphically. This structure aims to reveal the performance differences and trends of the methods across both periods in detail, allowing for a clear analysis of each method's reliability and accuracy over the long term.

The results obtained by the methods under Scenario I are presented in detail in Table 9 and Figure 5. This table and figure examine the energy demand forecasting performance of each method for the period 2012-2030, providing an in-depth analysis of variations across different years and conditions. Thus, the effectiveness and accuracy of each method used under Scenario I are evaluated from a comparative perspective. The same procedure was also performed for Scenario II and Scenario III.

When Table 9 and Figure 5 are analysed, it is seen that the methods have different error rates. According to Scenario 1, except for the WOA method, the other methods have generally displayed a more balanced performance and produced close results. In particular, the forecast values obtained for the years 2012-2015 are quite close to the probable actual values, indicating that the methods provide consistent results. However, the WOA method, unlike the other methods, exhibited a significant imbalance and showed significant deviations in some years, as clearly seen in Figure 1. This indicates that WOA provides more fluctuating and inconsistent performance compared to other methods. The results obtained by the methods under Scenario 2 are presented in Table 10 and Figure 6.

Table 9. Predicted Energy Demand Rates of the Methods according to Scenario 1 for the Years 2012-2020

	GET	GWO	WOA	AVOA	DBO	BWOA	BSLO
2012	120.0900	115.7065	105.5395	116.7947	117.4917	117.8998	117.1058
2013	120.2900	117.6107	107.9464	118.6532	119.3788	119.8051	118.9827
2014	123.9400	119.5677	110.4463	120.5608	121.3162	121.7614	120.9095
2015	129.2700	121.5795	113.0431	122.5195	123.3059	123.7709	122.8883
2016	N/A	123.6483	115.7413	124.5313	125.3499	125.8356	124.9209
2017	N/A	125.7763	118.5453	126.5981	127.4503	127.9575	127.0096
2018	N/A	127.9660	121.4600	128.7223	129.6094	130.1391	129.1565
2019	N/A	130.2198	124.4900	130.9059	131.8294	132.3825	131.3639
2020	N/A	132.5401	127.6407	133.1515	134.1128	134.6904	133.6342




Figure 5. Predicted Energy Demand Rates of the Methods according to Scenario 1 for the Years 2021-2030

Table 10. Predicted energy demand rates of the methods according to Scenario 2 for the years 2012-2020

	GET	GWO	WOA	AVOA	DBO	BWOA	BSLO
2012	120.0900	114.2969	103.5968	115.4640	116.1406	116.5364	115.7625
2013	120.2900	116.6236	106.3281	117.7862	118.4981	118.9169	118.1078
2014	123.9400	119.0322	109.1892	120.1882	120.9371	121.3803	120.5343
2015	129.2700	121.5268	112.1876	122.6740	123.4619	123.9307	123.0458
2016	N/A	124.1117	115.3309	125.2476	126.0765	126.5724	125.6467
2017	N/A	126.7913	118.6273	127.9135	128.7854	129.3098	128.3412
2018	N/A	129.5706	122.0855	130.6761	131.5932	132.1478	131.1340
2019	N/A	132.4543	125.7146	133.5402	134.5049	135.0912	134.0300
2020	N/A	135.4478	129.5240	136.5108	137.5255	138.1453	137.0342




Figure 6. Predicted Energy Demand Rates for the Years 2021-2030 by Methods under Scenario II

Under Scenario II, results similar to those of Scenario I were obtained; however, it is observed that the methods generally provide higher energy demand forecasts. Notably, the WOA method offers the lowest predictions compared to other methods up until 2025, after which it begins to provide higher forecast values than its counterparts. This

indicates a significant change and upward trend in the predictions made by the WOA method. On the other hand, the AVOA method displays a trajectory that closely aligns with the average of the other methods' forecast values, suggesting that it offers a more balanced and consistent predictive performance. This stability implies that AVOA could be a more reliable method for energy demand forecasting. The results obtained by the methods under Scenario 3 are presented in Table 11 and Figure 7.

Table 11. Predicted Energy Demand Rates of the Methods according to Scenario 3 for the Years 2012-2020

	GET	GWO	WOA	AVOA	DBO	BWOA	BSLO
2012	120.0900	114.7039	104.6267	115.8332	116.5176	116.9203	116.1386
2013	120.2900	117.4797	108.4884	118.5633	119.2915	119.7249	118.8994
2014	123.9400	120.3829	112.5882	121.4149	122.1897	122.6558	121.7839
2015	129.2700	123.4211	116.9418	124.3954	125.2195	125.7205	124.7993
2016	N/A	126.6026	121.5657	127.5124	128.3890	128.9271	127.9535
2017	N/A	129.9359	126.4776	130.7740	131.7062	132.2840	131.2549
2018	N/A	133.4302	131.6960	134.1889	135.1802	135.8002	134.7121
2019	N/A	137.0952	137.2410	137.7662	138.8203	139.4852	138.3345
2020	N/A	140.9413	143.1337	141.5157	142.6364	143.3492	142.1320




Figure 7. Predicted Energy Demand Rates for the years 2021-2030 by Methods under Scenario III

When examining Table 11 and Figure 7, it is evident that Scenario 3 presents the highest energy demand forecasts. In this scenario, the energy demand predictions from all methods are generally high. Notably, the WOA method stands out by providing significantly high forecast values starting from 2020. Conversely, the other methods exhibit a more balanced and stable performance, displaying similar behavior as in the previous scenarios.

Overall, the inference that can be drawn from all three scenarios is that AVOA provides forecasts close to the average throughout the years, while WOA presents low predictions for the initial eight years, followed by higher forecasts thereafter. Additionally, the other methods have also produced results that are balanced and consistent, similar to AVOA. This suggests that AVOA and other methods demonstrating similar behavior may be more reliable and stable in forecasting energy demand.

CONCLUSION AND DISCUSSIONS

This study investigates the effectiveness of modern metaheuristic optimization methods in forecasting Turkey's energy demand up to the year 2035. Accurate energy demand forecasts are critically important for shaping the country's energy policies. A comparative analysis using data from 1979 to 2011, which includes economic and demographic indicators, demonstrates that methods such as AVOA, GWO, and DBO provide the most accurate predictions with the lowest total error rates. Furthermore, the results indicate that the AVOA algorithm outperforms other methods in energy demand forecasting. Key findings indicate that AVOA achieved the highest accuracy, with

results closely aligning with actual energy demand values. The algorithm's low computational cost, ability to maintain population diversity, and its capacity to explore the solution space more efficiently without getting trapped in local minimal are fundamental reasons for its success in this domain. Table 2 presents the relative performance of all methods, while Figure 3 visualizes annual error trends, emphasizing AVOA's consistency and reliability. Additionally, methods such as DBO, BWOA, and BSLO also exhibit similar performance, offering effective alternatives alongside AVOA for accurately predicting energy demand.

This study aims to identify the key factors influencing energy demand, contributing to the development of sustainable energy policies in Turkey. The findings provide valuable insights for future energy planning, helping to maintain the balance between energy supply and demand. Therefore, the use of modern metaheuristic methods is expected to enhance the reliability of energy demand forecasting in developing countries like Turkey, facilitating the more effective implementation of energy policies.

REFERENCES

- Abdel-Basset, M., Mohamed, R., Jameel, M., & Abouhawwash, M. (2023). Nutcracker optimizer: A novel nature-inspired metaheuristic algorithm for global optimization and engineering design problems. *Knowledge-Based Systems*, 262, 110248.
- Abdollahzadeh, B., Gharehchopogh, F. S., & Mirjalili, S. (2021). African vultures optimization algorithm: A new nature-inspired metaheuristic algorithm for global optimization problems. *Computers & Industrial Engineering*, 158, 107408.
- Abualigah, L., Abd Elaziz, M., Sumari, P., Geem, Z. W., & Gandomi, A. H. (2022). Reptile Search Algorithm (RSA): A nature-inspired meta-heuristic optimizer. *Expert Systems with Applications*, 191, 116158.
- Abualigah, L., Diabat, A., Mirjalili, S., Abd Elaziz, M., & Gandomi, A. H. (2021). The arithmetic optimization algorithm. *Computer Methods in Applied Mechanics and Engineering*, 376, 113609.
- Abualigah, L., Yousri, D., Abd Elaziz, M., Ewees, A. A., Al-Qaness, M. A. A., & Gandomi, A. H. (2021). Aquila optimizer: a novel meta-heuristic optimization algorithm. *Computers & Industrial Engineering*, 157, 107250.
- Agarwal, T., & Kumar, V. (2022). A systematic review on bat algorithm: Theoretical foundation, variants, and applications. *Archives of Computational Methods in Engineering*, 1–30.
- Agency, I. E. (2009). *World energy outlook*. OECD/IEA Paris.
- Akter, A., Zafir, E. I., Dana, N. H., Joysoyal, R., Sarker, S. K., Li, L., ... Kamwa, I. (2024). A review on microgrid optimization with meta-heuristic techniques: Scopes, trends and recommendation. *Energy Strategy Reviews*, 51, 101298.
- Aydilek, I. B. (2018). A hybrid firefly and particle swarm optimization algorithm for computationally expensive numerical problems. *Applied Soft Computing*, 66, 232–249.
- Bai, J., Li, Y., Zheng, M., Khatir, S., Benaissa, B., Abualigah, L., & Wahab, M. A. (2023). A sinh cosh optimizer. *Knowledge-Based Systems*, 282, 111081.
- Bai, J., Nguyen-Xuan, H., Atroshchenko, E., Kosec, G., Wang, L., & Wahab, M. A. (2024). Blood-sucking leech optimizer. *Advances in Engineering Software*, 195, 103696.
- Beheshti, Z., & Shamsuddin, S. M. H. (2013). A review of population-based meta-heuristic algorithms. *Int. j. Adv. Soft Comput. Appl*, 5(1), 1–35.
- Bertsimas, D., & Tsitsiklis, J. (1993). Simulated annealing. *Statistical Science*, 8(1), 10–15.
- Biçer, A. (2017). *Enerji talep tahminine yönelik program geliştirme ve bir bölge için uygulaması*.
- Bilgen, S., Kaygusuz, K., & Sari, A. (2004). Renewable energy for a clean and sustainable future. *Energy Sources*, 26(12), 1119–1129.
- Bulut, Y. M., & Yıldız, Z. (2016). Comparing energy demand estimation using various statistical methods: the case of Turkey. *Gazi University Journal of Science*, 29(2), 237–244.
- Corne, D., Dorigo, M., Glover, F., Dasgupta, D., Moscato, P., Poli, R., & Price, K. V. (1999). *New ideas in optimization*. McGraw-Hill Ltd., UK.

- Dilaver, Z., & Hunt, L. C. (2011). Industrial electricity demand for Turkey: a structural time series analysis. *Energy Economics*, 33(3), 426–436.
- Dorigo, M. (2007). Ant colony optimization. *Scholarpedia*, 2(3), 1461.
- Ediger, V. Ş., & Akar, S. (2007). ARIMA forecasting of primary energy demand by fuel in Turkey. *Energy Policy*, 35(3), 1701–1708.
- Ediger, V. Ş., & Tatlıdil, H. (2002). Forecasting the primary energy demand in Turkey and analysis of cyclic patterns. *Energy Conversion and Management*, 43(4), 473–487.
- Erdogdu, E. (2007). Electricity demand analysis using cointegration and ARIMA modelling: A case study of Turkey. *Energy Policy*, 35(2), 1129–1146.
- Es, H., KALENDER ÖKSÜZ, F., & Hamzacebi, C. (2014). Forecasting the net energy demand of Turkey by artificial neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 29(3).
- Ezugwu, A. E., Shukla, A. K., Nath, R., Akinyelu, A. A., Agushaka, J. O., Chiroma, H., & Muhuri, P. K. (2021). Metaheuristics: a comprehensive overview and classification along with bibliometric analysis. *Artificial Intelligence Review*, 54, 4237–4316.
- Feoktistov, V. (2006). *Differential evolution*. Springer.
- Gendreau, M. (2003). An introduction to tabu search. In *Handbook of metaheuristics* (pp. 37–54). Springer.
- Guo, C., Tang, H., Niu, B., & Lee, C. B. P. (2021). A survey of bacterial foraging optimization. *Neurocomputing*, 452, 728–746.
- Güven, A. F., Yörükeren, N., Tag-Eldin, E., & Samy, M. M. (2023). Multi-objective optimization of an islanded green energy system utilizing sophisticated hybrid metaheuristic approach. *IEEE Access*.
- Holland, J. H. (1992). Genetic algorithms. *Scientific American*, 267(1), 66–73.
- Kankal, M., Akpınar, A., Kömürcü, M. İ., & Özşahin, T. Ş. (2011). Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables. *Applied Energy*, 88(5), 1927–1939.
- Kar, A. K. (2016). Bio inspired computing—a review of algorithms and scope of applications. *Expert Systems with Applications*, 59, 20–32.
- Karaboga, D., & Basturk, B. (2008). On the performance of artificial bee colony (ABC) algorithm. *Applied Soft Computing*, 8(1), 687–697.
- Kaur, S., Awasthi, L. K., Sangal, A. L., & Dhiman, G. (2020). Tunicate Swarm Algorithm: A new bio-inspired based metaheuristic paradigm for global optimization. *Engineering Applications of Artificial Intelligence*, 90, 103541.
- Kıran, M. S., Özceylan, E., Gündüz, M., & Paksoy, T. (2012). A novel hybrid approach based on particle swarm optimization and ant colony algorithm to forecast energy demand of Turkey. *Energy Conversion and Management*, 53(1), 75–83.
- Koç, İ., Nureddin, R., & Kahramanlı, H. (2018). Türkiye’de Enerji Talebini Tahmin Etmek İçin Doğrusal Form Kullanarak GSA (Yerçekimi Arama Algoritması) ve IWO (Yabani Ot Optimizasyon Algoritması) Tekniklerinin Uygulanması. *Selçuk Üniversitesi Mühendislik, Bilim ve Teknoloji Dergisi*, 6(4), 529–543.
- Kunkle, B. W., Grenier-Boley, B., Sims, R., Bis, J. C., Damotte, V., Naj, A. C., ... Amlie-Wolf, A. (2019). Genetic meta-analysis of diagnosed Alzheimer's disease identifies new risk loci and implicates A β , tau, immunity and lipid processing. *Nature Genetics*, 51(3), 414–430.
- Li, G., Zhang, T., Tsai, C.-Y., Yao, L., Lu, Y., & Tang, J. (2024). Review of the metaheuristic algorithms in applications: Visual analysis based on bibliometrics (1994–2023). *Expert Systems with Applications*, 124857.
- Martí, R., Sevaux, M., & Sörensen, K. (2024). 50 years of metaheuristics. *European Journal of Operational Research*.
- Martín-Santamaría, R., López-Ibáñez, M., Stützle, T., & Colmenar, J. M. (2024). On the automatic generation of metaheuristic algorithms for combinatorial optimization problems. *European Journal of Operational Research*.
- Mirjalili, S., & Lewis, A. (2016). The whale optimization algorithm. *Advances in Engineering Software*, 95, 51–67.

- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in Engineering Software*, 69, 46–61.
- Özdemir, D., & Dörterler, S. (2022). An adaptive search equation-based artificial bee colony algorithm for transportation energy demand forecasting. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30(4), 1251–1268.
- Özdemir, D., Dörterler, S., & Aydın, D. (2022). A new modified artificial bee colony algorithm for energy demand forecasting problem. *Neural Computing and Applications*, 34(20), 17455–17471.
- Pamuk, N. (2024). Techno-economic feasibility analysis of grid configuration sizing for hybrid renewable energy system in Turkey using different optimization techniques. *Ain Shams Engineering Journal*, 15(3), 102474.
- Passino, K. M. (2012). Bacterial foraging optimization. In *Innovations and Developments of Swarm Intelligence Applications* (pp. 219–234). IGI Global.
- Peña-Delgado, A. F., Peraza-Vázquez, H., Almazán-Covarrubias, J. H., Torres Cruz, N., García-Vite, P. M., Morales-Cepeda, A. B., & Ramirez-Arredondo, J. M. (2020). A Novel Bio-Inspired Algorithm Applied to Selective Harmonic Elimination in a Three-Phase Eleven-Level Inverter. *Mathematical Problems in Engineering*, 2020(1), 8856040.
- RC, K. J. E. (1995). Particle swarm optimization. *Proc IEEE Int Conf Neural Networks*, 4, 1942–1948.
- Resende, M. G. C., & Ribeiro, C. C. (2016). *Optimization by GRASP*. Springer.
- Salcedo-Sanz, S., Muñoz-Bulnes, J., Portilla-Figueras, J. A., & Del Ser, J. (2015). One-year-ahead energy demand estimation from macroeconomic variables using computational intelligence algorithms. *Energy Conversion and Management*, 99, 62–71.
- Sánchez-Oro, J., Duarte, A., & Salcedo-Sanz, S. (2016). Robust total energy demand estimation with a hybrid Variable Neighborhood Search–Extreme Learning Machine algorithm. *Energy Conversion and Management*, 123, 445–452.
- Sarzaeim, P., Bozorg-Haddad, O., & Chu, X. (2018). Teaching-learning-based optimization (TLBO) algorithm. *Advanced Optimization by Nature-Inspired Algorithms*, 51–58.
- Shehadeh, H. A. (2023). Chernobyl disaster optimizer (CDO): A novel meta-heuristic method for global optimization. *Neural Computing and Applications*, 35(15), 10733–10749.
- Sonmez, M., Akgüngör, A. P., & Bektaş, S. (2017). Estimating transportation energy demand in Turkey using the artificial bee colony algorithm. *Energy*, 122, 301–310.
- Sözen, A., Arcaklıoğlu, E., & Özkaymak, M. (2005). Turkey's net energy consumption. *Applied Energy*, 81(2), 209–221.
- Tanyildizi, E., & Demir, G. (2017). Golden sine algorithm: a novel math-inspired algorithm. *Advances in Electrical & Computer Engineering*, 17(2).
- Tiris, M. (2005). Global trends for energy. *Turkish Workshop on Sustainable Development: Meeting the Challenges, JuÖlich*.
- Uguz, H., Hakli, H., & Baykan, Ö. K. (2015). A new algorithm based on artificial bee colony algorithm for energy demand forecasting in Turkey. *2015 4th International Conference on Advanced Computer Science Applications and Technologies (ACSAT)*, 56–61. IEEE.
- Wilson, A. J., Pallavi, D. R., Ramachandran, M., Chinnasamy, S., & Sowmiya, S. (2022). A review on memetic algorithms and its developments. *Electrical and Automation Engineering*, 1(1), 7–12.
- Xue, J., & Shen, B. (2023). Dung beetle optimizer: A new meta-heuristic algorithm for global optimization. *The Journal of Supercomputing*, 79(7), 7305–7336.
- Yang, X.-S., & He, X. (2013). Bat algorithm: literature review and applications. *International Journal of Bio-Inspired Computation*, 5(3), 141–149.
- Yang, X.-S., & Slowik, A. (2020). Firefly algorithm. In *Swarm intelligence algorithms* (pp. 163–174). CRC Press.
- Yumurtaci, Z., & Asmaz, E. (2004). Electric energy demand of Turkey for the year 2050. *Energy Sources*, 26(12), 1157–1164.



Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences



Geliş Tarihi : 08.11.2024
Kabul Tarihi : 13.01.2025

Received Date : 08.11.2024
Accepted Date : 13.01.2025

Al7075-B₄C KOMPOZİTLERİN TOZ METALÜRJİSİ VE SICAK PRESLEMEYLE ÜRETİMİ, MEKANİK ÖZELLİKLERİNİN İNCELENMESİ PRODUCTION OF Al7075-B₄C COMPOSITES BY POWDER METALLURGY AND HOT PRESSING, INVESTIGATION OF THEIR MECHANICAL PROPERTIES

Aleyna TAŞKIN¹ (ORCID: 0000-0002-8308-9957)

Elif IŞIK² (ORCID: 0000-0000-0001-8289-9512)

Mahmut Can ŞENEL^{3*} (ORCID: 0000-0001-7897-1366)

¹Ondokuz Mayıs Üniversitesi, Makine Mühendisliği Bölümü, Samsun, Türkiye

²Sivas Bilim ve Teknoloji Üniversitesi, Mühendislik ve Doğa Bilimleri Fakültesi, Sivas, Türkiye

³Ondokuz Mayıs Üniversitesi, Makine Mühendisliği Bölümü, Samsun, Türkiye

*Sorumlu Yazar / Corresponding Author: Mahmut Can ŞENEL, mahmutcan.senel@omu.edu.tr

ÖZET

Bu çalışmada, Al7075 alaşımı matrise ağırlıkça %1, 3, 6, 9, 12, 15 ve 30 oranlarında bor karbür ilavesi yapılarak Al7075-B₄C kompozit malzemeler, toz metalürjisi ve sıcak presleme yöntemleri kullanılarak üretilmiştir. Bor karbür katkı oranının mikroyapı ile mekanik özellikler (yoğunluk, gözeneklilik oranı, Vickers sertliği ve basma dayanımı) üzerindeki etkisi incelenmiştir. Yürütülen testler sonucunda en yüksek yoğunluk (2,63 g/cm³), Vickers sertliği (256 HV), basma dayanımı (509 MPa) ve en düşük gözeneklilik oranı (%0,5) Al7075-30B₄C kompozitte elde edilmiştir. Mikroyapı incelemelerinde, %30 B₄C katkı oranıyla takviye partiküllerinin matris içinde homojen bir dağılım gösterdiği tespit edilmiştir. Sonuç olarak, %30 B₄C katkısının Al7075 matrisli kompozitin mikroyapısını ve mekanik özelliklerini önemli ölçüde iyileştirdiği görülmüştür.

Anahtar Kelimeler: Bor karbür, Al7075 alaşımı, sıcak presleme, mekanik özellik

ABSTRACT

In this study, Al7075-B₄C composite materials were produced by adding boron carbide (1, 3, 6, 9, 12, 15, and 30wt %) to the Al7075 alloy matrix using powder metallurgy and hot-pressing methods. The effect of the reinforcement ratio on the microstructure and mechanical properties (density, porosity ratio, Vickers hardness, and compressive strength) were investigated. As a result of the tests conducted, the highest density (2.63 g/cm³), Vickers hardness (256 HV), compressive strength (509 MPa), and the lowest porosity ratio (0.5%) were obtained in the Al7075-30B₄C composite. In the microstructural examinations, it was determined that the reinforcement particles (30% B₄C) showed a homogeneous distribution in the matrix. As a result, it was seen that the reinforcement of 30% B₄C significantly improved the microstructure and mechanical properties of the Al7075 matrix composite.

Keywords: Boron carbide, Al7075 alloy, hot pressing, mechanical property

GİRİŞ

ToCite: TAŞKIN, A., IŞIK, E., ŞENEL, M.C., (2025). AL7075-B₄C KOMPOZİTLERİN TOZ METALÜRJİSİ VE SICAK PRESLEMEYLE ÜRETİMİ, MEKANİK ÖZELLİKLERİNİN İNCELENMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 460-471.

Teknolojinin ilerlemesi ile birlikte yeni malzemelere yönelim gün geçtikçe artmaktadır. Kompozit malzemeler, en az iki malzemenin üstün özelliklerinin bir araya getirilmesiyle elde edilen yeni bir malzeme grubudur. Matris yapı ve takviye elemanı olmak üzere iki ana bileşenden oluşmaktadır (Tharanikumar vd., 2024). Matris yapı takviye elemanlarını bir arada tutar ve kompozit malzemeye gelen yükü takviye elemanına iletir. Takviye elemanı ise herhangi bir gerilme durumunda yükü taşıyarak kompozit malzemenin mukavemetini iyileştirir. Kompozitler matris malzemesine göre; metal, seramik ve polimer olmak üzere üç gruba ayrılmaktadır.

Metal matrisli kompozitler (MMK), matrisi metal veya metal alaşımı olan kompozitlerdir. MMK malzemeler düşük ağırlık/dayanım oranına, düşük yoğunluğa ve yüksek mukavemete sahiptir. Bu mükemmel özelliklerinden dolayı MMK'ler otomotiv endüstrisi, havacılık, biyomedikal başta olmak üzere birçok alanda yaygın bir şekilde kullanılmaktadır (Sharma vd., 2024). Alüminyum ve alaşımları yüksek elastik modülü, yüksek tokluk ve mükemmel özgül mukavemet gibi özelliklerinden dolayı metal matrisli kompozitlerde matris malzemesi olarak sıklıkla tercih edilmektedir. Al alaşımlarından 7xxx serisine ait olan Al7075 yüksek sertliğe, düşük çatlak ilerleme hızına ve yüksek kırılma tokluğuna sahiptir. Bu özellikler Al7075'in yüksek mukavemet ve hafiflik gerektiren uygulamalarda matris malzemesi olarak kullanılmasını sağlamaktadır (Chouhan vd., 2024).

Kompozit malzemenin mekanik özelliklerini iyileştirmek amacıyla matrise takviye elemanı eklenmektedir. Al matrise genellikle silisyum nitrür (Si_3N_4), tungsten karbür (WC), alümina (Al_2O_3), zirkonyum oksit (ZrO_2), bor karbür (B_4C) gibi yüksek sertliğe sahip seramik malzemeler takviye edilmektedir. Bu malzemeler arasından B_4C , 19. yüzyılda keşfedilen ve oksit içermeyen seramikler arasında yer alan önemli bir malzemedir. Yüksek sertlik, düşük yoğunluk, kimyasal kararlılık ve yüksek ergime sıcaklığı gibi üstün özelliklere sahip olması nedeniyle, özellikle havacılık, savunma ve nükleer sanayi gibi alanlarda yaygın olarak kullanılmaktadır. Bor karbür, bilinen en sert malzemelerden biri olup sadece elmas ve kübik bor nitrürden daha yumuşaktır. Bu sertlik seviyesi, bor karbürün aşınma direncinin çok yüksek olduğu uygulamalarda kullanımını sağlamaktadır. Ayrıca bor karbür, hafifliği ve yüksek sertliği sayesinde zırh sistemleri, kurşun geçirmez yelekler ve balistik plakaların üretiminde de kullanılmaktadır. Aynı zamanda, kimyasal kararlılığı ve aşınma dayanımından dolayı aşındırıcı malzemelerde, kesici uçlarda, pompalarda ve nozul gibi parçalarda da tercih edilmektedir (Rajanish vd., 2024).

Kompozit malzemeler karıştırmalı döküm, sıvı infiltrasyon, sıkıştırılmalı döküm, ekstrüzyon, toz metalürjisi vb. birçok yöntemle üretilebilmektedir. Bu yöntemler arasından toz metalürjisi (TM), son şekle yakın parça üretimi, karmaşık geometrilere sahip parçaların üretilmesi ve düşük maliyet gibi avantajlarından dolayı kompozit malzeme üretiminde sıklıkla tercih edilmektedir. TM yönteminde toz halindeki matris ve takviye malzemesi belirli oranlarda karıştırılarak sıkıştırılır ve şekillendirilen tozlara dayanımlarını artırmak amacıyla ısıl işlem uygulanmaktadır. Ardından kompozit numunelere ikincil işlemlerin uygulanması ile üretim tamamlanmaktadır. Bu yöntem farklı malzeme kombinasyonlarının kullanılarak kaliteli malzeme üretimini sağladığı için aşınma direnci yüksek, ısıya dayanıklı ve yüksek mukavemete sahip kompozit malzeme üretimini mümkün kılmaktadır (Bharathi & Kumar, 2024).

Literatürde Al matrisli B_4C takviyeli kompozit malzemelerin üretildiği birçok çalışma bulunmaktadır. Akçay vd., toz metalürjisi ve mekanik öğütme yöntemlerini kullanarak Al matrise ağırlıkça %10, 20 ve 40 oranlarında B_4C takviye ederek kompozit malzemeler üretmişlerdir. B_4C takviye oranının artmasıyla kompozitin sertliğinin arttığı ancak yoğunluğunun azaldığı belirlenmiştir. Bu azalmanın B_4C partiküllerinin düşük yoğunluğundan kaynaklandığı belirtilmiştir. En yüksek sertlik değeri (290,70 HV) Al-40 B_4C kompozitte elde edilmiştir. En yüksek yoğunluk değeri ($2,62 g/cm^3$) ise Al-10 B_4C kompozit yapıda belirlenmiştir (Akçay vd., 2022). Karabacak ve Çanakçı, TM ile Al2024 matrise ağırlıkça %2,5 ve %5 oranlarında B_4C ve SiC takviye ederek kompozit malzeme üretmişlerdir. En yüksek sertlik (209,9 HB) ve eğilme dayanımı (799,2 MPa) ise Al2024-5 B_4C kompozitte tespit edilmiştir. Ayrıca, B_4C ve SiC takviyeli kompozitlerin korozyon dayanımının, saf Al2024 alaşımına kıyasla yaklaşık %87 oranında arttığı belirtilmiştir. Takviye partiküllerinin yüksek sertliğinden dolayı katkı oranının artmasıyla kompozitin mekanik özelliklerinde bir iyileşme gözlemlenmiştir (Karabacak & Çanakçı, 2023). Nagaral vd. karıştırmalı döküm yöntemi ile Al2024 alaşımına ağırlıkça %2, 4, 6 ve 8 oranlarında B_4C takviye edilerek üretilen kompozitlerin mikroyapılarını ve mekanik özelliklerini incelemişlerdir. Al2024 alaşımı ile karşılaştırıldığında, Al2024-8 B_4C kompozitinde sertlik, basma, çekme ve akma dayanımlarının sırasıyla %62,6, %51,4, %54,1 ve %55,5 oranında arttığı belirlenmiştir. Ayrıca takviye elemanının matris içerisinde homojen dağıldığı tespit edilmiştir (Nagaral vd., 2021). Shantharaj vd. çalışmalarında, karıştırmalı döküm yöntemiyle Al7075 alaşım matrisine ağırlıkça %3 ve %6 oranlarında B_4C ekleyerek kompozit malzemeler üretmişlerdir. Al7075-6 B_4C kompozitin, Al7075 alaşımına göre akma dayanımında %27,2 ve çekme dayanımında %21,8 oranında artış gösterdiği ifade edilmiştir. Çalışma sonucunda, B_4C takviye oranının artması ile kompozitlerin mekanik özelliklerinin iyileştiği belirlenmiştir (Shantharaj vd., 2022). Ramadoss

vd. tarafından yapılan çalışmada Al7075 matrisli B₄C (ağırlıkça %3, 6 ve 9) ve BN (ağırlıkça %3) takviyeli kompozitler karıştırılmalı döküm yöntemi ile üretilmiştir. Üretilen kompozitlerin mikroyapıları ve mekanik özellikleri incelenmiştir. En yüksek sertlik (~100 HRC), çekme dayanımı (~250 MPa) ve basma dayanımı (~550 MPa) Al7075-9B₄C-3BN kompozitinde elde edilmiştir. Ayrıca mikroyapı analizleri sonucunda takviye elemanlarının matris içinde homojen bir şekilde dağılması ve partikül boyutunun küçülmesi nedeniyle, katkı oranı arttıkça kompozitlerin mekanik özelliklerinin iyileştiği sonucuna varılmıştır (Ramadoss vd., 2020). Topcu vd. tarafından yapılan çalışmada toz metalürjisi yöntemiyle Al-B₄C kompozitleri üretilmiştir. Al matrise ağırlıkça %5, 10, 15 ve 20 oranlarında B₄C takviye ederek ürettikleri kompozitlerin mekanik özelliklerini incelemişlerdir. Bor karbür katkı oranının artması ile kompozitlerin sertlik değerinin arttığı ve gözeneklilik oranının azaldığı belirlenmiştir. Ancak katkı oranının artması ile darbe dayanımının azaldığını ifade etmişlerdir (Topcu vd., 2009). Meignanamoorthy vd. yaptıkları çalışmada toz metalürjisi yöntemi ile Al8079 matrisli B₄C takviyeli (ağırlıkça %5, 10 ve 15) kompozit malzemeler üretilmişlerdir. Üretilen kompozitlerin mekanik özelliklerini incelendiğinde kompozitlerin yoğunluğu, sertliği ve basma dayanımı katkı oranının artması ile artmıştır. Bu artışın sebebinin, takviye oranının artması ile yapı içerisindeki gözeneklilik oranının azalmasından kaynaklandığı belirtilmiştir. Sonuç olarak Al8079 matrise ağırlıkça %15 B₄C takviye edildiğinde kompozitin mekanik özelliklerinin geliştiği ifade edilmiştir (Meignanamoorthy vd., 2021).

Literatür çalışmaları incelendiğinde alüminyum matrisli B₄C takviyeli kompozitlerin üretilmesi ile ilgili birçok çalışma mevcuttur. Ancak bu çalışmalar arasında toz metalürjisi ve indüksiyonla sıcak presleme yöntemiyle Al7075-B₄C kompozitlerin üretildiği herhangi bir çalışmaya rastlanılmamıştır. Bu nedenle yapılan bu çalışmada toz metalürjisi ve sıcak presleme yöntemleri kullanılarak Al7075 matrise farklı katkı oranlarında (ağırlıkça %1, 3, 6, 9, 12, 15 ve 30) B₄C ilave edilerek kompozit malzemeler üretilmiştir. Üretilen Al7075-B₄C kompozitlerin mikroyapıları ve mekanik özellikleri incelenmiştir.

MATERYAL ve YÖNTEM

Materyal

Yapılan bu çalışmada matris malzemesi olarak Al7075 alaşımı ve takviye elemanı olarak B₄C kullanılmıştır. Al7075 alaşım tozu ve B₄C tozu Nanografi Teknoloji (Türkiye) firmasından temin edilmiştir. Al7075 alaşımı; dayanım ve tokluk değerinin yüksek ancak yoğunluğunun düşük olması gibi özelliklere sahip olması nedeniyle tercih edilmiştir. Kullanılan Al7075 alaşım tozu 2,81 g/cm³ yoğunluğa ve ~10 µm (partikül) boyutuna sahiptir. B₄C ise yüksek darbe dayanımı, yüksek aşınma direnci ve kimyasal eylemsizliğe sahiptir. Kimyasal eylemsizlik bor karbürün kimyasal tepkimelere karşı direncinin yüksek olduğunu ifade etmektedir. Bu direncin yüksek olması bor karbürün kompozit malzemelerde matris malzemesi ile tepkimeye girmeden takviye elemanı olarak kullanılabilmesini açıklamaktadır. Bu nedenle Al7075 alaşımına takviye elemanı olarak tercih edilmiştir. B₄C tozu 2,52 g/cm³ yoğunluğa, 2700-3500 HV sertliğe ve ~44 µm partikül boyutuna sahiptir (Chand vd., 2021; Ramadoss vd., 2020). Kullanılan matris ve takviye elemanının genel özellikleri Tablo 1'de verilmiştir (Şahin, 2018; Yıldırım, 2016).


Tablo 1. Al7075 ve B₄C'nin Genel Özellikleri

Malzeme	Yoğunluk (g/cm ³)	Çekme Dayanımı (MPa)	Elastisite Modülü (GPa)	Sertlik (HV)	Ergime Sıcaklığı (°C)
Al7075	2,81	221	71,7	68	635
B ₄ C	2,52	155-162	290-450	2700-3500	2400

Yöntem

Yürütülen çalışmada toz metalürjisi ve sıcak presleme yöntemleri kullanılarak Al7075 matrisli B₄C takviyeli kompozitler üretilmiştir. Üretimin akış şeması Şekil 1'de verilmiştir. Öncelikle Al7075 tozu ısıtıcılı manyetik karıştırıcıda etanol ile birlikte 20 dk süresince 400 dev/dk hızda karıştırılmıştır. Eş zamanlı olarak B₄C tozu yüksek enerjili bilyalı değirmende 60 dk süresince 1200 dev/dk hızda öğütülmüştür. Sonrasında Al7075-etanol karışımı azar azar B₄C-etanol karışımı içerisine aktararak manyetik karıştırıcıda 20 dk süresince 400 dev/dk hızda karıştırılmıştır. Bu karışımdan etanolün uzaklaştırılması amacıyla karışım, filtrelenmiştir. Filtrelenen toz karışımdan nemi uzaklaştırmak için toz karışımı etüv fırında 45°C sıcaklıkta 16 saat süresince kurutulmuştur. Ardından tozlara 800 MPa basınç altında hidrolik pres makinesinde şekillendirme (sıkıştırma) işlemi uygulanmıştır. 11,5×11,5×4,5 mm boyutlarında numuneler elde edilmiştir. Elde edilen ham numunelere mukavemet kazandırmak amacıyla numuneler

60 dk süresince 600°C sıcaklıkta sinterlenmiştir. Sinterleme işlemi sonrasında numuneler oda sıcaklığında soğumaya bırakılmıştır. Ardından numunelere sıcak presleme işlemi uygulanmıştır. İlk olarak kompozit numuneler 70 mm çapındaki grafit kalıp içerisinde konularak 25 MPa basınç altında sıkıştırılmıştır. 41 sn'de 500°C sıcaklığa ısıtılmış, 30 sn süresince 500°C sıcaklıkta bekletilmiş ve 10 sn süresince soğutulmuştur. Soğutma işlemi ise 4 mm çapta ve 0,5 mm et kalınlığındaki bakır borularla sağlanmıştır. Numunelerin yüzeyindeki pürüzlerin giderilmesi amacıyla numuneler 600, 1200 ve 2500 gritlik su zımparaları kullanılarak 15 dk süresince zımparalanmıştır. Sonrasında numune yüzeyleri elmas solüsyonla elmas çuha üzerinde 15 dk boyunca parlatılmıştır. Üretim sonunda elde edilen numunelere mikroyapı analizleri ve mekanik testler uygulanmıştır.



Şekil 1. Toz Metalürjisi ve Sıcak Presleme Yöntemiyle Al7075-B₄C Kompozit Üretimi

Matris ve takviye malzemesi olarak kullanılan tozların ortalama partikül boyutları, Malvern marka Mastersizer 3000 model ortalama partikül boyutu ölçüm cihazı kullanılarak belirlenmiştir. Tozların yüzey yapısını, numunelerin kırık

yüzey görüntülerini ve element dağılım haritalarını incelemek için Jeol marka JSM-7001F model taramalı elektron mikroskopu (SEM) kullanılmıştır. Ayrıca, takviye malzemesinin matris içinde dağılımı enerji dağıtıcı X-ışını (EDX) analizi ile belirlenmiştir. Son olarak, numunelerin faz analizi Rigaku marka Smartlab model X-ışını kırınım cihazı (XRD) kullanılarak yapılmıştır.

Kompozit numunelerin deneysel yoğunlukları (ρ_D) Arşimet prensibi kullanılarak belirlenmiştir (Eşitlik 1). Öncelikle numunelerin suda asılı kütlesi (m_A), suya doymuş kütlesi (m_D) ve kuru kütleleri (m_K) tespit edilmiştir. Her numuneden 5 ölçüm alınarak ortalaması hesaplanmış ve deneysel yoğunluk belirlenmiştir.

$$\rho_D = [m_K / (m_D - m_A)] \rho_{SU} \quad (1)$$

Ardından kompozit numunelerin teorik yoğunluğu (ρ_K) Eşitlik 2 ile belirlenmiştir. Eşitlikteki ρ_M ve %M sırasıyla Al7075 alaşımının teorik yoğunluğu (2,81 g/cm³) ve ağırlıkça katkı oranıdır. ρ_{TK} ve %TK ise B₄C'nin teorik yoğunluğu (2,52 g/cm³) ve ağırlıkça katkı oranıdır.

$$\rho_K = (\rho_M \times \%M) + (\rho_{TK} \times \%TK) \quad (2)$$

Numunelerin gözeneklilik oranı (%G) ise Eşitlik 3 ile hesaplanmıştır. Gözeneklilik oranı kompozitlerin mekanik özelliklerini değerlendirmek için önemli bir parametredir. Çünkü yapı içerisinde gözenek (por) oluşması başta sertlik ve basma dayanımı olmak üzere diğer özelliklerin kötüleşmesine yol açmaktadır. Bu gözenekler, malzemeye herhangi bir yük uygulandığı esnada gerilme yığılmalarına yol açarak yapıda erken hasar oluşumuna sebep olmaktadır. Bu nedenle kompozit malzemelerde gözeneklilik (porozite) oranının minimuma indirilmesi malzeme dayanımı açısından oldukça önemlidir.

$$\%G = (1 - (\rho_D / \rho_K)) \times 100 \quad (3)$$

Al7075-B₄C kompozitlerin deneysel yoğunluk ölçümü, Vickers sertlik ölçümü ve basma dayanımı testleri gerçekleştirilmiştir. Al7075 alaşımı ve Al7075-B₄C kompozitlerin sertlikleri, Vickers sertlik ölçme yöntemiyle belirlenmiştir. Mikro Vickers sertlik ölçme cihazı (HV1000B) kullanılarak numune yüzeyine 15 s boyunca 1,961 N'luk yük uygulanmıştır. Yük kaldırıldıktan sonra kare tabanlı piramitin köşegen uzunlukları ölçülerek Vickers sertlik değerleri hesaplanmıştır. Her numuneden en az 7 ölçüm alınarak numunelerin ortalama sertlik değeri belirlenmiştir.


Üretilen kompozit numunelerin basma dayanımı ise Mares marka Tst-10t model basma cihazı kullanılarak ölçülmüştür. Numunelere önce 1 mm/dk hızla 5 MPa'lık bir ön yük uygulanmış, ardından 3 mm/dk hızla basma testi gerçekleştirilmiştir. Basma testi sırasında numune, test cihazına yükü homojen dağıtacak şekilde yerleştirilmiştir. Ayrıca basma testinin doğru bir şekilde uygulanması amacıyla numuneler 11,5×11,5×4,5 boyutlarında üretilmiştir. Her numune için en az üç test yapılarak elde edilen verilerin ortalaması alınmış ve kompozitlerin ortalama basma dayanımı belirlenmiştir.

BULGULAR VE TARTIŞMA


Karakterizasyon

Çalışmada kullanılan matris malzemesi (Al7075 alaşımı) ve takviye elemanı (B₄C) tozlarının SEM görüntüleri Şekil 2'de verilmiştir. Şekil incelendiğinde Al7075 alaşımının küresel bir yapıda olduğu görülmektedir. Takviye elemanı olan bor karbürün ise keskin kenarlı bir yapıda olduğu tespit edilmiştir.

Çalışma kapsamında Al7075 alaşımı ve B₄C tozlarının faz analizleri X-ışını kırınımı (XRD) cihazı kullanılarak gerçekleştirilmiştir (Şekil 3). XRD analizleri, malzemelerin kristal yapıları ve faz dağılımları hakkında bilgi sağlamak amacıyla kullanılmaktadır. Bu analizde, tozların kırınım desenleri incelenmiş ve Al7075 (JCPDS kart no:89-4184) ile B₄C'nin (JCPDS kart no:00-35-0798) karakteristik kırınım açıları belirlenmiştir. Al7075 alaşımının kırınım açıları, $2\theta = \sim 38^\circ, 45^\circ, 66^\circ$ ve 78° olarak tespit edilmiştir. B₄C'nin kırınım açıları ise $2\theta = \sim 22^\circ, 23^\circ, 26^\circ, 32^\circ, 35^\circ, 38^\circ, 39^\circ, 50^\circ, 54^\circ, 62^\circ, 64^\circ, 67^\circ, 72^\circ, 74^\circ, 75^\circ$ ve 78° 'dir.




Şekil 2. a. Al7075 Alaşım ve b. B₄C Tozunun SEM Görüntüleri



Şekil 3. a. Al7075 Alaşımı ve b. B₄C Tozlarına Ait XRD Örgü Desenleri

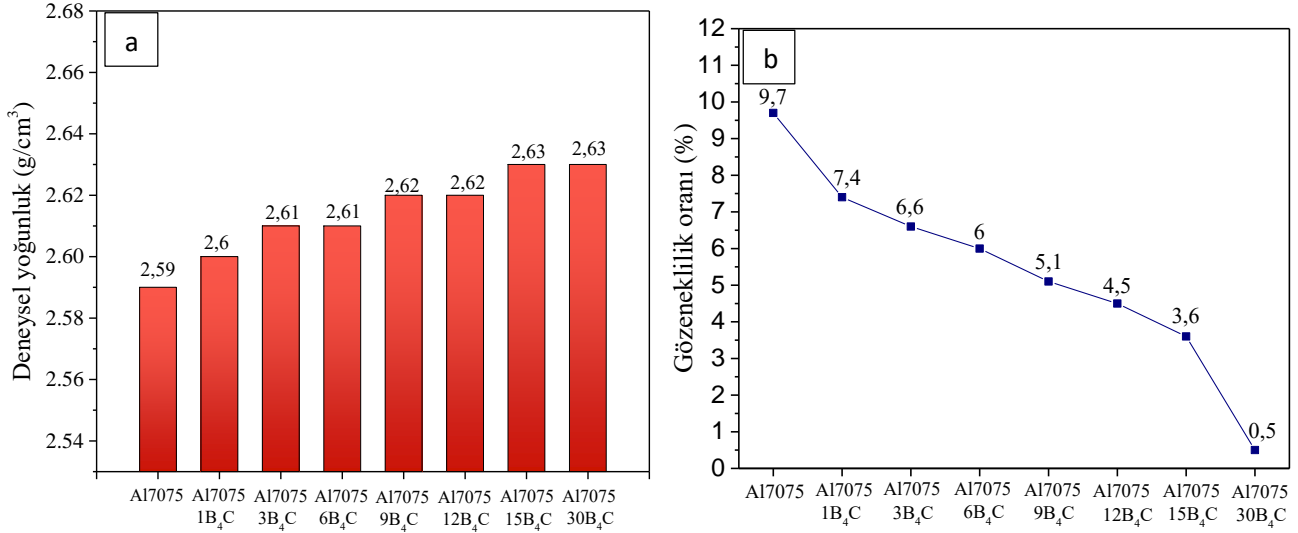
Kompozitlerin üretilmesinde kullanılan Al7075 alaşım ve B₄C tozlarına ait partikül boyut dağılımı Şekil 4'te gösterilmiştir. Partikül boyut dağılımı analizine göre Al7075 alaşım tozlarının ~10 µm boyutuna ve B₄C partiküllerinin ise ~44 µm boyutuna sahip olduğu gözlemlenmiştir.



Şekil 4. a. Al7075 Alaşımı ve b. B₄C Tozunun Partikül Boyut Dağılımı


Mekanik Test Sonuçları

Al7075 alaşımı ve Al7075-B₄C kompozitlerin yoğunluk ve gözeneklilik oranı değerleri Şekil 5'te verilmiştir. Şekil incelendiğinde maksimum yoğunluk (2,63 g/cm³) ve minimum gözeneklilik oranı (%0,5) Al7075-30B₄C kompozitte belirlenmiştir. B₄C katkısı kompozitin yoğunluğunu ve gözeneklilik oranını olumlu etkilemiştir. Ayrıca sıcak presleme işlemi sırasında kompozite uygulanan sıcaklık ve basıncın etkisiyle taneler birbirlerine yaklaşarak boyun vermiştir. Dolayısıyla kompozitin deneysel yoğunluğu artmış ve gözeneklilik oranı azalmıştır.



Şekil 5. Al7075 Alaşımı ve Al7075-B₄C Kompozitlerin a. Yoğunluk ve b. Gözeneklilik Oranı Değerleri

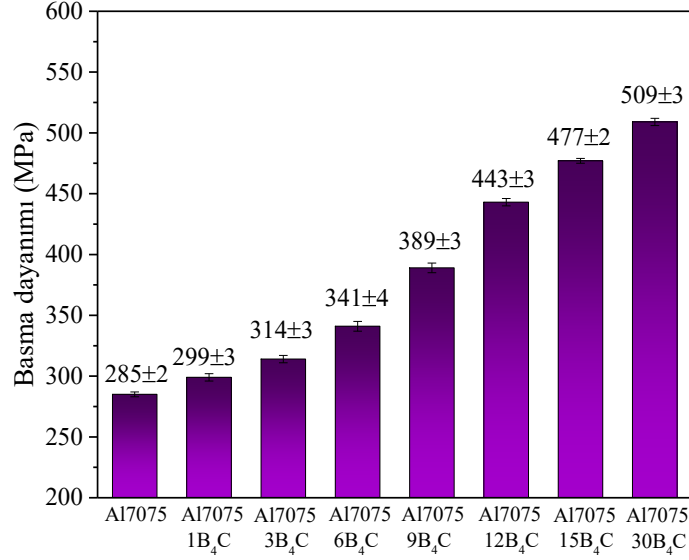
Şekil 6'da Al7075 alaşımı ve Al7075-B₄C kompozitlerin Vickers sertlik değerleri verilmiştir. En yüksek sertlik değeri Al7075-30B₄C kompozitte 226 HV olarak elde edilmiştir. Al7075 alaşımına kıyasla Al7075-30B₄C kompozitinde sertlik değeri %76,6 oranında artmıştır. Bor karbürün yüksek sertliğinden dolayı katkı oranı arttıkça kompozitin sertliğinde artış meydana gelmiştir. Sert takviye partiküllerinin yapı içerisinde dislokasyonlara karşı bariyer görevi görerek kompozitin Vickers sertliğini iyileştirdiği düşünülmektedir.



Şekil 6. a. Al7075 Alaşımı ve b. Al7075-B₄C Kompozitlerin Vickers Sertlik Değerleri


Şekil 7'de ise Al7075 alaşımı ve Al7075-B₄C kompozitlerin basma dayanımı değerleri verilmiştir. En yüksek basma dayanımı (509 MPa) Al7075-30B₄C kompozit yapıda elde edilmiştir. Al7075 alaşımının basma dayanımına kıyasla bu kompozitin basma dayanımının %79 oranında arttığı tespit edilmiştir. Bor karbürün yüksek sertliğinden dolayı

B₄C katkı oranının artmasıyla kompozitin basma dayanımında artış meydana geldiği görülmektedir. Ancak çalışmanın amacı minimum takviye oranı ile yüksek mekanik özelliklere sahip kompozit malzeme elde etmek olduğundan dolayı maksimum bor karbür katkı oranı %30 olacak şekilde belirlenmiştir (Zhao vd., 2016). Katkı oranı optimum değerden daha fazla ise sert takviye partikülleri matris içerisinde homojen dağılmamaktadır. Bundan dolayı yapıda gözenek oluşması nedeniyle kompozitin basma dayanımı başta olmak üzere diğer mekanik özelliklerinde kötüleşme meydana gelebilmektedir.




Şekil 7. Al7075 ve Al7075-B₄C Kompozitlerin Basma Dayanımı Değerleri

Al7075 matrisli bor karbür takviyeli kompozitlerin XRD faz analiz sonuçları Şekil 8’de gösterilmiştir. Alüminyum “Δ” simgesi ve B₄C ise “○” simgesi ile temsil edilmiştir. XRD örgü desenleri incelendiğinde tüm piklerin alüminyum ve bor karbüre ait olduğu belirlenmiştir. Ayrıca Al₄C₃ gibi istenmeyen ikincil faz oluşumu gözlenmemiştir. Al₄C₃ gibi istenmeyen fazlar kompozit malzemenin yapısına hasar verebilir ve mekanik özelliklerinin gelişmesini olumsuz etkileyebilir. Yüksek sıcaklıklarda oluşabilen ikincil fazlar malzemenin erken kırılmasına yol açabilir, matris ile takviye arasındaki arayüzeyi olumsuz etkileyebilir ve yapı içerisinde gözenek oluşumuna sebep olabilir. Bu sebeplerden dolayı ikincil faz oluşumu kompozit malzemenin yapısına zarar verebilmektedir (Shorowordi vd., 2003; Şenel vd., 2022). Ancak Al₄C₃ oluşumu için kritik sıcaklık 830°C’dir. Bu çalışmada 600°C sıcaklıkta sinterleme ve 500°C sıcaklıkta sıcak presleme işlemi yapıldığından ikincil faz oluşumu gözlenmemiştir.



Şekil 8. Al-B₄C Kompozite Ait XRD Faz Analizi



Şekil 9. a. Al7075 Alaşımına, b. Al7075-1B₄C, c. Al7075-3B₄C, d. Al7075-6B₄C, e. Al7075-9B₄C, f. Al7075-12B₄C, g. Al7075-15B₄C ve h. Al7075-30B₄C Kompozitlere Ait Kırık Yüzey SEM Görüntüleri

Al7075 alaşımı, Al7075-1B₄C, Al7075-3B₄C, Al7075-6B₄C, Al7075-9B₄C, Al7075-12B₄C, Al7075-15B₄C ve Al7075-30B₄C kompozitlerin kırık yüzey SEM görüntüleri Şekil 9'da verilmiştir. SEM görüntüleri incelendiğinde; bor karbür partiküllerinin matris yapı içerisinde homojene yakın dağıldığı belirlenmiştir. Ağırlıkça %30 B₄C katkı oranında taneler arası etkileşimin arttığı ve malzemenin mikroyapısının daha yoğun bir hale geldiği gözlemlenmiştir. Ayrıca uygulanan ısıl işlemin (sinterleme ve sıcak presleme) etkisiyle yapı içerisindeki gözenekliliğin azaldığı ve buna bağlı olarak mikroyapının iyileştiği tespit edilmiştir. SEM görüntüleri ile bor karbür partiküllerinin homojene yakın dağılımı ve ısıl işlemin etkisi ile Al7075-B₄C kompozitlerin dayanımının arttığı ve mekanik özelliklerinin geliştiği doğrulanmıştır.


Şekil 10'da Al7075-30B₄C kompozitin kırık yüzeyine ait SEM-EDX görüntüleri ve element dağılım haritası gösterilmiştir. Kompozit yapı içerisindeki elementler (Al, Zn (çinko), Cu (bakır), Mg (magnezyum), B (bor), O (oksijen)) farklı renkler ile temsil edilmiştir ve her bir elementin yapı içerisindeki dağılımı gösterilmiştir. Şekildeki Al, Zn, Fe, Mg ve O elementleri matris malzemesi olan Al7075 alaşımının varlığını doğrulamaktadır. Özellikle Al, Zn ve Mg elementleri Al7075 alaşımının ana bileşen olduğunu göstermektedir. B elementi ise takviye elemanı olan B₄C'nin varlığını göstermektedir. B₄C, malzemenin mekanik özelliklerinin gelişmesinde önemli bir rol oynamıştır. Al7075 matrise bor karbür ilave edilmesiyle kompozitin mekanik özelliklerinde iyileşme meydana gelmiştir. Yapı içerisinde gözenek oranının azalması ve partiküllerin homojen dağılması mekanik özelliklerin gelişmesine katkı sağlamıştır. Ayrıca bor karbürün yüksek sertliğe sahip olması da mekanik özellikleri doğrudan etkilemiştir. Bor karbür partiküllerinin yüksek sertliğine bağlı olarak katkı oranının artması ile kompozitin sertliğinde ve basma dayanımında artış gerçekleşmiştir. Böylece kompozitin mekanik özellikleri iyileşmiştir (Angadi vd., 2025; Bharathiraja ve Xavior, 2024). SEM-EDX analizi bu takviye partikülünün varlığını ve homojene yakın dağılımını doğrulamıştır. Element dağılım haritası, her bir elementin kompozit yapı içerisinde dağılımını gösterdiğinden dolayı malzemenin mikroyapısının yorumlanması için önemli bir araçtır.

SONUÇLAR

Yapılan çalışmada Al7075 matrisli B₄C takviyeli kompozit malzemeler toz metalürjisi ve sıcak presleme işlemleri kullanılarak üretilmiştir. Üretilen numunelerin mekanik özellikleri (yoğunluk, gözeneklilik oranı, Vickers sertliği ve basma dayanımı) ve mikroyapısı incelenmiştir. Elde edilen sonuçlar aşağıda sıralanmıştır:

- Al7075 matrise B₄C takviyesi yapıldığında kompozitin mekanik özelliklerinin iyileştiği gözlemlenmiştir. Al7075-B₄C kompozitleri arasında en yüksek deneysel yoğunluk (2,63 g/cm³), Vickers sertliği (226 HV), basma dayanımı (509 MPa) ve en düşük gözeneklilik oranı (%0,5) ağırlıkça %30 B₄C katkı oranında elde edilmiştir. Çünkü takviye elemanının yüksek sertliği ve sıcak preslemenin etkisi ile katkı oranı arttıkça kompozitin mekanik özelliklerinin iyileştiği belirlenmiştir.
- Al7075-B₄C kompozitte Al7075 alaşımına kıyasla deneysel yoğunluk, Vickers sertliği ve basma dayanımı değerleri sırasıyla %1,54, %76,6 ve %79 oranında artış göstermiştir. Bu artışın sebebi B₄C'nin yüksek sertliğe sahip olmasıdır.
- Al7075-30B₄C kompozitlerin SEM analizleri sonucunda takviye partiküllerinin matris içerisinde homojene yakın dağıldığı belirlenmiştir. XRD faz analizi sonucunda ise kompozit yapılarda Al₄C₃ gibi herhangi bir istenmeyen ikincil faz tespit edilmemiştir. Ayrıca Al7075-B₄C kompozitlerde katkı oranının artmasına bağlı olarak daha yoğun bir mikroyapı gözlemlenmiştir.
- Al7075 matrise B₄C katkısı ile kompozitin mekanik özelliklerinde gelişme meydana gelmiştir. Yapı içerisinde gözenek oranının azaltılması ve partiküllerin homojene yakın dağılması mekanik özelliklerin gelişmesine katkı sağlamıştır.

Sonuç olarak Al7075 matrise ağırlıkça %30 oranında B₄C takviye edildiğinde üretilen kompozit malzemenin mekanik özelliklerinin ve mikroyapısının iyileştiği belirlenmiştir. Gelişmiş mekanik özelliklere ve mikroyapıya sahip bu kompozit malzeme; havacılık, otomotiv ve savunma sanayi başta olmak üzere birçok alanda kullanılabilir.



Şekil 10. Al-%30B₄C Kompozite ait a. SEM, b. SEM-EDX Görüntüsü ve c-h. Element Dağılımları

KAYNAKLAR

- Akçay, S. B., Varol, T., Güler, O., & Aksa, H. C. (2022). Effect of Boron Carbide Reinforcement Amount on the Properties of Boron Carbide Reinforced Al Based Composites. *El-Cezeri Journal of Science and Engineering*, 9(2), 869–881. <https://doi.org/10.31202/ecjse.1023910>
- Angadi, S. B., Kumar, S., Nagaral, M., Auradi, V., Valukula, B. (2025). Effect of Ceramic Boron Carbide Particles Addition on the Mechanical and Microstructural Characteristics of Al7020 Alloy Composites. *Mechanics of Advanced Composite Structures*, 12(1), 169-180. <https://doi.org/10.22075/MACS.2024.33857.1655>
- Bharathi, P., & Kumar, T. S. (2024). Microstructure and Corrosion Characteristics of Dual Reinforced (SiC–B₄C) Al Matrix Composites Produced by Powder Metallurgy Process. *Journal of Materials Engineering and Performance*. <https://doi.org/10.1007/s11665-024-09772-1>
- Bharathiraja, P., Xavier, A. (2024). Effect of B₄C and Graphene on the Microstructural and Mechanical Properties of Al6061 Matrix Composites. *Journal of Materials Research and Technology*, 31, 496-505. <https://doi.org/10.1016/j.jmrt.2024.06.098>
- Chand, S., Chandrasekhar, P., Roy, S., & Singh, S. (2021). Influence of Dispersoid Content on Compressibility, Sinterability and Mechanical Behaviour of B₄C/BN Reinforced Al6061 Metal Matrix Hybrid Composites Fabricated via Mechanical Alloying. *Metals and Materials International*, 27(11), 4841–4853. <https://doi.org/10.1007/s12540-020-00739-0>

- Chouhan, M., Thakur, L., & Kumar, P. (2024). Parametric Optimization and Impact Behaviour of AA7075/SiC FGM Fabricated by Hot Compaction Powder Metallurgy Process. *Materials Today Communications*, 38(December 2023), 107833. <https://doi.org/10.1016/j.mtcomm.2023.107833>
- Karabacak, A. H., Çanakçı, A. (2023). Farklı Seramik Takviyeli Al Alaşım Matrisli Nanokompozitlerin Mekanik ve Korozyon Özelliklerinin İncelenmesi. *Karadeniz Fen Bilimleri Dergisi*, 13(1), 1–14. <https://doi.org/10.31466/kfbd.1085130>
- Meignanamoorthy, M., Ravichandran, M., Mohanavel, V., Afzal, A., Sathish, T., Alamri, S., Khan, S. A., Saleel, C. A. (2021). Microstructure, Mechanical Properties, and Corrosion Behavior of Boron Carbide Reinforced Aluminum Alloy (Al-Fe-Si-Zn-Cu) Matrix Composites Produced via Powder Metallurgy Route. *Materials*, 14(15), 4315. <https://doi.org/10.3390/ma14154315>
- Nagaral, M., Deshapande, R. G., Auradi, V., Boppana, S. B., Dayanand, S., & Anilkumar, M. R. (2021). Mechanical and Wear Characterization of Ceramic Boron Carbide-Reinforced Al2024 Alloy Metal Composites. *Journal of Bio-and Tribo-Corrosion*, 7(1), 1–12. <https://doi.org/10.1007/s40735-020-00454-8>
- Rajanish, M., Avilasha, B. G., Katti, P. P., Ashwini, M. V., Sudarshan, T. A., Anantha Padmanabham, T. C., Veerasha, G., Nagaraj, P., Hemanth Raju, T., & Udayashankar, S. (2024). Microstructure, Hardness and Wear Study of Al7075-B4C Metal Matrix Composites. *Journal of The Institution of Engineers (India): Series D*, 0123456789. <https://doi.org/10.1007/s40033-024-00793-7>
- Ramadoss, N., Pazhanivel, K., & Anbuezhayan, G. (2020). Synthesis of B₄C and BN reinforced Al7075 hybrid composites using stir casting method. *Journal of Materials Research and Technology*, 9(3), 6297–6304. <https://doi.org/10.1016/j.jmrt.2020.03.043>
- Shorowordi, K. M., Laoui, T., Haseeb, A. M. A., Celis, J. P., & Froyen, L. (2003). Microstructure and interface characteristics of B₄C, SiC and Al₂O₃ reinforced Al matrix composites: a comparative study. *Journal of Materials Processing Technology*, 142(3), 738-743.
- Şahin, O. (2018). TiB₂ ve B₄C Takviyeli Kompozitlerin Toz Metalürjisi Yöntemiyle Üretilirliğinin İncelenmesi. Yüksek Lisans Tezi. Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Svnma Teknolojileri Anabilim Dalı. Kırıkkale, 119s.
- Şenel, M. C., Kanca, Y., & Gürbüz, M. (2022). Reciprocating Sliding Wear Properties of Sintered Al-B4C Composites. *International Journal of Minerals, Metallurgy and Materials*, 29(6), 1261-1269.
- Shantharaj, P., Prashanth, A. S., Nagaral, M., Bharath, V., Auradi, V., & Dharshan, K. (2022). Microstructure, Tensile and Compression Behaviour of B₄C Particles Reinforced Al7075 Matrix Composites. *Materials Today: Proceedings*, 52, 1135–1139. <https://doi.org/10.1016/j.matpr.2021.11.008>
- Sharma, S. K., Saxena, K. K., Salem, K. H., Mohammed, K. A., Singh, R., & Prakash, C. (2024). Effects of Various Fabrication Techniques on the Mechanical Characteristics of Metal Matrix Composites: A Review. *Advances in Materials and Processing Technologies*, 10(2), 277–294. <https://doi.org/10.1080/2374068X.2022.2144276>
- Tharanikumar, L., Mohan, B., & Anbuezhayan, G. (2024). Synthesization and Characterization of Silicon Carbide and Boron Nitride-Reinforced Al–Zn–Mg Alloy Hybrid Nanocomposites Using Squeeze Casting Method. *International Journal of Metalcasting*, 18(2), 997–1011. <https://doi.org/10.1007/s40962-023-01070-1>
- Topcu, I., Gulsoy, H. O., Kadioglu, N., Gulluoglu, A. N. (2009). Processing and Mechanical Properties of B₄C Reinforced Al Matrix Composites. *Journal of Alloys and Compounds*, 482(1-2), 516-521. <https://doi.org/10.1016/j.jallcom.2009.04.065>
- Yıldırım, M. (2016). Mekanik Alaşımlama Yöntemi ile AA7075-Karbon Nanotüp Takviyeli Metal Matrisli Kompozit Üretimi Karakterizasyonu ve Aşınma Davranışlarının İncelenmesi. Doktora Tezi. Karabük Üniversitesi Fen Bilimleri Enstitüsü İmalat Mühendisliği Anabilim Dalı. Karabük, 134s.
- Zhao, Q., Yu, L., Xi, L., & Ren, L. (2016). Microstructure and Dry-Sliding Wear Behavior of B₄C Ceramic Particulate Reinforced Al 5083 Matrix Composite. *Metals*, 6(227): 1.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi :13.11.2024
Kabul Tarihi :23.12.2024

Received Date :13.11.2024
Accepted Date : 23.12.2024

BARİT KATKILI BETONLARDA RADYASYON GEÇİRGENLİĞİNİN REGREASYON ANALİZİ İLE MODELLENMESİ

MODELING OF RADIATION PERMEABILITY IN BARITE ADDITIVE CONCRETES USING REGRESSION ANALYSIS

Aytaç DİNÇER¹ (ORCID: 0009-0009-4767-4794)

¹ Kahramanmaraş Sütçü İmam Üniversitesi, İnşaat Mühendisliği Bölümü, Kahramanmaraş, Türkiye

*Sorumlu Yazar / Corresponding Author: Aytaç DİNÇER, aytacdincer@hotmail.com

ÖZET

Bu çalışmada, beton numunelerin içeriğindeki barit oranı, sıcaklık, basınç dayanımı, kuru birim ağırlık, doymun birim ağırlık parametrelerinin radyasyon geçirgenliği ile arasındaki ilişkiyi belirlemek amacıyla regrasyon analizi yapılmıştır. Regrasyon analizi, deney sonuçlarından elde edilen farklı parametrelerdeki verilerden en uygun modeli üretebilmek için çeşitli matematiksel fonksiyonlara olanak tanır. Çalışmada, parametreler arasında en uygun korelasyonu sağlayan denklem, regresyon analiziyle elde edilmiştir. Ayrıca, oluşturulan modelin istatistiksel güvenilirliği ve geçerliliği yazılımın sağladığı R² (Coefficient of Multiple Determination) değeri ve diğer istatistiksel parametreler kullanılarak değerlendirilmiştir. Bu sayede, beton numunelerindeki parametrelerin radyasyon geçirgenliği üzerindeki etkileri, matematiksel olarak doğrulanmış bir modelle öngörülebilir hale getirilmiştir. Çalışmada 6 farklı durum için 6 model üretilmiştir. Oluşturulan modellerde en yüksek R² değeri 0.99 olduğu görülmüştür.

Anahtar Kelimeler: Barit, beton, basınç dayanımı, radyasyon geçirgenliği, sayısal modelleme

ABSTRACT

In this study, DataFit 9.0 software was used to determine the relationship between the barite ratio, temperature, compressive strength, dry unit weight, and saturated unit weight parameters in the content of concrete samples and radiation permeability. Numerical modeling was performed as a result of experimental data belonging to different parameters. DataFit allows various mathematical functions to produce the most appropriate model from the data in different parameters obtained from the experimental results. In the study, the equation providing the most appropriate correlation between the parameters was obtained by regression analysis. In addition, the statistical reliability and validity of the created model were evaluated using the R² (Coefficient of Multiple Determination) value provided by the software and other statistical parameters. In this way, the effects of the parameters in the concrete samples on radiation permeability were made predictable with a mathematically verified model. In the study, 6 models were produced for 6 different situations. The highest R² value in the created models was observed to be 0.99.

Keywords: Barite, concrete, compressive strength, numerical modeling, radiation permability

GİRİŞ

Beton sahip olduğu üstün dayanım, dayanıklılık ve ekonomik özellikleri sayesinde inşaat sektörünün en çok kullanılan yapı malzemesidir. Çimento, kum, su, farklı agrega çeşitleri, gerektiğinde mineral ve kimyasal katkıların kullanılması nedeniyle beton heterojen bir yapıya sahiptir. Nükleer santral sayısındaki artış, nükleer silahların savaşlarda kullanma olasılığı, radyasyon yayan cihazların çoğalması ve teknolojinin gelişimi, radyasyon kaynaklı zararlı etkilerden korunmak için önlem almayı zorunlu hale getirmektedir. Radyasyon kaynaklarının yaydığı zararlı etkilerin yapı elemanları vasıtasıyla absorbe edilerek en aza indirilmesi gerekmektedir. Ağır agregalar ile üretilen

ToCite: DİNÇER, A., (2025). BARİT KATKILI BETONLARDA RADYASYON GEÇİRGENLİĞİNİN REGREASYON ANALİZİ İLE MODELLENMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 472-478.

betonların birim ağırlıklarında meydana gelen artışların radyasyon etkisine karşı koruyucu özelliğini arttırdığı ifade edilmektedir. Alfa (α), Beta (β), Gama (γ), x ve nötron ışın ve parçacık yayımların ortaya çıkardığı zararlı etkilerinden korunmak için zırh adı verilen tabakalar oluşturulmaktadır (Çoşkun A., 2010). Ortaya çıkan bu zararlı ışınların ağır betonlar tarafından tutulma özelliği bulunduğu belirtilmektedir. Dahiru (2008), yaptığı çalışmada barit agregalı ağır betonun radyasyon etkisine karşı kalkan görevi yaptığını belirtmiştir. Demir (2010), ışın iletim yöntemi ile kolemanit, barit ve normal agrega ile üretilen betonların doğrusal ve kütle zayıflatma katsayılarında barit ve kolemanit katkılı betonların soğurucu özelliklerinin bulunduğu belirtmiştir (Dahiru, 2008; Bashter et al., 1996). Barit katkı oranı arttıkça basınç dayanımlarının çok az miktarda düşüş göstermesinin sebebi olarak barit katkılı numunelerin S/Ç oranına bağlı olarak baritin beton içerisinde homojen bir şekilde karıştırılmamasından kaynaklandığı düşünülmektedir. Bu durumda barit katkılı çalışmalarda katkı malzemesi önceliği olarak hava sürükleyici katkı malzemesinin kullanılmasının önemi vurgulanmaktadır. Bu ifade literatür tarafından da desteklenmektedir (Dinçer 2024).

Bu çalışmada, barit katkılı betonların radyasyona karşı dayanım özelliklerinin daha iyi anlaşılması hedeflenmiştir. Barit katkılı betonun farklı kombinasyonlarının, basınç dayanımı, sıcaklık, doygun birim ağırlık, kuru birim ağırlık parametrelerinin radyasyon geçirgenliği üzerindeki etkileri incelenmiştir. Bu parametreler arasındaki ilişkileri belirlemek için DataFit programı kullanılarak sayısal bir model oluşturulmuştur. Barit katkılı beton numunelerinin radyasyon geçirgenliğine etkisini inceleyen bu modelleme çalışmasında, en yüksek R² değeri göz önünde bulundurularak bir formül tavsiye edilmiştir. Deneysel veriler, %95 güven aralığında analiz edilmiş ve bu sonuçlar barit katkılı betonların performansını optimize etme açısından önemli bulgular sunmuştur. Elde edilen bu modelleme, barit katkılı betonların radyasyon geçirgenliğinin hangi parametrelerle daha güvenilir bir şekilde hesaplanabilmesini belirlemeye yardımcı olacaktır.

MATERYAL VE YÖNTEM

Regresyon Analizi

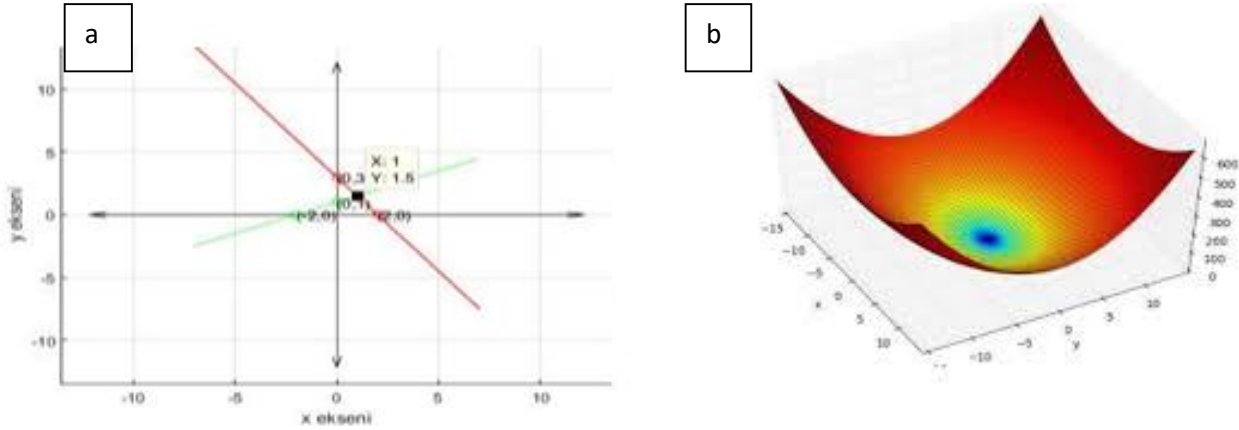
İki veya daha fazla değişkenlerin birbiri arasındaki ilişkiyi incelemek ve bilinmeyen verileri tahmin etmek amacıyla regresyon analizi kullanılmıştır. Regresyon analizleri, tekli ve çoklu regresyon olmak üzere değişken sayısına bağlı olarak ikiye ayrılmaktadır. Bir bağımlı ve bir bağımsız değişken arasındaki doğrusal ilişkiyi tanımlayan bir denklem üreten analize tekli regresyon analiz denir. Çoklu regresyon analizleri ise bir bağımlı değişken ile birden fazla bağımsız değişkenin yer aldığı modelleri kapsar. Bu çalışmada, grafiksel analizleri kolaylaştıran ve istatistiksel analizi basitleştiren kullanıcı dostu bir yazılım olan DataFit 9.0 programı kullanılmıştır. DataFit programı, regresyon modellerini çözümlenmek için belirli uygunluk kriterlerine (Korelasyon Katsayısı, Kalan Kareler Toplamı, Standart Hata ve Düzeltilmiş Korelasyon Katsayısı) göre otomatik olarak sıralar. Bu çalışmada, basınç dayanımı, sıcaklık, doygun kuru birim ağırlık ve kuru birim ağırlık gibi bağımsız değişkenler analiz edilmiştir. Radyasyon geçirgenliği ise çoklu regresyon modellerinde bağımlı değişken olarak ele alınmıştır. Ayrıca, çoklu regresyon modellerinde, bağımlı değişkenin tahminini en iyi şekilde sağlayacak bağımsız değişken kombinasyonlarını belirlemek amacıyla bir değişken seçim algoritması uygulanmıştır (Flynn, 2003). Bu yaklaşım, beton numunelerinin radyasyon geçirgenliği üzerindeki etkilerini anlamaya yönelik daha doğru tahminler elde etmeyi sağlamıştır.

Data Fit

Bu çalışmada kullanılan DataFit 9.0 programı, çalışma alanına ait parametrelerin değerlerini en iyi şekilde uyarlayabilmek için grafikler ve denklemler kullanarak çeşitli modeller üretmektedir. Bu modeller arasından en yüksek uyumluluğa sahip olanı belirlemek, çalışmanın temel amacını oluşturmaktadır.

Analizde birden fazla olabilen giriş verileri ve tek bir çıkış verisi olmak üzere iki ana veri girişi bulunmaktadır. Program, bu veriler üzerinden analiz yaparken lineer ve nonlineer analiz yöntemlerini kullanır. Her iki analiz türünde de belirli denklemler temel alınır. Lineer Denklem: Terimleri yalnızca sabit veya birinci dereceden olan bu denklemler, değişkenlerinin düzlem veya uzayda bir doğru şeklini alması nedeniyle doğrusal denklem olarak adlandırılır (Şekil 1.a).

Nonlinear Denklem: Lineer olmayan terimler içeren ve ikinci veya daha yüksek dereceli polinomlar ya da trigonometrik, logaritmik ve üstel ifadeler içeren denklemler nonlineer denklemler olarak tanımlanır (Şekil 1.b).



Şekil 1. a. Lineer Denklem Grafiği b. Nonlineer Denklem Grafiği (Nalcıoğlu et al., 2020)

BULGULAR

Analiz parametrelerine ait değerler Dinçer A. 2024 doktora tezinden alınmıştır (Dinçer 2024).

Barit katkılı betonun farklı kombinasyonlarının, 28 günlük basınç dayanımı, 4 farklı sıcaklık değeri (200 °C, 400 °C, 600 °C, 800 °C), doymun birim ağırlık, kuru birim ağırlık parametrelerinin radyasyon geçirgenliği parametrelerinin verileri DataFit programına giriş yapılarak aralarındaki ilişki gözlemlenmiştir.

Çalışmada farklı kombinasyonlar oluşturulmuş ve bu kombinasyonların radyasyon geçirgenliği ile ilişkisi incelenmiştir. (Tablo 1).

DataFit 9.0 kullanılarak yapılan analizde, modellerin uyumluluk ve kullanılabilirlik düzeyi R^2 değerleri veya grafiksel ifadeler yoluyla değerlendirilebilir. Bu R^2 değeri ve grafiksel gösterimler, programın çözümlendiği denklemlerden türetilmiştir. Çalışmada oluşturulan 6 farklı modele ilişkin en uygun denklemler aşağıda sunulmuştur. (Tablo 2).


Çalışmada; R = Radyasyon, B = Barit, S = Sıcaklık, BD = Basınç Dayanımı, KBA = Kuru Birim Ağırlık, DBA = Doymun Birim Ağırlık parametrelerini ifade etmektedir.

Tablo 1. Programda Kullanılan Giriş ve Çıkış Parametreleri

Model No	Giriş Verileri	Çıkış Verisi
Model 1	Kuru Birim Ağırlık, Doymun Birim Ağırlık, Barit, 200S	Radyasyon Geçirgenliği
Model 2	Kuru Birim Ağırlık, Doymun Birim Ağırlık, Barit, 400S	Radyasyon Geçirgenliği
Model 3	Kuru Birim Ağırlık, Doymun Birim Ağırlık, Barit, 600S	Radyasyon Geçirgenliği
Model 4	Kuru Birim Ağırlık, Doymun Birim Ağırlık, Barit, 800S	Radyasyon Geçirgenliği
Model 5	Barit, Basınç Dayanımı	Radyasyon Geçirgenliği
Model 6	Barit, Basınç Dayanımı, Kuru Birim Ağırlık, Doymun Birim Ağırlığı	Radyasyon Geçirgenliği


Tablo 2. Modellere Ait Denklemler

Model No	Denklem	R^2
Model 1	$R = a * KBA + b * DBA + c * B + d * S_{200}$	0.9305
Model 2	$R = a * KBA + b * DBA + c * B + d * S_{400}$	0.9775
Model 3	$R = a * KBA + b * DBA + c * B + d * S_{600}$	0.9249
Model 4	$R = a * KBA + b * DBA + c * B + d * S_{800}$	0.8871
Model 5	$R = a + b * B + c * B^2 + d * \ln(BD)$	0.9999
Model 6	$R = a * B + b * BD + c * KBA + d * DBA$	0.9988




Şekil 3. Model 1

Model 1'e ait grafik Şekil 3'te gösterilmektedir. Grafikte görüldüğü gibi, Barit, Kuru Birim Ağırlık, Doygun Birim Ağırlık ve Radyasyon arasında oldukça yüksek bir uyum bulunmaktadır. Ayrıca R^2 değeri 0.9305 olarak hesaplanmıştır.




Şekil 4. Model 2

Model 2'ye ait grafik incelendiğinde, giriş parametreleri olan Barit, Kuru Birim Ağırlık ve Doygun Birim Ağırlık ile çıkış parametresi olan Radyasyon arasında yüksek bir uyum olduğu gözlemlenmiştir. Bu parametreler doğrultusunda elde edilen denkleme göre $R^2=0.9775$ değeri bulunmuştur (Şekil 4).




Şekil 5. Model 3

Şekil 5'te Model 3'e ait grafik gösterilmektedir. Grafik incelendiğinde, giriş parametreleri olan Barit, Kuru Birim Ağırlık ve Doygun Birim Ağırlık ile çıkış parametresi olan Radyasyon arasında güçlü bir uyum olduğu görülmüştür. Bu parametrelerin sonucunda elde edilen denklem için R^2 değeri 0.9249 olarak bulunmuştur.



Şekil 6. Model 4

Model 4'e ait grafik sunulmaktadır. Grafik incelendiğinde, giriş parametreleri olan Barit, Kuru Birim Ağırlık ve Doygun Birim Ağırlık ile çıkış parametresi Radyasyon arasında yüksek bir uyum olduğu gözlemlenmiştir. Bu parametrelerin oluşturduğu denklem için R^2 değeri 0.8871 olarak hesaplanmıştır (Şekil 6).




Şekil 7. Model 5

Şekil 7'de Model 5'in uyumunu gösteren üç boyutlu grafik yer almaktadır. Model 5 incelendiğinde, giriş parametrelerinin oluşturduğu yüzeyel alan ile çıkış parametresi olan Radyasyonu temsil eden noktasal veriler arasında yüksek bir uyum olduğu görülmektedir. Bu kombinasyonun analizinden elde edilen R^2 değeri 0.9999 olup, diğer modeller arasında en yüksek uyumluluk değerini göstermektedir.

Model 6'nın parametreleri arasındaki uyumu gösteren grafik yukarıda Şekil 8'de sunulmuştur. Grafik incelendiğinde, giriş ve çıkış parametreleri arasındaki uyumun $R^2 = 0.9988$ olarak hesaplandığı görülmektedir.

DataFit 9.0 programı kullanılarak, barit katkı betonun farklı kombinasyonlarının, basınç dayanımı, sıcaklık, doymuş birim ağırlık, kuru birim ağırlık parametrelerinin radyasyon geçirgenliği üzerindeki etkileri incelenmiştir. Bu parametreler arasındaki ilişkileri belirlemek için DataFit programı kullanılarak sayısal bir model oluşturulmuştur. Model sonucu radyasyon geçirgenliği tahmini için farklı formülasyonlar üretilmiştir. R^2 değeri en yüksek 0.9999 elde edilmiştir.



Şekil 8. Model 6

Ancak R^2 değerleri incelendiğinde Model 5'e en yakın sonuçlar Model 6'da gözlemlenmiştir. Model-6, radyasyon geçirgenliği üzerinde önemli etkisi bulunan Kuru Birim Ağırlık ve Doygun Birim Ağırlığı parametrelerini de içerisinde bulundurmaktadır. Bu parametreler Radyasyon geçirgenliği açısından en önemli ve kritik parametreler arasında yer almaktadır. Bundan dolayı Model 6'nın Baritin, Radyasyon Geçirgenliğinin tespitinde kullanılması önerilmektedir.

SONUÇ

Bu çalışmada barit katkılı betonun farklı kombinasyonlarının, basınç dayanımı, sıcaklık, doymuş birim ağırlık, kuru birim ağırlık parametrelerinin ve radyasyon geçirgenliğinin birbirleriyle oluşturulmuş kombinasyonlarının uyumları incelenmiştir. Model sonuçları ile deney sonuçları arasında oldukça yüksek uyum olduğu görülmüştür.

Oluşturulan modellerde genel olarak oldukça yüksek R^2 değerleri elde edilmiştir. Bu modeller arasında uyumluluk indeksi olan R^2 değerleri dikkate alındığında 5. Model olan Barit-Basınç Dayanımı-Radyasyon modeli en yüksek uyum katsayısını $R^2=0.9999$ değerini vermiştir.

Ancak R^2 değerleri incelendiğinde Model 5'e en yakın sonuçlar Model 6'da gözlemlenmiştir. Model 6, radyasyon geçirgenliği üzerinde önemli etkisi bulunan Kuru Birim Ağırlık ve Doygun Birim Ağırlığı parametrelerini de içerisinde bulundurmaktadır. Bu parametreler Radyasyon Geçirgenliği açısından en önemli ve kritik parametreler arasında yer almaktadır. Bundan dolayı Model 6'nın Baritin, Radyasyon Geçirgenliğinin tespitinde kullanılması önerilmektedir.

Yapılan çalışmada, DataFit 9.0 kullanılarak elde edilen model formülünün, beton numunelerinin radyasyon geçirgenliğini tahmin etmek için geçerli bir yöntem sunduğu belirtilmiştir. Ayrıca, DataFit 9.0 yöntemiyle geliştirilen modellerin matematiksel denklemlerinin çıkarılabilmesi, yeni veriler eklendiğinde gelecekteki tahminlerin yapılmasını daha kolay ve pratik hale getirecektir.

KAYNAKLAR

Çoşkun, A. (2010). Ağır betonlarda barit agregasının kullanımı ve beton özelliklerinin araştırılması, Yüksek Lisans Tezi, Afyonkocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Afyonkarahisar.

Dahiru, D. (2008). Investigation of the compressive strength of heavy concrete made with locally sourced barite aggregates. *J. Appl. Sci*, 3, 447-455.

Demir, F. (2010). Determination of Mass Attenuation Coefficients of Some Boron Ores at 59,54 keV by Using Scintillation Detector. *Applied Radiation And Isotopes*, 68:1, 175-179. DOI: 10.1016/j.apradiso.2009.09.003.

Dinçer, A. (2024). Radyasyon Etkisine Karşı Serpantinit, Dolomit ve Barit Katkılı Beton Kullanılmasının Araştırılması, Doktora Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Kahramanmaraş.

Bashter, I.I., Makarious, A.S., El-Sayed Abdo, A., (1996). Investigation of Hematite Serpentine and Ilmenite-Limonite Concretes for Reactor Radiation Shielding. *Annals of Nuclear Energy*, 23(1): 65-71. [https://doi.org/10.1016/0306-4549\(95\)00011-G](https://doi.org/10.1016/0306-4549(95)00011-G).

Flynn R. H. (2003). Development of Regression Equations to Estimate Flow Durations and Low-Flow Frequency Statistics in New Hampshire Streams, *Water-Resources Investigations Report 02-4298*, Pembroke, New Hampshire.

Nalcioğlu, A., Ünsal, M., Ercan, B., & Yağcı, A. E. (2020). Asi havzasında hidrometeorolojik faktörler ve akım arasındaki ilişkinin modellenmesi. *Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi*, 23(6), 1510-1517. <https://doi.org/10.18016/ksutarimdog.vi.623770>.



Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences



Geliş Tarihi : 13.11.2024
Kabul Tarihi : 20.12.2024

Received Date : 13.11.2024
Accepted Date : 20.12.2024

A GRAPHICAL USER INTERFACE DESIGN FOR FORECASTING NUTRIENT CONCENTRATIONS IN WWTP

ATIKSU ARITIM TESİSİNDE ORGANİK MADDE ÖNGÖRÜSÜ İÇİN GRAFİKSEL ARAYÜZ GELİŞTİRİLMESİ

Eda GÖZ¹ (ORCID: 0000-0002-3111-9042)

¹ Ankara University, Department of Chemical Engineering, Ankara, Türkiye

*Sorumlu Yazar / Corresponding Author: Eda Göz, esemizer@eng.ankara.edu.tr

ABSTRACT

Wastewater management poses a global challenge. Integrating data-driven models has significantly enhanced treatment facilities' design and operational efficiency. In this study, an Artificial Neural Network (ANN) algorithm was adapted as a time-series forecasting model to predict effluent TN (Total Nitrogen) and TP (Total Phosphorus) concentrations in a real municipal wastewater treatment plant (WWTP). For this purpose, six independent TN and TP models were developed and evaluated using Mean Absolute Percentage Error (MAPE, %) and Root Mean Square Error (RMSE) metrics. Based on these criteria, all models demonstrated similar performance, with MAPE and RMSE values for TN forecasting at approximately 12% and 1.4, respectively, in the test phase. The MAPE was approximately 30% for TP forecasting, and RMSE was 0.25. Upon completing the modeling studies, one model was integrated into a user-friendly graphical user interface (GUI) and tested with actual data, allowing users to obtain results with a single click.

Keywords: Wastewater treatment plant, total nitrogen, total phosphorus, modelling, GUI design

ÖZET

Atıksu yönetimi, dünya genelinde önemli bir zorluk teşkil etmektedir. Veriye dayalı modellerin entegrasyonu, arıtma tesislerinin tasarım ve işletim verimliliğini artırmıştır. Bu çalışmada, yapay sinir ağı algoritması (ANN) evsel atıksu arıtım tesisinde çıkış akımı toplam azot (TN) ve toplam fosfor (TP) parametrelerinin tahmini için zaman serisi öngörüsü yapacak şekilde modifiye edilmiştir. Bu amaçla, 6 farklı ve bağımsız TN ve TP modelleri geliştirilmiştir. Model performansı, Ortalama mutlak yüzde hatası (MAPE, %) ve Hataların Karesinin Ortalamasının Karekökü (RMSE) ile değerlendirilmiştir. Bu kriterlere göre tüm alternatif modeller benzer performans sergilemiştir. Çıkış akımı toplam azot (TN) tahmin modellerinin test fazında MAPE ve RMSE değerleri sırasıyla %12 ve 1.4 civarında elde edilmiştir. Çıkış akımı toplam fosfor (TP) için MAPE değeri yaklaşık %30, RMSE ise 0.25 olarak hesaplanmıştır. Modelleme çalışmaları tamamlandıktan sonra, bir model kullanıcı dostu bir grafik kullanıcı arayüzüne (GUI) entegre edilmiştir ve gerçek verilerle test edilmiştir. Bu, kullanıcıya tek tıklama ile sonuç alma imkânı sunmaktadır.

Anahtar Kelimeler: Atıksu Arıtım Tesisi, toplam azot, toplam fosfor, modelleme, grafiksel arayüz tasarımı

INTRODUCTION

Water is essential for sustaining life, yet water pollution has dramatically increased in recent years due to industrialization, technological advancements, rapid population growth, and anthropogenic activities (Akhtar et al., 2021). Wastewater treatment has become crucial to prevent pollution, maintain water quality, and ensure water resource sustainability. However, wastewater treatment is a complex chemical, physical, and biological process (Sraavan et al., 2024), and the operation of treatment plants is challenging due to these processes' nonlinear and ToCite: GÖZ, E., (2025). A GRAPHICAL USER INTERFACE DESIGN FOR FORECASTING NUTRIENT CONCENTRATIONS IN WWTP. *Kahramanmaraş Sutcu Imam University Journal of Engineering Sciences*, 28(1), 479-486.

intricate nature. Modeling techniques are widely employed to better understand these processes, with mechanistic and empirical models providing foundational insights. Nonetheless, these models often involve complex equations and require in-depth process knowledge.

The rise of data mining has spurred the application of machine learning methods to wastewater treatment data. These methods identify input and output parameters and train models using historical data. In this context, artificial neural networks (ANN), support vector machines (SVM), extreme learning machines (ELM), fuzzy logic (FL), deep learning (DL), and random forest (RF) algorithms have been utilized to predict parameters such as biological oxygen demand (BOD), chemical oxygen demand (COD), and energy efficiency (Zhao et al., 2020; Safeer et al., 2022).

Wastewater treatment plants also need to monitor critical parameters, such as total nitrogen (TN) and total phosphorus (TP), which contribute to eutrophication and biodiversity loss due to algae growth. Measurement, monitoring, and prediction of these parameters are essential, although fewer TN and TP models exist for full-scale plants compared to BOD and COD models. For example, Manu and Thalla (2017) predicted total Kjeldahl nitrogen (TKN) using Support Vector Machines (SVM) and Adaptive-Network-Based Fuzzy Inference Systems (ANFIS) with data from a full-scale aerobic treatment plant. Model inputs included pH, COD, total solids (TS), free ammonia, and Kjeldahl nitrogen, with SVM outperforming ANFIS, based on correlation coefficient (R), root mean squared error (RMSE), and Nash-Sutcliffe (NS) coefficient.

Other studies have explored diverse modeling approaches. Yu and Bai (2018) applied least-squares support vector machine (LS-SVM), ELM, and ANN to predict TP, using inputs like COD, BOD, NH₃-N, suspended solid (SS), TP, and TN, with ELM showing the best results. Similarly, Abba et al. (2021) used ELM with principal component analysis and combined ANN with multiple linear regression to predict TN and TP values, with ELM yielding superior performance based on R², RMSE, and MAPE. Additional studies (Mohammadi et al., 2022; Wang et al., 2022) have tested a range of algorithms—such as K-nearest neighbours (KNN), decision trees (DT), gradient boosting decision trees (GBDT), Ridge, Lasso, and SVR—on effluent TN and TP prediction, with KNN and GBDT achieving strong performance.

Early warning or alarm systems based on time series forecasting are invaluable for real-time wastewater treatment applications. The Seasonal Autoregressive Integrated Moving Average with Exogenous Variables (SARIMAX) model has been widely used (Ly et al., 2022), often alongside recurrent neural network (RNN) models like Long Short-Term Memory (LSTM) networks, which are highly effective but require substantial datasets (Xu et al., 2021; Oliveira et al., 2021; Safeer et al., 2022). El-Rawy et al. (2021) also developed deep learning models for time series forecasting and Artificial Neural Network (ANN)--based prediction models targeting total suspended solid (TSS), COD, BOD₅, ammonia, and sulfur removal. These studies emphasize the importance of time series forecasting models in optimizing wastewater treatment plant operations, focusing on enhancing system efficiency and preventing operational issues. In a related study by Hansen et al. (2022), two distinct LSTM models were designed to predict TP concentration: the first model integrated environmental conditions with process operation data, while the second relied on previous TP values. The R² score was chosen as the performance metric to evaluate the models.

Despite the variety of models available, integrating these models into accessible systems for operators remains essential for streamlining operations in wastewater treatment plants. However, such user-friendly applications remain limited in the literature. Six independent ANN models with distinct input combinations were developed to address this gap and predict effluent TN and TP concentrations for the next day in a domestic wastewater treatment plant. Model performances were compared using RMSE and MAPE (%), and a model with optimal performance was incorporated into an interactive user interface in MATLAB 2023b. This interface simplifies model use, enabling users to obtain results with a single click, significantly reducing workload and laboratory costs.

MODELING STUDIES

Data Collection and Preprocessing

Data for this study were obtained from a wastewater treatment plant in South Carolina, USA, and include daily records from 2014 to 2018, comprising 2,168 data points. The dataset was converted into a time series format with mean imputation for any missing values. All data were normalized to a 0-1 range for consistency, as shown in Equation 1.

$$x_{nor} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Modelling Studies

This study developed independent models for predicting total nitrogen (TN) and total phosphorus (TP) concentrations, designated as Models 1.1 to 1.6 for TN and Models 2.1 to 2.6 for TP. Each model utilized six different input combinations, selected based on literature review and expert insights. Table 1 presents the specific input and output parameters for each model.

Table 1. Inputs and Outputs for Total Nitrogen (TN) and Total Phosphorus (TP) Models

Input Parameters	Output Parameters	Model 1.1/2.1	Model 1.2/2.2	Model 1.3/2.3	Model 1.4/2.4	Model 1.5/2.5	Model 1.6/2.6
Influent BOD (t)		√	√	√	√		
Influent TKN (t)		√		√		√	
Influent NH ₃ -N (t)			√		√		√
Influent TP (t)				√	√	√	√
Influent TSS (t)		√	√	√	√	√	√
Aeration basin pH(t)	Effluent TN (t+1)	√	√	√	√	√	√
Aeration basin alkalinity (t)		√	√	√	√	√	√
Aeration basin DO (t)	Effluent TP (t+1)	√	√	√	√	√	√
MLSS(t)		√	√	√	√	√	√
SRT (t)		√	√	√	√	√	√
Effluent temperature (t)		√	√	√	√	√	√
Effluent Flow rate (t)		√	√	√	√	√	√
Effluent TN(t)		√	√	√	√	√	√
Effluent TP (t)		√	√	√	√	√	√

DO(t) Dissolved oxygen concentration, MLSS: Mixed liquor suspended solids (MLSS), SRT: Sludge retention time

Artificial Neural Network (ANN)

Artificial Neural Networks (ANNs) are computational models that emulate the human brain's learning processes to generate new insights from data (Haykin, 1999). ANNs are fundamentally mathematical models trained on historical datasets and consist of interconnected units called neurons. A typical ANN architecture includes three main layers: the input layer (where data is received), the hidden layer (where data processing occurs), and the output layer (where results are generated). Neurons in these layers are connected through synapses, and each connection is assigned a weight. Transfer functions adjust signals passing through neurons, and this process is repeated until the network generates the desired output. The number of neurons in the hidden layer is generally problem-specific and often determined through trial and error.

This study employed a three-layer ANN structure, with separate models corresponding to each input combination in Table 1. The models were designed to predict TN and TP concentrations one day in advance. The dataset was divided into 60% for training, 20% for testing, and 20% for validation. During hyperparameter optimization, various activation functions and neuron quantities in the hidden layer were evaluated to identify optimal settings. Among tested activation functions, tangent sigmoid ('*tansig*'), linear ('*purelin*'), and logarithmic sigmoid ('*logsig*') provided the best results in the hidden and output layers. Training algorithms, including Levenberg-Marquardt ('*trainlm*'), Bayesian regularization ('*trainbr*'), and BFGS quasi-Newton ('*trainbfg*'), were applied, with Bayesian regularization yielding the highest accuracy.

Model performances were compared using RMSE and MAPE (%) metrics, which offer a more reliable assessment for nonlinear models than R² or R. R², while widely used, has limitations in nonlinear models as it does not always encapsulate simpler models with single parameters and fails to account for the number of parameters in complex models (Archontoulis and Miguez, 2015; Manav-Demir et al., 2022). This highlights the need for composite metrics, such as RMSE and MAPE (%), to provide a more accurate evaluation. The formulas for the metrics are provided in Equation 2 and Equation 3:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - x_i)^2}{N}} \quad (2)$$

$$MAPE(\%) = \frac{1}{N} \sum_{i=1}^N \left(\left| \frac{y_i - x_i}{x_i} \right| \right) 100 \quad (3)$$

N is the total number of data points in this equation, and y_i and x_i represent the observed and predicted values, respectively.

Graphical User Interface Design

A user-interactive interface for predicting effluent TN and TP concentrations was developed in the MATLAB environment. This software incorporates the ANN models and enables users to predict future TN and TP values with a single click. The interface is designed for ease of use, allowing operators to select from various TN and TP models as needed. An illustration of the graphical user interface, which includes options for selecting different models, is provided in Figure 1.

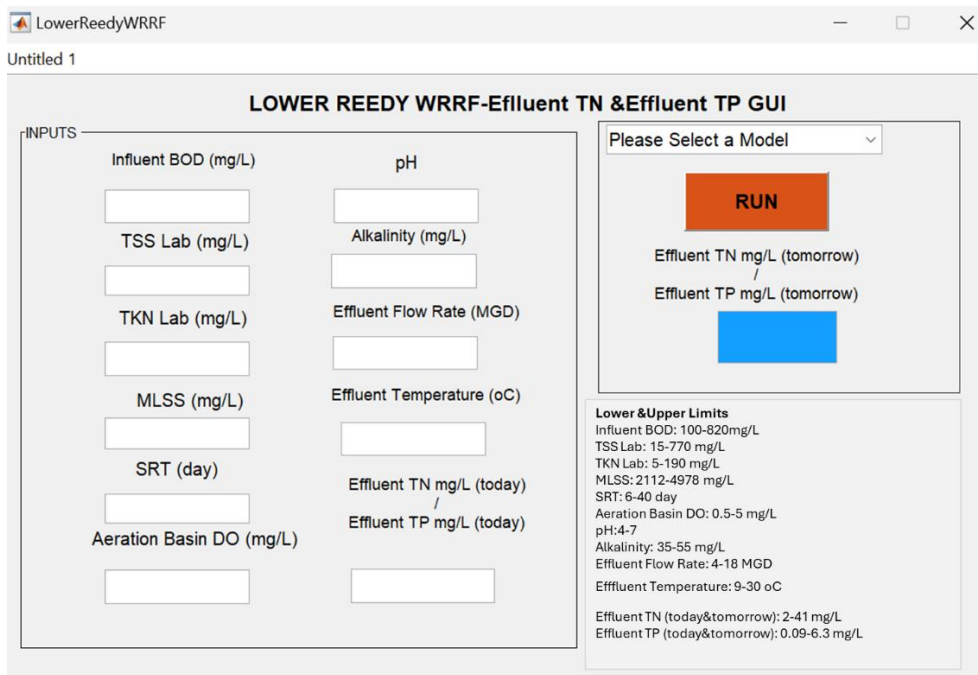


Figure 1. Overview of the Graphical Interface

The interface shown in Figure 1 provides a user-friendly area for inputting data, selecting models, and running predictions. In the input section, users can enter specific data values, reset the form, choose among different TN and TP models, execute the selected model, and print the output data. The design emphasizes simplicity and usability, making it an efficient tool for operators.

The steps to use the software are as follows:

- Launch MATLAB.
- Use the "Browse Folder" option to specify the folder location.
- Enter "LowerReedyWRRF" in the command window and press ENTER.
- The LowerReedy WRRF software page will open (as illustrated in Figure 1).
- Enter the model parameters in the appropriate fields on the interface.
- Select the desired model and click the RUN button to initiate the prediction.

RESULTS AND DISCUSSION

Total Nitrogen Forecasting Results

This study proposed six different models for predicting total nitrogen (TN) concentration in the effluent stream of a wastewater treatment plant. Evaluating influent TKN and $\text{NH}_3\text{-N}$ data was essential for accurately predicting effluent TN concentrations. Test phase results for these models are presented in Table 2.

Table 2. Total Nitrogen (TN) Forecasting Results

Models	Algorithm	Test Phase		Train Phase		Validation Phase	
		MAPE %	RMSE	MAPE %	RMSE	MAPE %	RMSE
Model 1.1	ANN	12.71	1.44	11.01	1.97	15.11	1.7
Model 1.2	ANN	12.15	1.4	10.8	1.96	14.73	1.68
Model 1.3	ANN	12.77	1.45	10.97	1.97	15.24	1.71
Model 1.4	ANN	12.61	1.44	10.77	1.95	15.05	1.69
Model 1.5	ANN	12.16	1.41	10.78	1.96	14.81	1.68
Model 1.6	ANN	12.13	1.4	10.75	1.96	14.89	1.68

Upon examining the test phase results in Table 2, it is observed that the model incorporating NH₃-N (Model 1.2) performs slightly better in predicting effluent TN concentration than the model using TKN (Model 1.1). This can be attributed to the greater influence of influent NH₃-N on effluent TN values compared to TKN. Pearson correlation analysis supports this finding, with correlation coefficients of R = 0.14 for TKN and R = 0.22 for NH₃-N. However, the minor differences in RMSE and MAPE values between Models 1.1 and 1.2 may stem from the high NH₃-N/TKN ratio of 0.56 in the dataset, indicating that the organic nitrogen portion of TKN, in addition to NH₃-N, has a limited effect on model performance.

The limited impact of other selected parameters on model performance may be due to the inherent characteristics of the time series models, where the previous day's total nitrogen concentration is the most significant predictor. This is supported by a Pearson correlation coefficient of R = 0.44 between the previous day's TN value and the effluent TN concentration. Prediction and actual fit graphs for total nitrogen concentration are displayed in Figure 2.




Figure 2. TN Forecasting Results

Model 1.1 was selected from the developed models for integration into the GUI due to its comparable performance and use of influent TKN data. This selection is advantageous as NH₃-N is already included within the Total Kjeldahl Nitrogen (TKN) parameter.

Total Phosphorus Forecasting Results

This study also proposed six models to predict total phosphorus (TP) concentration in the effluent stream of a wastewater treatment plant. In contrast to the TN model, TP predictions were based on the previous day's TP data rather than TN. The test phase performance results for effluent TP predictions are provided in Table 3.

Table 3. Effluent TP Forecasting Results

Models	Algorithm	Test Phase		Train Phase		Validation Phase	
		MAPE %	RMSE	MAPE %	RMSE	MAPE %	RMSE
Model 1.1	ANN	30.34	0.24	56.81	0.41	43.97	0.42
Model 1.2	ANN	30.08	0.26	55.45	0.41	44.26	0.42
Model 1.3	ANN	31.23	0.25	56.52	0.41	42.73	0.42
Model 1.4	ANN	30.46	0.26	55.03	0.41	44.01	0.42
Model 1.5	ANN	30.15	0.24	56.35	0.41	43.54	0.42
Model 1.6	ANN	29.65	0.26	54.8	0.41	44.66	0.42

Upon examining Table 3, no significant differences in performance were observed among the models. Correlation coefficient analysis between the effluent TP value and influent parameters revealed that the TP value from the previous day had the highest correlation ($R = 0.55$), which is typical for time series models. Among other parameters, temperature showed the next highest correlation with effluent TP ($R = 0.11$). The fit between experimental and predicted TP values from the test phase is illustrated in Figure 3.

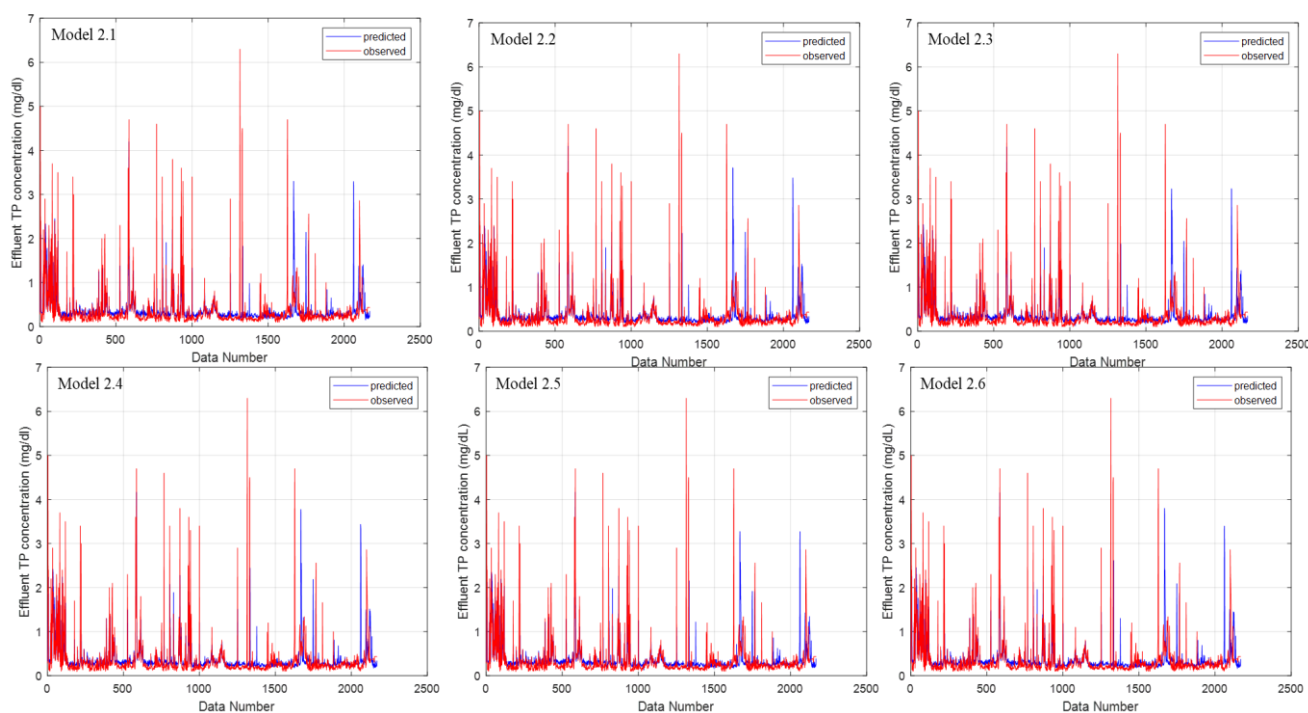


Figure 3. Effluent TP Forecasting Results

Graphical User Interface Results

The following results for total nitrogen (TN) were obtained from experiments using actual measurement values collected at the wastewater treatment plant, demonstrating the practical effectiveness of the graphical user interface (GUI)-integrated model.

Figure 4 displays model predictions based on actual measurement values obtained from WWTP data, demonstrating the model's effectiveness in forecasting TN concentrations for the following day.

A similar graphical user interface has also been implemented to predict TP concentrations, as shown in Figure 5.

As shown in Figure 5, the graphical user interface (GUI) effectively predicts TP concentrations for the following day, demonstrating its reliability for effluent TP forecasting.

CONCLUSION

This study developed artificial neural network (ANN) models with six different input combinations to predict total nitrogen (TN) and total phosphorus (TP) concentrations one day in advance at a municipal wastewater treatment plant. The highest-performing models were integrated into a user-friendly graphical interface, offering operators an

accessible tool for monitoring TN and TP levels. Managing TN and TP concentrations is essential, as elevated levels can result in significant environmental issues. Machine learning techniques, such as ANN, can provide substantial benefits in full-scale wastewater treatment's complex and cost-intensive environment. The implemented ANN models offer a straightforward and efficient solution, enabling users to obtain predictions with a single click. Future phases of this project will explore more advanced deep learning algorithms to enhance model accuracy.

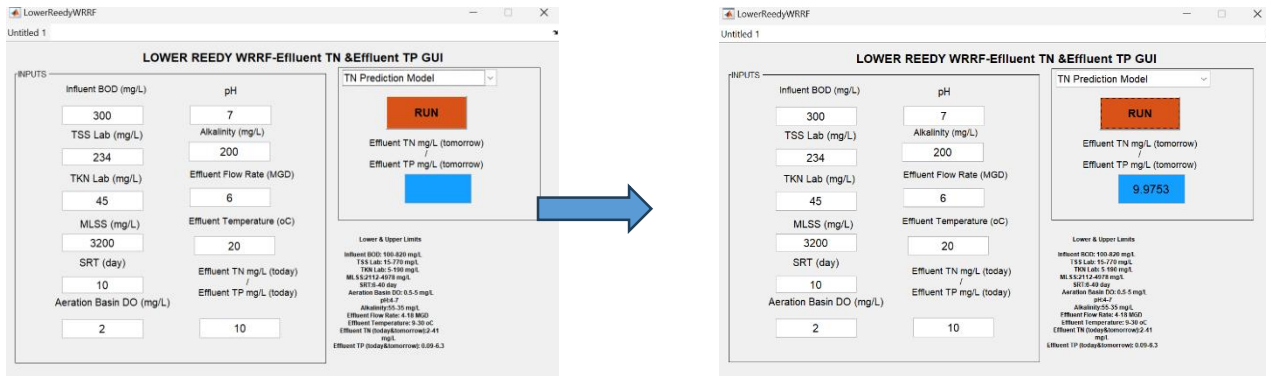


Figure 4. GUI Performance Results for Effluent TN

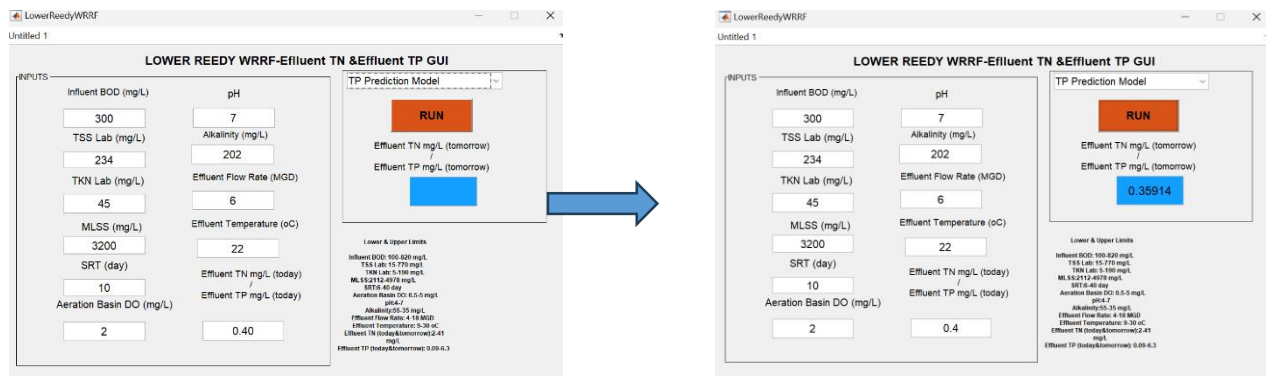


Figure 5. GUI Performance Results for Effluent TP

ACKNOWLEDGMENT

I would like to thank TÜBİTAK (The Scientific and Technological Research Council of Turkey) for financial support through the 2219 International Postdoctoral Research Fellowship Program for Turkish Citizens. I also acknowledge water utility in the USA for providing the data and express my gratitude to my supervisor, Prof. Dr. Tanju Karanfil, for his valuable insights and encouragement.

REFERENCES

- Abba, S., Elkiran, G., & Nourani, V. (2021). Improving novel extreme learning machine using PCA algorithms for multi-parametric modeling of the municipal wastewater treatment plant. *Desalination and Water Treatment*, 215, 414-426. <https://doi.org/10.5004/dwt.2021.26903>
- Akhtar, N., Ishak, M. I. S., Bhawani, S. A., & Umar, K. (2021). Various natural and anthropogenic factors responsible for water quality degradation: A review. *Water*, 13, 2660. <https://doi.org/10.3390/w13192660>
- Archontoulis, S. V., & Miguez, F. E. (2015). Nonlinear regression models and applications in agricultural research. *Agronomy Journal*, 107(3), 786-798. <https://doi.org/10.2134/agronj2012.0506>
- El-Rawy, M., Abd-Ellah, M. K., Fathi, H., & Ahmed, A. K. A. (2021). Forecasting effluent and performance of wastewater treatment plant using different machine learning techniques. *Journal of Water Process Engineering*, 44, 102380. <https://doi.org/10.1016/j.jwpe.2021.102380>
- Hansen, L. D., Stokholm-Bjerregaard, M., & Durdevic, P. (2022). Modeling phosphorous dynamics in a wastewater treatment process using Bayesian optimized LSTM. *Computers and Chemical Engineering*, 160, 107738. <https://doi.org/10.1016/j.compchemeng.2022.107738>

Haykin, S. (1999). *Neural networks: A comprehensive foundation* (2nd ed.). Prentice Hall.

Ly, Q. V., Truong, H., Ji, B., Nguyen, X. C., Cho, K. H., Ngo, H. H., & Zhang, Z. (2022). Exploring potential machine learning application based on big data for prediction of wastewater quality from different full-scale wastewater treatment plants. *Science of the Total Environment*, 832, 154930. <https://doi.org/10.1016/j.scitotenv.2022.154930>

Manav-Demir, N., Gelgor, H. B., Oz, E., Ilhan, F., Ulucan-Altuntaş, K., Tiwary, A., & Debik, E. (2022). Effluent parameters prediction of a biological nutrient removal (BNR) process using different machine learning methods: A case study. *Journal of Environmental Management*, 351, 119899. <https://doi.org/10.1016/j.jenvman.2023.119899>

Manu, D. S., & Thalla, A. K. (2017). Artificial intelligence models for predicting the performance of biological wastewater treatment plant in the removal of Kjeldahl nitrogen from wastewater. *Applied Water Science*, 7, 3783-3791. <https://doi.org/10.1007/s13201-017-0526-4>

Mohammadi, F., Yavari, Z., Mohammadi, F., & Rahimi, S. (2022). Prediction the performance of full scale wastewater treatment plant with A-B process using artificial neural network and genetic algorithm. *International Journal of Environmental Health Engineering*, 11(1), 1-7. https://doi.org/10.4103/ijehe.ijehe_52_20

Oliveira, P., Fernandes, B., Analide, C., & Novais, P. (2021). Forecasting energy consumption of wastewater treatment plants with a transfer learning approach for sustainable cities. *Electronics*, 10, 1149. <https://doi.org/10.3390/electronics10101149>

Safeer, S., Pandey, R. P., Rehman, B., Hasan, S. W., & Ullah, A. (2022). A review of artificial intelligence in water purification and wastewater treatment: Recent advancements. *Journal of Water Process Engineering*, 49, 102974. <https://doi.org/10.1016/j.jwpe.2022.102974>

Sravan, J. S., Matsakas, L., & Sarkar, O. (2024). Advances in biological wastewater treatment processes: Focus on low-carbon energy and resource recovery in biorefinery context. *Bioengineering*, 11(3), 1-15. <https://doi.org/10.3390/bioengineering11030281>

Wang, R., Yu, Y., Chen, Y., Pan, Z., Li, X., Tan, Z., & Zhang, J. (2022). Model construction and application for effluent prediction in wastewater treatment plant: Data processing method optimization and process parameters integration. *Journal of Environmental Management*, 302, 114020. <https://doi.org/10.1016/j.jenvman.2021.114020>

Xu, Y., Zeng, X., Bernard, S., & He, Z. (2021). Data-driven prediction of neutralizer pH and valve position towards precise control of chemical dosage in a wastewater treatment plant. *Journal of Cleaner Production*, 348, 131360. <https://doi.org/10.1016/j.jclepro.2022.131360>

Yu, T., & Bai, Y. (2018). A comparative study of extreme learning machine, least squares support vector machine, and back propagation neural network for outlet total phosphorous prediction. In *Prognostics and System Health Management Conference* (pp. 717-722).

Zhao, L., Dai, T., Qiao, Z., Sun, P., Hao, J., & Yang, Y. (2020). Application of artificial intelligence to wastewater treatment: A bibliometric analysis and systematic review of technology, economy, management, and wastewater reuse. *Process Safety and Environmental Protection*, 133, 169-182. <https://doi.org/10.1016/j.psep.2019.11.014>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 20.08.2024
Kabul Tarihi : 20.12.2024

Received Date : 20.08.2024
Accepted Date : 20.12.2024

ADNet: A CNN MODEL FOR ALZHEIMER'S DISEASE DIAGNOSIS ON OASIS-1 DATASET

ADNet: OASIS-1 VERİ KÜMESİ ÜZERİNDE ALZHEİMER HASTALIĞI TEŞHİSİ İÇİN BİR CNN MODELİ

Ahmet Samed SARAÇOĞLU¹ (ORCID: 0009-0003-7835-4191)
Ayşe Merve ACILAR^{1,2*} (ORCID: 0000-0002-0133-2694)
Özlem ERDAŞ ÇİÇEK¹ (ORCID: 0000-0003-4019-7744)

¹Necmettin Erbakan University, Engineering Faculty, Computer Engineering Department, Konya, Türkiye

²Necmettin Erbakan University, Trauma Intervention and Research Center, Konya, Türkiye

*Sorumlu Yazar / Corresponding Author: Ayşe Merve ACILAR, m.acilar@erbakan.edu.tr

ABSTRACT

Alzheimer's disease (AD) is a chronic neurodegenerative disorder affecting memory, thinking, and behavior. Deep learning models, particularly CNNs, have shown promise in detecting AD at initial stages using the brain's magnetic resonance images (MRI). In this study, a CNN model called ADNet, trained using the OASIS-1 dataset, was proposed. The experimental approaches for evaluating the performance of ADNet are as follows: First, three different datasets were prepared using slices taken from the first quarter, middle, and third quarter of the sagittal plane from each MRI, to determine the most informative slice among the 128 slices. Each dataset was split into 80% training and 20% testing. It was found that the first quarter slice showed the best performance. The potential use of the obtained model as a transfer learning model was also examined. For this, a low-performance model was retrained using ADNet as a transfer learning model, and significant improvements in the results were observed. At last, the model's robustness was evaluated in a more detailed evaluation, using 5-fold cross-validation repeated three times, resulting in a mean accuracy of 97.05%. As a result, ADNet can be used for Alzheimer's screening in clinical settings and could enable patients to receive earlier treatment.

Keywords: Alzheimer's disease diagnosis, deep learning, convolutional neural network, magnetic resonance imaging data, transfer learning, open access series of imaging studies brain database.

ÖZET

Alzheimer hastalığı (AD), hafıza, düşünme ve davranış üzerinde ciddi etkileri olan kronik bir nörodejeneratif hastalıktır. Evrişimli Sinir Ağları (CNN) gibi derin öğrenme modelleri, beyin manyetik rezonans görüntüleri (MRI) kullanılarak AD'nin erken aşamalarda tespit edilmesinde umut verici sonuçlar göstermektedir. Bu çalışmada, Alzheimer teşhisi için OASIS-1 veri seti kullanılarak eğitilen ADNet adlı bir CNN modeli önerilmiştir. ADNet'in performansını değerlendirmek için, ilk olarak, her bireyin MR görüntüsünden alınan sagittal düzlemdeki 128 dilimin ilk çeyreğinden, ortasından ve üçüncü çeyreğinden alınan dilimler kullanılarak üç farklı veri seti hazırlanmış ve en bilgilendirici dilim hangisi araştırılmıştır. Her veri seti %80 eğitim ve %20 test olarak ayrılmış ve ilk çeyrek dilimin en iyi performansı gösterdiği saptanmıştır. Ek olarak, elde edilen modelin transfer öğrenme modeli olarak kullanılıp kullanılamayacağı incelenmiştir. Bunun için düşük performanslı bir model, ADNet transfer öğrenme modeli kullanılarak yeniden eğitilmiş ve sonuçların oldukça iyileştiği gözlemlenmiştir. Son olarak, modelin dayanıklılığı 5 katlı çapraz doğrulama ile üç kez tekrarlanarak daha ayrıntılı bir değerlendirmeye tabi tutulmuş ve %95,36 ortalama doğruluk elde edilmiştir. Sonuç olarak, ADNet'in klinik ortamlarda Alzheimer taramasında kullanılabileceği ve hastaların daha erken tedavi almasını sağlayabileceği düşünülmektedir.

Anahtar Kelimeler: Alzheimer hastalığı teşhisi, derin öğrenme, evrişimli sinir ağı, manyetik rezonans görüntüleme verisi, transfer öğrenme, açık erişimli görüntüleme çalışmaları serisi beyin veri tabanı.

ToCite: SARAÇOĞLU A.S.; ACILAR A. M. & ERDAŞ ÇİÇEK. Ö., (2025). ADNet: A CNN MODEL FOR ALZHEIMER'S DISEASE DIAGNOSIS ON OASIS-1 DATASET. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 487-504.

INTRODUCTION

A neurodegenerative disease characterized by the progressive death and loss of the function of nerve cells in the brain is referred to as Alzheimer's Disease (AD). Memory, language, reasoning, and problem-solving may be affected by this disease (Scheltens et al., 2022). In the beginning, patients usually have minor memory problems, however as time goes on, they might have difficulty in performing their daily activities, show behavior changes, or fail to communicate (Afzal et al., 2021) (Porsteinsson, Isaacson, Knox, Sabbagh, & Rubino, 2021).

AD is a growing global health problem that causes impairment in cognitive abilities. The World Health Organization's 2023 Report predicts that 55 million people were affected by the disease in 2021 (Alzheimer's Association, 2023). This number is expected to rise significantly in the coming years. Alzheimer's disease not only affects the quality of life of patients but also places a huge strain on healthcare systems. Researchers are constantly working to improve the comprehension and management of this complex disease. In recent years, considerable progress has been made in understanding the causes, diagnostic methods, and approaches to potential treatment.

Although its exact cause remains unknown, the development of AD is attributed to the accumulation of amyloid plaques and tau deposits in the brain (Breijyeh & Karaman, 2020). These protein deposits impair neurons' function and ultimately result in their death. While aging is the most important risk factor for developing AD, genetic susceptibility, diabetes, heart disease, and low education level are associated with an increased risk (Bendlin et al., 2011).

AD currently has no definitive cure, but some life changes may help in preventing or delaying AD. Exercising regularly, eating healthy food, engaging oneself mentally, and interacting socially can all help maintain cognitive health and reduce the risk of AD (Bendlin et al., 2011). Symptoms can be managed by diagnosing early and slowing down the progression of the disease. Diagnosis normally involves thorough clinical evaluation which includes neuropsychological testing and neuroimaging (Porsteinsson et al., 2021). There is extensive research on novel therapeutic interventions for combating ADs. The aim is to find new drugs that inhibit or eliminate amyloid plaques and tau proteins (Ovsepian, Leary, Zaborszky, & Ntziachristos, 2019), decrease inflammation, and save nerve cells (Breijyeh & Karaman, 2020). Timely diagnosis is crucial for efficient management/treatment of the disease and the design of new drugs. Besides, progress in artificial intelligence and imaging technology presents new prospects for early detection of the disease and monitoring treatment response (Alzheimer's Association, 2023). The application of classic machine learning algorithms and deep learning techniques to medical image analysis has garnered significant attention in recent years. Various studies have explored different approaches to improve the accuracy and reliability of diagnostic tools, each contributing unique methods and findings to the field. Baglat et al. (2020) applied a Random Forest classifier to T1-weighted Magnetic Resonance Imaging (MRI) data with a dataset of 150 samples into two categories and used a 5-fold cross-validation method. Test accuracy of 86% was obtained (Baglat, Salehi, Gupta, & Gupta, 2020). In another study, Logistic Regression on a dataset of 373 samples, classifying them into three categories was employed by Alroobaea and colleagues. They used 5-fold cross-validation method and achieved a test accuracy of 84.33% (Alroobaea & Bragazzi, 2021). Extra Tree Classifier on longitudinal MRI data with a dataset of 373 samples was performed and achieved a test accuracy of 85% by Jadhao et al. (Jadhao et al., 2023). Another machine learning algorithm Random Forest used by Shrivastava et al. to detect dementia on a dataset of 136 samples divided into two classes: non-demented and demented. The dataset was split into training and testing sets with a 75:25 ratio, achieving the best test accuracy of 84% (Shrivastava, Singh, & Kaur, 2023). Rajayyan and Mustafa (2023) utilized the Gaussian Naïve Bayes method on a dataset of 373 samples, classified into three categories: non-demented, moderate dementia, and demented. The study used an 80:20 hold-out cross-validation technique, achieving a test accuracy of 95% (Rajayyan & Mustafa, 2023).

As the field progressed, researchers began to leverage deep learning methods to capture the intricate features of neuroimaging data. Inception-v3 models, as Salami et al. (2022) proposed, represented a significant leap, achieving an accuracy of 87.75%. More recent studies have focused on advanced CNN architectures and transfer learning. Saratxaga and colleagues (2021) applied deep learning methods to a dataset of 1,114 samples, focusing on 10 central MRI slices. They classified the data into three categories: non-demented, moderate dementia, and demented, with a 70:10:20 split between training, validation, and test sets. They obtained the highest test accuracy of 89% using the ResNet18 model (Saratxaga et al., 2021). Khagi and colleagues (2019) employed a Scratch Trained CNN method on a smaller dataset of fifty-six samples, using 30 MRI slices per sample. The study classified the data into two

categories: moderate dementia and demented, achieving a high test accuracy of 98.51% with a 60:20:20 data split for training, validation, and testing (Khagi & Kwon, 2019). Chui et al. (2022) used a GAN-CNN-TL model on a large dataset of 2,168 samples, classifying them into four categories: non-demented, very mildly demented, mildly demented, and moderately demented. The study employed a 5-fold cross-validation method, achieving a test accuracy of 97.5% (Chui, Gupta, Alhalabi, & Alzahrani, 2022). Balasundaram et al. (2023) applied a combination of CNN, multilayer models, and ResNet50 to a dataset of 373 samples, focusing on a single MRI slice. The data was classified into four categories, and the study reported a test accuracy of 94% (Balasundaram, Srinivasan, Prasad, Malik, & Kumar, 2023). In another study, the MobileNet model was applied to a dataset of 436 coronal plane MRI images, classifying them into two categories: non-demented and demented. The study employed an 80:10:10 split for training, validation, and testing, achieving a test accuracy of 95.24% (Ghosh et al., 2023). Hajamohideen et al. (2023) used a Siamese CNN model with a triplet-loss function on a large dataset of 6,400 axial plane MRI images. The study classified the data into four categories and reported a test accuracy of 93.85% (Hajamohideen et al., 2023). Another study that uses 2 deep learning approaches in the diagnosis of AD, examines Simplistic CNN Architectures and Transfer Learning. Simplistic CNN Architectures uses simple CNN architectures with 2D and 3D convolutions to process 2D and 3D structured brain scanning. This approach achieves 93.61% and 95.17% accuracy for 2D and 3D multi-class AD classifications, respectively (Lu et al., 2022). The second method applies the principles of transfer learning to take advantage of pre-trained models. This approach uses pre-trained models for classification of the medical images such as the VGG19 model (Helaly, Badawy, & Haikal, 2022). The pretrained VGG19 model achieves 97% accuracy for multiclass AD classification. Continued endeavors to combat this disease give hope that it may be possible to prevent or treat AD in the future.

This paper aims to use deep learning to develop a new method for diagnosing AD. For this purpose, answers to the following research questions were sought:

- How can high accuracy be obtained in AD diagnosis with deep learning models using RAW MRI data in the Oasis-1 dataset from the Oasis Brain Database?
- How does the use of different quartiles and median slices impact CNN model performance?
- Could the obtained model be used as a transfer learning method to improve the performance of low-performing models?

In this study, a new CNN model called ADNet was proposed for Alzheimer's disease diagnosis on the OASIS-1 dataset. This paper is organized as follows: The Materials and Methods section details and prepares the dataset, description of performance metrics, and the model architecture of ADNET proposed in this study. Next, the Experimental Results section is given. In the Discussion section, these results were interpreted in the context of existing literature. Finally, the Conclusion section summarizes the key findings and highlights the contributions of the study.

MATERIALS AND METHODS

MRI (Magnetic Resonance Imaging) images are obtained by placing the patient within a strong magnetic field, which aligns the hydrogen protons in the body and allows for precise sectional views of specific body regions by capturing images in slices. Slicing refers to the acquisition of cross-sectional images of the body or brain in thin layers. They are typically generated in different types of planes, including axial, sagittal, and coronal, to provide a comprehensive view of internal structures from multiple perspectives. Examples of the MRI slices of the axial, sagittal, and coronal planes are given in Figure 1.




Figure 1. Example of the MRI Slices of the Axial, Sagittal, And Coronal Planes (Avots, Jafari, Ozcinar, & Anbarjafari, 2024)

Axial, coronal, and sagittal are the three main MRI imaging planes. As shown in Figure 1, the axial plane captures cross-sectional images from top to bottom, allowing visualization of structures as if viewed from above. The coronal

plane provides front-to-back sectional views, giving a perspective like looking directly at the face. The sagittal plane divides the body into left and right sections, offering a side view of the brain and other structures. Each plane allows for a distinct anatomical perspective, aiding in a comprehensive analysis of structural details within the nervous system. Slices are taken from these planes. Slice thickness, usually ranging from 1 to 5 mm, is selected depending on the required resolution, with thinner slices providing more detail but requiring longer scan times.

Dataset Descriptions

OASIS data sets are open-source brain MRI datasets namely OASIS-1, OASIS-2, OASIS-3, OASIS-3 TAU, and OASIS-4. The OASIS-1 dataset, which consisted of a cross-sectional collection of 416 respondents aged 18 to 96 years, was used in the present study. There are three to four individual T1-weighted MRI scans for each subject. The subjects were both men and women and all were right-handed. All data have been anonymized to accommodate public distribution. The data are available at <http://www.oasis-brains.org> (Marcus et al., 2007). A total of 1688 data was made available in this dataset. After the removal of the missing data, 905 images remained for training and testing. The data has three classes: images of non-AD, subjects at the initial phase of AD, and subjects with AD. The technical specifications for all MRIs used in this study are as follows: The MRI data had dimensions of **256 x 256 x 128**, indicative of the resolution of the scan. This indicates that the image comprises 256 pixels in width, 256 pixels in height, and 128 slices, thus facilitating a comprehensive representation of the brain's structure. The **voxel size** was **1x1x1.25 mm**, where each voxel, the three-dimensional equivalent of a pixel, has a width of 1 mm, a height of 1 mm, and a depth of 1.25 mm. The smaller the voxel size, the higher the spatial resolution, enabling more precise visualization of anatomical structures. The scan was obtained in the **sagittal plane** (Sag), meaning the images were taken along a vertical plane that divides the brain into left and right hemispheres. This orientation provides a clear view of midline brain structures, which is critical for assessing various neurological conditions. Slice examples of MRI according to classes from the Sagittal Plane are depicted in Figure 2.

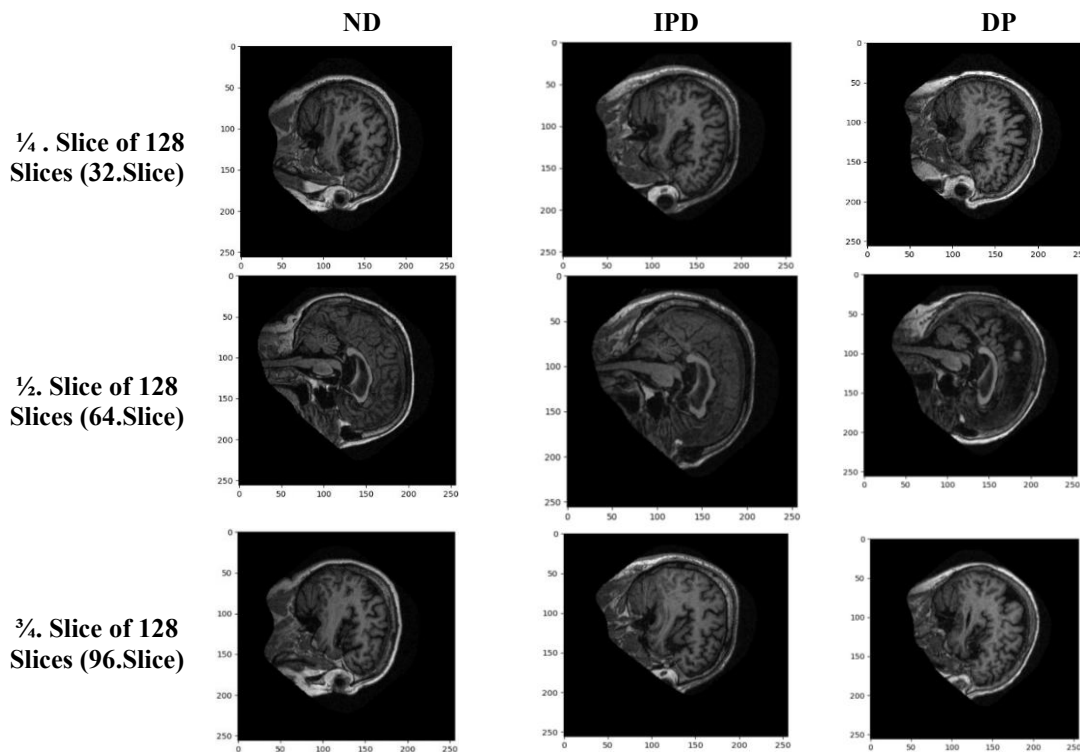


Figure 2. Slice Examples of MRI According to Classes from the Sagittal Plane

MRI slice examples are depicted in Figure 2 from the sagittal plane for three different classes: ND, IPD, and DP. The slices are taken from three distinct parts of the brain, representing the $\frac{1}{4}$., $\frac{1}{2}$., and $\frac{3}{4}$. slice of the total 128 slices in the scan for each subject. Each column corresponds to a different condition, while each row illustrates a different slice location in the sagittal plane. These images help visualize and compare the brain structures across these three diagnostic categories.

The OASIS-1 dataset has individual folders for each MRI scan. Each MRI scan has two different versions (preprocessed and raw) placed in these folders. In this study, the raw data in the RAW folder was preferred. In this folder, the MRI scans are in IMG file format and the *measures* of the relevant scans are in CSV format. These parameters are: "ID (unique identification number of each subject), M/F (gender of the subject), Hand (dominant hand of the subject), Age (age of the subject), Education (education level of the subject), SES (socioeconomic status of the subject), MMSE (Cognitive function test scores), CDR (Clinical Dementia Ratings), eTIV (Brain volume estimation), nWBV (Normalized brain size), ASF (Brain scan size correction factors), Delay (Time delay between brain scan). Only the CDR value was considered in this study for labeling the MRI images. The dataset was divided into three classes using the Clinical Dementia Rating (CDR) parameter as Nondemented – ND (CDR=0), Initial Phase of Dementia -IPD (CDR=0.5), and Dementia Patient -DP (CDR=1). The plot given in Figure 3 shows the class distribution based on the CDR parameters in the OASIS dataset across three classes: Nondemented (ND), Initial Phase Dementia (IPD), and Dementia Patient (DP).




Figure 3. Distribution of Dataset According to Classes

As shown in Figure 3, The Nondemented, Initial Phase Dementia, and Dementia Patient classes have 526, 270, and 109 individuals, respectively.

Data Preparing

In this work, raw MR data from the OASIS-1 dataset were utilized to explore the potential of deep learning models in AD detection. The data preparation stage is important so that this raw data can be given as input to deep learning models. The steps below were performed in this phase:

Conversion to NII File Format: The images in the OASIS-1 dataset are saved in IMG format which cannot be directly processed by the deep learning model. In the first stage, IMG files were transformed into NII file format to render them as a Numpy array in Python. This was performed by the Nibabel library which is a commonly used tool for the analysis of brain imaging arrays (Salhi et al., 2023).

Selection of MRI Slices: After the conversion of the NII files as a Numpy array, it was determined that the MRI scans consist of 128 slice images, with each slice representing a distinct axis of the brain image. The human brain is a complicated organ, and imaging from different angles provides a better insight into brain function and pathology. Quarter slices (1/4, 3/4) and center slices (1/2) were selected for the experiments, in this study. This selection will enable brain images to be analyzed from different angles and model performance to be assessed. The slice choice was modeled after this study (Gramfort et al., 2013) which examined the effect of the distinct slice selections on model performance for the analysis of MEG and EEG data.

Conversion from NII to PNG: NII files were transformed into PNG files for each slice selected using the Nibabel library. This transformation served two major purposes: size reduction and deep learning model adaptability. The total size of the NII file decreased from 15,183,699,040 bytes to 86,262,583 bytes for PNG files. This substantial size reduction has significantly decreased data storage and maintenance costs. PNG format is one of the accepted formats for training the CNN model. This conversion makes the data processable by the model directly.

Methodology and Classification

In this work, a Convolutional Neural Network (CNN) deep learning architecture is designed and trained. CNN is a deep-learning algorithm generally used in image processing. This is a highly effective mechanism for image recognition and classification. The proposed CNN architecture aims to accurately detect AD from MRI. The model

is designed in Python within the Keras framework. It consists of two conventional layers, two maximum pooling layers, a flattening layer, a fully connected layer, and an output layer. The schema of the model architecture of ADNet is depicted in Figure 4.

Table 1. Hyper Parameter Tuning of ADNet

Hyperparameter Values	Metric	ND	IPD	DP	Avg.
Kernel Size for Conv. Layers = 3x3	Prec	0.867	0.533	1.000	0.800
Number of Units for 1. Conv. Layer = 32	Rec	0.684	0.800	0.833	0.773
Number of Units for 2. Conv. Layer = 64	F1	0.765	0.640	0.909	0.771
Activation Function = Adam	Acc				0.743
Kernel Size for Conv. Layers = 3x3	Prec	0.667	0.429	0.857	0.651
Number of Units for 1. Conv. Layer = 32	Rec	0.737	0.300	1.000	0.679
Number of Units for 2. Conv. Layer = 64	F1	0.700	0.353	0.923	0.659
Activation Function = Rmsprop	Acc				0.657
Kernel Size for Conv. Layers = 5x5	Prec	0.731	1.000	1.000	0.910
Number of Units for 1. Conv. Layer = 32	Rec	1.000	0.300	1.000	0.767
Number of Units for 2. Conv. Layer = 64	F1	0.844	0.462	1.000	0.769
Activation Function = Adam	Acc				0.800
Kernel Size for Conv. Layers = 5x5	Prec	0.750	0.500	0.857	0.702
Number of Units for 1. Conv. Layer = 32	Rec	0.632	0.600	1.000	0.744
Number of Units for 2. Conv. Layer = 64	F1	0.686	0.545	0.923	0.718
Activation Function = Rmsprop	Acc				0.686
Kernel Size for Conv. Layers = 3x3	Prec	0.708	0.600	1.000	0.769
Number of Units for 1. Conv. Layer = 64	Rec	0.895	0.300	1.000	0.732
Number of Units for 2. Conv. Layer = 128	F1	0.791	0.400	1.000	0.730
Activation Function = Adam	Acc				0.743
Kernel Size for Conv. Layers = 3x3	Prec	0.688	0.417	0.833	0.646
Number of Units for 1. Conv. Layer = 64	Rec	0.579	0.556	0.833	0.656
Number of Units for 2. Conv. Layer = 128	F1	0.629	0.476	0.833	0.646
Activation Function = Rmsprop	Acc				0.618
Kernel Size for Conv. Layers = 5x5	Prec	0.542	0.375	0.333	0.417
Number of Units for 1. Conv. Layer = 64	Rec	0.684	0.300	0.167	0.384
Number of Units for 2. Conv. Layer = 128	F1	0.605	0.333	0.222	0.387
Activation Function = Adam	Acc				0.486
Kernel Size for Conv. Layers = 5x5	Prec	0.667	0.400	0.857	0.641
Number of Units for 1. Conv. Layer = 64	Rec	0.632	0.400	1.000	0.677
Number of Units for 2. Conv. Layer = 128	F1	0.649	0.400	0.923	0.657
Activation Function = Rmsprop	Acc				0.629

Since using the complete dataset for hyperparameter tuning would be a weighty and time-consuming process, 30% of the dataset was selected as a sample using the Stratified Sampling Method, and the experiments were conducted using this sample set. Since only 30% of the data set was studied, the results were relatively low. The primary hyperparameters adjusted in these experiments were the kernel size of the convolutional layers, the number of units in the first and second convolutional layers, and the choice of activation function). The experimental design involved using both 3x3, and 5x5 for kernel sizes, testing different numbers of units for the convolutional layers (either 32 and 64 units or 64 and 128 units), and comparing the effect of Adam and Rmsprop optimization functions. This systematic

approach permitted an assessment of the impact of each combination of hyperparameters on the model's performance across different dementia stages. For each configuration, precision, recall, F1 score, and accuracy performance metrics were recorded across three classes. The mean value for each metric was calculated to evaluate the overall performance of each configuration. These results are given in Table 1.

Based on the hyperparameter tuning results presented in Table 1, the optimal configuration appears to be the model with a 3x3 kernel size, 32 units in the first convolutional layer, 64 units in the second convolutional layer, and the Adam optimizer. This configuration achieves the highest mean accuracy (0.743), indicating superior overall performance across all classes. Moreover, the highest F1 score of 0.771 suggests a well-balanced model in terms of precision and recall, in datasets such as this. The use of the Adam optimizer enhances the model's performance compared to Rmsprop. The default hyperparameter values for the Adam optimization algorithm in Keras (learning_rate = 0.001, beta_1 = 0.9, beta_2 = 0.999, epsilon = 1e-7) were used. The Sparse_Categorical_Crossentropy that computes the difference between the model's outputs and the observed labels as a loss function, ReLU, and Softmax as activation functions were also used in this study. A detailed description of the ADNet layers depicted in Figure 4 is given below.

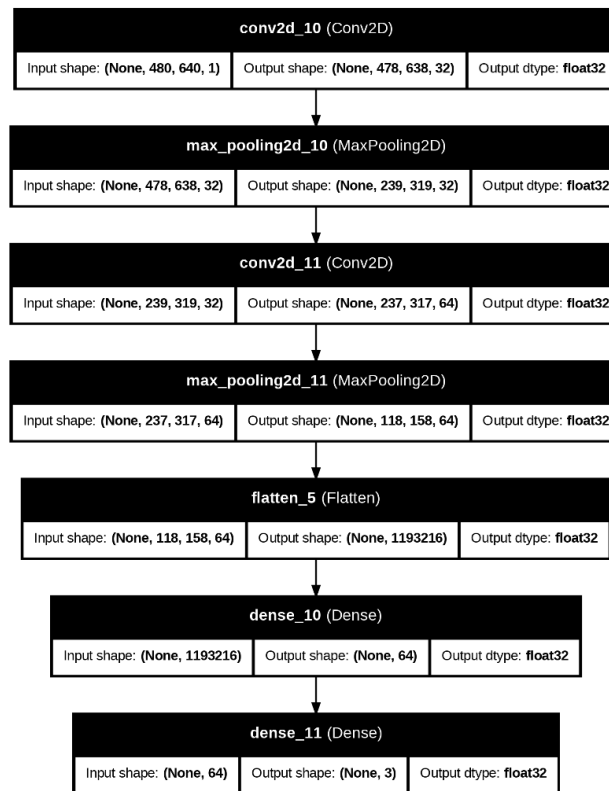


Figure 4. The Schema of the Model Architecture Called ADNet

Input Layer: 480 x 640 x 1 gray scale MRI is acquired. Every image is represented by a single channel (gray scale) containing 480 rows and 640 columns.

First Convolutional Layer: It has 32 kernels of size 3x3. Each kernel produces a new image feature map by shifting a 3x3 window on the image. The ReLU activation function discards values less than or greater than zero while retaining values greater than zero. This layer helps to extract edges, textures, and other significant details in the images.

First Maximum Pooling Layer: Reduces the image using a 2x2 window. It minimizes the size of the image by selecting the largest value in each window. This layer helps the model avoid over-learning and be more stable.

Second Convolutional Layer: It has 64 kernels of size 3x3. It works similarly to the first convolutional layer but aims to extract more complex features. The ReLU Activation Function is utilized.

Second Maximum Pooling Layer: It works similarly to the first Maximum Pooling Layer but minimizes the output of the 2nd Convolutional Layer.

Flatten Layer: It transforms three-dimensional vectors into a one-dimensional vector. This conversion is required for processing by the fully connected layer.

First Fully Connected Layer: It contains 64 neurons. Each Neuron is connected to all the inputs from the preceding layer and uses a weights matrix to convert them into an output. ReLU is selected as the activation function.

Output Layer: It contains 3 neurons. Each neuron predicts the probability of each of the three classes in an image. Softmax activation function makes sure that the sum of the output of each neuron is equal to 1 and each of them generates a likelihood value from 0 to 1.

Performance Evaluation Metrics

The accuracy (Acc), precision (Prec), recall or sensitivity (Rec), F1 score, specificity(spec.), Matthew's Correlation Coefficient (MCC), and Jaccard similarity Index (JSI) metrics obtained from the confusion matrix were used for evaluating the performance of the proposed model. The diagonal members of the matrix show the number of instances correctly classified by the model. The other cells show the number of instances that the model misclassified. For all metrics, a higher value indicates a more successful classification. While evaluating the results, success performance metrics obtained from the confusion matrix were used for multiple classifications which is illustrated in Figure 5.




Figure 5. Confusion Matrix for Multi-Class Classification with N Classes, $0 \leq k \leq n$ (Krüger, 2016)

Figure 5 provides a visual representation of the confusion matrix for multi-class classification with n classes, demonstrating the distribution of true and predicted classes across categories. The formulas utilized in this study and calculated from the confusion matrix are also provided in equations (1), (2), (3),(4),(5),(6) and (7).

$$Accuracy (Acc) = (TP + \sum_i TN_i) / (TP + \sum_i TN_i + \sum_i FP_i + \sum_i FN_i) \quad (1)$$

$$Precision (Prec) = TP / (TP + \sum_i FP_i) \quad (2)$$

$$Recall (Rec \text{ or } Sensitivity) = TP / (TP + \sum_i FN_i) \quad (3)$$

$$Spec = \sum_i TN_i / (\sum_i TN_i + \sum_i FP_i) \quad (4)$$

$$F1 = (2 * Prec * Rec) / (Prec + Rec) \quad (5)$$

$$MCC = (TP \cdot \sum_i TN_i - (\sum_i FP_i \cdot \sum_i FN_i)) / \sqrt{(TP + \sum_i FP_i)(TP + \sum_i FN_i)(\sum_i TN_i + \sum_i FP_i)(\sum_i TN_i + \sum_i FN_i)} \quad (6)$$

$$JSI = TP / (TP + \sum_i FN_i + \sum_i FP_i) \quad (7)$$

where,

- True Positives (TP): The number of instances correctly predicted as positive,
- True Negatives (TN): The number of instances correctly predicted as negative,
- False Positives (FP): The number of instances incorrectly predicted as positive,

False Negatives (FN): The number of instances incorrectly predicted as negative,
i: index of the class.

As seen from the equations, accuracy indicates overall effectiveness by measuring the proportion of correctly classified instances out of all instances. Precision assesses the model's exactness by calculating the proportion of true positive predictions among all positive predictions. Complementing this, Recall (or Sensitivity) measures the model's ability to capture relevant instances by identifying the proportion of actual positives correctly classified. The F1 Score, as the harmonic means of Precision and Recall, offers a balanced measure of accuracy, particularly valuable in the context of imbalanced datasets. MCC (Matthews Correlation Coefficient) provides a comprehensive measure by considering all elements of the confusion matrix, which makes it suitable for datasets with class imbalance. Specificity focuses on the model's ability to correctly identify true negatives, providing insight into its effectiveness at identifying negative instances. Lastly, the JSI (Jaccard Similarity Index) quantifies the overlap between true positives and predicted positives, measuring the similarity between predicted and actual positives, which is crucial for evaluating the model's ability to capture relevant instances accurately. High values are acceptable for all metrics.

EXPERIMENTAL RESULTS

Three different experimental studies have been conducted in this study to evaluate the performance of the proposed ADNet model. First, an experimental study was conducted to decide which slice of the 128 slices taken from the sagittal panel would be used. For this, three different datasets were composed using slices taken from the first quarter, middle, and third quarter of the sagittal plane for each individual MRI, respectively. Slice examples of MRI according to classes are given in Figure 2. Each dataset was split into 80% training and 20% testing using a hold-out method. The model was trained with the training set and was evaluated with the test set, and the results were reported in Table 2. As a result of this experimental study, it was decided to use images on the first quarter slice (1/4) of each MRI. In experiment 2, it was investigated whether the obtained model could be used as a transfer learning model. For this purpose, a model with low performance was retrained using ADNet as a transfer learning model, and the results were examined. The last experimental study involved evaluating the proposed model in more detail, the data set was trained using 5-fold cross validation and this process was repeated 3 times. The results were also reported in Table 4 and interpreted.

The Interpretation of Data from the Middle (1/2) and Quarter Slices (1/4, 3/4) of Sagittal Plane (Experiment 1)

Initially, three different datasets were created from MRI data for this study. As previously mentioned, the MRI data had dimensions of 256 x 256 x 128, meaning that there were 128 sagittal plane slices available for each individual. The three datasets were formed using specific slices from the 128 available MRI slices: the 1/4 slice (32nd slice), the 1/2 slice (64th slice), and the 3/4 slice (96th slice). Each dataset was split into 80% training and 20% testing using a hold-out method and the distribution of train and test datasets is given in Figure 6. To determine which of these slices would be used in this study, experimental analyses were conducted. The test results obtained from three slices trained using the same model architecture showed that the slicing techniques had a major effect on the model's performance.




Figure 6. Distribution of (a) Train and (b) Test Dataset

Figure 6(a) shows that the training dataset is composed of 430 non-demented individuals, 219 with initial phase dementia, and 81 diagnosed as dementia patients. Figure 6(b) presents the testing dataset, which includes 96 non-demented individuals, 51 in the initial phase of dementia, and 28 dementia patients. This distribution highlights the class imbalance, with a higher proportion of non-demented individuals in both datasets. As a result of experimental

studies given in Table 2, it has been seen that ADNet could deal with this problem using $\frac{1}{4}$. slice of 128 Slices (32.Slice).

Table 2. Performance Metrics of ADNet Models Trained with Different Slices

		Acc.	Prec.	Rec.(Sens.)	F1
$\frac{1}{4}$. Slice of 128 Slices (32.Slice)	ND		1.0000	0.9792	0.9895
	IPD	0.9829	0.9615	0.9804	0.9709
	DP		0.9655	1.0000	0.9825
	Avg.		0.9757	0.9865	0.9809
$\frac{1}{2}$. Slice of 128 Slices (64.Slice)	ND		0,9720	0,9541	0,9630
	IPD	0,9282	0,8824	0,9184	0,9000
	DP		0,8261	0,8261	0,8261
	Avg.		0,8935	0,8995	0,8963
$\frac{3}{4}$. Slice of 128 Slices (96.Slice)	ND		0,5556	1	0,7143
	IPD	0,5556	-	0	-
	DP		-	0	-
	Avg.		-	0,333333	-

* The - sign indicates that the relevant metric cannot be calculated.

Accuracy, precision, recall, and F1 score were calculated for each class and depicted in Table 2. The 32. slice exhibits the highest performance across all metrics, with accuracy, precision, recall (sensitivity), and F1 scores close to or exceeding 0.98, suggesting that this slice provides highly informative features for the model. In contrast, the performance metrics for the 64. slice is somewhat lower, with an average accuracy of 0.8935, and precision, recall, and F1 scores in a similar range, indicating moderate model efficacy for this region. Notably, the 96. slice yields substantially lower results, with accuracy and precision values around 0.55, and recall and F1 metrics not calculable for certain classes. The accuracy rates by epochs during training are shown in Figure 7.




Figure 7. Training Accuracy of ADNet According to Quarter and Center Slices of MRI

A significant disparity in accuracy performance depending on the MRI slice location is seen in Figure 7. The blue line represents the $\frac{1}{4}$. Slice of 128 slice data, exhibits a sharp increase in accuracy, achieving near-perfect classification by epoch 10. The green line, indicating the accuracy on center slices, also shows an upward trend, though it stabilizes at a slightly lower level compared to the $\frac{1}{4}$ slice. In contrast, the red line represents the $\frac{3}{4}$. Slice of 128, remains consistently low across all epochs, suggesting minimal learning from this slice region. This variation in performance suggests that different regions of MRI data provide varying degrees of discriminative information, potentially due to anatomical and pathological differences across slices. This observation emphasizes the importance of slice selection and its impact on model performance.

Effect of Transfer Learning (Experiment 2)

Another question tackled in this article is whether the obtained most successful model could be used as a transfer learning method to improve the performance of low-performing models. For this, transfer learning was performed using the ADNet model trained with the most successful quartile (1/4), and then the data from the lowest-performing quartile (3/4) was retrained using this obtained model. This technique increased the test accuracy of the lowest successful quartile (3/4) from 55.56% to 96.11%. These results are given in Table 3. Also, the comparisons of the accuracy rates according to the epochs during the training are presented in Figure 8.




Figure 8. Accuracy Comparison with Transfer Learning in AD Diagnosis

As seen in Figure 8, the transfer learning method enabled the model to adjust to the new dataset and significantly improved its performance. The green line represents the model trained with transfer learning, showing a rapid increase in accuracy within the first 10 epochs, reaching over 90%, and stabilizing close to 1.0. This rapid convergence and high accuracy indicate the effectiveness of transfer learning in accelerating model training and improving performance by leveraging pre-existing knowledge. In contrast, the red line, representing the basic model trained from scratch, maintains a low and stable accuracy of around 0.55 throughout all epochs, suggesting limited learning and poor classification ability. It is said that the ADNet could be used as a transfer learning method to improve the performance of low-performing models. These significant findings have the potential to improve AD recognition to be more precise and reliable.

Table 3. Performance Metrics after using ADNet as transfer learning on the composed of 3/4. Slice of 128 Slices

		Acc	Prec	Rec(Sens)	F1
3/4. Slice of 128 Slices (96.Slice) using ADNET as Transfer Learning	ND		0,9709	1,0000	0,9852
	IPD	0,9611	1,0000	0,8727	0,9320
	DP		0,8621	1,0000	0,9259
	Avg.		0,9443	0,9576	0,9477

Table 3 presents the performance metrics of the ADNet model utilizing transfer learning on the 3/4. slice (96th slice) of the 128-slice. The model achieved high accuracy, precision, recall (sensitivity), and F1 scores across the three classes. For the ND class, recall reached 1.0 with an accuracy of 0.9611, indicating excellent classification capability for this category. In the IPD class, precision was 1.0, but recall dropped slightly to 0.8727, reflecting a minor trade-off between precision and recall. The DP class exhibited strong performance, with a precision of 0.8621 and perfect recall at 1.0, yielding an F1 score of 0.9259. The average metrics for accuracy, precision, and recall (0.9443, 0.9576, and 0.9477, respectively) highlight the robustness of the transfer learning approach in enhancing model performance on this slice.

Cross Validation Results (Experiment 3)

To evaluate the proposed model in more detail, the data set was trained using 5-fold cross validation and this process was repeated 3 times. Figure 5 presents the confusion matrices obtained from a 3x5 cross-validation (CV) scheme applied to evaluate the model’s classification performance across different repeats and folds. Each row in the figure represents a distinct repeat of the cross-validation, while each column corresponds to a specific fold within that repeat. The matrices illustrate the counts of actual versus predicted labels for three classes: ND, IPD, and DP. These results highlight the model’s consistency and robustness in correctly identifying each class across multiple cross-validation folds, allowing for a comprehensive assessment of its performance stability.

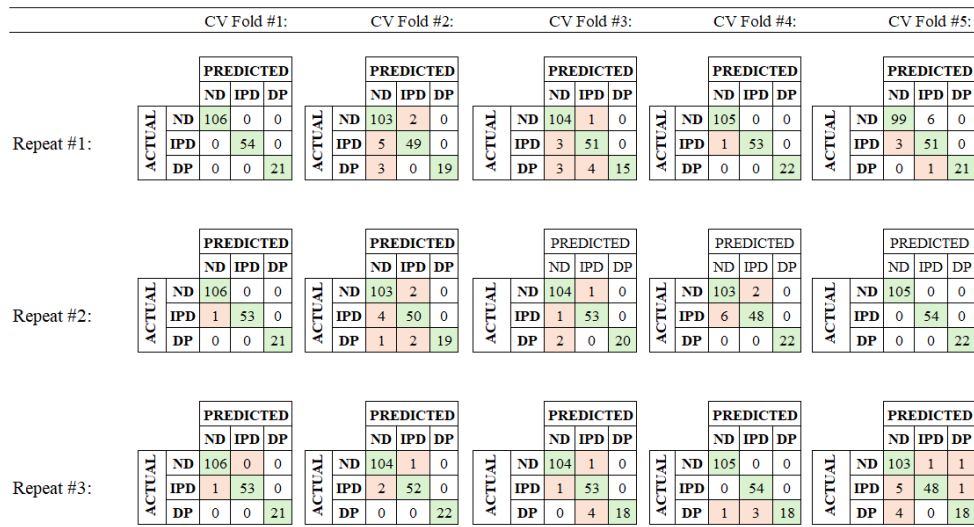


Figure 9. Confusion Matrices of 3x5cv for Dementia Classification Classes for Test Sets

As seen in Figure 9, the results demonstrate high consistency in classification accuracy with minimal misclassifications across folds and repetitions. Overall, the results suggest the model’s robustness and reliability across different CV folds and repetitions, highlighting its potential effectiveness in multi-class medical image classification tasks. The performance metrics given in equations (1)-(7) are calculated from these confusion matrices shown in Figure 9 according to each fold of repeats. The average results of folds placed in repeats and the average of metrics obtained from repeats are reported for test sets in Table 4.

Table 4. Performance Metrics of 3x5cv for Dementia Classification Classes for Test Sets

Repeat #1:							
	Acc.	Prec.	Rec.	F1	Spec.	MCC	JSI
ND	0.9646	0.9669	0.9829	0.9746	0.9759	0.9794	0.9829
IPD		0.9502	0.9556	0.9524	1.0000	0.9680	0.9556
DP		1.0000	0.9000	0.9429	0.9936	0.9366	0.9000
Avg.		0.9724	0.9461	0.9566	0.9899	0.9613	0.9461
Repeat #2:							
	Acc.	Prec.	Rec.	F1	Spec.	MCC	JSI
ND	0.9757	0.9723	0.9905	0.9812	0.9861	0.9883	0.9905
IPD		0.9735	0.9556	0.9642	1.0000	0.9683	0.9556
DP		1.0000	0.9545	0.9758	0.9974	0.9730	0.9545
Avg.		0.9819	0.9669	0.9738	0.9945	0.9765	0.9669
Repeat #3:							
	Acc.	Prec.	Rec.	F1	Spec.	MCC	JSI
ND	0.9713	0.9745	0.9924	0.9832	0.9916	0.9905	0.9924
IPD		0.9644	0.9630	0.9628	0.9984	0.9731	0.9630
DP		0.9800	0.8909	0.9314	0.9913	0.9350	0.8909
Avg.		0.9730	0.9488	0.9592	0.9938	0.9662	0.9488
Avg. Results of all the Repeats							
	Acc.	Prec.	Rec.	F1	Spec.	MCC	JSI
ND	0.9705	0.9716	0.9769	0.9740	0.9845	0.9860	0.9886
IPD		0.9715	0.9577	0.9637	0.9995	0.9698	0.9580
DP		0.9873	0.9193	0.9494	0.9941	0.9482	0.9152
Avg.		0.9727	0.9474	0.9579	0.9927	0.9680	0.9539

Table 4 provides an in-depth performance analysis of the model across three repeated tests for the ND, IPD, and DP categories, evaluating metrics including Accuracy (Acc.), Precision (Prec.), Recall (Rec.), F1 Score (F1), Specificity (Spec.), Matthews Correlation Coefficient (MCC), and Jaccard Similarity Index (JSI). This multi-metric approach demonstrates the model's stability across varying conditions. In terms of Accuracy, ND and IPD consistently exhibit high values across each repeat, with averages of 0.9705 and 0.9715, respectively. DP achieves the highest overall accuracy at 0.9873, indicating reliable classification performance throughout. Precision metrics are similarly consistent, with ND maintaining an average of 0.9716, IPD at 0.9577, and DP slightly lower at 0.9193. Although DP's precision remains high, this relative drop implies a minor discrepancy in true positive predictions, potentially due to feature overlap or subtle distinctions within the DP class. The Recall results show the model's effectiveness in capturing true positives. ND achieves the highest Recall average (0.9769), followed by IPD (0.9637) and DP (0.9494). These high Recall scores confirm the model's ability to detect relevant samples accurately. The F1 Score, which balances Precision and Recall, shows optimal scores for ND and IPD, averaging 0.9740 and 0.9995, respectively, signifying strong balance. DP, with an F1 Score of 0.9941, maintains robust performance though it indicates a slightly less consistent balance between Precision and Recall. Specificity values highlight the model's proficiency in identifying true negatives and minimizing false positive rates. The consistency in Specificity across repeats underscores the model's reliability. MCC, a key indicator for imbalanced data performance, also reflects this trend. ND achieves the highest MCC at 0.9860, followed by IPD (0.9580) and DP (0.9152). JSI remains high, with averages of 0.9886 for ND, 0.9580 for IPD, and 0.9152 for DP, indicating a strong overlap between predicted and actual classifications. The high JSI values reflect the model's ability to align closely with true distributions, which is crucial for tasks demanding precise class correspondence. Overall, the model demonstrates robust performance across all metrics. Collectively, the results confirm the model's reliability and capability in diverse classification scenarios. Descriptive Statics of the performance metrics of 3x5 fold cross validation results were given in Figure 10. The accuracy and loss graph according to epoch numbers for training the best model among these models is given in Figure 11.




Figure 10. Descriptive Statics of the Performance Metrics of 3x5 Fold Cross Validation Results

Figure 10 presents graphs of the descriptive statistics for the performance metrics of ADNet evaluated through 3x5 fold cross-validation. The minimum, maximum, average, and standard deviation of accuracy, precision, recall, F1 score, specificity, Matthews correlation coefficient, and Jaccard similarity index.

The ND, and IPD classes display consistently high performance across all metrics, with average values close to 1.0 and low standard deviations, indicating stable and reliable performance across folds. However, the DP class exhibits more variability, with lower minimum values for recall and F1 score however, the standard deviation was calculated as 0.1 at most. This shows that the cross-validation results demonstrate robust and consistent classification performance for detection the Alzheimer. The accuracy and loss graphs of the best model from 3x5cv according to epoch number are shown in Figure 11.




Figure 11. Accuracy and Loss Graphs of the (a) Worst and (b) Best Model from 3x5cv According to Epoch Number

The stability observed in both metrics over subsequent epochs implies that the model has reached a point of minimal overfitting and exhibits consistent performance from Figure 11. This figure highlights the model's efficient convergence and reliability across the cross-validation process, reinforcing the robustness of the selected architecture and training strategy.

DISCUSSION

This study examines the efficacy of ADNet which is a Convolutional Neural Network based Deep Learning model for the diagnosis of Alzheimer's Disease on the OASIS-1 dataset. This section presents a discussion of the implications of the experimental findings and a comparison of ADNet's performance with existing studies on Alzheimer's diagnosis using the OASIS-1 dataset. The comparative analysis presented in Table 5 provides a comprehensive overview of the performance of various state-of-the-art methods applied to the OASIS dataset. All studies given in Table 5 were conducted using the OASIS-1 dataset, with accuracy as the common metric for evaluating success. Consequently, the discussion is primarily focused on this metric. Table 5 also presents detailed information for each study, including the number of records in the dataset, data type, sampling method, method used, class labels used, and test accuracy value.

As seen from Table 5, a comparison with earlier studies shows that traditional machine learning methods such as Random Forest and SVM have demonstrated competitive results, with accuracies ranging from 84.00% to 94.80%. The findings indicate that the deep networks employed in recent methodologies are more adept at capturing the intricate features essential for the tasks pertaining to the OASIS dataset. Deep learning models have demonstrated a notable enhancement, as evidenced by models such as Inception-v3 model (87.75%), Supervised Autoencoder-SSAs (90%), and MobileNet (95.24%) which use holdout as a sampling method. The proposed method, ADNet, exhibits superior accuracy in comparison to alternative approaches, attaining 98.29% test accuracy for the dataset divided into 80% training and 20% testing with the holdout method in experiment 1. It is noteworthy that while the ADNet, when used as a transfer learning approach, achieved a slightly lower accuracy of 96.11%, it still outperforms many of the existing models in the literature. This illustrates the robustness and adaptability of the ADNet architectural design, thereby establishing its potential as a valuable tool for applications beyond the OASIS dataset.

Furthermore, the results obtained from experiment 2 demonstrated that the selection of MRI sections had a considerable influence on the performance of the models. The use of a quarter (1/4) of the data provided resulted in the highest accuracy compared to other slicing strategies, thereby underscoring the significance of data preprocessing techniques. The application of transfer learning resulted in a notable enhancement in the performance of the data with relatively lower accuracy, from 55.56% to 96.11%. This effectively exploited the information from a model that had demonstrated efficacy on a subset of disparate data sets to enhance classification in a novel data set. In addition to the notable performance of the developed convolutional neural network (CNN) model, it is essential to emphasize the originality of our transfer learning approach. The self-training version has been derived from a subset of the OASIS dataset. This data-driven adaptation further optimized the model's performance by ensuring that the information conveyed was consistent with the characteristics and distribution of the target dataset. The introduction

of the self-training model removed the necessity for reliance on pre-trained external models, which may no longer be readily available or optimized for the specific task at hand. This approach encourages self-sufficiency and enables researchers to adapt transfer learning to suit specific datasets and research objectives.

Table 5. Comparison with the State-of-the-Art on OASIS-1 Dataset

Reference	Name of Best Method Used	Data Count	Type of Data Used	Class Labels (number of classes)	Sampling Method (Train(%): Test(%) for Holdout)	Test Accuracy (%)
(Shrivastava et al., 2023)	Random Forest	136	Measures Included in the OASIS dataset	Nondemented, demented (2)	75:25 (Holdout)	84
(Jadhao et al., 2023)	Extra Tree Classifier	373	Measures Included in the OASIS dataset	Nondemented, moderate dementia, demented (3)	85:15 (Holdout)	85,71
(Baglat et al., 2020)	Random forest classifier	150	Measures Included in the OASIS dataset	Nondemented, demented (2)	5-fold cross validation	86.84
(Salami, Bozorgi-Amiri, Hassan, Tavakkoli-Moghaddam, & Datta, 2022)	Inception-v3 model	1094	MRI Data	CN (Cognitively Normal), AD (Alzheimer's Disease)(2)	80:20 (Holdout)	87.75
(Mendoza-Leon, Puentes, Felipe, & Hern, 2020)	Supervised Autoencoder : SSAs	174	MRI Data	Healthy, AD-demented (2)	80:20 (Holdout)	90
(Neffati, Ben Abdellafou, Jaffel, Taouali, & Bouzrara, 2019)	DKPCA + MKSVM	198	MRI Data	No dementia, Very mild AD, Mild AD, Moderate AD(4)	5-fold cross validation	92.50
(Saratxaga et al., 2021)	Deep Learning	1114	MRI Data	Nondemented, moderate dementia, demented (3)	70:30 (Holdout)	93.18
(Mohammed et al., 2021)	AlexNet+SVM hybrid model	6400	MRI Data	Mild dementia, Moderate dementia, Non-dementia, Very mild dementia (4)	80:20 (Holdout)	94.80
(Rajayyan & Mustafa, 2023)	Gaussian Naïve Bayes	373	Measures Included in the OASIS	Nondemented, moderate dementia, demented (3)	80:20 (Holdout)	95
(Ghosh et al., 2023)	MobileNet	436	MRI Data	Nondemented, demented (2)	80:20 (Holdout)	95.24
(Chui et al., 2022)	GAN-CNN-TL	2168	MRI Data	Non-demented, Very Mildly Demented, Mildly Demented, Moderately Demented (4)	5-fold cross validation	96.8
<i>Proposed Method (Exp.2)</i>	<i>ADNet using as a Transfer Learning</i>	905	<i>MRI Data</i>	<i>Non Demented, Initial Phase Dementia, Dementia Patient(3)</i>	<i>80:20 (Holdout)</i>	<i>96.11</i>
<i>Proposed Method (Exp. 3)</i>	<i>ADNet</i>	905	<i>MRI Data</i>	<i>Non Demented, Initial Phase Dementia, Dementia Patient(3)</i>	<i>5-fold cross validation</i>	97.05
<i>Proposed Method (Exp. 1)</i>	<i>ADNet</i>	905	<i>MRI Data</i>	<i>Non Demented, Initial Phase Dementia, Dementia Patient(3)</i>	<i>80:20 (Holdout)</i>	98.29

This considerable improvement demonstrates ADNet's capability to enhance model performance in cases with limited training data or suboptimal initial performance. The robustness of ADNet was also evaluated through a comprehensive testing process, employing 5-fold cross-validation repeated three times in experiment 3. This evaluation produced a mean test set accuracy of 97.05%, indicating that ADNet is a reliable and stable model across varying subsets of data. Furthermore, the results of the ADNet demonstrate higher performance than those of the previously leading method with 5-fold cross validation, GAN-CNN-TL, which achieved an accuracy of 96.8%. Despite the encouraging outcomes, it is acknowledged that the methodology employed in this study is subject to certain constraints. Firstly, the relatively limited size of the dataset may restrict the model's generalizability. Further

research is required with a larger and more diverse dataset to confirm the model's effectiveness in real-world clinical settings. Secondly, the study focused on three diagnostic categories. Subsequent studies may wish to incorporate supplementary phases of Alzheimer's disease (AD) to achieve a more comprehensive analysis. Furthermore, an investigation of alternative convolutional neural network (CNN) architectures and hyperparameter settings has the potential to enhance the model's performance.

CONCLUSIONS

Alzheimer's disease (AD) is a major global health problem characterized by progressive cognitive decline and functional impairment. Early and accurate diagnosis is of paramount importance for the timely implementation of appropriate interventions that may improve patient outcomes. This study investigates the effectiveness of a convolutional neural network based deep learning model for diagnosing Alzheimer's disease using the OASIS-1 dataset, a widely used neuroimaging dataset.

In this study, three distinct datasets were constructed to identify the most informative slice among the 128 sagittal slices present in each MRI. Slices were selected from the first, middle, and third quarters of the sagittal plane to identify which region held the most valuable information for the diagnosis of Alzheimer's disease. The datasets were divided into two distinct sets: 80% for training and 20% for testing. This allowed for a comprehensive evaluation of ADNet's performance. The results demonstrated that the slice from the first quarter exhibited the highest accuracy, achieving a score of 98.26% on the test set. This finding indicates that slices from the initial sagittal region contain significant information that ADNet effectively utilizes for accurate diagnosis. Moreover, the study investigated the potential of ADNet as a transfer learning model. A model with initially low performance, achieving only 55.56% accuracy, was retrained using ADNet as a transfer learning foundation, resulting in a significantly improved accuracy of 96.11%. This considerable improvement demonstrates ADNet's capability to enhance model performance in cases with limited training data or suboptimal initial performance. The robustness of ADNet was also evaluated through a comprehensive testing process, employing 5-fold cross-validation repeated three times. This evaluation produced a mean accuracy of 97.05%, indicating that ADNet is a reliable and stable model across varying subsets of data. Collectively, these findings suggest that ADNet has promising applications for clinical Alzheimer's screening and serves as a reliable transfer learning model, enabling more accurate and earlier diagnoses.

The ADNet model with transfer learning exhibits superior test accuracy in comparison to the majority of existing studies, particularly those that employ more straightforward machine learning algorithms. The efficacy of this methodology is particularly noteworthy considering the limited size of the dataset and the complexity of the three-class classification task. Notwithstanding the promising results, the study is aware of the limitations intrinsic to the research process. Further research is required with a larger and more diverse dataset to verify the generalizability of the model. Furthermore, incorporating additional AD stages and investigating sophisticated deep learning architectures may potentially result in additional improvements.

Consequently, this study has successfully optimized a convolutional neural network (CNN) model for the diagnosis of Alzheimer's disease (AD) using the OASIS dataset. The model's state-of-the-art test accuracy, the effectiveness of transfer learning from the self-supervised learning model, and its robust performance demonstrate the potential of deep learning for early and accurate Alzheimer's disease (AD) detection. Further research is required to validate the findings with larger datasets, incorporate more AD stages, and explore advanced deep-learning architectures for more robust and reliable AD diagnostics.

ACKNOWLEDGEMENT

This study has been financially supported by the Coordinatorship of Scientific Research Projects of Necmettin Erbakan University [Project no: 23GAP19015].

REFERENCES

- Afzal, S., Maqsood, M., Khan, U., Mehmood, I., Nawaz, H., Aadil, F., & Nam, Y. (2021). *Alzheimer Disease Detection Techniques and Methods : A Review*. 6, 26–38. <https://doi.org/10.9781/ijimai.2021.04.005>
- Alroobaea, R., & Bragazzi, N. L. (2021). *Alzheimer 's Disease Early Detection Using Machine Learning Techniques*. 1–16.
- Alzheimer's Association. (2023). 2023 Alzheimer's disease facts and figures. *Alzheimer's Dement.*, 19(4)(February), 1598–1695. <https://doi.org/10.1002/alz.13016>

- Avots, E., Jafari, A., Ozcinar, C., & Anbarjafari, G. (2024). Comparative efficacy of histogram-based local descriptors and CNNs in the MRI-based multidimensional feature space for the differential diagnosis of Alzheimer's disease: a computational neuroimaging approach. *Signal, Image and Video Processing*, 18(1), 1–13. <https://doi.org/10.1007/s11760-023-02942-z>
- Baglat, P., Salehi, A. W., Gupta, A., & Gupta, G. (2020). Multiple Machine Learning Models for Detection of Alzheimer's Disease Using OASIS Dataset. In S. K. Sharma, Y. K. Dwivedi, B. Metri, & N. P. Rana (Eds.), *Re-imagining Diffusion and Adoption of Information Technology and Systems: A Continuing Conversation. TDIT 2020. IFIP Advances in Information and Communication Technology* (Vol. 617, pp. 614–622). https://doi.org/10.1007/978-3-030-64849-7_54
- Balasundaram, A., Srinivasan, S., Prasad, A., Malik, J., & Kumar, A. (2023). Hippocampus Segmentation-Based Alzheimer's Disease Diagnosis and Classification of MRI Images. *Arabian Journal for Science and Engineering*. <https://doi.org/10.1007/s13369-022-07538-2>
- Bendlin, B. B., Carlsson, C. M., Gleason, C. E., Johnson, S. C., Sodhi, A., Puglielli, L., ... Wharton, W. (2011). Midlife predictors of Alzheimer's disease. *Maturitas*, 65(2), 131–137. <https://doi.org/10.1016/j.maturitas.2009.12.014>
- Breijyeh, Z., & Karaman, R. (2020). Comprehensive Review on Alzheimer's Disease : Causes and Treatment. *Molecules*, 25(5789), 1–28.
- Chui, K. T., Gupta, B. B., Alhalabi, W., & Alzahrani, F. S. (2022). An MRI Scans-Based Alzheimer's Disease Detection via Convolutional Neural Network and Transfer Learning. *Diagnostics*, 12(1531), 1–14.
- Ghosh, T., Palash, M. I. A., Yousuf, M. A., Hamid, M. A., Monowar, M. M., & Alassafi, M. O. (2023). A Robust Distributed Deep Learning Approach to Detect Alzheimer's Disease from MRI Images. *Mathematics*, 11(12), 2633. <https://doi.org/10.3390/math11122633>
- Gramfort, A., Luessi, M., Larson, E., Engemann, D. A., Strohmeier, D., Garcia, S., ... I, B. L. (2013). MEG and EEG data analysis with MNE-Python. *Frontiers in Neuroscience*, 7(December), 1–13. <https://doi.org/10.3389/fnins.2013.00267>
- Hajamohideen, F., Shaffi, N., Mahmud, M., Subramanian, K., Al Sariri, A., Vimbi, V., & Abdesselam, A. (2023). Four-way classification of Alzheimer's disease using deep Siamese convolutional neural network with triplet-loss function. *Brain Informatics*, 10(1). <https://doi.org/10.1186/s40708-023-00184-w>
- Helaly, H. A., Badawy, M., & Haikal, A. Y. (2022). Deep Learning Approach for Early Detection of Alzheimer ' s Disease. *Cognitive Computation*, (September 2021), 1711–1727. <https://doi.org/10.1007/s12559-021-09946-2>
- Jadhao, P., Palsodkar, P., Raut, R., Chaube, K., Rathod, D., & Palsodkar, P. (2023). Prediction of Early Stage Alzheimer ' s using Machine Learning Algorithm. *2023 4th International Conference for Emerging Technology (INCET)*, 1–5. <https://doi.org/10.1109/INCET57972.2023.10170583>
- Khagi, B., & Kwon, G. R. (2019). CNN model performance analysis on MRI images of an OASIS dataset for distinction between healthy and Alzheimer's patients. *IEIE Transactions on Smart Processing and Computing*, 8(4), 272–278. <https://doi.org/10.5573/IEIESPC.2019.8.4.272>
- Krüger, F. (2016). Activity, Context, and Plan Recognition with Computational Causal Behaviour Models. *Faculty of Computer Science and Electrical Engineering, University of Rostock, Phd Thesis*, p:71-72.
- Lu, B., Li, H., Chang, Z., Li, L., Chen, N., Zhu, Z., & Zhou, H. (2022). *A practical Alzheimer ' s disease classifier via brain imaging-based deep learning on 85 , 721 samples*.
- Marcus, D. S., Wang, T. H., Parker, J., Csernansky, J. G., Morris, J. C., Data, C. M. R. I., ... Buckner, R. L. (2007). Open Access Series of Imaging Studies (OASIS): Cross-sectional MRI Data in Young , Middle Aged , Nondemented , and Demented Older Adults Citation Open Access Series of Imaging Studies (OASIS): Nondemented , and Demented Older Adults. *Journal of Cognitive Neuroscience*, 19(9), 1498–1507. <https://doi.org/10.1162/jocn.2007.19.9.1498>
- Mendoza-Leon, R., Puentes, J., Felipe, L., & Hern, M. (2020). Single-slice Alzheimer ' s disease classification and disease regional analysis with Supervised Switching Autoencoders. *Computers in Biology and Medicine*, 116(October 2019), 1–14. <https://doi.org/10.1016/j.combiomed.2019.103527>

- Mohammed, B. A., Senan, E. M., Rassem, T. H., Makbol, N. M., Alanazi, A. A., Al-Mekhlafi, Z. G., ... Ghaleb, F. A. (2021). Multi-method analysis of medical records and mri images for early diagnosis of dementia and alzheimer's disease based on deep learning and hybrid methods. *Electronics (Switzerland)*, 10(22). <https://doi.org/10.3390/electronics10222860>
- Neffati, S., Ben Abdellafou, K., Jaffel, I., Taouali, O., & Bouzrara, K. (2019). An improved machine learning technique based on downsized KPCA for Alzheimer's disease classification. *International Journal of Imaging Systems and Technology*, 29(2), 121–131. <https://doi.org/10.1002/ima.22304>
- Ovsepian, S. V., Leary, V. B. O., Zaborszky, L., & Ntziachristos, V. (2019). *HHS Public Access*. 25(4), 288–297. <https://doi.org/10.1177/1073858418791128>.Amyloid
- Porsteinsson, A. P., Isaacson, R. S., Knox, S., Sabbagh, M. N., & Rubino, I. (2021). *Diagnosis of Early Alzheimer's Disease: Clinical Practice in 2021*. 3(8), 371–386.
- Rajayyan, S., & Mustafa, S. M. M. (2023). Prediction of dementia using machine learning model and performance improvement with cuckoo algorithm. *International Journal of Electrical and Computer Engineering*, 13(4), 4623–4632. <https://doi.org/10.11591/ijece.v13i4.pp4623-4632>
- Salami, F., Bozorgi-Amiri, A., Hassan, G. M., Tavakkoli-Moghaddam, R., & Datta, A. (2022). Designing a clinical decision support system for Alzheimer's diagnosis on OASIS-3 data set. *Biomedical Signal Processing and Control*, 74(September 2021), 1–7. <https://doi.org/10.1016/j.bspc.2022.103527>
- Salhi, S., Kora, Y., Ham, G., Zadeh, H., Id, H., & Simon, C. (2023). Network analysis of the human structural connectome including the brainstem. *PLoS ONE*, 18(4), 1–20. <https://doi.org/10.1371/journal.pone.0272688>
- Saratxaga, C. L., Moya, I., Picón, A., Acosta, M., Moreno-Fernandez-de-leceta, A., Garrote, E., & Bereciartua-Perez, A. (2021). Mri deep learning-based solution for alzheimer's disease prediction. *Journal of Personalized Medicine*, 11(9). <https://doi.org/10.3390/jpm11090902>
- Scheltens, P., Strooper, B. De, Kivipelto, M., Holstege, H., Chételat, G., Teunissen, C. E., ... Flier, W. M. Van Der. (2022). *Alzheimer ' s disease*. 397(10284), 1577–1590. [https://doi.org/10.1016/S0140-6736\(20\)32205-4](https://doi.org/10.1016/S0140-6736(20)32205-4).Alzheimer
- Shrivastava, R. K., Singh, S. P., & Kaur, G. (2023). shrivastava.pdf. In D. Koundal, D. K. Jain, Y. Guo, A. S. Ashour, & A. Zaguia (Eds.), *Data Analysis for Neurodegenerative Disorders. Cognitive Technologies*. (pp. 111–126). https://doi.org/10.1007/978-981-99-2154-6_6



Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences



Geliş Tarihi : 29.11.2024
Kabul Tarihi : 24.01.2025

Received Date : 29.11.2024
Accepted Date : 24.01.2025

FARKLI İŞLEM KOŞULLARINDA AĞARTILAN KENEVİR KUMAŞIN BEYAZLIK DERESESİNİN TAHMİNLENMESİ

PREDICTION OF THE WHITENESS DEGREE OF HEMP FABRIC BLEACHED UNDER DIFFERENT CONDITIONS

Gamze GÜLŞEN BAKICI¹* (ORCID: 0000-0002-4241-7096)

¹ Çukurova Üniversitesi, Tekstil Teknolojisi, Adana, Türkiye

*Sorumlu Yazar / Corresponding Author: Gamze GÜLŞEN BAKICI, gamzegulsenbakici@gmail.com

ÖZET

Bu çalışmada, Nm 25 inceliğinde ham kenevir iplik kullanılarak 14 gauge düz örgü makinesinde 1x1 rib ham kumaş üretilmiş ve bu kumaşlara hidrofilleştirme işlemi uygulanmıştır. Hidrofilleştirilen numuneler, 100°C, 110°C ve 120°C sıcaklıklarında, 10, 11, 12 ve 13 pH değerlerinde ve 2, 4, 6, 8, 10, 12 g/L ağartıcı konsantrasyonlarında ağartılmıştır. Numunelerin beyazlık seviyeleri Berger Beyazlık İndeksi ile ölçülmüştür. Sıcaklık arttıkça beyazlık derecelerinde beklenen artış gözlemlenmiş, sabit sıcaklıkta ise pH ve ağartıcı konsantrasyonundaki artışla beyazlık derecelerinde genel bir artış eğilimi görülmüş, ancak küçük sapmalar tespit edilmiştir. Ağartma işlemlerinde kullanılan sıcaklık, pH ve konsantrasyon değişkenleri bağımsız, beyazlık dereceleri ise bağımlı değişken olarak ele alınarak çoklu doğrusal regresyon analizi yapılmıştır. Analiz, bu değişkenlerin beyazlık derecesi üzerindeki etkisinin istatistiksel olarak anlamlı olduğunu ($p<0.05$) ve modelin belirleme katsayısı (R^2) değerinin, bağımsız değişkenlerin beyazlık derecesindeki varyansı %82 oranında açıkladığını ortaya koymuştur.

Anahtar Kelimeler: Kenevir, sürdürülebilir, ağartma, beyazlık, regresyon

ABSTRACT

In this study, Nm 25 hemp yarn was used to produce 1x1 rib knitted fabric on a 14 gauge flat knitting machine, and the fabric was subjected to a hydrophilization process. The hydrophilized samples were bleached at temperatures of 100°C, 110°C, and 120°C, with pH values of 10, 11, 12, and 13, and hydrogen peroxide concentrations of 2, 4, 6, 8, 10, and 12 g/L. Whiteness levels of the samples were measured using the Berger Whiteness Index. As the temperature increased, the whiteness levels showed the expected increase. At a constant temperature, an overall increasing trend in whiteness levels was observed with increasing pH and hydrogen peroxide concentration, although small deviations were detected. The temperature, pH, and concentration variables used in the bleaching process were considered as independent variables, while the whiteness levels were taken as the dependent variable, and multiple linear regression analysis was applied. The analysis revealed that the effects of these variables on whiteness were statistically significant ($p<0.05$), and the coefficient of determination (R^2) of the model explained 82% of the variance in whiteness levels.

Keywords: Hemp, sustainable, bleaching, whiteness, regression

GİRİŞ

Artan çevresel ve sağlık kaygıları, araştırmacıları çevre dostu ve sürdürülebilir kaynaklar aramaya yöneltmiştir. Bitkiler, böcekler ve hayvanlardan elde edilen doğal malzemeler, yenilenebilir ve düşük çevresel etki ile biyo-kaynaklar olarak öne çıkmaktadır. Bu malzemeler, çevresel etkileri azaltarak ekolojik dengeyi koruma potansiyeli taşır ve gıda, kozmetik ve tekstil uygulamalarında önemli rol oynar (Inprasit vd., 2020). Tarihsel olarak pamuk, oldukça sürdürülebilir bir malzeme olarak görülmüştür; ancak ayrıntılı araştırmalar bunun aksini ortaya koymaktadır. ToCite: GÜLŞEN BAKICI, G., (2025). FARKLI İŞLEM KOŞULLARINDA AĞARTILAN KENEVİR KUMAŞIN BEYAZLIK DERESESİNİN TAHMİNLENMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 505-512.

Artan kirlilik seviyeleri ve iklim değişikliğiyle mücadele ihtiyacı, sürdürülebilir alternatiflerin küresel çapta aranmasına yol açmıştır (Tripa vd., 2023). Kenevir (*Cannabis Sativa*), tarihsel olarak önemli bir ticari ürün olmuş ve günümüzde endüstriyel bir mahsul olarak yeniden önem kazanmıştır. Kenevir, pamuktan daha az su tüketir ve herbisit ya da pestisit gerektirmez. Pamuk ton başına 4,2 ton karbon ayak izi bırakırken, kenevirin ayak izi sadece 1,9 tondur (Ertek Avcı ve Demiryürek, 2022). Kenevir, dayanıklılığı, hızlı büyüme kapasitesi, zararlılara ve hastalıklara karşı direnci, düşük pestisit gereksinimi, doğada hızla çözünme özelliği, düşük su tüketimi özelliği ile sürdürülebilir çevre için değerli bir malzemedir ve bu durum kenevirin gelecekteki potansiyelini daha da artırmaktadır (Kurtuldu ve İşmal, 2019; Ling vd., 2023).

Kenevir lifi, antistatik, antibakteriyel özellikleri, mükemmel nem emilimi, yüksek mukavemeti, nefes alabilirliği, UV direnci, küf direnci ve desorpsiyon hızı (pamuktan üç kat daha hızlı) gibi birçok üstün doğal özelliği nedeniyle, geleceğin en umut verici selüloz lifi olarak öne çıkmaktadır. Aynı zamanda, kenevir kumaşları pamuklu kumaşlardan daha güçlü ve daha dayanıklıdır ve kolayca bozulmaz (Ling vd., 2023; Guo vd., 2019; Ertek Avcı ve Demiryürek, 2022; Zhang vd., 2023; Göre ve Kurt, 2021; Stankovic vd., 2017). Bu özellikler, kenevirin çeşitli endüstriyel uygulamalarda, özellikle tekstil ve sağlık sektörlerinde, sürdürülebilir ve verimli bir malzeme olarak kullanılmasını mümkün kılmaktadır (Yayla, 2024; Alonso-Montemayor vd., 2020). Kenevir lifi %57,01 selüloz, %17,84 hemiselüloz, %7,32 lignin, %5,80 pektin, %1,96 ester mumu ve %10,09 suda çözünen maddelerden oluşmakta olup eser miktarda kül içermektedir (Srisuk vd., 2024).

Kenevir bitkisinin hasadı sonrasında saplardan liflerin ayrılması işlemi keten lif eldesi yöntemleriyle benzerlik göstermektedir. Saplardan liflerin ayrılması işlemi için mekanik ayırma, çiğde bekletme, havuzlama, kimyasal işlem ve enzim uygulama gibi yöntemler mevcuttur. Burada yapılan işlem, saplardaki odunsu bölümlerin uzaklaştırılması ile liflerin ortaya çıkarılmasıdır (Kaya ve Öner, 2020). Kenevir kumaş terbiyesinin ilk aşaması, hafif alkali bir çözelti kullanılarak yapılan kaynatmadır. Bu işlem, kirleri temizlemenin yanı sıra liflerde bulunan doğal mumları, proteinleri ve pektinleri de giderir (Sponner vd., 2005). Kenevir, keten ve rami gibi sak liflerinin renk özellikleri, ham halleriyle tekstil uygulamaları için genellikle uygun değildir. Bu liflerdeki selüloz dışı bileşenler nedeniyle renklerin iyileştirilmesi için kimyasal işlemler gereklidir. Sak lifleri, yüksek kristalin yapıları sayesinde pamuğa göre kimyasal etkilere daha dirençlidir. Bu doğal renk vericilerin yanı sıra, tekstil ürünleri işleme ve depolama sırasında dış faktörlerle kirlenebilir. Ağartma işleminin amacı, sadece bu renk vericileri uzaklaştırmak değil, aynı zamanda bileşenleri parçalamaktır (Gedik ve Avinc, 2018).

Kök boya, kestane, soğan, andız otu ve bakkam bitkilerinden elde edilmiş boyama ekstraktlarıyla boyanmış kenevir kumaşın UV koruma özellikleri (Grifoni vd., 2020), hem doğal hem de kimyasal mordantların boyama üzerindeki etkileri ve *Sambucus Ebulus L.* bitkisinden elde edilen doğal boyanın kenevir kumaşın boyanmasındaki kullanımı (Özomay ve Akalın, 2022) araştırılmıştır. Atav vd 2024, çalışmalarında %100 kenevir iplikleri kullanarak ürettikleri örme kenevir kumaşlara hidrojen peroksit ağartması uygulamışlardır. Ağartma sonrası reaktif boyanan kumaşların renk ölçümleri gerçekleştirilmiştir. Mecir (2024), çalışmasında %100 kenevir kumaşlara uygulanan ozonlama, ultrason destekli ozonlama ve UV ağartma yöntemlerini incelemiştir. Ozonlama, kimyasal gerektirmemesi ve düşük mukavemet kaybıyla çevreci bulunurken, Ozon+US yöntemi daha yüksek beyazlık sağlamıştır. Kenevirin ağartılması konusundaki literatür çalışmaları ise aşağıdaki gibi özetlenebilir:

Sonmez vd.,(2023) yaptıkları çalışmada kenevir liflerini, sülfürik asit ve sodyum hidroksit karışımı ile farklı koşullarda modifiye etmişlerdir. Modifiye edilip ağartılan kenevir lifinin beyazlık indeksi, modifiye edilmeden ağartılan ham kenevir lifine göre daha yüksek bulunmuştur. Ayrıca, modifiye edilip ağartılan kenevir lifin reaktif boyalarla boyama sonrası renk haslık değerleri ise ağartılmış ham kenevir lifine göre üstün bulunmuştur.

Gedik vd. (2023), yaptıkları çalışmanın amacı, kenevir liflerinin havuzlama sıvısında ozon işlemiyle ağartılması sırasında mikroorganizmaları ortadan kaldırarak havuzlama atık sularındaki biyolojik yükü azaltmaktır. Kenevir sapsarı havuzlama sıvısında bekletilirken farklı konsantrasyonlarda ve sürelerde ozon gazıyla işlem yapılmıştır. Kenevir liflerinin beyazlık derecesi, havuzlanmış numunelere kıyasla ozon uygulamasıyla %72'ye kadar artmıştır.

Yılmaz Şahinbaşkan (2019), kenevir dokuma kumaşının enzimlerle ön işlem olanakları araştırmıştır. NaOH, H₂O₂ ve α -amilaz, pektinaz, lakkaz enzimleri kullanılarak üç farklı yöntemle ön terbiye işlemi gerçekleştirmiştir. Uygulamalar içerisinde en düşük sarılık değeri NaOH ile hidrofilleştirilip H₂O₂ ile ağartılan kumaşa 33,10 olarak bulunmuştur.

Gedik (2012), kenevir liflerinin optimum ağartma koşullarının belirlenmesi amacıyla % 100 kenevir lifinden üretilmiş dokuma kumaşa yükseltgen (hidrojen peroksit, perasetik asit, potasyum permanganat, sodyum perborat, sodyum perkarbonat) ve indirgen (thioüre dioksit, sodyum borohidrit, glikoz) ağartma ajanları uygulamış ve en yüksek beyazlık derecesini hidrojen peroksit ile yapılan ağartmada elde etmiştir.

Zhang ve He (2013), kenevir kumaşları, bir banyoda haşıl sökme ve kaynatma işlemlerine tabi tutmuşlardır (NaOH-25 g/L, Na₃PO₄-3 g/L, Na₂SO₃-2 g/L). Daha sonra kumaşlar, hidrojen peroksit ile ağartılmıştır (Na₂SiO₃-1.5 g/L, Na₂CO₃-0.5 g/L, NaOH-1 g/L, H₂O₂ (%30)-5 g/L, banyo oranı 20:1, 95°C, 1 saat). Kenevir kumaşlar, Na₂HPO₄ (5 g/L) ve sitrik asit (6 g/L) içeren tampon çözelti ile muamele edilmiştir. Banyo oranı 1:20 olacak şekilde pH 4-6 aralığında, 40-60 dakika ve 40-60°C sıcaklık aralığında işlem uygulanmıştır. Lakkaz konsantrasyonu 20-30 mL/300 mL olarak ayarlanmıştır. Kenevir kumaş üzerinde lakkaz işlemi için en uygun koşullar; 50°C, pH 4, 25 mL/300 mL lakkaz konsantrasyonu ve 50 dakika işlem süresi olarak bulunmuştur. En iyi koşullar altında kenevir kumaşın beyazlık değeri GB/T 9338-2008 standardına göre SBDY-1 beyazlık cihazı kullanılarak 60.7 olarak ölçülmüştür.

Kushwaha vd. (2024) yaptıkları çalışmada, kenevir kumaşın fiziksel ve mekanik özelliklerini araştırmışlardır. Haşıl sökme işlemi için sodyum hidroksit, ağartma işlemi için hidrojen peroksit kullanmışlardır. Haşıl sökme sonrasında beyazlık indeksinde belirgin bir artış olmuştur. Öte yandan, ağartma işlemi sonrasında beyazlık indeksinde önemli bir artış gözlenmiş, ancak hidrojen peroksitin asidik yapısı nedeniyle kumaşın yüzeyinin zayıflayıp bozulması sonucu çekme mukavemeti ve kalınlık azalmıştır. Beyazlık indeksi (CIE) ham kumaşta 49,24, haşılı sökülmüş kumaşta 61,94 ve haşıl sökme sonrası ağartılmış kumaşta 76,76 olarak bulunmuştur.

Qu vd. (2005) kenevir liflerini, alkali-H₂O₂ bir banyoda kaynatmış ve ağartmışlardır. Kenevirde bulunan hemiselüloz, pektin ve lignin gibi çeşitli bileşenlerin asit, alkali ve hidrojen peroksit karşı fiziksel ve kimyasal özellikleri analiz edilmiştir. Kenevir lifi için en uygun koşullar; NaOH 10.5 g/L, H₂O₂ 9.8 g/L, %0.1 MgSO₄ (H₂O₂ stabilizatörü olarak) 2.7 g/L, 127 dakika işlem süresi ve 100°C sıcaklık olarak bulunmuştur. Bu koşullar altında, en düşük lignin içeriği, artık zambak içeriği ve kenevir lifinin en iyi mukavemet ve beyazlık özellikleri arasında bir denge sağlanmaktadır.

Merdan (2017) çalışmasında, kenevir liflerini farklı konsantrasyonlarda (%1, %2 ve %3) lakkaz enzimi ile farklı sürelerde muamele etmiştir. İşlem, geleneksel yöntem, ultrasonik enerji yöntemi ve mikrodalga enerji yöntemi kullanılarak gerçekleştirilmiştir. İşlem görmemiş kenevir liflerinin beyazlık değeri (CIE) %20,2 olarak ölçülmüştür. En yüksek beyazlık değeri (CIE), ultrasonik enerji yöntemiyle %3 lakkaz konsantrasyonu ve 20 dakika işlem sonucunda 31,2 olarak elde edilmiştir.

Sürdürülebilirlik anlayışı doğrultusunda, tekstil endüstrisinde yeni kavramlar ve yaklaşımlar ortaya çıkarken, kenevir lifi çevre dostu bir alternatif olarak dikkat çekmektedir (Kurtuldu ve İşmal, 2019). Kenevir kumaşların ağartılması konusunda yapılan çalışmalar sınırlıdır. Bu çalışmada ham kenevir kumaşlara hidrofilleştirme ardından farklı sıcaklık, pH ve konsantrasyonlarda hidrojen peroksit ağartması yapılmıştır. Amaç ağartma işleminde sıcaklık, pH ve hidrojen peroksit konsantrasyonu parametrelerinin beyazlık üzerindeki etkisini incelemek ve bu parametreleri kullanarak kumaşların beyazlık derecesini tahmin etmek amacıyla bir model oluşturmaktır. Model tahmini ile ağartma sonrası elde edilecek beyazlık derecesi belirlenebilmekte ve bunun literatüre katkı sağlayacağı düşünülmektedir.

MATERYAL ve METOT

Materyal

Çalışmada Nm 25 inceliğe sahip ham kenevir iplik temin edilerek 14 gauge düz örgü makinesinde 1x1 rib ham örme kumaş üretilmiştir. Kumaş gramajı 380 g/m² olarak ölçülmüştür.

Metot

Ham kenevir kumaşlara ilk olarak 4 g/L Sodyum Hidroksit (NaOH-38°C Be) ve 0,2 g/L ıslatıcı kullanılarak hidrofilleştirme işlemi yapılmıştır. İşlem 1:15 flote oranı kullanılarak 98°C'de 45 dakika süreyle gerçekleştirilmiştir. Hidrofilleştirilen numuneler laboratuvar tipi çektirme aparatında 3 farklı ağartma sıcaklığı (100-110-120°C), 4 farklı pH (10-11-12-13) ve 6 farklı ağartıcı konsantrasyonu (2-4-6-8-10-12g/L) kullanılarak ağartılmış bu sayede toplam 72 farklı parametreye sahip ağartma işlemi gerçekleştirilmiştir.

Ağartma Reçetesi

Flotte oranı	:1:20
Islatıcı	:0,5 g/L
Yağ sökücü sabun	:0,5 g/L
Peroksit stabilizatörü	:0,8 g/L

Hidrojen peroksit flotte içerisinde Tablo 1’de verilen konsantrasyonlarda eklenmiş olup flottelerin pH ayarında sodyum hidroksit kullanılmıştır. Tüm ağartma işlemleri Tablo 1’de verilen sıcaklıklarda 60 dakika süreyle yapılmıştır.

Tablo 1. Ağartma Denei Planı

İşlem No	Numune Kodu	Sıcaklık (°C)	pH	Konsantrasyon (g/L)	İşlem No	Numune Kodu	Sıcaklık (°C)	pH	Konsantrasyon (g/L)	İşlem No	Numune Kodu	Sıcaklık (°C)	pH	Konsantrasyon (g/L)			
1	K-100-10-2	100	10	2	25	K-110-10-2	110	10	2	49	K-120-10-2	120	10	2			
2	K-100-10-4			4	26	K-110-10-4			4	50	K-120-10-4			4			
3	K-100-10-6			6	27	K-110-10-6			6	51	K-120-10-6			6			
4	K-100-10-8			8	28	K-110-10-8			8	52	K-120-10-8			8			
5	K-100-10-10			10	29	K-110-10-10			10	53	K-120-10-10			10			
6	K-100-10-12			12	30	K-110-10-12			12	54	K-120-10-12			12			
7	K-100-11-2		11	11	2	31		K-110-11-2	11	11	2		55	K-120-11-2	11	11	2
8	K-100-11-4				4	32		K-110-11-4			4		56	K-120-11-4			4
9	K-100-11-6				6	33		K-110-11-6			6		57	K-120-11-6			6
10	K-100-11-8				8	34		K-110-11-8			8		58	K-120-11-8			8
11	K-100-11-10				10	35		K-110-11-10			10		59	K-120-11-10			10
12	K-100-11-12				12	36		K-110-11-12			12		60	K-120-11-12			12
13	K-100-12-2	12	12	2	37	K-110-12-2	12	12	2	61	K-120-12-2	12	12	2			
14	K-100-12-4			4	38	K-110-12-4			4	62	K-120-12-4			4			
15	K-100-12-6			6	39	K-110-12-6			6	63	K-120-12-6			6			
16	K-100-12-8			8	40	K-110-12-8			8	64	K-120-12-8			8			
17	K-100-12-10			10	41	K-110-12-10			10	65	K-120-12-10			10			
18	K-100-12-12			12	42	K-110-12-12			12	66	K-120-12-12			12			
19	K-100-13-2	13	13	2	43	K-110-13-2	13	13	2	67	K-120-13-2	13	13	2			
20	K-100-13-4			4	44	K-110-13-4			4	68	K-120-13-4			4			
21	K-100-13-6			6	45	K-110-13-6			6	69	K-120-13-6			6			
22	K-100-13-8			8	46	K-110-13-8			8	70	K-120-13-8			8			
23	K-100-13-10			10	47	K-110-13-10			10	71	K-120-13-10			10			
24	K-100-13-12			12	48	K-110-13-12			12	72	K-120-13-12			12			


Ağartma işleminden sonra numunelere 1 g/L antiperoksit enzim ve 0,5 g/L asetik asit kullanılarak hazırlanan flotteler içerisinde 50°C sıcaklıkta 20 dakika süreyle peroksit uzaklaştırma işlemine tabi tutulmuştur.

BULGULAR ve TARTIŞMA


Bu çalışmada, ham kenendir kumaşlara yönelik ağartma işlemleri, 100°C, 110°C ve 120°C olmak üzere üç farklı sıcaklıkta gerçekleştirilmiştir. Her bir sıcaklık için farklı pH ve ağartıcı konsantrasyonlarına sahip ağartma flotteleri hazırlanmış ve bu koşullar altında ağartma işlemleri uygulanmıştır. İşlem sonrası, numunelerin Berger Beyazlık İndeksi değerleri ölçülmüştür. 100°C’de gerçekleştirilen ağartma işlemlerine ait Berger Beyazlık İndeksi değerleri Şekil 1’de sunulmuştur. Veriler, ağartma işleminde sıcaklığın yanı sıra pH ve ağartıcı konsantrasyonlarının beyazlık üzerindeki etkisini analiz etmek amacıyla kıyaslanmıştır.

100°C’de yapılan ağartma işleminde pH 10’da gerçekleştirilen ağartma işlemlerinde, ağartıcı konsantrasyonundaki artışa rağmen beyazlık değerlerinde belirgin bir artış olmadığı gözlemlenmektedir. Bu durum, pH seviyesinin ağartma işleminin etkinliği üzerinde belirleyici bir rol oynadığını açıkça ortaya koymaktadır ve düşük pH

seviyelerinde ağartıcı etkinliğinin sınırlı kaldığını göstermektedir. Bunun nedeninin, düşük pH seviyelerinde ağartıcıların kimyasal aktivitesinin azalması olduğu düşünülmektedir. pH 11'e yükseltilmesiyle birlikte, özellikle 10 g/L ve 12 g/L konsantrasyona sahip numunelerde beyazlık değerlerinin kayda değer şekilde artması, yüksek pH seviyelerinin ağartıcıların daha etkili bir şekilde çalışmasına olanak tanıdığını göstermektedir. pH 12 ve pH 13 seviyelerinde ise 2 g/L konsantrasyona sahip numuneler dışında tüm konsantrasyonlarda ciddi bir beyazlık artışı gözlenmiştir. Bu durum, yüksek pH ortamının, daha düşük ağartıcı konsantrasyonlarında bile etkili sonuçlar alınmasını sağladığını ortaya koymaktadır. Bu bulgulardan hareketle, ağartma işleminin optimizasyonunda pH seviyesi, ağartıcı konsantrasyonu kadar kritik bir parametre olarak değerlendirilebilir. Daha yüksek pH seviyelerinde, ağartıcı kimyasalların aktivitesi artmakta, bu da daha az kimyasal kullanımıyla istenen beyazlık seviyelerinin elde edilmesini sağlamaktadır. Bu durum, daha düşük kimyasal tüketimi ve çevresel etkilerin azaltılması açısından sürdürülebilir üretim süreçleri için önemli bir avantaj sunmaktadır. 110°C'de uygulanan ağartma işlemi sonrası elde edilen beyazlık indeksi değerleri Şekil 2'de verilmiştir.




Şekil 1.100°C'de Yapılan Ağartma İşlemi Sonrası Numunelerin Berger Beyazlık Ölçümü Sonuçları



Şekil 2.110°C'de Yapılan Ağartma İşlemi Sonrası Numunelerin Berger Beyazlık Ölçümü Sonuçları

110°C'de yapılan ağartma işleminde pH 10 seviyesinde elde edilen beyazlık değerlerinin, 100°C'de pH 11 seviyesinde elde edilen değerlerle eşdeğer olması, sıcaklık artışının ağartma etkinliğini artırarak daha düşük bir pH seviyesinde aynı beyazlık seviyesini elde etmeyi mümkün kıldığını göstermektedir. Bu, yüksek sıcaklığın ağartma işlemi üzerinde güçlü bir katalitik etkisi olduğunu ve kimyasal aktiviteyi artırdığını ortaya koymaktadır. pH 10 ve 11 seviyelerinde ağartıcı konsantrasyonundaki artışa rağmen beyazlık değerlerinde ciddi bir artış görülmemesi, bu pH seviyelerinde kimyasal etkinliğin sınırlı kaldığını ve ağartıcıların tam potansiyelini ortaya koyamadığını işaret etmektedir. Yani bu aralıkta konsantrasyon artışı ekonomik açıdan verimsizdir. pH 12 ve 13 seviyelerinde artan

ağartıcı konsantrasyonu ile beyazlık değerlerinde düzenli bir artış eğilimi görülmesi, yüksek pH seviyelerinin ağartıcıların kimyasal aktivitesini artırarak daha etkili bir beyazlatma sağladığını göstermektedir. Ancak, pH 13 seviyesinde 8-10 ve 12 g/L konsantrasyonlarında beyazlık değerlerinin doygunluğa ulaşması, belirli bir konsantrasyonun üzerinde ağartıcı kullanımının ek bir fayda sağlamadığını göstermektedir. Bu durum, fazla kimyasal kullanımının maliyet artırıcı ve çevresel açıdan olumsuz etkiler yaratabileceğini ortaya koymaktadır. Yapılan tüm ağartma işlemleri dikkate alındığında, en yüksek beyazlık değerleri, 110°C'de, pH 13 seviyesinde ve 8, 10 ve 12 g/L ağartıcı konsantrasyonu kullanılarak ağartılan numunelerde elde edilmiştir. 8, 10 ve 12 g/L ağartıcı konsantrasyonlarıyla gerçekleştirilen ağartma işlemleri sonucunda, numunelerdeki beyazlık seviyesinin yüksek oranda değişmediği gözlemlenmiştir. Bu nedenle, 110°C'de, pH 13 seviyesinde ve 8 g/L ağartıcı konsantrasyonu kullanılarak ağartma işleminin yapılması önerilmektedir.



Şekil 3.120°C'de Yapılan Ağartma İşlemi Sonrası Numunelerin Berger Beyazlık Ölçümü Sonuçları

Ağartma sıcaklığının 120°C'ye ulaşmasıyla birlikte farklı pH seviyelerinde ağartıcı konsantrasyonunun artmasıyla beyazlık dereceleri düzenli bir şekilde artış göstermiştir. 120°C'de pH seviyesinden bağımsız olarak ağartıcı konsantrasyonunun artışı ile beyazlık derecelerinde düzenli bir artış sağlanması, yüksek sıcaklıkta pH'nın etkisinin daha az kritik hale geldiğini göstermektedir.

Konsantrasyon, pH ve sıcaklık değişkenleri bağımsız değişken, beyazlık değişkeni ise bağımlı değişken olarak alınarak çoklu doğrusal regresyon analizi yapılmış ve elde edilen sonuçlar Tablo 2'de verilmiştir.

Tablo 2.Regresyon Analizi Sonuçları

Değişken	Katsayı	Standart Hata	t-istatistiği	p değeri
Sabit	-87,858	7,077	-12,415	0,000
Sıcaklık	0,311	0,051	6,145	0,000
pH	5,687	0,370	15,367	0,000
Konsantrasyon	0,954	0,121	7,873	0,000
R ²	0,832	Düzeltilmiş R ² : 0,824		
F istatistiği	111,963	P değeri: 0,000		

Regresyon analizi sonucunda düzeltilmiş R² değeri 0,824 olarak bulunmuş olup, sıcaklık, pH ve konsantrasyon bağımsız değişkenlerinin bağımlı değişkendeki değişimin %82'sini açıklayabildiğini ifade etmektedir. Belirleme katsayısı (R²) değerinin yüksek olması, modelin beyazlık derecesindeki varyansın büyük bir kısmını açıkladığını ve kullanılan bağımsız değişkenlerin tahmin gücünün yüksek olduğunu işaret etmektedir. Ağartma işlemlerinde seçilen sıcaklık, pH ve konsantrasyon değişkenlerinin modele etkisi anlamlı bulunmuştur (p<0.05). F istatistiği sonucu ise elde edilen modelin anlamlı olduğunu göstermektedir. Regresyon denklemi aşağıdaki şekilde yazılabilir:

$$\text{Beyazlık indeksi} = -87,858 + 0,311 * \text{Sıcaklık} + 5,687 * \text{pH} + 0,954 * \text{Konsantrasyon} \quad (1)$$

Regresyon denklemi kullanılarak tahminlenen beyazlık değerleri ile, gerçekte ölçülen beyazlık değerleri arasındaki korelasyon anlamlı olup pozitif yönde çok yüksek (r=0,912) bulunmuştur.

SONUÇ

Bu araştırmada, sürdürülebilir tekstil liflerinden biri olan kenevir kumaşların hidrojen peroksit ile ağartılması, farklı işlem parametreleri altında incelenmiştir. Çalışmada, farklı sıcaklıklar, değişen ağartıcı konsantrasyonları ve farklı pH değerlerine sahip flotteler kullanılarak ağartma işlemleri gerçekleştirilmiştir. Ağartma işlemlerinin ardından elde edilen numunelerin beyazlık seviyeleri Berger Beyazlık İndeksi ile ölçülerek değerlendirilmeye alınmıştır.

Yapılan çoklu doğrusal regresyon analizi, ağartma işlemlerinde kullanılan konsantrasyon, pH ve sıcaklık değişkenlerinin beyazlık dereceleri üzerindeki etkisinin istatistiksel olarak anlamlı olduğunu ($p<0.05$) ortaya koymaktadır. Bu sonuç, bu üç bağımsız değişkenin, beyazlık derecesi üzerinde önemli bir rol oynadığını ve birbirleriyle birlikte değerlendirilmesi gerektiğini göstermektedir.

Kimyasal konsantrasyonun optimize edilmesi, sürdürülebilirlik açısından gereksiz kimyasal kullanımını engelleyerek hem maliyetleri azaltır hem de atık suyun kimyasal yükünü düşürerek çevresel etkileri minimuma indirir. Sıcaklık artışı kimyasal reaksiyon hızını artırarak daha düşük pH ve konsantrasyon seviyelerinde etkili ağartma sağlar. Ancak yüksek sıcaklık, enerji maliyetlerini artırabilir ve sürdürülebilirlik açısından dezavantaj oluşturabilir. Çalışmada en yüksek beyazlık değerleri, 110°C'de, pH 13 seviyesinde ve 8-10-12 g/L ağartıcı konsantrasyonlarına sahip numunelerde elde edilmiştir. Ancak bu konsantrasyona sahip numunelerin beyazlık değerleri arasında belirgin bir değişiklik gözlemlenmemiştir. Bu nedenle, 8 g/L ağartıcıyla ağartma işlemi önerilmektedir.

TEŞEKKÜR

Kumaşların Berger Beyazlık Ölçümleri, Kimteks Tekstil İşletmesinde gerçekleştirilmiştir. Desteklerinden dolayı Kimteks Tekstil'e ve çalışanlarına teşekkürlerimi sunarım.

KAYNAKLAR

Alonso-Montemayor, F.J., López-Badillo, C.M., Aguilar-González, C.N., Ávalos-Belmontes, F., Castañeda-Facio, A.O., Reyna-Martínez, R., ... & Narro-Céspedes, R. I. (2020). Effect of cold air plasmas on the morphology and thermal stability of bleached hemp fibers. *Revista Mexicana de Ingeniería Química*, 19(Sup. 1), 457-467. <https://doi.org/10.24275/rmiq/Mat1510>

Atav, R., Dilden, D. B., Keskin, S. & Ergünay, U. (2024). Investigation of the dyeability and various performance properties of fabrics produced from flax and hemp fibres and their blends with cotton in comparison with cotton. *Coloration Technology*, 140(3), 440-450. <https://doi.org/10.1111/cote.12720>

Ertek Avcı, M. & Demiryürek, O. (2022). Development of sustainable and ecological hybrid yarns: hemp fiber in denim fabric production. *Cellulose Chemistry and Technology*, 56(9-10), 1089-1100.

Gedik, G., Aydın Kızılkaya, Y.M., Uyak, V. & Koluman, A. (2023). Simultaneous Eco-friendly Bleaching and Retting Wastewater Treatment of Hemp Fiber with Ozone Application. *Fibers and Polymers*, 24(1), 57-72. <https://doi.org/10.1007/s12221-023-00021-1>

Gedik, G. & Avinc, O. (2018). Bleaching of hemp (*Cannabis sativa* L.) fibers with peracetic acid for textiles industry purposes. *Fibers and Polymers*, 19(1), 82-93. <https://doi.org/10.1007/s12221-018-7165-0>

Gedik, G. (2012). Kenevir liflerinden üretilen kumaşların optimum ağartma koşullarının ve yöntemlerinin belirlenmesi. Yüksek Lisans Tezi. Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Tekstil Mühendisliği Anabilim Dalı, Denizli.

Göre, M. & Kurt, O. (2020). Bitkisel üretimde yeni bir trend: Kenevir. *International Journal of Life Sciences and Biotechnology*, 4(1), 138-157. <https://doi.org/10.38001/ijlsb.789970>

Grifoni, D., Roscigno, G., Falco, E.D., Vece, A., Camilli, F., Sabatini, F., Fibbi L. & Zipoli, G. (2020). Evaluation of dyeing and UV protective properties on hemp fabric of aqueous extracts from vegetal matrices of different origin. *Fibers and Polymers*, 21(8), 1750-1759. <https://doi.org/10.1007/s12221-020-1045-8>

Guo, Y., Sun, Z., Guo, X., Zhou, Y., Jiang, L., Chen, S. & Ma, J. (2019). Study on enzyme washing process of hemp organic cotton blended fabric. *International Journal of Clothing Science and Technology*, 31(1), 58-64. <https://doi.org/10.1108/IJCST-08-2017-0117>

- Inprasit, T., Pukkao, J., Lertlaksameephan, N., Chuenchom, A., Motina, K. & Inprasit, W. (2020). Green dyeing and antibacterial treatment of hemp fabrics using Punica granatum peel extracts. *International journal of polymer science*, 2020, 6084127. <https://doi.org/10.1155/2020/6084127>
- Kaya, S. & Oner, E. (2020). Kenevir liflerinin eldesi, karakteristik özellikleri ve tekstil endüstrisindeki uygulamaları. *Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 11(1), 108-123. <https://doi.org/10.29048/makufebed.693406>
- Kurtuldu, E. & İşmal, Ö.E. (2019). Sürdürülebilir tekstil üretim ve tasarımında yeniden değer kazanan lif: Kenevir. *SDÜ Art-E Güzel Sanatlar Fakültesi Sanat Dergisi*, 12(24), 694-718.
- Kushwaha, R., Kesarwani, P. & Kushwaha, A. (2024). Effect of Scouring and Bleaching on the Physico-mechanical Properties of the Hemp Fabric. *Fibers and Polymers*, 25, 3563–3570. <https://doi.org/10.1007/s12221-024-00665-7>
- Ling, Y., Hart, J., Henson, C., West, A., Kumar, A., Karanjikar, M. & Yin, R. (2023). Investigation of Hemp and Nylon Blended Long-Staple Yarns and Their Woven Fabrics. *Fibers and Polymers*, 24(5), 1835-1843. <https://doi.org/10.1007/s12221-023-00180-1>
- Mecir, B. (2024). Kenevir terbiyesinde yenilikçi ve çevre dostu yöntem geliştirilmesi. Yüksek Lisans Tezi. Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Tekstil Mühendisliği Ana Bilim Dalı, Bursa.
- Merdan, N. (2017). Effects of environmental surface modification methods on physical properties of hemp fibers. *Materials Science*, 23(4), 416-421. <https://doi.org/10.5755/j01.ms.23.4.17469>
- Özomay, M. & Akalın, M. (2022). Optimization of fastness properties with gray relational analysis method in dyeing of hemp fabric with natural and classic mordant. *Journal of Natural Fibers*, 19(8), 2914-2928. <https://doi.org/10.1080/15440478.2020.1837328>
- Qu, L. J., Zhu, S. F., Liu, M. J., & Wang, S. Y. (2005). The mechanism and technology parameters optimization of alkali-H₂O₂ one-bath cooking and bleaching of hemp. *Journal of applied polymer science*, 97(6), 2279-2285. <https://doi.org/10.1002/app.22024>
- Sonmez, S., Marcello, C. & Salam, A. (2023). Chemical Modification for Resistance to Photo-Oxidative Degradation and Improved Bleaching and Color Fastness Properties of Hemp Fiber. *Cellulose Chemistry & Technology*, 57 (5-6), 551-556.
- Sponner, J., Toth, L., Cziger, S. & Franck, R.R. (2005). Hemp. In Frank R.R (Eds.), *Bast and other plant fibres* (pp. 176-206). Cambridge: Woodhead Publishing.
- Srisuk, S., Intarat, T., Damkham, N. & Pisitsak, P. (2024). Comparison of infrared-, ultrasonic-, and microwave-assisted mordanting methods for the natural dyeing properties of hemp fabrics. *Fibers and Polymers*, 25(11), 4349-4360. <https://doi.org/10.1007/s12221-024-00724-z>
- Stanković, S., Popović, D.M., Kocić, A. & Poparić, G.B. (2017). Ultraviolet protection factor of hemp/filament hybrid yarn knitted fabrics. *Tekstilec*, 60(1), 49-57. <https://doi.org/10.14502/Tekstilec2017.60.49-57>
- Tripa, S., Kadıncık, N., Kanwal, A., Nazeer, M.A., Nazir, A., Tripa, F., & Uzun, M. (2023). Analysing the Impact of the Bleaching Process on Wet Spun Hemp Yarn Properties. *Sustainability*, 15(24), 16894. <https://doi.org/10.3390/su152416894>
- Yayla, A. (2024). İç mekânlarda ses yutum malzemesi olarak kullanılan dokuma kumaşların kenevir lifi ile akustik özelliklerinin iyileştirilmesi. Yüksek Lisans Tezi. Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Tekstil Mühendisliği Anabilim Dalı, Bursa.
- Yılmaz Şahinbaşkan, B.Y. (2019). Kenevir Dokuma Kumaşa Enzimatik Ön İşlemlerin Etkisi. *International Journal of Advances in Engineering and Pure Sciences*, 31(3), 208-213. <https://doi.org/10.7240/jeps.508952>
- Zhang, M., Qiao, X., Liu, X., Fang, K., Gong, J., Lu, X., Gao, W., Si, J. & Sun, F. (2023). Environmental urea-free pretreatment process to form new surface on hemp for enhancing the inkjet printing performance. *Progress in Organic Coatings*, 174(2023), 107317. <https://doi.org/10.1016/j.porgcoat.2022.107317>
- Zhang, X. L., & He, Y. D. (2013). Effects of laccase on the properties of hemp fabric. *Advanced Materials Research*, 690, 999-1002. <https://doi.org/10.4028/www.scientific.net/AMR.690-693.999>



Kahramanmaraş Sütçü İmam University Journal of Engineering Sciences



Geliş Tarihi : 16.12.2024
Kabul Tarihi : 26.01.2025

Received Date : 16.12.2024
Accepted Date : 26.01.2025

A COMPARATIVE STUDY OF DOUBLE-STEP DEEP LEARNING FRAMEWORK FOR BURNED AREA IDENTIFICATION AND SEVERITY ASSESSMENT IN WILDFIRES

YANGINLARDA YANMIŞ ALANLARIN BELİRLENMESİ VE ŞİDDET DEĞERLENDİRMESİ İÇİN ÇİFT ADIMLI DERİN ÖĞRENME ÇERÇEVESİNİN KARŞILAŞTIRMALI BİR ÇALIŞMASI

Murat Mert YURDAKUL^{1} (ORCID: 0009-0000-7285-7802)*
Bülent BAYRAM² (ORCID: 0000-0002-4248-116X)
Tolga BAKIRMAN² (ORCID: 0000-0001-7828-9666)
Hamza Osman İLHAN¹ (ORCID: 0000-0002-1753-2703)

¹ Yıldız Technical University, Department of Computer Engineering, İstanbul, Türkiye
² Yıldız Technical University, Department of Geomatic Engineering, İstanbul, Türkiye

*Sorumlu Yazar / Corresponding Author: Murat Mert YURDAKUL, mert.yurdakul@std.yildiz.edu.tr

ABSTRACT

As wildfires become more frequent and intense, it is essential to develop sophisticated techniques for precise detection and damage evaluation. This research examines a Double-Step Deep Learning Framework using several U-Net models, including MultiResUNet, to identify burned areas and estimate severity. Using satellite images, the study explores the effect of different severity levels within mask output, focusing on both 4 and 5 level severity classifications. Additionally, the Mask R-CNN model was evaluated independently for image segmentation, revealing challenges due to its reliance on pretrained weights and limited spectral input. The comparative analysis illustrates how changes in the granularity of severity intervals influence model performance, providing insights into the benefits of more nuanced severity segmentation for wildfire assessment. This approach has the potential to improve the precision of damage assessments and support more informed decision-making in the management and response of wildfires.

Keywords: Wildfire severity prediction; deep neural networks; double-step architecture; satellite imagery analysis.

ÖZET

Orman yangınlarının daha sık ve yoğun hale gelmesiyle birlikte, doğru tespit ve hasar değerlendirmesi için gelişmiş tekniklerin geliştirilmesi büyük önem taşımaktadır. Bu araştırma, yanmış alanları belirlemek ve yangın şiddetini tahmin etmek için MultiResUNet dahil olmak üzere çeşitli U-Net modellerini kullanan Çift Aşamalı Derin Öğrenme Çerçevesi'ni incelemektedir. Uydu görüntülerinden elde edilen maske çıktılarında, özellikle 4 ve 5 şiddet seviyelerine odaklanılarak, farklı şiddet seviyelerinin etkileri detaylı bir şekilde incelenmiştir. Ayrıca, Mask R-CNN modeli, önceden eğitilmiş ağırlıklar ve sınırlı spektral girdiler nedeniyle görüntü segmentasyonunda yaşanan zorlukları göstermek için bağımsız olarak incelenmiştir. Yapılan analizler, şiddet aralıklarının granülerliğindeki değişikliklerin model performansını nasıl etkilediğini göstererek, yangın değerlendirme için daha ayrıntılı şiddet segmentasyonunun faydalarına dair önemli bilgiler sağlamaktadır. Bu yaklaşım, hasar değerlendirmelerinin doğruluğunu artırma ve yangın yönetimi ile müdahalesinde daha bilinçli kararlar alınmasını destekleme potansiyeline sahiptir.

Anahtar Kelimeler: Yangın şiddeti tahmini; derin sinir ağları; çift adımlı mimari; uydu görüntü analizi.

ToCite: YURDAKUL, M.M., BAYRAM, B., BAKIRMAN, T. & İLHAN, H.O. (2025). A COMPARATIVE STUDY OF DOUBLE-STEP DEEP LEARNING FRAMEWORK FOR BURNED AREA IDENTIFICATION AND SEVERITY ASSESSMENT IN WILDFIRES. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi* 28(1), 513-523.

INTRODUCTION

The growing threat posed by wildfires in recent years has increased the need for advanced technologies to assess fire damage accurately and efficiently. The destruction caused by these fires affects ecosystems, economies, and communities worldwide, making it essential to have reliable tools for fire detection and damage assessment. High-resolution satellite imagery from missions such as Sentinel-2 offers a critical resource for monitoring large-scale environmental events such as wildfires.

This paper explores the Double-Step Deep Learning Framework (DSF) with derivative models of U-Net, as used in the paper prepared by Monaco et al. (Monaco et al., 2021), for wildfire detection and severity estimation. The framework incorporates a binary segmentation model to detect burned areas and a regression model to estimate the severity of the damage.

This study introduces MultiResUNet (Ibtehaz and Rahman, 2020), a U-Net variant not previously evaluated in the DSF, to assess its performance in comparison to other U-Net-based models such as Attention U-Net, Nested U-Net, and SegU-Net. This study also investigates the impact of adjusting severity levels by merging levels 4 and 3 into a 4-level classification, addressing data imbalance issues and improving model training stability. Additionally, a pretrained Mask R-CNN model is evaluated independently from the DSF to benchmark its performance on burned area detection. This comparison highlights the strengths and limitations of the DSF framework relative to state-of-the-art object detection models.

This paper also reviews related works that focus on wildfire detection and burned area analysis, with an emphasis on studies that predominantly utilize deep learning models, some of which are variants of the U-Net architecture. It details the materials and methodology, including a description of the employed dataset and the architecture of the proposed MultiResUNet approach. The experimental results are presented and discussed, comparing the performance of different U-Net architectures on the dataset. Finally, the paper concludes with insights and suggestions for future research.

RELATED WORK

Various U-Net models and their extensions have been widely applied in forest fire-related tasks. Adaptations such as attention mechanisms, residual blocks, and integration of temporal and environmental data have enhanced the effectiveness of U-Net in wildfire detection, smoke segmentation, and severity assessment.

Farasin et al. introduced a methodology for assessing wildfire damage severity using Sentinel-2 satellite imagery through a deep learning model named Double-Step U-Net (Farasin et al., 2020). In their study, they also proposed and compared the performance of Single, Parallel, and Double-Step U-Net frameworks, evaluating their effectiveness in burned area detection and severity estimation.

Monaco et al. utilized an extension of the Double-Step U-Net (Farasin et al., 2020) to predict wildfire severity using a multichannel deep learning framework for post-fire satellite imagery analysis. Their approach, referred to as the Double-Step Deep Learning Framework (Monaco et al., 2021), incorporates an attention mechanism into the U-Net. The framework compares its results with derivatives of the U-Net model to evaluate its effectiveness. The Double-Step Framework operates in two steps: the first performs binary segmentation to identify burned regions, while the second assigns severity levels to each pixel within the identified burned areas. Leveraging Sentinel-2 data with twelve channels, the Double-Step Framework captures diverse terrain features and applies multi-channel attention analysis to assess the importance of each spectral band in predicting burn severity.

MultiResUNet model, proposed by Ibtehaz and Rahman (Ibtehaz and Rahman, 2020), is an enhancement of the original U-Net architecture designed specifically for improved performance in medical image segmentation. While traditional U-Net consists of an encoder-decoder structure with simple convolutional layers, MultiResUNet introduces MultiRes blocks. Furthermore, Ibtehaz and Rahman replaced the standard U-Net skip connections with Res paths. These paths apply additional convolutional layers to reduce the semantic gap between encoder and decoder features.

Colomba et al. introduced a new data set specifically designed to delineate the burned area and estimate severity from satellite imagery (Colomba et al., 2022). The authors used Sentinel-1 and Sentinel-2 satellite data to categorize burn severity on a scale from 0 (undamaged) to 4 (completely destroyed).

Han et al. proposed a transformer-based change detection model to accurately map burned areas and assess the severity of the burn (Han et al., 2024). Their approach leverages multispectral Landsat-8 imagery and auxiliary environmental data such as vegetation indices to enhance model performance and accuracy in identifying fire-affected areas. The model compares pre-fire and post-fire images to detect changes in vegetation and land surface features. This work demonstrates the potential of combining transformer-based methods with environmental data to improve wildfire impact assessments and aid in post-fire recovery planning (Han et al., 2024).

Pinto et al. developed a deep learning model called BA-Net, which is tailored for identifying and timing burned regions by utilizing a temporal series of satellite images from the VIIRS sensor (Pinto et al., 2020). This approach addresses key limitations of traditional burned area mapping techniques by eliminating the need for cloud masking and complex preprocessing steps. The model utilizes a U-Net architecture modified with a Long-Short-Term Memory (LSTM) layer to capture temporal dependencies (Pinto et al., 2020).

Navarro et al. analyzed 2016 forest fires on Madeira Island using Sentinel-2A imagery to evaluate the severity of the burn (Navarro et al., 2017). They focused on the application of spectral indices such as the Normalized Difference Vegetation Index (NDVI), Green Normalized Difference Vegetation Index (GNDVI), and Normalized Burn Ratio (NBR). By comparing these indices with data from the Copernicus Emergency Management Service, the authors confirmed that red-edge spectral indices were highly effective in identifying levels of burn severity (Navarro et al., 2017).

Li et al. developed an early forest fire segmentation algorithm named F-Unet, designed to aid fire rescue operations (Li et al., 2021). F-Unet introduces a contraction path, a feature fusion layer, and an expansion path to enhance the precision of the segmentation. The contraction path leverages the first 13 layers of VGG16 to capture multiscale feature maps. The feature fusion network integrates these features to improve segmentation accuracy. The results from the experimental evaluation of the FLAME dataset (Shamsoshoara et al. 2020) indicate that F-Unet substantially improves the accuracy of fire segmentation (Li et al., 2021).

Khennou and Akhloufi presented FU-NetCastV2, a deep learning convolutional neural network developed to predict fire spread and map burned areas (Khennou and Akhloufi, 2023). FU-NetCastV2 identifies areas around wildfires that are at high risk of future spread by integrating satellite imagery with topographical and weather data. This approach leverages consecutive forest wildfire perimeters, satellite images, Digital Elevation Model maps, aspect, slope, and weather variables (Khennou and Akhloufi, 2023).

Wang et al. proposed an enhanced approach to early forest fire smoke detection through the development of Smoke-Unet, an improved U-Net model incorporating attention mechanisms and residual blocks (Wang et al., 2022). Their method leverages the RGB, SWIR2, and AOD bands to improve recognition accuracy, demonstrating a 3.1% improvement over standard U-Net performance on a diverse dataset encompassing multiple seasons, regions, and types of land cover.

Zou et al. propose an attention-based deep learning model (Zou et al., 2023) for wildfire spread prediction, integrating spatial and channel attention modules with a CNN. Trained on fire-tracking satellite data and environmental factors, it outperforms benchmark models like FARSITE (Finney, 1998) in predicting fire progression and final perimeters, offering valuable applications for fire risk management.

MATERIAL AND METHOD

Dataset Information

The dataset includes 73 distinct regions, each typically represented by four images: pre-fire and post-fire Sentinel-1 and Sentinel-2 images, along with a mask image indicating the burned area. The mask images feature five pixel intensity levels, ranging from black (level 0 - unburned) to white (level 4 - severely burned). The time frame between pre-fire and post-fire images is standardized to two months (Colomba et al., 2022). The data set is divided into

training, validation, and test sets based on predefined folds as shown in Table 1 from the article (Colomba et al., 2022):

Table 1. The Organization Schema of The Validation and Test Sets In the Experiments

Sets		Folds					
Test	Purple	Coral	Pink	Grey	Cyan	Lime	Magenta
Validation	Coral	Cyan	Coral	Coral	Coral	Coral	Coral

The fold colors represent sets grouped by their similar morphological features, primarily corresponding to regions in closely situated cities throughout Europe. As shown in Table 1, if the test set is 'purple', the validation set will be 'coral'. The remaining folds form the training set. The majority of the dataset consists of unburned areas as shown by the grey bar in Figure 1. Only a small portion of the dataset represents burned areas. This disparity highlights the difficulty of training models effectively to predict burned areas, given that fire-affected regions are relatively less represented than unburned zones.

Data Preprocessing

This research exclusively utilized post-fire Sentinel-2 imagery for the experiments. During the selection process, images with excessive cloud cover were filtered out by applying a cloud cover threshold. The resolution of the images is excessively high for straightforward use in training neural network models. Consequently, the images were split into square tiles, each measuring 480x480 pixels.




Figure 1. Logarithmic Representation of Pixels from Mask Images Based on Folds. From Left to Right: Purple, Coral, Pink, Grey, Cyan, Lime, and Magenta. The Number of Images in Each Fold Set Is Indicated in Parentheses, With Purple Containing 8, Coral 12, Pink 14, Grey 9, Cyan 11, Lime 10, and Magenta 9 Images, Totaling 73 Images Across All Folds.

Data Augmentation

During training, random data augmentation techniques were applied to improve model performance, ensure robustness, address data imbalances, and prevent overfitting. The methods employed include rotating images by a maximum of 50 degrees, cropping images by as much as 20 degrees, and flipping images both horizontally and vertically. Each of these techniques was executed with a 50% probability for each batch of images. Furthermore, all images were normalized using a mean and standard deviation of 0.5.

Only the training dataset is enhanced using data augmentation methods like rotation and flipping. The performances are assessed using Intersection over Union (IOU) for binary predictions and Root Mean Square Error (RMSE) for regression tasks. IoU is a metric calculated by dividing the area of overlap between the predicted and ground truth regions by the area of their union. RMSE measures the average magnitude of the error between predicted and ground truth values, calculated as the square root of the mean of the squared differences. IoU is used to evaluate the binary segmentation performance in the first step of the framework, while RMSE is employed in the second step to assess the accuracy of severity estimation.

Mask R-CNN

Mask R-CNN (He et al., 2017) is an advanced deep learning architecture designed for instance segmentation tasks. It extends Faster R-CNN (Ren et al., 2015) by adding a branch for predicting segmentation masks on each detected object. The architecture combines object detection and pixel-level segmentation, making it highly effective for applications requiring precise localization, such as satellite image analysis and medical imaging. Mask R-CNN uses a backbone network (e.g., ResNet) (He et al., 2016) for feature extraction and a Region Proposal Network (RPN) (Ren et al., 2015) to identify candidate object regions.

Double-Step Deep Learning Framework

Double-Step Deep Learning Framework is designed to predict the severity of wildfires, dividing the task into two steps: detection of the wildfire and estimation of the severity. Figure 2 outlines the general structure of the Double-Step Framework.

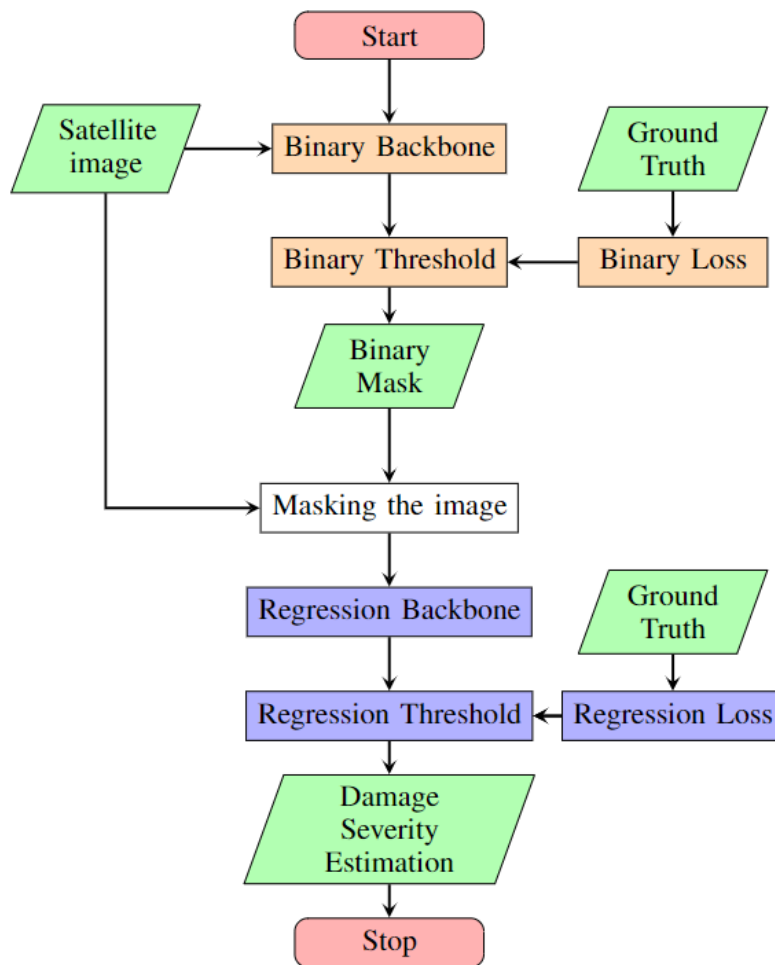


Figure 2. Double-Step Framework Architecture. Green Shapes: Inputs/Outputs. Orange Shapes: Wildfire Detection. Blue Shapes: Severity Estimation.

The initial phase of the Double-Step Framework, known as the Wildfire Detection Task (Step One), aims to identify if a particular region has been burned. In this stage, a binary-class backbone was utilized that analyzes satellite images and generates a binary probability map. Each pixel represents the likelihood of being burned (values between 0 and 1). The initial backbone training uses a binary loss function to compare the predictions with the ground-truth binary masks. After generating the probability map, the values are thresholded to create a final binary mask (burned/unburned regions). This research utilized a threshold value of 0.5. Applying the resulting binary mask to the original image effectively conceals the unburned regions, ensuring that only the burned areas are visible in preparation for the model's subsequent step.

In the second step, the model uses masked satellite images and predicts the severity of fire damage using a regression backbone. The result is a map assigning each pixel a severity score from 0 to 4, indicating varying levels of burn damage. The second step involves posing it as a regression problem where the model is trained to reduce the disparity between the predicted and actual severity levels. If the binary mask produced initially contains inaccuracies, it will negatively impact the performance of the second model. Thus, ensuring an accurate binary mask enhances the overall effectiveness of severity estimation.

DSF approach supports the implementation of various neural network architectures for both binary detection and severity assessment processes. In this study, several deep learning-based segmentation networks have been deployed. Each step uses the same deep learning model architecture. The subsequent subtitles provide a summary of the models employed.

U-Net

U-Net (Ronneberger et al., 2015) is a convolutional neural network architecture specifically designed for image segmentation tasks. The architecture consists of an encoder that captures context through convolutions and pooling operations and a decoder that uses upsampling. This structure allows U-Net to excel in segmenting complex structures within images, making it highly suitable for applications like medical imaging, satellite image analysis, and more.

Attention U-Net

It is an advanced version of the U-Net, incorporating attention mechanisms to enhance segmentation accuracy by focusing on relevant image features. Attention U-Net (Oktay et al., 2018) applies attention gates in these connections. This approach enables the model to selectively emphasize significant regions while suppressing less important areas. The architecture retains the same encoder-decoder structure as U-Net. Attention gates ensure that only the most relevant features are passed to the decoding layers.

Nested U-Net

Also known as UNet++ (Zhou et al., 2018), is an enhancement of the original U-Net architecture designed to improve segmentation performance by adding multiple nested and dense skip pathways between encoder and decoder. This architecture introduces a series of intermediate layers called nested dense skip connections.

SegU-Net

It is a segmentation model (Kamal et al., 2020) that combines the strengths of the U-Net architecture with a pretrained VGG backbone for feature extraction. The encoder path leverages the VGG network to capture detailed spatial and contextual information from the input image.

MultiResUNet

It is an advanced version of the U-Net architecture specifically designed for medical image segmentation. Unlike the classical U-Net, MultiResUNet (Ibtehaz and Rahman, 2020) incorporates MultiRes blocks to capture image features at multiple resolutions. This design allows it to more effectively identify structures at varying scales within medical images. Additionally, the model replaces U-Net's standard skip connections with "Res paths", helping to bridge the gap between feature representations at different levels. These enhancements make MultiResUNet more robust in segmenting challenging images. Given its ability to handle multi-resolution features and bridge encoder-decoder disparities, MultiResUNet was considered for wildfire segmentation tasks, where complex and varied spatial patterns in satellite imagery pose significant challenges. Its unique architectural features align well with the need for precise detection and segmentation of burned areas across diverse geographic regions.

EXPERIMENTAL RESULTS

In this study, DSF is used to assess the effectiveness of several variations of U-Net for the detection and segmentation of wildfire severity. In the experiments, U-Net, Attention U-Net, Nested U-Net, SegU-Net, and MultiResUNet models were tested. The first four models are integral components of the Double-Step Framework proposed by (Monaco et al., 2021). MultiResUNet, however, is included primarily for comparison purposes with minimal customization. Additionally, this study employs two distinct severity scales for the second step of DSF: one with five levels and another with four levels. The 5-level classification allows for more detailed differentiation of severity, useful for ecological studies requiring precise segmentation of fire impacts. In contrast, the 4-level classification simplifies the analysis by addressing data imbalance and grouping levels 4 and 3.

In DSF model training, the binary cross-entropy loss was used for the binary segmentation criterion, which measures the difference between predicted probabilities and actual binary labels (0 or 1) by calculating the negative log likelihood of the correct classification. Table 2 shows the rest of the parameters utilized in this study.

Table 2. Hyperparameters

Hyperparameter	Value
Batch size	8
Input channels	12
Epochs	50
Seed	1
Patience	5
Tolerance	0.01
Criterion	nn.BCEWithLogitsLoss
Regr_criterion	nn.MSELoss
Optimizer	optim.Adam (lr=0.0001)
Trainer - Precision	16
Trainer - Gradient_clip_val	5.0

The first step of the Double-Step Framework focuses on binary detection, distinguishing burned from unburned areas. IoU results, as shown in Table 3, include models within the Double-Step Framework as well as an evaluation of Mask R-CNN as an external benchmark for binary segmentation. MultiResUNet demonstrated notable performance, achieving an IoU score of 0.84 on the Coral and Pink dataset. However, it is important to note that the model's predicted mask images often exhibited predicted lines close to the edge of the images, likely due to the minimal customization applied to the model. Attention U-Net also performed well in this step. It achieved an IoU of 0.82 in the Magenta data set. Nested U-Net exhibited the most consistent performance overall with its highest IoU score of 0.85 on the Magenta and Pink dataset. The results of Step 1 suggest that MultiResUNet and Nested U-Net may be better suited for binary detection, as they achieved high IoU scores across different levels and datasets.

Table 3. Step 1 Result (Wildfire Detection Phase) Results

Binary - IoU						
Fold	Double-Step Framework					Single Step
	U-Net	Attenti on U-Net	Nested U-Net	SegU-Net	MultiResUNet	Mask R-CNN
Coral	0.83	0.74	0.84	0.75	0.84	0.31
Cyan	0.66	0.68	0.68	0.59	0.66	0.27
Grey	0.48	0.71	0.78	0.70	0.64	0.22
Lime	0.56	0.60	0.57	0.57	0.58	0.38
Magenta	0.84	0.82	0.85	0.82	0.82	0.17
Pink	0.81	0.79	0.85	0.82	0.84	0.28
Purple	0.82	0.81	0.81	0.81	0.65	0.26

Mask R-CNN was evaluated independently from the DSF to observe its performance on binary segmentation tasks. The model was trained using 3-channel satellite images as input and mask images for binary segmentation of burned areas. The results were extremely poor, with IoU values across different test folds shown in Table 3, suggesting that the model failed to learn effectively. This could be attributed to the reliance on pretrained weights, which are likely optimized for general-purpose object detection tasks rather than wildfire-specific segmentation. The model's inability to generalize may also stem from the unique spectral and geographical characteristics of wildfire datasets, which require domain-specific training. Training the Mask R-CNN model from scratch, without using pretrained weights, could better adapt it to the wildfire dataset and improve its performance. Additionally, modifying the model to accept 12-channel Sentinel-2 images, which capture a broader range of spectral information, could further enhance its segmentation accuracy for wildfire datasets.

The second step of the Double-Step Framework is designed to perform a severity estimation on the detected burned areas, evaluating the models' ability to predict severity levels accurately. Table 4 shows the RMSE results for each dataset and their corresponding levels. MultiResUNet achieved the lowest RMSE value of 0.17 in the Lime data set with the 4-level configuration. However, it is important to note that this RMSE result is at level 0, which represents

unburned areas. Predicting unburned areas should be evaluated differently from other levels since it largely reflects the model's binary detection accuracy rather than its capability for detailed severity classification. Nested U-Net displayed higher variability in RMSE values across different datasets, especially in the Coral dataset. The standard U-Net model maintained relatively stable RMSE results. In Figure 3 examples of predicted images are shown.

Table 4. Double-Step Framework Step 2 (Wildfire Severity Classification) Results

		Regression - RMSE									
	Level	U-Net		Attention U-Net		Nested U-Net		SegU-Net		MultiResUNet	
Fold		5 Lvl	4 Lvl	5 Lvl	4 Lvl	5 Lvl	4 Lvl	5 Lvl	4 Lvl	5 Lvl	4 Lvl
Coral	0	0.71	0.61	0.66	0.49	0.56	0.54	0.42	0.44	0.48	0.47
	1	0.93	0.84	0.97	0.60	0.79	0.77	0.56	0.67	0.65	0.65
	2	1.04	0.60	1.01	0.86	0.88	0.53	0.83	0.79	0.54	0.63
	3	0.74		0.52		0.35		1.10		0.98	
	4	0.83	0.51	1.79	1.07	1.52	0.55	2.48	1.19	2.42	1.05
	ALL	0.79	0.60	0.86	0.69	0.72	0.55	0.90	0.70	0.86	0.63
Cyan	0	0.45	0.54	0.52	0.47	0.46	0.49	0.41	0.49	0.56	0.41
	1	1.05	1.08	1.09	1.02	1.04	0.93	0.81	0.65	1.17	0.90
	2	0.99	0.83	0.90	0.90	0.93	0.85	0.98	0.96	0.94	1.04
	3	0.71	1.36	0.68	1.44	0.74	1.39	1.14	1.80	0.67	1.62
	4	2.30		2.21		2.31		2.67		2.33	
	ALL	1.03	0.78	1.02	0.76	1.03	0.75	1.15	0.89	1.07	0.79
Grey	0	0.38	0.26	0.30	0.24	0.31	0.29	0.63	0.27	0.29	0.29
	1	1.14	0.95	1.15	0.72	0.91	0.88	0.70	0.75	0.89	0.93
	2	1.25	1.37	1.06	0.89	0.66	1.07	0.93	0.65	0.81	0.94
	3	1.23	1.47	1.16	1.55	1.21	1.27	1.55	1.44	1.47	1.30
	4	2.37		1.91		2.02		2.64		2.49	
	ALL	0.57	0.52	0.49	0.42	0.44	0.46	0.72	0.40	0.47	0.44
Lime	0	0.28	0.32	0.26	0.23	0.21	0.26	0.19	0.28	0.23	0.17
	1	0.76	0.63	0.75	0.73	0.71	0.65	0.82	0.80	0.77	0.78
	2	1.00	1.06	1.05	1.06	1.16	1.02	1.32	1.26	1.13	1.51
	3	1.60	1.48	1.85	1.61	2.03	1.48	2.30	1.90	1.95	2.27
	4	1.91		2.11		2.18		2.58		2.23	
	ALL	0.47	0.44	0.50	0.41	0.50	0.41	0.56	0.49	0.51	0.52
Magenta	0	0.38	0.42	0.39	0.45	0.34	0.39	0.34	0.26	0.29	0.48
	1	1.28	1.34	1.30	1.41	1.15	1.41	1.10	0.82	0.74	1.57
	2	0.84	0.84	0.96	0.80	0.79	0.84	0.84	0.76	0.76	0.87
	3	1.05		1.18		1.17		1.37		1.54	
	4	1.24	0.97	1.27	0.83	1.42	0.91	1.72	1.29	2.12	0.95
	ALL	0.63	0.62	0.67	0.61	0.63	0.60	0.70	0.57	0.74	0.68
Pink	0	0.32	0.23	0.28	0.25	0.23	0.26	0.26	0.24	0.18	0.21
	1	0.94	0.80	0.87	0.84	0.95	0.93	0.88	0.64	0.56	0.54
	2	0.56	0.79	0.92	0.80	0.66	0.60	0.78	0.55	0.93	0.70
	3	0.91	1.14	1.36	1.09	1.05	1.05	1.25	1.52	1.78	1.56
	4	1.69		2.55		1.66		1.78		2.26	
	ALL	0.45	0.48	0.57	0.48	0.45	0.46	0.52	0.57	0.65	0.58
Purple	0	0.20	0.21	0.28	0.20	0.20	0.26	0.24	0.17	0.22	0.34
	1	1.11	0.93	1.08	0.88	1.00	1.03	0.95	0.73	0.83	0.84
	2	0.54	0.51	0.71	0.44	0.48	0.57	0.36	0.50	0.69	0.56
	3	1.45	1.51	1.39	1.18	1.25	1.07	1.43	1.34	1.89	1.23
	4	1.74		1.67		1.85		2.03		2.24	
	ALL	0.57	0.41	0.59	0.43	0.60	0.43	0.65	0.46	0.71	0.51

The experiments reveal that merging levels 4 and 3 into a 4-level classification consistently reduces RMSE values across most folds and models compared to the 5-level classification. This improvement is particularly notable in folds with significant data imbalance, such as Coral and Grey. For example, in the Coral fold, the RMSE for U-Net decreases from 0.79 (5-level) to 0.60 (4-level), and MultiResUNet exhibits similar trends with RMSE decreasing from 0.86 to 0.63. However, the Lime fold showed less consistent improvement, highlighting that the effectiveness of this adjustment may vary depending on the dataset's severity level distribution.

In Table 5, the performance benchmarks of various models and methods employing the Double-Step Framework, including related works and the results from this study, are presented. The table includes metrics such as the Intersection over Union, Root Mean Squared Error for all levels (RMSE All), and Root Mean Squared Error for individual severity levels (RMSE Level). RMSE Level does not include Level 0 (unburned pixels), as unburned pixels dominate the dataset and could disproportionately influence the metric. By excluding Level 0, RMSE Level focuses on burned severity levels, providing a more meaningful comparison of the models' performance in assessing burned areas. The results allow for a comparative analysis of different approaches, highlighting the effectiveness of the Double-Step Framework and related methods.

Table 5. Performance Benchmark of Related Works


Model/Method	IoU	RMSE All	RMSE Level	Reference
DS-UNet	0.75	1.32	-	
DS-UNet++	0.74	1.41	-	Monaco et al.,2021
DS-SegU	0.65	1.66	-	
DS-AttU	0.72	1.38	-	
dNBR	-	0.91	0.48	
Single U-Net	-	0.95	0.35	Farasin et al.,2020
Parallel U-Net	-	0.97	0.35	
Double-Step U- Net	-	0.76	0.39	
MultiResUNet	0.84	0.44	0.54	This Study

CONCLUSION

This paper presents the implementation and evaluation of a Double-Step Deep Learning Framework for the detection and severity assessment of burned areas using Sentinel-2 satellite imagery. The Double-Step Framework leverages various U-Net model variations like Attention U-Net, Nested U-Net, SegU-Net, and MultiResUNet to assess wildfire impact across multiple severity levels. The first step in this framework successfully utilizes binary detection to distinguish burned from unburned regions, with MultiResUNet and Nested U-Net demonstrating strong performance in terms of IoU. Although MultiResUNet achieved high accuracy in the Coral dataset, predicted mask images exhibited lines close to the edge of the image, suggesting potential limitations due to the model's minimal customization.

The results of the 4-level and 5-level severity classifications demonstrate that merging levels 4 and 3 helps address data imbalance and reduces RMSE for underrepresented high-severity categories. This adjustment simplifies the classification task and often leads to better overall model performance, as seen in the lower RMSE values across most folds and models. However, the variability in performance across certain folds, such as Lime, underscores the need for further investigation into the impact of severity level distribution on model generalization.

The Mask R-CNN model was evaluated independently to benchmark its binary segmentation performance. Its results were extremely poor, likely due to the reliance on pretrained weights and the use of 3-channel input images instead of the full spectral range provided by Sentinel-2. Enhancing Mask R-CNN through domain-specific training and modifying its architecture to accept 12-channel Sentinel-2 imagery could improve its ability to process wildfire datasets effectively. Incorporating Mask R-CNN into the severity estimation step of the DSF represents a promising area for future exploration.






Figure 3. a. Ground Truth b. U-Net Predicted Mask Image c. Attention U-Net Predicted Mask Image d. Nested U-Net Predicted Mask Image e. SegU-Net Predicted Mask Image f. MultiResUNet Predicted Mask Image

The experimental results from the second step show that Nested U-Net showed greater variability in RMSE across different folds, with the Coral dataset posing particular challenges. The Pink fold achieved the best overall performance, suggesting that the distribution of severity levels in the data set can impact the accuracy of the model. By contrast, the Lime fold exhibited the poorest detection results, likely due to the unique geographical characteristics of volcanic areas, which may introduce greater complexity in accurately detecting burned regions.

This study demonstrates the potential of integrating multi-sensor deep learning models, leveraging the rich spectral information provided by Sentinel-2 imagery, for wildfire detection and severity assessment. Among the models tested, MultiResUNet with minimal customization showed similar results to other U-Net variants, particularly for burned area detection. This suggests that the first step of the Double-Step Framework could be optimized specifically for U-Net-based architectures. Furthermore, a potential area of future research could involve leveraging different model families, such as applying U-Net-based models for binary detection and architectures like Mask R-CNN for severity estimation. Additionally, employing more balanced satellite datasets could enhance the Double-Step Framework's effectiveness across a wider range of geographical features and severity levels.

ACKNOWLEDGMENT

This study was supported by the Scientific and Technological Research Council of Turkey (TUBITAK) ARDEB 2549 (NCBR) Grant No: 122N254.

REFERENCES

- Colomba, L., Farasin, A., Monaco, S., Greco, S., Garza, P., Apiletti, D., Baralis, E., & Cerquitelli, T. (2022). A dataset for burned area delineation and severity estimation from satellite imagery. In *Proceedings of the 31st ACM International Conference on Information & Knowledge Management (CIKM '22)* (pp. 3893–3897). Association for Computing Machinery. <https://doi.org/10.1145/3511808.3557528>
- Farasin, A., Colomba, L., & Garza, P. (2020). Double-Step U-Net: A deep learning-based approach for the estimation of wildfire damage severity through Sentinel-2 satellite data. *Applied Sciences*, 10(12), 4332. <https://doi.org/10.3390/app10124332>
- Finney, M. A. (1998). *FARSITE: Fire Area Simulator—Model Development and Evaluation* (Research Paper RMRS-RP-4, Revised 2004). U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station.
- Han, Y., Zheng, C., Liu, X., Tian, Y., & Dong, Z. (2024). Burned area and burn severity mapping with a transformer-based change detection model. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 17, 13866–13880. <https://doi.org/10.1109/JSTARS.2024.3435857>
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask R-CNN. *Proceedings of the IEEE International Conference on Computer Vision (ICCV)*, 2961–2969. <https://doi.org/10.1109/ICCV.2017.322>

- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- Ibtehaz, N., & Rahman, M. S. (2020). Multiresunet: Rethinking the U-Net architecture for multimodal biomedical image segmentation. *Neural Networks*, 121, 74–87. <https://doi.org/10.1016/j.neunet.2019.08.025>
- Kamal, U., Tonmoy, T. I., Das, S., & Hasan, M. K. (2020). Automatic traffic sign detection and recognition using SegU-Net and a modified Tversky loss function with L1-constraint. *IEEE Transactions on Intelligent Transportation Systems*, 21(4), 1467–1479. <https://doi.org/10.1109/TITS.2019.2911727>
- Khennou, F., & Akhloufi, M. A. (2023). Improving wildland fire spread prediction using deep U-Nets. *Science of Remote Sensing*, 8, 100101. <https://doi.org/10.1016/j.srs.2023.100101>
- Li, M., Zhang, Y., Xin, J., Mu, L., Yu, Z., Liu, H., Xie, G., Jiao, S., & Yi, Y. (2021). Early forest fire segmentation based on deep learning. In *2021 CAA Symposium on Fault Detection, Supervision, and Safety for Technical Processes (SAFEPROCESS)* (pp. 1–5). IEEE. <https://doi.org/10.1109/SAFEPROCESS52771.2021.9693660>
- Monaco, S., Greco, S., Farasin, A., Colomba, L., Apiletti, D., Garza, P., Cerquitelli, T., & Baralis, E. (2021). Attention to fires: Multi-channel deep learning models for wildfire severity prediction. *Applied Sciences*, 11(22), 11060. <https://doi.org/10.3390/app112211060>
- Navarro, G., Caballero, I., Silva, G., Parra, P.-C., Vázquez, Á., & Caldeira, R. (2017). Evaluation of forest fire on Madeira Island using Sentinel-2A MSI imagery. *International Journal of Applied Earth Observation and Geoinformation*, 58, 97–106. <https://doi.org/10.1016/j.jag.2017.02.003>
- Oktay, O., Schlemper, J., Le Folgoc, L., Lee, M., Heinrich, M., Misawa, K., Mori, K., McDonagh, S., Hammerla, N. Y., Kainz, B., Glocker, B., & Rueckert, D. (2018). Attention U-Net: Learning where to look for the pancreas. *arXiv preprint*, arXiv:1804.03999
- Pinto, M. M., Libonati, R., Trigo, R. M., Trigo, I. F., & DaCamara, C. C. (2020). A deep learning approach for mapping and dating burned areas using temporal sequences of satellite images. *ISPRS Journal of Photogrammetry and Remote Sensing*, 160, 260–274. <https://doi.org/10.1016/j.isprsjprs.2019.12.014>
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. In *Advances in Neural Information Processing Systems* (Vol. 28).
- Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional networks for biomedical image segmentation. In N. Navab, J. Hornegger, W. M. Wells, & A. F. Frangi (Eds.), *Medical Image Computing and Computer-Assisted Intervention – MICCAI 2015* (pp. 234–241). Springer International Publishing. https://doi.org/10.1007/978-3-319-24574-4_28
- Shamsoshoara, A., Afghah, F., Razi, A., Zheng, L., Fulé, P. Z., & Blasch, E. (2020). *Aerial imagery pile burn detection using deep learning: The FLAME dataset*. arXiv. <https://arxiv.org/abs/2012.14036>
- Wang, Z., Yang, P., Liang, H., Zheng, C., Yin, J., Tian, Y., & Cui, W. (2022). Semantic Segmentation and Analysis on Sensitive Parameters of Forest Fire Smoke Using Smoke-Unet and Landsat-8 Imagery. *Remote Sensing*, 14(1), 45. <https://doi.org/10.3390/rs14010045>
- Zou, Y., Sadeghi, M., Liu, Y., Puchko, A., Le, S., Chen, Y., Andela, N., & Gentine, P. (2023). Attention-Based Wildland Fire Spread Modeling Using Fire-Tracking Satellite Observations. *Fire*, 6(8), 289. <https://doi.org/10.3390/fire6080289>
- Zhou, Z., Rahman Siddiquee, M. M., Tajbakhsh, N., & Liang, J. (2018). Unet++: A nested u-net architecture for medical image segmentation. In *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4* (pp. 3–11). Springer International Publishing. https://doi.org/10.1007/978-3-030-00889-5_1



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 05.08.2024
Kabul Tarihi : 10.11.2024

Received Date : 05.08.2024
Accepted Date : 10.11.2024

IOT DESTEKLİ HAVA DURUMU VERİLERİ İLE YAPAY ZEKÂ TABANLI HAVA TAHMİN SİSTEMİNİN GELİŞTİRİLMESİ

DEVELOPMENT OF ARTIFICIAL INTELLIGENCE-BASED WEATHER FORECASTING SYSTEM WITH IOT-SUPPORTED WEATHER DATA

Nurullah DOĞAN^{1*} (ORCID: 0009-0002-4714-5402)
Fatih ÖZYURT¹ (ORCID: 0000-0002-8154-6691)

¹ Fırat Üniversitesi, Yazılım Mühendisliği Bölümü, Elazığ, Türkiye

*Sorumlu Yazar / Corresponding Author: Nurullah DOĞAN, ndogan@firat.edu.tr

ÖZET

Son yıllarda, hava durumu tahmini süreçleri büyük veri analitiği ve yapay zekâ (AI) algoritmalarının artan gücü ile önemli ilerlemeler kaydetmiştir. Özellikle Nesnelerin İnterneti (IoT) teknolojilerinin entegrasyonu, çevresel verilerin toplanması ve bu verilerin işlenmesi süreçlerine büyük katkı sağlamıştır. Bu çalışmada, IoT sensörlerinden toplanan hava durumu verilerinin yapay zekâ temelli algoritmalar ile işlenerek hava tahmin modellerinin geliştirilmesi hedeflenmiştir. Çalışmanın veri seti, Fırat Üniversitesi'nde kurulan hava istasyonunda belirli tarihler arasında toplanan yaklaşık 600.000 adet hava durumu bilgisinden oluşmaktadır. Bu veriler, sıcaklık, nem, basınç, rüzgâr hızı gibi çeşitli meteorolojik parametreleri içermektedir. Çalışmada, dört farklı makine öğrenmesi ve derin öğrenme algoritması kullanılarak hava durumu tahmini yapılmıştır: Destek Vektör Makineleri (SVM), K-En Yakın Komşu (KNN), Uzun Kısa Süreli Bellek (LSTM) ve XGBoost algoritmaları. Modeller, elde edilen verilerle eğitilmiş ve her bir algoritmanın performansı, doğruluk oranları ile karşılaştırılmıştır. Sınıflandırma sonuçları değerlendirildiğinde, SVM ve KNN modelleri %98 doğruluk oranı ile başarılı sonuçlar vermiştir. LSTM modeli ise %99 doğruluk oranına ulaşmış, en yüksek doğruluk oranı ise %100 ile XGBoost algoritması tarafından elde edilmiştir. Bu sonuçlar, farklı makine öğrenmesi tekniklerinin hava tahmini süreçlerine nasıl katkı sağlayabileceğini ve IoT cihazlarından elde edilen verilerin nasıl daha etkili bir şekilde kullanılabilirliğini göstermektedir.

Anahtar Kelimeler: Hava durumu izleme, hava istasyonu, sensör sistemleri, raspberry pi, yapay zekâ

ABSTRACT

In recent years, weather forecasting processes have made significant advancements with the increasing power of big data analytics and artificial intelligence (AI) algorithms. The integration of Internet of Things (IoT) technologies has made a substantial contribution to the collection of environmental data and the processing of this data. This study aims to develop weather prediction models by processing weather data collected from IoT sensors using AI-based algorithms. The dataset consists of approximately 600,000 weather data points recorded between specific dates at the weather station established at Fırat University. This data includes various meteorological parameters such as temperature, humidity, pressure, and wind speed. Four different machine learning and deep learning algorithms were used to forecast the weather in the study: Support Vector Machines (SVM), K-Nearest Neighbors (KNN), Long Short-Term Memory (LSTM), and XGBoost algorithms. The models were trained on the collected data, and the performance of each algorithm was compared in terms of accuracy rates. The classification results showed that the SVM and KNN models achieved a 98% accuracy rate. The LSTM model reached a 99% accuracy rate, while the highest accuracy rate of 100% was achieved by the XGBoost algorithm. These results demonstrate how different machine learning techniques can contribute to weather forecasting processes and how IoT-derived data can be used more effectively.

Keywords: Weather monitoring, weather station, sensor systems, raspberry pi, artificial intelligence

ToCite: DOĞAN, N., & ÖZYURT, F., (2025). IOT DESTEKLİ HAVA DURUMU VERİLERİ İLE YAPAY ZEKÂ TABANLI HAVA TAHMİN SİSTEMİNİN GELİŞTİRİLMESİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 524-535.

GİRİŞ

İklim değişikliği ve hava olaylarının giderek artan etkileri, günümüz toplumlarında hava tahminlerinin doğruluğunu ve güvenilirliğini büyük bir önem haline getirmiştir. Hava durumu tahminleri, tarım, ulaşım, enerji yönetimi ve acil durum yönetimi gibi birçok kritik alanda hayatı doğrudan etkileyen kararların alınmasını destekler. Geleneksel hava tahmin yöntemleri genellikle karmaşık atmosfer modellerine dayalı olmakla birlikte, bu yöntemlerin doğrulukları belirli sınırlamalara ve belirsizliklere tabidir.

Geleneksel hava tahmin yöntemleri, genellikle karmaşık atmosfer modellerine dayanmaktadır ve bu modeller, atmosferdeki dinamikleri simüle etmek için matematiksel denklemler kullanmaktadır. Ancak, bu yöntemlerin doğruluğu, modelleme süreçlerinde kullanılan verilerin doğruluğu ve kapsamı ile sınırlıdır. Ayrıca atmosferik olayların karmaşıklığı ve belirsizlikler, geleneksel yöntemlerle yapılan tahminlerin zaman zaman hatalı olmasına yol açmaktadır (Ogunbunmi vd., 2024). Bu bağlamda, daha doğru ve yerel tahminler yapabilmek için yeni teknolojik yaklaşımların geliştirilmesi gerekmektedir. Son yıllarda, Nesnelerin İnterneti (IoT) teknolojilerinin gelişimi ve yaygınlaşması, hava durumu verilerinin toplama ve analiz süreçlerinde devrim niteliğinde değişiklikler meydana getirmiştir. IoT cihazları, çeşitli meteorolojik sensörler aracılığıyla gerçek zamanlı veri toplama kapasitesine sahip olup, bu verilerin büyük veri setleri halinde toplanmasını ve işlenmesini mümkün kılmaktadır. Bu veri bolluğu, hava tahmini sistemlerinin performansını artırma potansiyeline sahip olup, daha hassas ve yerel hava tahminlerinin yapılabilmesini sağlamaktadır (Banara vd.,2022; Laghari vd.,2021; Schiller vd.,2022).

Bununla birlikte, yapay zekâ (AI) ve makine öğrenmesi (ML) teknolojileri, bu büyük veri setlerinin işlenmesi ve analiz edilmesinde kritik bir rol üstlenmektedir. Yapay zekâ destekli sistemler, geçmiş hava durumu verilerini analiz ederek gelecekteki hava olaylarını daha yüksek doğrulukla tahmin edebilmektedir. Özellikle derin öğrenme (Deep Learning) algoritmaları, karmaşık veri yapıları arasında ilişki kurabilme ve örüntüleri tanıma yeteneği ile geleneksel yöntemlerden daha üstün performans göstermektedir (Dewitte vd., 2021). AI tabanlı hava tahmin modelleri, veri madenciliği, modelleme ve öngörü süreçlerinde hız ve doğruluk açısından geleneksel yöntemlerin ötesine geçmektedir (Faïd vd., 2021).

Bu çalışmada, IoT tabanlı hava durumu veri toplama sistemleri ile yapay zekâ tabanlı hava tahmin sistemlerinin entegrasyonu incelenecektir. IoT cihazları tarafından sağlanan gerçek zamanlı veriler, yapay zekâ algoritmaları tarafından analiz edilerek daha güvenilir hava tahminleri elde edilecektir. Bu bağlamda, sistemin tasarımı, veri toplama metodolojileri, algoritma seçimleri ve performans değerlendirme kriterleri detaylı bir şekilde ele alınacaktır. Çalışmanın amacı, IoT tabanlı hava durumu veri toplama ve yapay zekâ tabanlı tahmin sistemlerinin entegrasyonunu sağlayarak, hava tahminlerinin doğruluğunu artırmak ve hava olaylarına karşı daha etkili ve hızlı yanıt mekanizmaları geliştirmektir. Bu doğrultuda, hava tahmin sistemlerinin geliştirilmesi, çeşitli uygulama alanlarındaki potansiyel faydaları ve bu teknolojilerin gelecekteki rolü üzerine bir çerçeve sunulacaktır.

LİTERATÜR ARAŞTIRMASI

Günümüzde hava tahmini, yaşamın birçok yönünü etkileyen önemli bir konudur. Güvenilir hava tahmini, tarım, ulaşım, enerji yönetimi, güvenlik planlaması gibi birçok sektörün karar süreçlerini şekillendirir. Teknolojinin ilerlemesiyle birlikte, İnternet of Things (IoT) gibi yeni nesil veri toplama yöntemleri, hava durumu verilerinin daha doğru ve kapsamlı bir şekilde elde edilmesini mümkün kılmaktadır (Mohapatra vd., 2022; Holovaty, 2021).

Üçgün ve arkadaşları, hava durumundaki değişikliklerin hızlı ve doğru bir şekilde tespit edilmesi amacıyla Raspberry Pi 3 kontrolcü kartı kullanılarak bu karta bağladıkları sıcaklık ve nem sensörü, basınç sensörü, yağmur sensörü, rüzgâr hızı sensörü ve rüzgâr yönü sensörü ile uygun maliyetli bir hava durumu izleme sistemi geliştirmişlerdir. Geliştirilen veritabanı ile bilgiler veritabanına kaydedilmiştir ve sonrasında, geliştirilen web arayüzü ile bu bilgiler kullanıcılara anlık olarak sunulmuştur (Üçgün vd., 2021).

Aashiq ve arkadaşları, günlük yaşamımızda daha sık ihtiyaç duyulan hava ve hava parametrelerini ölçebilen, IoT tabanlı taşınabilir bir hava durumu izleme cihazı geliştirmişlerdir. Geliştirilen sistem ile sıcaklık, basınç, nem, rakım, PM2.5, PM10 seviyesi, VOC ve CO seviyesini ölçmüştür. Diğer cihazların sahip olmadığı düşük maliyetli ve düşük güç tüketimi ile taşınabilir ve elde tutulabilir boyutta hava ve hava kalitesi parametrelerinin ölçümleyebilen bir sistem geliştirilerek literatüre kazandırılmıştır (Aashiq vd., 2023).

Mahmood ve arkadaşları, Arduino UNO kartını kullanarak sıcaklık, nem, ışık yoğunluğu ve rüzgâr hızı verilerini ölçmek ve depolamak için sistem geliştirmişlerdir. Bir veritabanı geliştirerek hava durumu verilerine daha sonradan erişim imkânı sağlanmıştır. Aynı sistem, belirlenen yerleri istenilen hava koşullarında tutulabilmesi için hava koşullarında meydana gelen periyodik değişime göre bu lokasyonları yerel olarak denetleyip yöneten sistemi tasarlanmıştır (Mahmood vd., 2017).

Murugan ve arkadaşları, karar destek sistemine dayalı yapay zekâ denetleyici kullanılarak görüntü işleme ile hava tahmini çalışması yapmışlardır. Çalışmada kullanılan ESP32 kamera modülü ile çevreden aldığı görüntüleri işleyerek hava tahmini yapılmıştır. Çalışmada herhangi bir hava ölçüm çıktısı yoktur. Sadece lokasyondan alınan görüntüleri işleyerek havanın güneşli mi yoksa yağmurlu mu vs. gibi bilgilerin çıktısını vermektedir. Çeşitli yapay zeka teknolojileri kullanılarak görüntü işleme ile hava tahmininin başarılı bir şekilde gerçekleştirildiği görülmektedir (Murugan vd., 2022).

Ateş ve arkadaşları, yapay zekâ ile hava araçlarında buzlanma risk derece tahmini yapılmışlardır. Karar ağacı algoritması kullanılarak sıcaklık, nem, hava aracı sıcaklığı ve yağış gibi bilgiler ile buzlanma derecesi tahmini yapılmıştır. Çalışma sonucunda %74,38 doğruluk değeri edildiği görülmektedir (Ateş vd., 2021).

Goap ve arkadaşları, akıllı bir sulama sistemi geliştirmek için IoT tabanlı bir mimari ve hibrit makine öğrenmesine dayalı bir yaklaşım önermişlerdir. Toprak neminin tahmini için geçmiş sensör verileri ve hava durumu tahmin verilerini kullanmışlardır. Önerilen algoritma, toprak neminin ileri günlerdeki değişimini tahmin etmektedir. Sonuç olarak % 96 doğruluk oranı sağlayarak yüksek başarı oranı elde etmişlerdir (Goap vd., 2018).

Dogan ise Yapay Sinir Ağları (YSA) ve Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi (ANFIS) kullanılarak hava tahmini yapmıştır. Çalışmada toplam 9 girdi değerine karşılık tek çıktı olan ortalama sıcaklık değeri tahmin edilmiştir. En düşük ortalama tahmin hatası ile ANFIS modelinin YSA modeline göre daha performanslı olduğu görülmüştür (Dogan, 2024).

Bu çalışmada, IoT tabanlı hava durumu verilerinin kullanılmasıyla yapay zekâ algoritmalarının entegrasyonunu amaçlayan bir hava tahmin sistemi geliştirilmesi hedeflenmektedir. IoT cihazları aracılığıyla sürekli olarak toplanan gerçek zamanlı hava verileri, yapay zekâ modelleri tarafından analiz edilerek gelecekteki hava durumu koşullarının tahmin edilmesi sağlanacaktır. Ayrıca çalışmada kullanılan Raspberry Pi 4 kontrolcü kartı ve SEN0186 hava istasyon modülü ile ilgili detaylı bilgilere yer verilmesi amaçlanmaktadır. Bu sayede çalışmalarında bu donanımlara ihtiyaç duyacak kişiler için literatüre gerekli katkılar sağlanması hedeflenmektedir.

MATERYAL VE METHOD

Çalışmada Raspberry Pi 4 kontrolcü kartı, SEN0186 hava istasyon modülü ve bu cihazların çalışmasını sağlayan çeşitli donanım birimleri kullanılmıştır.

Raspberry Pi 4 Kontrolcü Kartı

Raspberry Pi, düşük maliyetli bir bilgisayar platformudur ve genellikle eğitim, hobi projeleri ve prototip geliştirme gibi amaçlarla kullanılır. İlk olarak 2012 yılında Birleşik Krallık' taki Raspberry Pi Vakfı tarafından piyasaya sürülmüştür. Temel amacı, araştırmacıların programlama ve bilgisayar bilimi eğitimini yaygınlaştırmak, bilgisayar ve elektronik konularında beceri kazanmalarını teşvik etmektir (Wikipedia Raspberry Pi 4, 2023). Şekil 1.'de projede kullanılan Raspberry Pi 4 kontrolcü kartı görülmektedir.



Şekil 1. Projede Kullanılan Raspberry Pi 4 Kontrolcü Kartı

SEN0186 Hava İstasyon Modülü

SEN0186, bir hava istasyon modülüdür. Bu modül, çevresel verileri toplamak ve analiz etmek için kullanılır. Özellikle, sıcaklık, nem, atmosfer basıncı, rüzgâr hızı, rüzgâr açısı, rüzgâr frekansı, yağış bilgisi gibi çeşitli meteorolojik parametreleri ölçebilir. Bu tür veriler, hava durumu tahminleri, çevresel araştırmalar ve otomasyon sistemlerinde kullanılmak üzere önemlidir. Şekil 2.'de SEN0186 hava istasyon modülünün örnek gösterimi verilmiştir.



Şekil 2. SEN0186 Hava İstasyon Modülü Gösterimi

SEN0186 hava istasyon modülü, 3.3V veya 5V çalışma voltajı, -40°C ile $+80^{\circ}\text{C}$ sıcaklık ölçüm aralığı, 4 pinli konektör (VCC, GND, TX, RX) bağlantı tipi, 4480 gr ağırlık, 0% ile 100% RH nem ölçüm aralığı, 300 hPa ile 1100 hPa hava basıncı ölçüm aralığı gibi teknik özelliklere sahiptir.



Şekil 3. SEN0186 Hava İstasyon Modülü Sensör Kartı


Şekil 3.'te SEN0186 hava istasyon modülünün sensör kartı görülmektedir. A ile gösterilen kısım hava kalitesi ölçüm girişi, B ile gösterilen yağış ölçüm girişi, C ile gösterilen rüzgâr parametreleri ölçüm girişi, D ile gösterilen data output portudur. PMS5003 sensöründen gelen veri çıkışını sağlamak için kullanılan bir bağlantı noktasıdır. Bu port, sensörün dışarıya veri iletmesini ve bu verilerin mikrodenetleyici veya bilgisayar gibi bir cihaza aktarılmasını sağlar. E ile gösterilen kartın gösterge ışığı, I ile gösterilen I2C sıcaklık, nem ve hava basıncı portu, J1 ile gösterilen metrik ve imperial jumper'lar ve son olarak J2 ile gösterilen ise veri arayüzü 2400/9600 baud hızı jumper'ıdır. (DFRobot APRS Weather Station Sensor Kit SEN0186,2023).

Raspberry Pi 4 ve Hava İstasyon Modülü Kartlarının Bağlantılarının Yapılması

Raspberry Pi' de yazılacak kodun çalışabilmesi için öncelikle kartların bağlantılarının doğru bir şekilde yapıldığından emin olunması gerekmektedir. Şekil 4.'te kartların bağlantı şeması görülmektedir.

Hava istasyon modülünden gelen iki adet port bulunmaktadır. Rüzgâr sensörlerinden gelen kablo hava istasyon sensör kartının "WD/WS" port kısmına takılmıştır. Yağmur kovanından gelen kablo ise "Rain" portu kısmına takılmıştır. Daha sonrasında Raspberry Pi ve hava istasyon sensör kartında bulunan 5V, GND, TX ve RX bağlantıları yapılmıştır. Burada dikkat edilmesi gereken nokta hava istasyon sensör kartından gelen TX bağlantısının Raspberry Pi 4' te RX'e, RX'in ise Raspberry Pi 4' te TX'e bağlantısının doğru yapılmasıdır. 5V ve GND bağlantıları da olduğu

gibi denk bir şekilde yapılmıştır. Şekil 5.'te Raspberry Pi 4'e gerekli bağlantıların yapılmış vaziyetteki hali görülmektedir.



Şekil 4. Kartların Bağlantı Şeması



Şekil 5. Raspberry Pi 4 Gerekli Bağlantıları Yapılmış Gösterimi

Hava İstasyon Modülünün Uygun Lokasyona Sabitlenmesi

Öncelikle hava istasyon modülünün uygun bir lokasyona sabitlenmesi gerekmektedir. Şekil 6.'da görüldüğü üzere hava istasyon modülü, rüzgâr açılarını ve hızını iyi ölçümlayebilecek bir yere sabitlenmiştir. Çalışmada hava istasyonu, Fırat Üniversitesi Spor Bilimleri Dekanlık binası çatısı olarak uygun görülen bir yere sabitlenmiştir.



Şekil 6. Hava İstasyon Modülü

Raspberry Pi 4'e Güç Verilmesi

Raspberry Pi 4'ün gerekli kurulumları yapıldıktan ve uygun bir yere sabitlendikten sonra cihaza güç verebilir. Cihazın olası elektrik kesintilerinden etkilenmemesi için kesintisiz güç kaynağı (UPS) kullanılmalıdır. Cihaz düşük güç tüketimine sahip olduğundan olası bir elektrik kesintisi durumunda kesintisiz güç kaynağı (UPS) sayesinde cihaz uzun saatler çalışmasına devam edebilmektedir. Şekil 7.'de görüldüğü üzere uygun yere konulan ve güç bağlantıları yapılmış cihazın çalışır vaziyette hali görülmektedir.



Şekil 7. Raspberry Pi 4 Konumlandırılmış Gösterimi

Raspberry Pi arayüzünde bulunan ve python ile yazılan kod sayesinde SEN0186 hava istasyon modülünden gelen hava durumu verileri txt dosyasına kaydedilmiştir. Bu veriler; tarih ve saat, anlık rüzgâr açısı, son 1 dakikadaki rüzgâr hızı, son 5 dakikadaki en yüksek rüzgâr hızı, anlık rüzgâr hızı, son 24 saatteki yağış miktarı, son 1 saat içindeki yağış miktarı, son dakika yağış miktarı, sıcaklık, nem, basınç gibi ölçüm sonuçlarından oluşmaktadır. Bu ölçüm bilgilerine Raspberry Pi' ye kurulmuş TeamViewer uzaktan erişim programı yardımıyla istenilen yerden cihaza erişimi mümkün kılmaktadır.

Hava istasyonundan gelen veri çıkış formatı sensör kartı üzerinde bulunan J1 ve J2 pinlerinin hangisinin takılı olduğuna göre değişmektedir. Çalışmada kullanılan pin daha kapsamlı bilgiler veren J2 pinidir. Yazılan kod sayesinde ham halde bulunan veri çıkış formatı Şekil 8.'de görülen anlamlı hava ölçüm sonuçlarına çevrilmiştir ve bu ölçüm sonuçları weather_data.txt adındaki dosyaya kaydedilmiştir.

```
Shell
Veriler Kaydedildi:
2024-01-09 13:42:49
135derece 3.2km/sa 2.2km/sa 11.9km/sa 0.0mm 0.0mm 0.0mm 8.9°C 59.8% 1023.1hPa
-----
Veriler Kaydedildi:
2024-01-09 13:42:50
113derece 2.2km/sa 2.2km/sa 11.9km/sa 0.0mm 0.0mm 0.0mm 8.9°C 59.8% 1023.1hPa
-----
Veriler Kaydedildi:
2024-01-09 13:42:51
45derece 2.2km/sa 2.2km/sa 11.9km/sa 0.0mm 0.0mm 0.0mm 8.9°C 59.8% 1023.1hPa
-----
Veriler Kaydedildi:
2024-01-09 13:42:52
158derece 3.2km/sa 2.2km/sa 11.9km/sa 0.0mm 0.0mm 0.0mm 8.9°C 59.8% 1023.1hPa
-----
Veriler Kaydedildi:
2024-01-09 13:42:53
135derece 3.2km/sa 2.2km/sa 11.9km/sa 0.0mm 0.0mm 0.0mm 8.9°C 59.8% 1023.1hPa
-----
Veriler Kaydedildi:
2024-01-09 13:42:54
90derece 2.2km/sa 2.2km/sa 11.9km/sa 0.0mm 0.0mm 0.0mm 8.9°C 59.9% 1023.1hPa
-----
```

Şekil 8. Hava Ölçüm Çıktısının Gösterimi

VERİ SETİ

Fırat Üniversitesi yerleşkesine kurulan hava istasyonu ile 31.12.2023 - 08.01.2024 tarihleri arasında her saniye olacak şekilde yaklaşık bir haftalık hava durumu verileri txt dosyasına kaydedilmiştir. Veri seti yaklaşık 600.000 adet hava durumu verisinden oluşmaktadır. Ayrıca on adet öznitelik değeri vardır. Bu öznitelikler; anlık rüzgâr açısı, son 1 dakikadaki rüzgâr hızı, son 5 dakikadaki en yüksek rüzgâr hızı, anlık rüzgâr hızı, son 24 saatteki yağış miktarı, son 1 saat içindeki yağış miktarı, son dakika yağış miktarı, sıcaklık, nem ve basınç değerleridir. Daha sonrasında txt dosyasını tahmin işleminde kullanabilmek için csv formatına çevrilmiştir. Kullanılan modellerde verilerin %80' i eğitim için, %20' si ise test işlemi için kullanılmıştır.

Kullanılan Yapay Zekâ Yöntemleri

Bu çalışmada, yapay zekâ yöntemlerinden SVM, KNN, LSTM ve XGBoost modelleri kullanılmıştır.

SVM

Destek Vektör Makineleri (SVM), sınıflandırma problemlerinde kullanılan etkili bir makine öğrenmesi algoritmasıdır. Temel amacı, veriyi ayıran en iyi hiperdüzlemi bulmaktır. Bu hiperdüzlem, iki sınıfa ait verilerin en

yakın noktaları arasındaki marjini maksimize eder. Matematiksel olarak, bir hiperdüzlem $w \cdot x + b = 0$ şeklinde tanımlanır ve w vektörü hiperdüzlemin normalidir. SVM, bu hiperdüzlemi bulurken $\frac{1}{2} \|w\|^2$ 'yi minimize eder (Singh vd., 2021).

Doğrusal olarak ayrılabilen veriler için SVM doğrudan kullanılabilirken, doğrusal olmayan verilerde kernel trick uygulanır. Kernel yöntemi, verileri daha yüksek boyutlu bir uzaya projelendirerek doğrusal ayrılabilir hale getirir. En yaygın kullanılan kernel fonksiyonlarından bazıları lineer kernel ve Gaussian (RBF) kerneldir (Abdullah vd., 2021; Wang vd., 2023).

SVM, yalnızca destek vektörleriyle ilgilenir ve sınıflandırma sonucunu bu vektörler üzerinden belirler. Destek vektörleri, hiperdüzleme en yakın noktalar olup sınıflandırma performansını doğrudan etkiler. SVM'nin yüksek doğruluk sağlaması ve genelleme yeteneği, onu birçok sınıflandırma probleminde tercih edilen bir yöntem yapar.

KNN

K-En Yakın Komşu (K-Nearest Neighbors, KNN) algoritması, denetimli öğrenmede kullanılan basit ve etkili bir sınıflandırma yöntemidir. KNN, yeni bir veriyi sınıflandırmak için en yakın K komşusunu belirleyerek, bu komşuların çoğunluk sınıfına göre tahminde bulunur. Algoritma, eğitim aşamasında herhangi bir model oluşturmaz, sadece mevcut veriyi saklar ve sınıflandırma işlemi sırasında en yakın komşuları bulur (Uddin vd., 2022; Zhang, 2021).

Matematiksel olarak, yeni bir veri noktası X_i 'yi sınıflandırmak için KNN, eğitim verisindeki tüm noktalarla olan mesafeleri hesaplar. Bu mesafeler genellikle Denklem (1)' deki Öklidyen Mesafe ile ölçülür (Zhang vd., 2021).

$$d(x_i, x_j) = \sqrt{\sum_{n=1}^N (x_{in} - x_{jn})^2} \quad (1)$$

Burada $d(x_i, x_j)$, x_i ve x_j noktaları arasındaki mesafeyi gösterir. KNN, bu mesafeye göre en yakın K komşuyu seçer ve bu komşuların sınıfına göre tahmin yapar.

KNN'nin avantajı, basit ve yorumlanabilir bir algoritma olmasıdır. Ancak büyük veri setlerinde ve yüksek boyutlu verilerde, yavaşlama ve bellek kullanımı sorunlarıyla karşılaşılabilir.

LSTM

Uzun Kısa Süreli Bellek (Long Short-Term Memory, LSTM), özellikle zaman serisi verileri ve sıralı verilerle çalışan RNN (Yinelenen Sinir Ağı) türüdür. LSTM, geleneksel RNN'lerin uzun dönemli bağımlılıkları öğrenme konusundaki zorluklarını aşmak için geliştirilmiştir. Bu ağlar, her zaman adımında veriyle birlikte bir hücre durumu taşıyarak, önemli bilgileri uzun süre boyunca "hatırlama" yeteneğine sahiptir. Bu sayede LSTM'ler, dil modelleme, konuşma tanıma ve zaman serisi tahmini gibi uygulamalarda oldukça etkili olur (Ren vd., 2022; Wang vd., 2021).

LSTM'nin temel yapısı, her bir zaman adımında üç temel kapıdan oluşur: unutma kapısı (forget gate), girdi kapısı (input gate) ve çıktı kapısı (output gate). Bu kapılar, hücre durumunu nasıl güncelleyeceğini ve hangi bilginin hatırlanacağını belirler. Matematiksel olarak, LSTM hücresi Denklem (2), (3), (4), (5), (6) ve (7)' deki formüller ile tanımlanır (Thapa vd., 2021; Wadud vd., 2022).

Unutma Kapısı: Geçmiş bilgilerin ne kadarının unutulacağını belirler.

$$f_t = \sigma(w_f \cdot [h_{t-1}, x_t] + b_f) \quad (2)$$

Girdi Kapısı: Yeni bilgilerin hücre durumuna ne kadar ekleneceğini belirler.

$$i_t = \sigma(w_i \cdot [h_{t-1}, x_t] + b_i) \quad (3)$$

$$\tilde{c}_t = \tan h(w_c \cdot [h_{t-1}, x_t] + b_c) \quad (4)$$

Hücre Durumu Güncellemesi:

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (5)$$

Çıktı Kapısı: Hangi bilginin çıktı olarak verileceğini belirler.

$$o_t = \sigma(w_o \cdot [h_{t-1}, x_t] + b_o) \quad (6)$$

$$b_t = o_t * \tan h(C_t) \quad (7)$$

Bu matematiksel formüller, LSTM'nin hücre durumunu ve çıktısını nasıl güncellediğini gösterir. LSTM, bu sayede geçmiş verilerden gelen önemli bilgileri unutmadan işleyebilir ve zaman içindeki bağımlılıkları öğrenebilir.

XGBoost

XGBoost (Extreme Gradient Boosting), karar ağaçları üzerine kurulu bir topluluk öğrenme yöntemidir. Boosting tekniği, zayıf öğrenicilerin (genellikle karar ağaçlarının) ardışık olarak eğitilmesiyle çalışır. XGBoost, diğer gradient boosting algoritmalarına göre daha hızlı ve verimli çalışır, ayrıca overfitting'i azaltmak için çeşitli düzenleme (regularization) teknikleri kullanır (Çakmak, 2024).

XGBoost'un temel amacı, her adımda hatalı tahminleri minimize ederek bir model oluşturmaktır. Model, bir kayıp fonksiyonunu optimize eder ve her iterasyonda, hatalı tahmin edilen veriler üzerinde daha çok ağırlık vererek yeni karar ağaçları ekler. Matematiksel olarak, XGBoost Denklem (8) ve (9)'daki formüller ile ifade edilir (Gad vd., 2022; Yelgeç vd., 2022; Yeşilyurt vd., 2021).

Tahmin edilen değer:

$$\hat{y}_i^{(t)} = \sum_{k=1}^t f_k(x_i) \quad (8)$$

Burada $f_k(x_i)$ her bir ağaç tarafından yapılan tahmin, t ise iterasyon sayısıdır.

Kayıp fonksiyonu:

$$L^{(t)} = \sum_i l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (9)$$

Burada l kayıp fonksiyonu (genellikle MSE gibi), $\Omega(f_t)$ ise ağaçların karmaşıklığını cezalandıran düzenleme terimidir. Bu düzenleme, overfitting'i azaltmak için kullanılır.

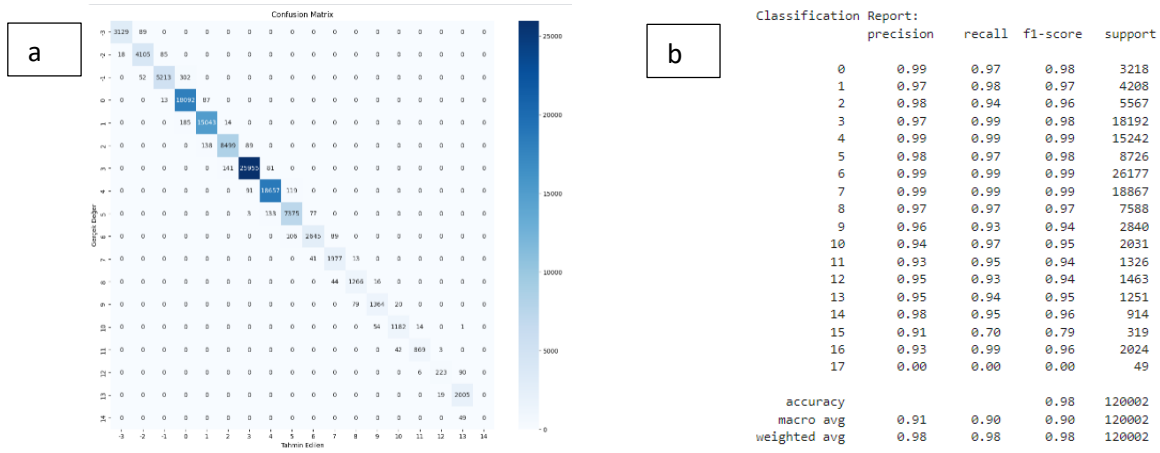
XGBoost, hem regresyon hem de sınıflandırma problemlerinde yaygın olarak kullanılan, güçlü bir algoritmadır. Verimliliği, hız optimizasyonları ve düzenleme kabiliyeti ile büyük veri setlerinde dahi yüksek performans gösterir.

DeneySEL Sonuçlar

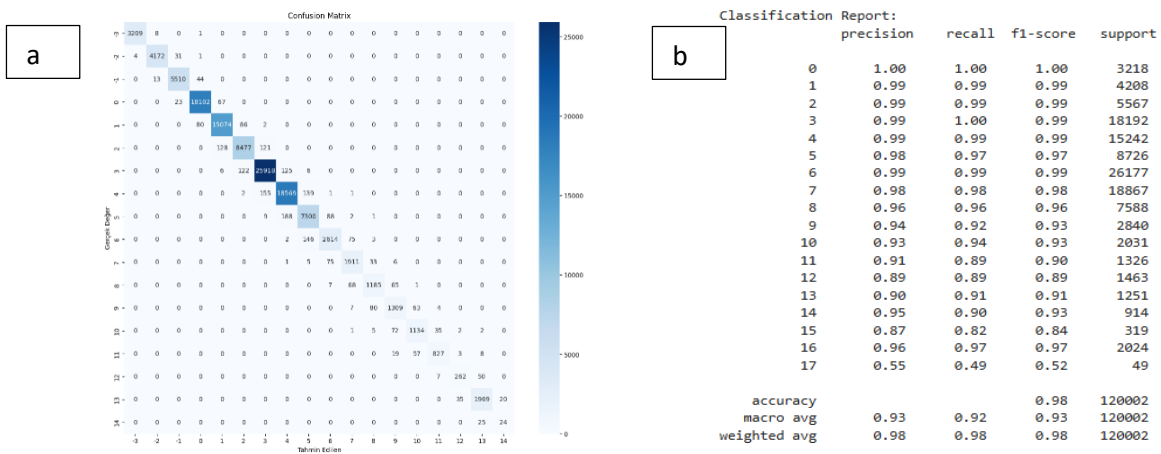
Veri setimiz Kaggle sunucusu kullanılarak SVM, KNN, LSTM ve XGBOOST modelleri ile tahmin işlemini gerçekleştirildi. Veri setinde yaklaşık 600.000 veri ve on adet öznitelik değeri bulunmaktadır. Öznitelik değerlerinden hedef değer olarak "sıcaklık" bilgisi seçilmiştir. Yani çalışmada kullanılan modeller diğer dokuz özneliğin durumuna göre havanın sıcaklık değerini tahmin edip sınıflandırma işlemi yapacaktır. Her bir modelde verilerin %80' i eğitim için, %20' si ise test işlemi için kullanılmıştır. Test işlemi sonucunda SVM modeli ile %98, KNN modeli ile %98, LSTM modeli ile %99, XGBoost modeli ile de %100 doğruluk değerleri elde edilmiştir.

Şekil 9. a.'da SVM modelinin confusion matrix' ini görülmektedir. Şekil 9. b.'de SVM modelinin tahmin edilen sınıflandırma raporu görülmektedir.

Şekil 10. a.'da KNN modelinin confusion matrix' i görülmektedir. Şekil 10. b.'de KNN modelinin tahmin edilen sınıflandırma raporu görülmektedir.




Şekil 9. a. SVM Modeli Confusion Matrix'i b. SVM Modeli Sınıflandırma Raporu



Şekil 10. a. KNN Modeli Confusion Matrix'i b. KNN Modeli Sınıflandırma Raporu


Şekil 11. a.'da LSTM modelinin confusion matrix' i görülmektedir. Şekil 11. b.'de LSTM modelinin tahmin edilen sınıflandırma raporunu görülmektedir.



Şekil 11. a. LSTM Modeli Confusion Matrix'i b. LSTM Modeli Sınıflandırma Raporu

Şekil 12. a.'da XGBoost modelinin confusion matrix' i görülmektedir. Şekil 12. b.'de XGBoost modelinin tahmin edilen sınıflandırma raporu görülmektedir.

Tablo 1.'de çalışmada kullanılan modeller ve çalışma sonucunda elde edilen doğruluk değerleri tablo halinde görülmektedir.



Şekil 12. a. XGBoost Modeli Confusion Matrix'i b. XGBoost Modeli Sınıflandırma Raporu

Tablo 1. Çalışma Sonucu Doğruluk Değerleri

Model	Doğruluk Değeri (%)
XGBoost	100
LSTM	99
KNN	98
SVM	98

SONUÇ

Yaptığımız çalışmada öncelikle Raspberry Pi 4 ve hava istasyonunun çalışma mantığını öğrenerek ve bunların uygun lokasyonlara kurulumlarını yaparak 31.12.2023 - 08.01.2024 tarihleri arasında her saniye olacak şekilde yaklaşık bir haftalık hava durumu verileri txt dosyasına kaydedilmiştir. Bu txt dosyasını tahmin işlemine tabi tutabilmek için veri seti csv formatına dönüştürülmüştür. Veri seti, yaklaşık olarak 600.000 adet veriden ve on adet öznitelikten oluşmaktadır. Bu öznitelikler; anlık rüzgâr açısı, son 1 dakikadaki rüzgâr hızı, son 5 dakikadaki en yüksek rüzgâr hızı, anlık rüzgâr hızı, son 24 saatteki yağış miktarı, son 1 saat içindeki yağış miktarı, son dakika yağış miktarı, sıcaklık, nem ve basınç değerlerinden oluşmaktadır. Öznitelik değerlerinden hedef değer olarak "sıcaklık" bilgisi seçilmiştir. Veri seti Kaggle sitesi kullanılarak SVM, KNN, LSTM, XGBoost modelleri ile tahmin işlemine tabi tutulmuştur. Kullanılan her bir modelde veri setinin %80' i eğitim verisi %20' si ise test verisi olarak ayarlanmıştır. İşlem sonucunda SVM modeli ile %98, KNN modeli ile %98, LSTM modeli ile %99, XGBoost modeli ile de %100 doğruluk değerleri elde edilmiştir.

Sonuç olarak hava tahmini için karşılaştırılan bu dört modelden en yüksek başarı oranı sağlayan modelin XGBoost modeli olduğu görülmüştür. Yapılan çalışma sonucunda XGBoost modelinin hava tahmin çalışmalarında kullanılması diğer üç modele göre daha yüksek başarı sağlama nedeniyle en uygun model olduğu görülmüştür.

Bu çalışma, hava tahmini alanında makine öğrenimi modellerinin etkinliğini ortaya koyarak, özellikle XGBoost modelinin yüksek doğruluk oranıyla dikkate değer bir başarı sağladığını göstermektedir. Günümüzde hava durumu tahminleri, tarım, ulaşım ve altyapı hizmetleri gibi birçok sektörde kritik öneme sahiptir. Bu çalışmanın literatüre katkısı, yerel veri setlerinin kullanılması ve Raspberry Pi 4 gibi ulaşılabilir teknolojilerin entegre edilmesiyle, düşük maliyetli ve verimli hava tahmin sistemlerinin geliştirilmesine olanak tanınmasıdır. Ayrıca, farklı makine öğrenimi yöntemlerinin karşılaştırılması, araştırmacılara ve uygulayıcılara hangi yöntemlerin belirli koşullar altında daha etkili olduğunu belirleme konusunda değerli bilgiler sunmaktadır. İleriki çalışmalarımızda ise görüntü işleme teknikleri ile meyve üzerindeki hastalık belirtilerini tespit ederek ve hava durumu verilerini kullanarak bu hastalıkların yayılma riskini modellemeyi düşünmekteyiz.

TEŞEKKÜR

ADEP.23.09 numaralı Bilimsel Araştırma Projesi kapsamındaki desteğinden dolayı Fırat Üniversitesine teşekkür ederiz.

KAYNAKLAR

- Aashiq, M. N. M., Kurera, W. T. C. C., Thilekaratne, M. G. S. P., Saja, A. M. A., Rouzin, M. R. M., Neranjan, N., & Yassin, H. (2023). An IoT-based handheld environmental and air quality monitoring station. *Acta IMEKO*, 12(3), 1-9. <https://doi.org/10.21014/actaimeko.v12i3.1487>
- Abdullah, D. M., & Abdulazeez, A. M. (2021). Machine learning applications based on SVM classification a review. *Qubahan Academic Journal*, 1(2), 81-90. <https://doi.org/10.48161/qaj.v1n2a50>
- Ateş, F., & Şenol, R. (2021). Hava Araçlarında Buzlanma Risk Derecesinin Yapay Zeka İle Tahmin Edilmesi. *International Journal of 3D Printing Technologies and Digital Industry*, 5(3), 457-468. <https://doi.org/10.46519/ij3dptdi.957478>
- Banara, S., Singh, T., & Chauhan, A. (2022, January). Iot based weather monitoring system for smart cities: A comprehensive review. In 2022 International Conference for Advancement in Technology (ICONAT) (pp. 1-6). IEEE. <https://doi.org/10.1109/ICONAT53423.2022.9726106>
- Çakmak, M. (2024, March). Classification of Apple Quality Using XGBoost Machine Learning Model. In Konya: 4th International Conference on Innovative Academic Studies (pp. 607-615).
- Dewitte, S., Cornelis, J. P., Müller, R., & Munteanu, A. (2021). Artificial intelligence revolutionises weather forecast, climate monitoring and decadal prediction. *Remote Sensing*, 13(16), 3209. <https://doi.org/10.3390/rs13163209>
- DFRobot - APRS Weather Station Sensor Kit SEN0186. (2023, August 3). APRS Weather Station Sensor Kit SEN0186 - DFRobot. https://wiki.dfrobot.com/APRS_Weather_Station_Sensor_Kit_SEN0186
- Dogan, T. Yapay Sinir Ağları ve Uyarlanabilir Sinirsel Bulanık Çıkarım Sistemi ile Hava Tahmini. *International Journal of Pure and Applied Sciences*, 10(1), 12-24. <https://doi.org/10.29132/ijpas.1384431>
- Faid, A., Sadik, M., & Sabir, E. (2021). An agile AI and IoT-augmented smart farming: a cost-effective cognitive weather station. *Agriculture*, 12(1), 35. <https://doi.org/10.3390/agriculture12010035>
- Gad, I., & Hosahalli, D. (2022). A comparative study of prediction and classification models on NCDC weather data. *International Journal of Computers and Applications*, 44(5), 414-425. <https://doi.org/10.1080/1206212X.2020.1766769>
- Goap, A., Sharma, D., Shukla, A. K., & Krishna, C. R. (2018). An IoT based smart irrigation management system using Machine learning and open source technologies. *Computers and electronics in Agriculture*, 155, 41-49. <https://doi.org/10.1016/j.compag.2018.09.040>
- Holovatyy, A. (2021). Development of IOT weather monitoring system based on Arduino and ESP8266 Wi-Fi Module. In IOP Conference Series: Materials Science and Engineering (Vol. 1016, No. 1, p. 012014). IOP Publishing. <https://doi.org/10.1088/1757-899X/1016/1/012014>
- Laghari, A. A., Wu, K., Laghari, R. A., Ali, M., & Khan, A. A. (2021). A review and state of art of Internet of Things (IoT). *Archives of Computational Methods in Engineering*, 1-19. <https://doi.org/10.1007/s11831-021-09622-6>
- Mahmood, S. N., & Hasan, F. F. (2017). Design of weather monitoring system using Arduino based database implementation. *Journal of Multidisciplinary Engineering Science and Technology (JMEST)*, 4(4), 7109.
- Mohapatra, D., & Subudhi, B. (2022). Development of a cost-effective IoT-based weather monitoring system. *IEEE Consumer Electronics Magazine*, 11(5), 81-86. <https://doi.org/10.1109/MCE.2021.3136833>
- Murugan, K., Tiruveedhi, R. K., Ramireddygar, D. R., Thota, D., & Neeli, C. (2022, December). AI based Weather Monitoring System. In 2022 Second International Conference on Advanced Technologies in Intelligent Control, Environment, Computing & Communication Engineering (ICATIECE) (pp. 1-5). IEEE. <https://doi.org/10.1109/ICATIECE56365.2022.10047380>
- Ogunbunmi, S., Taiwo, A. A., Oladosu, J. B., Sanusi, H., Inaolaji, F. A., Olasunkanmi, U. G., ... & Enabulele, E. C. (2024). Internet of things weather monitoring system. *World Journal of Advanced Research and Reviews*, 22(2), 2099-2110. <https://doi.org/10.30574/wjarr.2024.22.2.1647>
- Ren, J., Yu, Z., Gao, G., Yu, G., & Yu, J. (2022). A CNN-LSTM-LightGBM based short-term wind power prediction method based on attention mechanism. *Energy Reports*, 8, 437-443. <https://doi.org/10.1016/j.egyr.2022.02.206>

- Schiller, E., Aidoo, A., Fuhrer, J., Stahl, J., Ziörjen, M., & Stiller, B. (2022). Landscape of IoT security. *Computer Science Review*, 44, 100467. <https://doi.org/10.1016/j.cosrev.2022.100467>
- Singh, K. R., Neethu, K. P., Madhurekaa, K., Harita, A., & Mohan, P. (2021). Parallel SVM model for forest fire prediction. *Soft Computing Letters*, 3, 100014. <https://doi.org/10.1016/j.socl.2021.100014>
- Thapa, K. N. K., & Duraipandian, N. (2021). Malicious traffic classification using long short-term memory (LSTM) model. *Wireless Personal Communications*, 119(3), 2707-2724. <https://doi.org/10.1007/s11277-021-08359-6>
- Uddin, S., Haque, I., Lu, H., Moni, M. A., & Gide, E. (2022). Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction. *Scientific Reports*, 12(1), 6256. <https://doi.org/10.1038/s41598-022-10358-x>
- Üçgün, H., Kaplan, Z.K., & Yüzgeç, U., (2021). Akıllı Hava İstasyonu ile IoT Tabanlı Hava Durumu İzleme Sistemi. *European Journal of Science and Technology*, (21), 563-571. <https://doi.org/10.31590/ejosat.886025>
- Wadud, M. A. H., Kabir, M. M., Mridha, M. F., Ali, M. A., Hamid, M. A., & Monowar, M. M. (2022). How can we manage offensive text in social media-a text classification approach using LSTM-BOOST. *International Journal of Information Management Data Insights*, 2(2), 100095. <https://doi.org/10.1016/j.ijime.2022.100095>
- Wang, H., Li, G., & Wang, Z. (2023). Fast SVM classifier for large-scale classification problems. *Information Sciences*, 642, 119136. <https://doi.org/10.1016/j.ins.2023.119136>
- Wang, J., Li, J., Wang, X., Wang, J., & Huang, M. (2021). Air quality prediction using CT-LSTM. *Neural Computing and Applications*, 33, 4779-4792. <https://doi.org/10.1007/s00521-020-05535-w>
- Wikipedia - Raspberry Pi 4. (2023, October 5). Raspberry Pi 4 - Wikipedia. https://en.wikipedia.org/wiki/Raspberry_Pi_4
- Yelgeç, M. A., & Bingöl, O. (2022). Ayrık dalgacık dönüşümü ve XGBoost ile rüzgâr gücü tahmini. *Uluslararası Teknolojik Bilimler Dergisi*, 14(2), 58-65. <https://doi.org/10.55974/utbd.1132336>
- Yeşilyurt, S., & Dalkılıç, H. (2021). XGBoost ve gradient boost machine ile günlük nehir akımı tahmini. In 3rd International Symposium of III Engineering Applications on Civil Engineering and Earth Sciences.
- Zhang, S. (2021). Challenges in KNN classification. *IEEE Transactions on Knowledge and Data Engineering*, 34(10), 4663-4675. <https://doi.org/10.1109/TKDE.2021.3049250>
- Zhang, S., & Li, J. (2021). KNN classification with one-step computation. *IEEE Transactions on Knowledge and Data Engineering*, 35(3), 2711-2723. <https://doi.org/10.1109/TKDE.2021.3119140>



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 10.10.2024
Kabul Tarihi : 17.11.2024

Received Date : 10.10.2024
Accepted Date : 17.11.2024

HİDROJEN: SÜRDÜRÜLEBİLİR ENERJİ İÇİN ÇOK YÖNLÜ ÇÖZÜM

HYDROGEN: A VERSATILE SOLUTION FOR SUSTAINABLE ENERGY

Elif DAŞ¹ (ORCID: 0000-0002-3149-6016)
Emine TEKE ÖNER^{2*} (ORCID: 0000-0003-3365-7378)

¹ Atatürk Üniversitesi, Fizik Bölümü, Fen Fakültesi, Erzurum, Türkiye
^{2*} Atatürk Üniversitesi, Kimya Mühendisliği Bölümü, Erzurum, Türkiye

*Sorumlu Yazar / Corresponding Author: Emine TEKE ÖNER, eemineteke@gmail.com

ÖZET

Fosil yakıtların büyük ölçüde tükenmesi, atmosferdeki karbondioksit seviyesinin artması ve buna bağlı olarak gelişen çevresel tehlikeler insanlık için giderek artan bir endişe kaynağıdır. Bu nedenle son yıllarda hidrojen ekosisteminin kurulmasına yönelik önemli çabalar sarf edilmektedir. Hidrojen, sıfır veya sıfıra yakın emisyonla üretilen, yüksek verimle enerji dönüşümü sağlayabilen bir enerji taşıyıcısıdır. Öte yandan, ulaşım, ısınma ve enerji üretimi gibi farklı alanlarda çok yönlü olarak kullanılabilir potansiyeline sahiptir. Hidrojen, mavi, yeşil, gri gibi farklı üretim yöntemleriyle elde edilmektedir. Yeşil hidrojen, yenilenebilir enerji kaynaklarından üretildiğinden çevre dostu bir seçenek sunmaktadır. Ancak, mevcut durumda hidrojen ekonomisinin gelişimi ve yaygın kullanımıyla ilgili birtakım zorluklarla karşılaşmaktadır. Bu zorluklar arasında üretim maliyetleri, depolama ve taşıma teknolojilerinin geliştirilmesi, altyapı entegrasyonu ve güvenlik önlemleri gibi konular yer almaktadır. Bu bağlamda, Dünya genelinde birçok ülke hidrojenin enerji dönüşümündeki rolünü değerlendirerek kendi yol haritalarını oluşturmuşlardır. Bu yol haritalarıyla ülkeler, ulusal enerji bağımsızlığını, çevresel sürdürülebilirliği ve ekonomik büyümeyi desteklemeyi amaçlamaktadır. Bu mini derleme kapsamında da sürdürülebilir bir enerji geleceği için hidrojenin rolü ele alınmaktadır.

Anahtar Kelimeler: Hidrojen ekonomisi, sıfır emisyon, sürdürülebilirlik, temiz enerji

ABSTRACT

The massive depletion of fossil fuels, increasing level of carbon dioxide in the atmosphere and the associated environmental hazards are a growing concern for humanity. That is why significant efforts have been made in the last few decades to build a hydrogen ecosystem. Hydrogen is a highly efficient energy carrier that can lead to zero or near-zero emissions. On the other hand, it has the potential to be used versatilely in different areas such as transportation, heating and energy generation. Hydrogen is obtained through different production methods such as blue, green and grey. Green hydrogen offers an environmentally friendly option when produced from renewable energy sources. However, there are currently a number of challenges to the development and widespread use of the hydrogen economy. These challenges include production costs, development of storage and transportation technologies, infrastructure integration and security measures. In this context, many countries around the world have created their own roadmaps by assessing the role of hydrogen in the energy transition. With these roadmaps, countries aim to promote national energy independence, environmental sustainability and economic growth. This mini-review covers the role of hydrogen for a sustainable energy future.

Keywords: Hydrogen economy, zero emission, sustainability, clean energy

GİRİŞ

Son yıllardaki nüfus artışı, ekonomik gelişme ve teknolojiye gelinen son nokta küresel enerji tüketiminde istikrarlı bir artış ile sonuçlanmıştır. Günümüzde elektrik, ulaşım ve konut hizmetleri için birincil enerji kaynağı olarak petrol, doğal gaz ve kömür içeren fosil yakıtlar kullanılmaktadır (Vidas & Castro, 2021). Milyonlarca yıllık doğal süreçler sonucunda organik maddelerden elde edilen bu fosil yakıtlar, sosyal ve ekonomik kalkınmanın en temel girdilerinden biri olan enerji için büyük önem arz etmekte ve küresel kalkınmada oldukça etkili rol oynamaktadır. Bu yakıtların belirli rezervlerle sınırlı olması uzun vadede enerji güvenliğini tehdit etmektedir (Sarker vd., 2023). Biyokütle, rüzgâr, jeotermal ve güneş enerjisi gibi yenilenebilir kaynaklara kıyasla nispeten düşük maliyetleri nedeniyle kullanımları oldukça cazip görülse de (Sarker vd., 2023) fosil yakıtların yanması sonucu oluşan sera gazlarının atmosfere salınması çağımızın en büyük sorunları haline gelmiş küresel ısınma ve iklim değişikliği gibi hayati önem arz eden çevre sorunlarına sebebiyet vermektedir (Hydrogen Insights, 2022). Birçok gelişmiş ve gelişmekte olan ülke bu alanda yapılan çalışmaları desteklemekte ve enerji verimliliğinin artması için yoğun çaba sarf etmektedir. Yapılan bilimsel araştırmalar enerji kaynaklı CO₂ emisyon oranının artarak devam edeceğini ve bu durumun dünya sıcaklığındaki öngörülen artış oranının üstünde bir değer ile sonuçlanacağını ortaya koymaktadır. Dünya sıcaklığında ortalama 2 °C'lik artış olması, milyonlarca insanı açlığa, sıtmaya, sel felaketlerine ve tatlı su kıtlığına maruz bırakacak çok ciddi bir sorundur. Dünya geleceğini tehdit eden bu durum karşısında atmosfere salınan sera gazlarının azaltılması için alınabilecek tedbirler arasında fosil kaynaklı enerji kullanımının azaltılması oldukça etkin bir yaklaşımdır (Öner, E. T., & Yurtcan, A. B., 2023). Bu nedenle, fosil yakıtların sürdürülebilir ve çevre dostu enerji kaynakları veya yakıtlarıyla değiştirilmesi son yıllarda önemli bir hedef haline gelmiştir (European Commission, 2020; Ishaq & Dincer, 2021). Yenilenebilir enerji kaynakları, çevre üzerine olumsuz etkisi geleneksel enerji üretim yöntemlerine göre daha az olan ve karbon emisyonunun neredeyse sıfır olduğu temiz enerji kaynaklarıdır. Karbon içermeyen bir yakıt olarak, hidrojen, geleceğin enerjisi için en umut verici enerji taşıyıcısı haline gelmiştir. Hidrojenin kütle bazında mükemmel bir kalorifik değeri vardır bu da onu çeşitli alanlarda kullanılması için çekici bir yakıt haline getirmektedir. (Zhang vd., 2024).

Hidrojen elementi 1766'da İngiliz bilim adamı Henry Cavendish tarafından keşfedilmesine karşın, bu elemente "su oluşturu" anlamına gelen "hidrojen" adı 1783 yılında Fransız kimyacı Antoine Lavoiser tarafından verilmiştir (Dawood vd., 2023). Evrende en bol bulunan molekül olmasına rağmen metalik olmayan elementlerin çoğuyla kolayca bileşik oluşturduğundan Dünya'daki hidrojen büyük oranda su veya organik bileşiklerin yapısında moleküler formlarda bulunmaktadır (Elshafei & Mansour, 2023). 1874 yılında, Jules Verne'nin "su geleceğin kömürü olacaktır" ifadesi, günümüzde hidrojenin enerji anlamındaki önemini vurgulayan güçlü bir öngörüü temsil etmektedir (Zohuri, 2016). Öyle ki, hidrojen, tarih boyunca çeşitli endüstrilerde yaygın olarak kullanılan bir element olmuştur. Ayrıca sahip olduğu yüksek enerji yoğunluğu nedeniyle diğer birçok yakıtta göre daha fazla enerji (birim kütle başına) taşımaktadır (Vidas & Castro, 2021; Osman vd., 2022). Bu nedenle, son yıllarda, temiz enerji taleplerini karşılamak, çevresel sürdürülebilirlik hedeflerini gerçekleştirmek ve iklim değişikliğiyle mücadele etmek için kritik öneme sahiptir (Dash vd., 2023; Ishaq & Dincer, 2020). Hidrojen, bilinenin aksine bir enerji kaynağı olmayıp herhangi bir birincil enerji kaynağından elde edilebilen ikincil bir enerji taşıyıcısıdır (Zohuri, 2016; Vidas & Castro, 2021). Sahip olduğu birçok özellik nedeniyle temiz ve sürdürülebilir enerji için önemli bir oyuncu olarak görülmekte ve yenilenebilir enerji kaynaklarından üretimine büyük ilgi gösterilmektedir (Acar & Dincer, 2019). Bu nedenle, hidrojen üretim yöntemlerinin etkinliği, çevresel etkileri ve ticarileşmesi üzerine yürütülen çalışmalar her geçen gün hızla artmaktadır.

Literatür incelendiğinde hidrojen bazlı enerji sistemlerini konu alan araştırmaların temel olarak, hidrojen üretimi, depolanması, güvenliği ve kullanımı üzerine dört temel kriterin değerlendirilmesi şeklinde olduğu görülmektedir (Sadeq vd., 2023). Bu çalışmada hidrojenin fiziksel ve kimyasal özellikleri, üretim yöntemleri ve bu yöntemlerde karşılaşılan zorluklar, küresel ölçekte hidrojen ekonomisi, hidrojenin güvenilirliği ve Türkiye'nin hidrojen teknolojileri açısından ihtiyaçları ve bu ihtiyaçları karşılayacak teknolojik/destekleyici çözümler ele alınmaktadır.

Hidrojenin Fiziksel ve Kimyasal Özellikleri

İdeal bir alternatif yakıt, ucuz, kullanımı kolay, temiz ve daha düşük karbon içeriğine sahip olmalıdır. Mevcut alternatifler arasında hidrojen, ideal bir yakıt için gerekli kriterlerin çoğunu karşılayan en umut verici seçenek olarak öne çıkmaktadır (Coleman vd., 2020; Hanusch & Schad, 2021; Capurso vd., 2022). Hidrojen, sembolü H, atom numarası 1, moleküler ağırlığı 1,00794 olan periyodik tablodaki en hafif elementtir. Standart sıcaklık ve basınçta (STP), H₂ moleküler formülüne sahip, renksiz, kokusuz, tatsız, toksik olmayan ve yüksek derecede yanıcı diatomik

bir gazdır. Hidrojenin bazı fiziksel ve kimyasal özellikleri Tablo 1’de verilmektedir (Hassan vd., 2023), (Dawood, F., Anda, M., & Shafiullah, G. M., 2020).

Tablo 1. Hidrojenin Fiziksel ve Kimyasal Özellikleri

Özellik	Açıklaması
Kimyasal sembolü	H
Fazı (STP’de)	Gaz
Katı, sıvı ve gaz hali için denklilikler (981 mbar ve 20°C’de)	1 kg=14, 104 l= 12, 126 m ³
Moleküler ağırlığı	1,00794 g/mol
Atom numarası	1
Renk	Renksiz
Buhar basıncı (-252,8 ° C’de)	101,283 kPa
Gazın kaynama noktasındaki yoğunluğu (1 atm’de)	1,331 kg/m ³
Gazın özgül ağırlığı (0 °C ve 1 atm’de)	0,0696
Gazın özgül hacmi (21,1 °C ve 1 atm’de)	11,99 m ³ /kg
Kaynama noktası (101,283 kPa)	-252,8 °C
Donma/Erime noktası (101,283 kPa)	-259,2 °C
Kritik sıcaklık	-239,9 °C
Kritik basınç	1296,212 kPa
Üçlü nokta	-259,3 °C, 7,042 kPa
Buharlaşma ısısı	(H ²) 0,904 kJ.mol ⁻¹
Molar ısı kapasitesi	(H ²) 28,836 J.mol ⁻¹ K ⁻¹
İyonlaşma potansiyeli	13,5984 eV
C _p (sabit basınçta ısı sığası)	14,34 kJ/(kg) (°C)
C _v (sabit hacimde ısı sığası)	10,12 kJ/(kg) (°C)
Ağırlık bazında alt ısıtma değeri	120 MJ/kg
Ağırlık bazında üst ısıtma değeri	141,8 MJ/kg
Hacim bazında alt ısıtma değeri (1 atm’de)	11 MJ/m ³
Hacim bazında üst ısıtma değeri (1 atm’de)	13 MJ/m ³
Maksimum alev sıcaklığı	1526,85 °C
Oksidasyon durumları	1, -1
Elektronegatiflik	2,20 (Pauling ölçeği)
Kovalent yarıçapı	31 ± 5 pm
Van der Waals yarıçapı	120 pm
Kristal yapısı	Altıgen
Termal iletkenlik	0,1805 W. M ⁻¹ K ⁻¹
Eletriksel iletkenliği	Elektriği iyi iletmez ancak iyonlaştığında iletilebilir
Reaktivitesi	Birçok element ve bileşikle reaksiyona girer
Çözünürlüğü	Suda az çözünür
CAS* kayıt numarası	1333-74-0

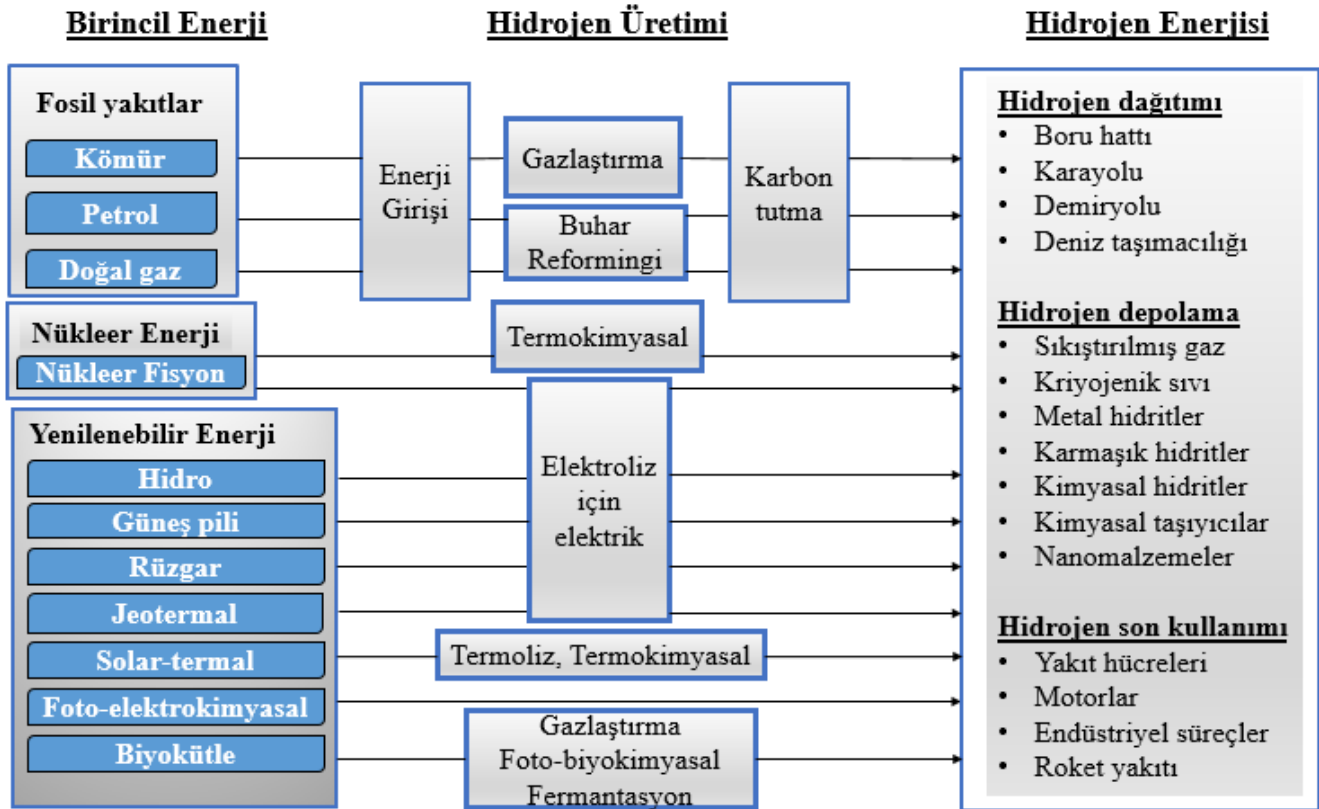
*CAS: Kimyasal özetler servisi (Chemical abstracts service)

Hidrojen Üretimi

Hidrojen üretim yöntemleri bu bölümde özet olarak derlenmiştir. Literatürde hidrojen üretimi konusunda birçok sınıflandırma şekli mevcuttur. Ancak temelde birincil enerji olarak kullanılacak kaynağın fosil yakıt, nükleer enerji ya da yenilenebilir enerji bazlı oluşuna göre kategorize edilmektedir. Seçilen enerji kaynaklarından hidrojen üretimi için gazlaştırma, buhar reformu, elektroliz, termoliz gibi farklı yöntemler sunulmaktadır. Literatürde üretim yönteminde kullanılan metot ve birincil enerji kaynağına göre hidrojen üretiminin mavi, mor, turkuaz, yeşil ve gri gibi farklı renklerle ilişkilendirildiği görülmektedir.

Mavi hidrojen, fosil yakıtlardan hidrojen üretmek için kullanılan mevcut süreçlerin, sera gazı (SG) emisyonlarının çoğunu azaltmak için karbon yakalama ve depolama (KYD) teknolojileriyle birleştirilebileceği fikrine dayanmaktadır. Mor hidrojen, birincil enerji kaynağı olarak nükleer enerjinin kullanıldığı ve nükleer reaktörün yüksek sıcaklıkları sayesinde termokimyasal süreçlerle üretilen hidrojendir. Turkuaz hidrojen, hidrokarbonların parçalanmasını içeren bir prosesle üretilen hidrojen türüdür. Başka bir ifadeyle, hidrojen ve karbon siyahının birlikte üretimi için metanın yüksek sıcaklıkta pirolizinden elde edilen hidrojen türüdür. Yeşil hidrojen, yenilenebilir enerjiye dayalı hidrojen üretimini tanımlamak için kullanılan bir terimdir (Sukpancharoen & Phetyim, 2021). Yeşil hidrojen, suyun yenilenebilir enerji kaynakları veya düşük karbonlu güç kaynakları tarafından üretilen elektrikle elektrolize edilmesi yoluyla elde edilmektedir (Yu vd., 2021). Gri hidrojen terimi genellikle fosil yakıtlardan elde edilen hidrojeni ifade etmektedir. En yaygın gri hidrojen türü, buhar metan reformu (BMR) ve ototermal reformu (OR) gibi süreçler kullanılarak doğal gazdan elde edilmektedir (Elshafei & Mansour, 2023). Gri hidrojenin ana dezavantajı ise hidrojen sentezi sırasında üretilen ve yıllık 830 milyon ton (Mt) civarında olduğu tahmin edilen CO₂ emisyonlarıdır (Dash vd., 2023; Sarker vd., 2023).

Genel olarak hidrojen üretim yöntemleri, kullanılan birincil enerji kaynakları, hidrojen dağıtım şekilleri, depolanma şekilleri ve kullanım alanları Şekil 1'de derlenerek sunulmuştur.



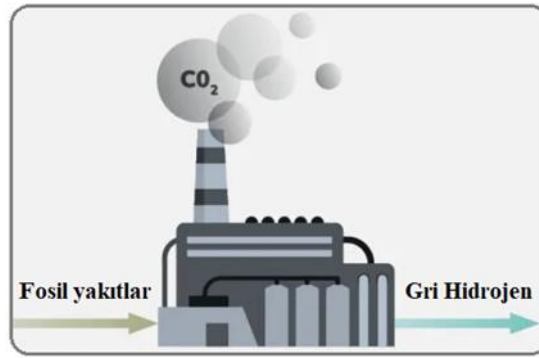
Şekil 1. Hidrojen Enerjisi Elde Etmek İçin Kullanılan Birincil Enerji Kaynakları ve Hidrojen Üretimi

Buhar reformu yöntemi, genellikle doğal gaz olmak üzere propan, benzin, etanol, dizel gibi fosil yakıtların da kullanılabilirdiği, hidrojen üretimi için oldukça yaygın ve bilinen bir yoldur. Bu teknolojide yüksek sıcaklık (700-1000 °C) ve basınç değerlerinde (3-25 bar) tutulan buhar, uygun bir katalizör varlığında metan (CH₄) ile reaksiyona girerek hidrojen, karbondioksit ve karbonmonoksit üretir. Seçilen yakıtı göre belirlenecek en uygun katalizör ile üretim süreci tamamlanır. Bu teknik, ticari hidrojen üretiminde talepleri karşıladığı ve uygun maliyetli olduğu için çoğunlukla tercih edilmektedir. Ancak fosil yakıt miktarındaki azalma ve son yıllardaki SG emisyonundaki artış bu yöntemin en büyük dezavantajlarıdır (Song vd., 2015).

Hidrojen üretiminin bir diğer önemli yolu kömür gazlaştırma yöntemidir. Bu süreçte kömür, yüksek basınç altında hidrojen (H₂), oksijen (O₂) ve buharla reaksiyona girerek karbon monoksit ve hidrojen karışımı (sentez gazı) oluşturmaktadır. Karbon monoksit su-gaz kayması reaksiyonu yoluyla buharla reaksiyona girerek hidrojen ve karbon oluşumunu sağlar. Bu işlemten sonra saf hidrojen sistemden ayrılır ve karbon yakalanarak tutulur (Howaniec &

Smoliński, 2014). Bu sentez yönteminde de SG emisyonlarının sebep olduğu çevresel etkiler göz önünde bulundurulduğunda prosesin çevre dostu hale getirilmesi ve bu şekilde yaygınlaşması için karbon yakalama ve birikme sorunlarının önüne geçilmesi gerekmektedir.

Fosil yakıt temelli hidrojen üretim sistemleri olan buhar reformu ve kömür gazlaştırma proseslerine karbon yakalama ünitesi entegre edilmeden üretilen hidrojen, literatürde karşımıza gri hidrojen olarak çıkmaktadır (Elshafei & Mansour, 2023). Şekil 2’de gri hidrojen üretim yöntemine ait şematik bir gösterim sunulmuştur. Kömür, dünyadaki fosil yakıtlar arasında en büyük rezerve sahip olduğundan kömür gazlaştırma yöntemi de sıklıkla kullanılmaktadır. Özellikle Çin, doğalgazın yüksek maliyeti ve kömür rezervlerinin bolluğu nedeniyle bu yöntem ile önemli miktarda hidrojen üretmektedir (Schneider vd., 2020) ve bugün hidrojenin çoğu Çin’de üretilmektedir (%30’dan fazlası) (IEA, 2022a). Çin hidrojen ittifakı, hidrojen pazarının yaklaşık 30 kat artarak, Çin’in hidrojen üretimindeki yeşil hidrojen payının 2019 yılındaki %1 değerinden 2030 yılında %10 değerine ulaşacağını ve bu durumun farklı iş fırsatları sunarak Çin’in hidrojen konusundaki rekabet avantajını artıracaklarını öngörmektedir (Huang vd., 2024).



Şekil 2. Gri Hidrojen Üretim Prosesi Şematik Gösterimi

Gri hidrojen üretimi ile oluşan çevresel tahribatın önüne geçmek ve bu durumu kontrol altına almak için sisteme karbon yakalama ünitesi entegre edilerek üretilen ve mavi hidrojen olarak bahsedilen sistemler, yeşil hidrojene geçmekten daha az maliyetli olarak görülmektedir. Ancak bu sistemlerde de KYD uygulaması ile ilgili yaşanabilecek teknik sorunlar ve üretilen hidrojenin gri yerine mavi olarak sınıflandırılabilmesi için gerekli olan CO₂ yakalama oranının standart bir değerinin belirlenmemiş olması sistemin dezavantajlarından. Literatürdeki bazı çalışmalarda, kullanılan teknolojiye ve CO₂ yakalama prosesinin uygulandığı aşamalara bağlı olarak %70 ile %95 aralığında maksimum yakalama oranları belirtilmiştir (Newborough, 2020). Doğal gazdan mavi hidrojen üretimini değerlendirirken, üretimin ilk aşamalarında metan sızıntısından kaynaklanan ek çevresel etkiyi de hesaba katmak çok önemlidir. Bu etkiyi tam olarak ölçmek zor olduğu için araştırma çalışmalarında sıklıkla göz ardı edilen bir faktördür. Mevcut gri hidrojen üretim altyapısından yararlanarak geliştirilip güçlendirilebilme imkânı sunduğu için yeni bir tesis kurulumuna göre mavi hidrojen üretimi nispeten avantajlı görülmektedir. Yani, tamamen yeni tesisler inşa etmek yerine, mevcut hidrojen üretim tesislerini modifiye ederek ve güçlendirerek (böylece karbon emisyonlarını azaltarak) gri hidrojen üretiminden mavi hidrojen üretimine geçiş sağlamak mümkündür (Yu vd., 2021). Ancak, CO₂’nin etkili ve kalıcı bir şekilde depolanmasını sağlamak için belirli koşulların karşılanması gerekmektedir. Özel bir CO₂ altyapısı, toplam maliyeti önemli ölçüde artırabilir ve bu maliyetin büyüklüğü her tesis için farklılık göstereceğinden genelleştirmek pek mümkün değildir. Ayrıca, bir KYD sisteminin işletilmesi ile BMR sürecinin enerji verimliliğini %5 ile %14 arasında değişen bir düşüşe neden olacağı öngörülmektedir (Noussan vd., 2021). Yine de Kanada, İran, Norveç, Katar, Rusya ve Amerika gibi fosil yakıt üreticileri için sürdürülebilir bir perspektif sunmaktadır (Irena, 2019; Yu vd., 2021). Şekil 3’te mavi hidrojen üretim sistemine ait şematik bir gösterim verilmiştir.

Termokimyasal proses yönteminde yüksek sıcaklıkta (500–2000 °C) gerçekleşen kimyasal reaksiyon ile hidrojen üretilmektedir. Bu yöntemde ısı kaynağı nükleer reaktörler veya güneş yoğunlaştırıcılarıdır ve proste kimyasallar her döngüde yeniden kullanılarak hidrojen üretimi için yalnızca su tüketimiyle kapalı devre bir kimyasal reaksiyon oluşturulur. Termokimyasal su ayrıştırmada, suyu hidrojen ve oksijene ayırmak için yüksek sıcaklıklarda bir dizi kimyasal reaksiyon gerçekleştirilir. Bu teknoloji de sıfır SG emisyonu ile temiz, saf, büyük ölçekli ve merkezi hidrojen üretimi için uygun bir yöntem olarak görülmektedir. Ancak güneş yoğunlaştırıcılarının ve ısı transfer ortamının maliyetinin azaltılması, ayrıca düşük sıcaklıkta gerekli ısıyı sağlamak için nükleer reaktör teknolojisinin

geliştirilmesi gibi sorunların giderilmesi gerekmektedir. Literatürde nükleer enerji varlığında gerçekleşen bu proses mor hidrojen üretim sistemi olarak da karşımıza çıkmaktadır.



Şekil 3. Mavi Hidrojen Üretim Prosesi

Metan pirolizi ya da metan ayrışması olarak adlandırılan yöntemde, CH₄ gaz halindeki H₂ ve elementel karbona (C) ayrılır. Hidrojen ve karbon siyahının birlikte üretimi için metanın yüksek sıcaklıkta pirolizinden elde edilen bu hidrojen türü literatürde turkuaz hidrojen olarak da adlandırılmaktadır (Dash vd., 2023). Turkuaz hidrojenin temel avantajı, termodinamik açıdan su elektrolizi ve BMR ile karşılaştırıldığında çok daha az enerji yoğunluğunun olması ve mevcut doğal gaz altyapısından yararlanılmasıdır (Diab vd., 2022). Yapılan çalışmalarda birçok turkuaz hidrojen üretim yönteminin incelenmiş olduğu görülmektedir. Bunlar arasında, katalitik ve katalitik olmayan termal ayrışma/piroliz, erimiş metal veya tuz banyosu, konsantre güneş ve termal olmayan plazma gibi yöntemler bulunmaktadır (Diab vd., 2022).


Son yıllarda hidrojen üretim yöntemleri üzerine yapılan çalışmalarda temiz enerji üretim sistemleri oldukça ilgi çeken bir araştırma konusudur. Yenilenebilir enerjiye dayalı hidrojen üretimini tanımlamak için yeşil hidrojen terimi sıklıkla kullanılmaktadır (Sukpancharoen & Phetyim, 2021). Yeşil hidrojen üretim sistemleri, suyun elektrolizi ile hidrojenin elde edildiği proseslerdir. Bu yöntemde elektroliz için gereken enerji yenilenebilir enerji kaynakları veya düşük karbonlu güç kaynakları tarafından üretilen elektrikle karşılanmaktadır (Yu vd., 2021). Elektroliz işleminde atmosfere zararlı emisyonlar salınmamakta ve su buharı dışında herhangi bir yan ürün oluşmamaktadır. Bu özellikleri sayesinde, yeşil hidrojen üretimi iklim değişikliği ile mücadelede etkili bir çözüm olarak görülmekte ve enerji sektöründeki karbon ayak izini azaltmaya yönelik çabaları desteklemektedir (Abad & Dodds, 2020).

Yeşil hidrojen üretimi için en yaygın kullanılan elektrolizörler, alkali elektrolizör (AE), polimer elektrolit membranı (PEM), anyon değişim membranı (ADM) ve katı oksit elektrolizörüdür (KOE) (El-Emam & Özcan, 2019; Nicita vd., 2020; Dash vd., 2023). PEM elektrolizörleri, diğer elektrolizör teknolojilerine göre şu anda piyasada bulunmakla kalmayıp aynı zamanda hızla pazara yayılmaktadır (Nicita vd., 2020). Şekil 4'te su elektroliz yöntemlerine ilişkin bir görsel verilmiştir (Kumar & Lim, 2022). Elektroliz yöntemi ile hidrojen üretimi temiz ve çevreci bir yöntem olmasına rağmen, dünya çapındaki hidrojen üretiminin %5'inden azını temsil etmektedir (Han vd., 2021). Mevcut endüstriyel elektrolizörlerin elektrik tüketimi, elektrolizörün boyutuna, türüne ve dikkate alınan çıkış basıncına bağlı olarak değişiklik göstermektedir. 10 ile 30 bar aralığındaki çıkış basınçları dikkate alındığında ortalama elektroliz verimliliği %65 ile %70 aralığında değişmektedir (Noussan vd., 2021). Ayrıca, gelecek 10 yıl içinde hidrojenin elektroliz ile üretim maliyetinin yaklaşık %70 oranında düşmesi beklenmektedir. Bu gelişme yeşil hidrojen üretim yöntemlerinin daha yaygın şekilde kabul görmesine ve kullanılmasına olanak sağlayacaktır (Osman vd., 2022).

Elektroliz yönteminde üzerinde durulması gereken diğer bir konu da su tüketimidir. Üretilen her bir kilogram hidrojen için elektroliz işleminde yaklaşık olarak 10 ile 15 litre su kullanılmaktadır (Al-Qahtani vd., 2021) ve kullanılan suyun deiyonize edilmesi gerekmektedir. Tatlı su kaynaklarının bulunmadığı durumlarda, deniz suyunun tuzdan arındırılması veya atık suyun geri kazandırılması gibi yöntemler düşünülmektedir. Deniz suyunun tuzdan arındırılması için halihazırda ticari olarak farklı teknolojiler kullanılmaktadır. Bu sistemler enerji tüketiminde minimum bir artışla elektroliz ile birleştirilebilir.

Yeşil hidrojen üretimi için çoğunlukla güneş ve rüzgâr teknolojileri kullanılmaktadır ve Şekil 5'te bu teknolojilere ait yeşil hidrojen üretim süreçleri özetlenmektedir (Benghanem vd., 2023). Uluslararası Yenilenebilir Enerji Ajansının (UYEA/IRENA) yayınlamış olduğu bir raporda yeşil hidrojen üretim maliyetinin 2019 yılı için kilogram başına 2,5-4,5 dolar aralığında olduğu ve 2050 yılına kadar bu miktarın 0,95 dolara kadar düşeceği tahmin edilmektedir (BloombergNEF, 2020; Noussan vd., 2021). Bu maliyete katkıda bulunan temel faktörler arasında elektrolizör için gerekli yatırım ve elektrik maliyeti yer almaktadır. Bunun yanı sıra, mevcut AE'lerin CAPEX

maliyetleri (sermaye harcamaları) 750 €/kW civarındadır, ancak 2025 yılına kadar 500 €/kW civarına düşmesi ön görülmektedir (Noussan vd., 2021). Ayrıca son yıllarda, tekil enerji kaynaklarıyla ilgili karşılaşılan zorlukların üstesinden gelebilmek için hibrit yenilenebilir enerji sistemleri (HYES) alternatif bir çözüm olarak değerlendirilmektedir. Bu konuda dünya çapında devam etmekte olan birçok araştırma projesiyle SG emisyonlarının azaltılmasının yanı sıra hidrojen üretim maliyetlerinin de azaltılması hedeflenmektedir (Sarker vd., 2023).




Şekil 4. Hidrojen Üretmek için Kullanılan Su Elektroliz Yöntemleri

(Creative Commons Attribution (CC-BY) lisansının hüküm ve koşulları altında dağıtılan açık erişim makalesine göre MDPI'den Ref. (Kumar & Lim., 2022) yeniden üretilmiştir.)

(Reproduced with some modification from Ref. (Kumar & Lim, 2022)) from the MDPI according to the open access article distributed under the terms and conditions of the Creative Commons Attribution (CC-BY) license (<http://creativecommons.org/licenses/by/4.0/>)

Hidrojen Üretim Yöntemlerindeki Zorluklar

Hidrojen birçok kullanım alanına sahip ve birçok farklı yöntemle üretilen önemli bir kimyasaldır. Ancak bir enerji vektörü olarak kabul görmesi için kimyasal kullanım amacıyla üretildiği maliyetten çok daha ucuza elde edilmesi gereklilik arz etmektedir. Bu bağlamda değerlendirildiğinde büyük hacimli bir endüstriyel üretimde son derece önemli olan maliyet tasarrufu kolay değildir. Özellikle yerel boyutlu küçük ölçekte kurulum maliyetleri daha yüksek düzeydedir. Ancak fosil kaynakların sınırlı oluşu ve kullanımları sonucu oluşan büyük çevresel tahribatlar hidrojen elde etmek için daha fizibil koşulların geliştirilmesini elzem kılmaktadır. Literatürde farklı teknikler sonucu üretilen ve mavi, mor, turkuaz, yeşil, gri renklerle bahsedilen üretim proseslerinde karşılaşılan genel zorluklar aşağıda sunulmaktadır



Şekil 5. Güneş ve Rüzgâr Enerjisi Yoluyla Yeşil Hidrojen Üretimine Yönelik Süreçler

(Creative Commons Attribution (CC BY) lisansının hüküm ve koşulları altında dağıtılan açık erişim makalesine göre MDPI'den Ref. (Benghanem vd., 2023)) yeniden üretilmiştir.
(Reproduced from Ref. (Benghanem vd., 2023)) from the MDPI according to the open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<http://creativecommons.org/licenses/by/4.0/>)

Mavi hidrojen:

- Karbonsuzlaştırma maliyeti ve enerji verimliliği: KYD süreçleri oldukça maliyetli olup, enerji verimliliğini azaltabilmektedir.
- Altyapı ihtiyacı: KYD altyapısı gerektirmekte olup, bu da ilave yatırım maliyetlerini beraberinde getirmektedir (Yu vd., 2021).

Mor hidrojen:

- Nükleer güvenlik: Nükleer enerjinin kullanımı, güvenlik ve radyoaktif atık yönetimi gibi zorlukları beraberinde getirmektedir. Bu durum, özellikle kamu güvenliği ve uzun vadeli atık depolama açısından riskler taşımaktadır.

Turkuaz hidrojen:

- Teknolojik olgunluk: Bu yöntem henüz deneysel aşamada olduğu için teknolojik olgunluğa ulaşması biraz daha zaman alabilir.

Yeşil hidrojen:

- Yüksek başlangıç maliyeti: Elektroliz ekipmanlarının ve yenilenebilir enerji tesislerinin yatırım maliyeti yüksektir (Liu vd., 2020). Özellikle, ilk kurulum yatırım maliyetleri fosil yakıt alternatiflerine kıyasla çok daha yüksektir.
- Elektroliz verimliliği: Elektroliz süreci enerji yoğun olabilir, bu da verimliliği etkileyebilir (Yu vd., 2021).

- Depolama ve Taşıma: Hidrojenin düşük yoğunluğu ve uçuculuğu nedeniyle depolama ve taşıma zorlukları bulunmaktadır (Vallejos-Romero vd., 2022).
- Maliyet ve talep belirsizliği: Yeşil hidrojenin maliyeti, diğer yakıtlara kıyasla halen oldukça yüksek olup, bu durum gelecekte yeşil hidrojene olan talebin sürdürülebilirliği konusunda belirsizlik yaratmaktadır (Farrell, 2023).
- Kaynak ve çevresel etkiler: Yeşil hidrojen projelerinin su tüketimi, tatlı suya erişim gibi doğal kaynaklar üzerindeki potansiyel etkileri çevresel sürdürülebilirlik açısından soru işaretleri doğurmaktadır. Özellikle su kıtlığı yaşanan bölgelerde elektroliz için gereken su miktarı önemli bir sorun olabilir (Du vd., 2024).
- Uluslararası düzenlemelerin eksikliği: Uluslararası hidrojen üretimi ve taşımacılığı için yeterli düzenleme ve standartların olmaması, yeşil hidrojen projelerinin gelişmesini zorlaştıran bir başka etkidir (Jayachandran vd., 2024).
- Düşük sistem verimliliği ve hammadde zorlukları: Elektrolizörlerde kullanılan pahalı katalizörler, yüksek saflıkta hammadde gerekliliği ve bu hammaddelerin saflaştırma zorlukları da önemli maliyet faktörleridir (Kumar vd., 2024).

Gri hidrojen:

- Enerji verimliliği: Fosil yakıtlardan elde edilen gri hidrojenin üretim süreçlerinde enerji yoğunudur ve yüksek karbon emisyonlarına yol açarak çevresel ve ekonomik olumsuz etkilere neden olmaktadır (Ajanovic vd., 2022).

Bu zorluklara rağmen, hidrojen üretiminde maliyetlerin düşürülmesi, çevresel etkilerin minimize edilmesi ve enerji verimliliğinin artırılması amacıyla geniş çaplı Ar-Ge çalışmaları devam etmektedir. Bu araştırmalar, hidrojenin sürdürülebilir ve uygun maliyetli bir enerji kaynağı olarak ölçeklenebilir hale gelmesi için kritik öneme sahiptir.

Hidrojen Ne Kadar Güvenlidir?

Hidrojen havadan çok daha hafif ve toksik olmayan kimyasal bir elementtir. Hafif olması nedeniyle salındığında hızla dağılır, bu da sızıntı durumunda yakıtın hızlı bir şekilde dağılmasına sebep olmaktadır. Toksik olmadığı için sızıntı yapan diğer gazlara nispeten daha güvenli olarak değerlendirilmektedir. Ancak hidrojen kullanımında en temel güvenlik endişesi, sızıntının fark edilememesi durumunda gazın sıkışık bir alan içinde birikmesi ve nihayetinde ateş alarak bir patlamaya sebebiyet vermesidir (Li vd., 2022). Çünkü hidrojen son derece yanıcıdır ve kolaylıkla tutuşabilir. Bu bağlamda güvenli kullanım için depolanması, sızıntıların önlenmesi ve risklerin minimuma indirilmesi için özel ekipman ve prosedürler gerekmektedir. Depolama ve işleme alanında çalışacak personelin yeterli donanıma sahip olmaları da güvenlik açısından oldukça elzemdir. Hidrojenin hava içerisinde %4 -%75 gibi geniş bir yanıcı konsantrasyon aralığına sahip olması ve benzinin ateşlenmesi için gereken enerjinin onda biri kadar düşük bir ateşleme enerjisi ile alevlenmesi bu alandaki güvenlik tedbirlerinin önemini açıkça göstermektedir. Ayrıca nakliye güvenliği konusu da hidrojenin uzun mesafelerde güvenli bir şekilde taşınması, düşük enerji yoğunluğu ve özel konteynerlere veya boru hatlarına ihtiyaç duyulması nedeniyle çeşitli tedbirler gerektirmektedir. Hidrojenin metalleri gevrekletirebilir yapısı ekipman ve altyapının yapısal bütünlüğünde sorunlara neden olabilir ve ayrıca bir güvenlik riski oluşturabilir. Oluşabilecek olumsuz durumların önlenmesi için hem halkın hem de hidrojen endüstrisinde çalışanların konuyla ilişkili güvenlik risklerinin farkında olması ve uygun şekilde kullanımı konusunda eğitilmesi önemlidir.

Hidrojen enerji geleceği için umut verici bir yaklaşım olsa da endüstride geniş kabul görmesi ve başarısı için güvenlik sorunlarının etkin bir şekilde ele alınması kritik önem taşımaktadır. Bu zorlukların üstesinden gelmek ve hidrojenin temiz bir enerji taşıyıcısı olarak tüm potansiyeli ile kullanımını gerçekleştirmek için hükümetler, endüstri ve araştırma enstitüleri arasındaki iş birliği zorunludur. Yeterli ve gerekli tedbirler alındığında, hidrojen de diğer yaygın kullanılan yakıtlar kadar güvenli bir enerji taşıyıcısı olabilir. Ayrıca, teknolojik gelişmeler ve deneyim arttıkça, hidrojen güvenliği konusundaki bilgi ve güven de artmaktadır.

Hidrojenin Uygulamaları

Hidrojen çoğunlukla petrol endüstrisinde ya petrol işleme ya da petrokimyasal üretim için bir reaktan olarak kullanılmaktadır. Petrol işleme için, hidrojen katalizör varlığında hidrokarbon ile reaksiyona sokulur, bu işlem hidroişlem (veya hydrocracking) olarak adlandırılır. Hidroişleme, ürünlerdeki sülfür ve azot bileşiklerinin kolayca

uzaklaştırılması için amonyak ve hidrojen sülfüre hidrojenize edilmesi amacıyla hidrojenin kullanıldığı bir süreçtir. Petrokimyasal üretimde ise hidrojen, yüksek basınç ve sıcaklıkta katalizör eşliğinde metanol üretmek için karbon monoksit ile reaksiyona sokulur. Bunun yanı sıra, hidrojenin reaktan olarak kullanıldığı bir diğer süreç ise gübre için amonyak üretimidir. Amonyak, gübre üretiminde kullanılan ana ham maddeler olduğundan dünya genelinde üretilen hidrojenin yaklaşık %50'sini tüketmektedir. Hidrojenin en önemli uygulamalarından bir diğeri de yakıt olarak kullanılabilmesidir. Bu anlamda ilk akla gelen kullanım alanı havacılık ve uzay endüstrisidir. Öte yandan, yakıt hücreleri aracılığıyla otomobillerde de kullanımı hızla yaygınlaşmaktadır. Tablo 2'de hidrojenin farklı endüstrilerdeki kullanım alanları verilmektedir (Abdalla vd., 2018). Günümüzde hidrojenin yakıt olarak kullanımında karşılaşılan en büyük zorluk, diğer gazları işleme ve depolama maliyetlerine kıyasla, hidrojenin mevcut maliyetinin yüksek olmasıdır.

Tablo 2. Hidrojenin Farklı Endüstrilerdeki Kullanımı

Endüstri türü	Kullanımı
Petrol	<ul style="list-style-type: none">✓ Sülfür ve diğer safsızlıkların giderilmesi✓ Büyük hidrokarbonların yakıt distilatlarına hidrokrankı
Kimyasal	<ul style="list-style-type: none">✓ Amonyak, metanol vb. sentezi
Gıda	<ul style="list-style-type: none">✓ Şekerlerin poliollere dönüşümü✓ Yenilebilir yağların hızlı dönüşümü✓ Don yağı veya gresin hayvan yemine dönüştürülmesi
Plastik	<ul style="list-style-type: none">✓ Naylon, poliüretan, poliestere, poliolefin sentezi✓ Geri dönüştürülebilir daha hafif moleküller üretmek için kullanılmış plastiklerin kırılması (cracking)
Metaller	<ul style="list-style-type: none">✓ O₂ tutucu✓ Demir, magnezyum, molibden vb. üretimi için indirgeyici✓ Sünekliği ve işleme kalitesini iyileştirmek, gerilimi azaltmak, sertleştirmek, gerilme mukavemetini artırmak, manyetik veya elektriksel özellikleri değiştirmek için ısıtma işlemi
Elektronik	<ul style="list-style-type: none">✓ Polisilikonun "Epitaksiyel" büyümesi✓ Vakum tüpleri imalatı✓ Isıl bağlayıcı malzemeler
Cam	<ul style="list-style-type: none">✓ Yüksek sıcaklık kesme hamlacı✓ Cam cilalama✓ Optik fiberlerin ısıtma işlemleri✓ Float-cam prosesi için indirgeyici ortam
Elektrik enerjisi	<ul style="list-style-type: none">✓ Büyük motor jeneratörleri için soğutma sıvısı✓ Nükleer yakıt işleme

Hidrojen günümüzde endüstriyel olarak enerjiden ziyade kimyasal bir malzeme olarak kullanılmaktadır. Hidrojenin enerji olarak kullanılabilmesi en önemli uygulama alanlarına hidrojenle çalışan otomobiller, otobüsler (Honda, Toyota ve BMW), denizaltıları ve gemiler (Hamburg, Almanya'daki feribotlar) örnek verilebilir (Abdalla vd., 2018; Das vd., 2021).

Hidrojen Ekonomisi için Küresel Vizyon ve Hedefler

Hidrojen ekonomisi, gelecekte hidrojenin birincil enerji taşıyıcısı haline geldiği varsayımsal bir ekonomik sistemi ifade etmektedir (Mosca vd., 2020; Megia vd., 2021). Bu öngörülen sistemde hidrojen, ulaşım, sanayi ve enerji üretimi gibi çeşitli sektörlerdeki enerji ihtiyaçlarının karşılanmasında önemli rol oynamaktadır (Megia vd., 2021). Ayrıca bu sistemde temiz ve çok yönlü bir enerji taşıyıcısı olarak hidrojenin üretimi, dağıtımı ve kullanımı etraflıca değerlendirilmektedir. Bu anlamda, önde gelen ülkelerin vizyon ve hedefleri ele alındığında önemli projelerin ve yatırımların yürütülmekte olduğu görülmektedir (Suwidji vd., 2020). Örneğin, Mart 2022'de Avrupa Komisyonu üye ülkeleri, 2030 yılına kadar fosil yakıt kullanımını durdurmak için 10 milyon ton hidrojen üretimi ve 10 milyon ton

yeşil hidrojen ithalatını hedefleyen “REPowerEU Planı”nı yayınlamıştır. Bu plan kapsamında, Avrupa Birliği’nin (AB) hedefleri revize edilerek 2030 yılına kadar kurulu elektrolizör kapasitesinin 65-80 GW’a çıkarılması planlanmaktadır. Bunun yanı sıra, AB’nin uzun vadeli planlarında, Avrupa’nın enerji tüketimindeki hidrojen payının 2050’ye kadar %13-14’e çıkarmayı hedeflediği görülmektedir. Tablo 3’te bazı ülkelerdeki yakın gelecek için belirledikleri elektrolizör kapasite hedefleri özetlenmektedir (ETKB, 2023).

Tablo 3. Bazı Ülkelerin Elektrolizör Kapasite Hedefleri

Ülkeler	Hedefler
Almanya	Elektrolizör kapasitesi hedefi 2030 yılı için 10 GW’tır. Bu elektrolizör kapasitesini desteklemek için 20 TWh yenilenebilir enerji kaynağına (çoğunlukla rüzgâr) ihtiyaç bulunmaktadır. Ayrıca, toplam 29 MW kurulu güce sahip 34 gazdan elektrik üreten (G-T) tesis bulunmaktadır.
İngiltere	Bu kapsamda 2030 yılına kadar 10 GW düşük karbonlu hidrojen üretimi hedefi belirlemiş olup, bunun en az yarısının elektrolit hidrojen olması planlanmaktadır.
İspanya	Elektrolizör kapasitesi hedefi 2030 yılı için 4 GW’tır.
Hollanda	2030 yılına kadar 3-4 GW’lık bir elektrolizör kapasitesi geliştirmeyi hedeflemektedir. Ayrıca 50 hidrojen dolum istasyonu kurmaya, 15000 yakıt hücreli otomobil ile 3000 yakıt hücreli kamyonu kullanıma sokmayı planlamaktadır.
Fransa	Elektrolizör kapasitesi hedefi 2030 yılı için 6,5 GW’tır. 2020 yılı itibarıyla gri hidrojene 44,6 €/tonCO ₂ karbon vergisi uygulanmaktadır. Bu karbon vergisinin 2030 yılında 100 €/tonCO ₂ ’ya çıkarılması öngörülmektedir.
Diğer Avrupa Ülkeleri	AB ülkelerinin 2030 yılına kadar kurulu elektrolizör kapasitesi hedefi 65-80 GW’tır. Danimarka 4-6 GW, İtalya 5 GW, İsveç 5 GW, Portekiz 2-2,5 GW ve Polonya 2 GW elektrolizör kapasitesi hedefi belirlemiştir.
Avustralya	Planlanan projelere dayanarak 2030 yılına kadar yaklaşık 50 GW’lık bir elektrolizör kapasitesine ulaşılması beklenmektedir. Çin, Japonya, Güney Kore ve Singapur ile anlaşmalar yapılmış olup, ihracatın 2030 yılına kadar 3,8 Mt hidrojene (yaklaşık 9,5 milyar Avustralya doları) ulaşması planlanmaktadır.
Türkiye	Elektrolizör kapasitesinin 2035 yılına kadar 5 GW’a ulaşması hedeflenmektedir.

Türkiye, AB’nin altıncı büyük ticaret ortağı ve küresel yenilenebilir enerji arenasında dikkate değer bir oyuncu olması nedeniyle, bu tür hedeflerle başa çıkabilmesi için hidrojen teknolojileri alanında net bir ulusal strateji ortaya koymalı, bu teknolojilerde yetkinlik kazanmalı ve küresel düzeyde rekabetçi bir oyuncu olmalıdır. Bu anlamda, 4 Eylül 2022 tarihli 31943 sayılı Resmî Gazete’de yayımlanan “Orta Vadeli Program (2023-2025)” kapsamında verimli ve rekabetçi yeşil dönüşüm politikalarına uygun olarak 2053 net sıfır emisyon hedeflerine ulaşmak için tüm sektörlerde gerekli adımların atılacağı vurgulanmaktadır (ETKB, 2023).

Türkiye’nin Hidrojen Teknolojileri Açısından İhtiyaçları ve Bu İhtiyaçları Karşılacak Teknolojik/Destekleyici Çözümler

Türkiye, enerji üretimi alanında fosil yakıt ithalatına yüksek derecede bağımlı olsa da son on yılda hidroelektrik, güneş ve rüzgâr enerjisi temelli yenilenebilir elektrik üretimini iki katına çıkarmış bulunmaktadır. Türkiye’nin güneş ve rüzgâr enerjisindeki mevcut potansiyeli göz önünde bulundurulduğunda yenilenebilir enerjide daha fazla büyüme elde edeceği de açıktır. Dolayısıyla, bu yenilenebilir enerji kaynakları yardımıyla üretilecek yeşil hidrojen, enerji arz güvenliği, çevresel sürdürülebilirlik ve yaşam kalitesinin artırılması yönünde belirlenen hedeflere ulaşmayı sağlayacaktır. Ancak, bu yenilenebilir enerji kaynaklarının kesintili olması nedeniyle enerji depolama konusu hem teknik hem de ekonomik nedenlerle zorunlu bir ihtiyaç olarak görülmektedir. Bu anlamda, bütüncül bir hidrojen ekosistemi kurulmasına yönelik ihtiyaçların belirlenmesi ve bu ihtiyaçları karşılayacak teknolojik/destekleyici çözümlerin geliştirilmesi güçlü bir Türkiye için hayati önem arz etmektedir. Enerji ve Tabii Kaynaklar Bakanlığı (ETKB) tarafından hazırlanan “Türkiye Hidrojen Teknolojileri Stratejisi ve Yol Haritası” raporunda bu ihtiyaç ve

teknolojik/destekleyici çözümler yirmi maddede kapsamlı olarak belirtilmektedir (ETKB, 2023). Bu yol haritasının hayata geçirilmesi, Türkiye'nin sürdürülebilir enerji alanında liderlik yapmasına olanak tanıyacak ve ülkeyi gelecekteki enerji zorluklarına karşı koruyacaktır.

ÖNERİ VE SONUÇLAR

Hidrojen, küresel enerji ve endüstri sektörlerinin dekarbonizasyonunu desteklemek amacıyla ortaya çıkan bir enerji taşıyıcısıdır. Enerji sektöründeki önemi ve avantajları, temiz ve sürdürülebilir bir enerji geleceği için kilit bir rol oynamaktadır. Hidrojenin üretimi, özellikle yeşil hidrojen üretimi (yenilenebilir enerji kaynaklarına dayalı elektroliz yöntemleriyle) karbon emisyonlarını en aza indirerek çevre dostu bir seçenek sunmaktadır. Ancak, hidrojenin yaygın kullanımı ve entegrasyonu bazı zorluklarla karşılaşmaktadır. Depolama, taşıma ve kullanım altyapısını geliştirilmesi, ekonomik üretim yöntemlerinin bulunması ve güvenlik konuları gibi faktörler, hidrojenin küresel anlamda yaygın bir şekilde benimsenmesini etkileyen önemli faktörlerdir. Bu bağlamda, ülkelerin kendi enerji dönüşüm yol haritalarını oluşturarak, hidrojenin entegrasyonunu teşvik etmeleri ve teknolojik gelişmelere yatırım yapmaları önemlidir. Yeşil hidrojenin üretim maliyetinin düşürülmesi, depolama ve taşıma altyapısının güçlendirilmesi, endüstriyel sektörlerde hidrojenin kullanımının teşvik edilmesi gibi adımlar, küresel ölçekte temiz enerji dönüşümüne katkı sağlayacaktır.

Yazar Katkısı

Çalışmanın tamamı yazarlar tarafından eşit katkı sağlanarak yapılmıştır.

Etik Beyanı

Bu makalenin yazarları, bu çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel izin gerektirmediğini beyan etmektedir.

Çıkar Çatışması Beyanı

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan etmektedir.

KAYNAKLAR

Abad, A. V., & Dodds, P. E. (2020). Green hydrogen characterisation initiatives: Definitions, standards, guarantees of origin, and challenge. *Energy Policy*, 138, 111300. <https://doi.org/10.1016/j.enpol.2020.111300>

Abdalla, A. M., Hossain, S., Nisfindy, O. B., Azad, A. T., Dawood, M., & Azad, A. K. (2018). Hydrogen production, storage, transportation and key challenges with applications: A review. *Energy Conversion and Management*, 165, 602-627. <https://doi.org/10.1016/j.enconman.2018.03.088>

Acar, C., & Dincer, I. (2019). Review and evaluation of hydrogen production options for better environment. *Journal of Cleaner Production*, 218, 835-849. <https://doi.org/10.1016/j.jclepro.2019.02.046>

Ajanovic, A., Sayer, M., Haas, R. (2022). The economics and the environmental benignity of different colors of hydrogen. *International Journal of Hydrogen Energy*, 47, 5, 24136-24154. <https://doi.org/10.1016/j.ijhydene.2022.02.094>

Al-Qahtani, A., Parkinson, B., Hellgardt, K., Shah, N., & Guillen-Gosalbez, G. (2021). Uncovering the true cost of hydrogen production routes using life cycle monetisation. *Applied Energy*, 281, 115958. <https://doi.org/10.1016/j.apenergy.2020.115958>

Benghanem, M., Mellit, A., Almohamadi, H., Haddad, S., Chettibi, N., Alanazi, A. M., Dasalla, D., & Alzahrani, A. (2023). Hydrogen Production Methods Based on Solar and Wind Energy: A Review. *Energies*, 16(2), 757. <https://doi.org/10.3390/en16020757>

BloombergNEF. (2020). Hydrogen Economy Outlook. Key messages March 30. <https://data.bloomberglp.com/professional/sites/24/BNEF-Hydrogen-Economy-Outlook-Key-Messages-30-Mar-2020.pdf> Available online:19/11/2023.

Capurso, T., Stefanizzi, M., Torresi, M., & Camporeale, S.M. (2022). Perspective of the role of hydrogen in the 21st century energy transition. *Energy Conversion and Management*, 251, 114898. <https://doi.org/10.1016/j.enconman.2021.114898>

- Coleman, D., Kopp, M., Wagner, T., & Scheppat B. (2020). The value chain of green hydrogen for fuel cell buses – a case study for the Rhine-Main area in Germany. *International Journal of Hydrogen Energy*, 45(8), 5122-5133. <https://doi.org/10.1016/j.ijhydene.2019.06.163>
- Das, E., Gürsel, S.A., & Yurtcan, A. B. (2021). Simultaneously deposited Pt-alloy nanoparticles over graphene nanoplatelets via supercritical carbon dioxide deposition for PEM fuel cells. *Journal of Alloys and Compounds*, 874, 159919. <https://doi.org/10.1016/j.jallcom.2021.159919>
- Dash, S. K., Chakraborty, S., & Elangovan, D. (2023). A brief review of hydrogen production methods and their challenges. *Energies*, 16, 1141. <https://doi.org/10.3390/en16031141>
- Dawood, F., Anda, M., & Shafiullah, G. M. (2023). Hydrogen production for energy: An overview. *International Journal of Hydrogen Energy*, 45, 3847-3869. <https://doi.org/10.1016/j.ijhydene.2019.12.059>
- Diab, J., Fulcheri, L., Hessel, V., Rohani, V., & Frenklach, M. (2022). Why turquoise hydrogen will be a game changer for the energy transition. *International Journal of Hydrogen Energy*, 47(61), 25831-25848. <https://doi.org/10.1016/j.ijhydene.2022.05.299>
- Du, L., Yang, Y., Bai, X., Xu, S., Lin, L., & Liu, M. (2024). Water scarcity footprint and water saving potential for large-scale green hydrogen generation: Evidence from coal-to-hydrogen substitution in China. *Science of The Total Environment*, 940, 173589. <https://doi.org/10.1016/j.scitotenv.2024.173589>.
- El-Emam, R., & Özcan, H. (2019). Comprehensive review on the techno-economics of sustainable large-scale clean hydrogen production. *Journal of Cleaner Production*, 220, 593-609. <https://doi.org/10.1016/j.jclepro.2019.01.309>
- Elshafei, A. M., & Mansour, R. (2023). Green hydrogen as a potential solution for reducing carbon emission: A review. *Journal of Energy Research and Reviews*, 13(2), 1-10. <https://doi.org/10.9734/jenrr/2023/v13i2257>
- ETKB. (2023). Türkiye hidrojen teknolojileri stratejisi ve yol haritası. T.C. Enerji ve Tabii Kaynakları Bakanlığı. https://enerji.gov.tr/Media/Dizin/SGB/tr/Kurumsal_Politikalar/HSP/ETKB_Hidrojen_Stratejik_Plan2023.pdf
- European Commission. (2020). Communication from the Commission to the European Parliament, the Council, the European Economic and Social Committee and the Committee of the Regions: A hydrogen strategy for a climate-neutral Europe 2020.
- Farrell, N. (2023). Policy design for green hydrogen. *Renewable and Sustainable Energy Reviews*, 178, 113216. <https://doi.org/10.1016/j.rser.2023.113216>.
- Han W-B et al (2021). Directly sputtered nickel electrodes for alkaline water electrolysis. *Electrochimica Acta*, 386, 138458. <https://doi.org/10.1016/j.electacta.2021.138458>
- Hanusch, F., & Schad, M. (2021). Hydrogen research: Technology first, society second? *GAIA-Ecological Perspectives for Science and Society*, 30, 82. Erişim tarihi: 19/11/2023
- Howaniec, N., & Smoliński, A. (2014). Effect of fuel blend composition on the efficiency of hydrogen-rich gas production in co-gasification of coal and biomass. *Fuel*, 128, 442-450. <https://doi.org/10.1016/j.fuel.2014.03.036>
- Huang, Y., Zhou, Y., Zhong, R., Wei, C., & Zhu, B. (2024). Hydrogen energy development in China: Potential assessment and policy implications. *International Journal of Hydrogen Energy*, 49, 659-669. <https://doi.org/10.1016/j.ijhydene.2023.10.176>
- Hydrogen Insights 2022: An updated perspective on hydrogen market development and actions required to unlock hydrogen at scale, Hydrogen Council and McKinsey & Company, 2022. Erişim tarihi: 19/11/2023
- IEA. (2022a). Opportunities for Hydrogen Production with CCUS in China. International Energy Agency, Paris. Erişim tarihi: 19/11/2023
- IEA. (2022b). Global Hydrogen Review, IEA, Paris. Erişim tarihi: 19/11/2023
- Irena. (2019). Hydrogen: a renewable energy perspective. Report prepared for the 2nd Hydrogen Energy Ministerial Meeting in Tokyo, Japan. https://www.irena.org/-/media/Files/IRENA/Agency/Publication/2019/Sep/IRENA_Hydrogen_2019.pdf

- Ishaq, H., & Dincer, I. (2020). The role of hydrogen in the global transition to 100% renewable energy. In *Accelerating the Transition to a 100% Renewable Energy Era* (pp. 275-307). Springer Nature Switzerland AG. https://doi.org/10.1007/978-3-030-40738-4_13
- Ishaq, H., & Dincer, I. (2021). Comparative assessment of renewable energy-based hydrogen production methods. *Renewable and Sustainable Energy Reviews*, 135, 110192. <https://doi.org/10.1016/j.rser.2020.110192>
- Ishaq, H., Dincer, I., & Crawford, C. (2022). A review on hydrogen production and utilization: Challenges and opportunities. *International Journal of Hydrogen Energy*, 47(62), 26238-26264. <https://doi.org/10.1016/j.ijhydene.2021.11.149>
- Jayachandran, M., Gatla, R. K., Flah, A., A., Milyani, A. H., Milyani, H. M., Blazek, V., ... Kraiem, H. (2024). Challenges and Opportunities in Green Hydrogen Adoption for Decarbonizing Hard-to-Abate Industries: A Comprehensive Review. *IEEE Access*, 12, 23363-23388. <https://doi.org/10.1109/access.2024.3363869>
- Kumar, R., Singh, R., & Dutta, S. (2024). Review and Outlook of Hydrogen Production through Catalytic Processes. *Energy Fuels*, 34 (4), 2601-2629. <https://doi.org/10.1021/acs.energyfuels.3c04026>
- Kumar, S. S., & Lim, H. (2022). An overview of water electrolysis technologies for green hydrogen production. *Energy Reports*, 8, 13793-13813. <https://doi.org/10.1016/j.egyr.2022.10.127>
- Li, H., Cao, X., Liu, Y., Shao, Y., Nan, Z., Teng, L., Peng, W., & Bian, J. (2022). Safety of hydrogen storage and transportation: An overview on mechanisms, techniques, and challenges. *Energy Reports*, 8, 6258-6269. <https://doi.org/10.1016/j.egyr.2022.04.067>
- Liu, B., Liu, S., Guo, S., & Zhang, S. (2020). Economic study of a large-scale renewable hydrogen application utilizing surplus renewable energy and natural gas pipeline transportation in China. *International Journal of Hydrogen Energy*, 45(3), 1385-1398. <https://doi.org/10.1016/j.ijhydene.2019.11.056>
- Megia, P. J., Vizcaino, A. J., Calles, J. A., & Carrero, A. (2021). Hydrogen Production Technologies: From Fossil Fuels toward Renewable Sources. A Mini Review. *Energy Fuels*, 35, 16403-16415. <https://doi.org/10.1021/acs.energyfuels.1c02501>
- Mosca, L., Jimenez, J. A. M., Wassie, S. A., Gallucci, F., Palo, E., Colozzi, M., Taraschi, S., & Galdieri, G. (2020). Process design for green hydrogen production. *International Journal of Hydrogen Energy*, 45(12), 7266-7277. <https://doi.org/10.1016/j.ijhydene.2019.08.206>
- Newborough, M., & Cooley, G. (2020). Developments in the global hydrogen market: The spectrum of hydrogen colours. *Fuel Cells Bulletin*, 2020, 16-22. [https://doi.org/10.1016/S1464-2859\(20\)30546-0](https://doi.org/10.1016/S1464-2859(20)30546-0)
- Nicita, A., Maggio, G., Andaloro, A. P. F., & Squadrito, G. (2020). Green hydrogen as feedstock: Financial analysis of a photovoltaic-powered electrolysis plant. *International Journal of Hydrogen Energy*, 45(20), 11395-11408. <https://doi.org/10.1016/j.ijhydene.2020.02.062>
- Noussan, M., Raimondi, P.P., Scita, R., & Hafner, M. (2021). The Role of Green and Blue Hydrogen in the Energy Transition: A Technological and Geopolitical Perspective. *Sustainability*, 13, 298. <https://doi.org/10.3390/su13010298>
- Osman, A.I., Mehta, N., Elgarahy, A. M., Hefny, M., Hinai, A. A., Muhtaseb A. A., & Roney, D. W. (2022). Hydrogen production, storage, utilisation and environmental impacts: a review. *Environmental Chemistry Letters*, 20, 153-188. <https://doi.org/10.1007/s10311-021-01322-8>
- Öner, E. T., & Yurtcan, A. B. (2023). Clean and Efficient Transportation with Hydrogen Fuel Cell Electric Vehicles. In *Hydrogen Fuel Cell Technology for Mobile Applications* (pp. 32-58). IGI Global.
- Pinsky, R., Sabharwall, P., Hartvigsen, J., & O'Brien, J. (2020). Comparative review of hydrogen production technologies for nuclear hybrid energy systems. *Progress in Nuclear Energy*, 123, 103317. <https://doi.org/10.1016/j.pnucene.2020.103317>
- Q. Hassan, I.S. Abdulrahman, H.M. Salman, O.T. Olapade, & M. Jaszczur. (2023). Techno-economic assessment of green hydrogen production by an off-grid photovoltaic energy system. *Energies*, 16(2), 744. <https://doi.org/10.3390/en16020744>

- Sadeq, A. M., Homod, R. Z., Hussein, A. K., Togun, H., Mahmoodi, A., Isleem, H. F., ... & Moghaddam, A. H. (2024). Hydrogen energy systems: Technologies, trends, and future prospects. *Science of The Total Environment*, 173622. <https://doi.org/10.1016/j.scitotenv.2024.173622>
- Sarker, A.K., Azad, A.K., Rasul, M.G., & Doppalapudi, A.T. (2023). Prospect of Green Hydrogen Generation from Hybrid Renewable Energy Sources: A Review. *Energies*, 16, 1556. <https://doi.org/10.3390/en16031556>
- Schneider, S., Bajohr, S., Graf, F., & Kolb, T. (2020). State of the art of hydrogen production via pyrolysis of natural gas. *Chemical and Biological Engineering Reviews*, 7, 150–158. <https://doi.org/10.1002/cben.202000014>
- Song, C., Liu, Q., Ji, N., Kansha, Y., & Tsutsumi, A. (2015). Optimization of steam methane reforming coupled with pressure swing adsorption hydrogen production process by heat integration. *Applied energy*, 154, 392-401. <https://doi.org/10.1016/j.apenergy.2015.05.038>
- Sukpancharoen, S., & Phetyim, N. (2021). Green hydrogen and electrical power production through the integration of CO₂ capturing from biogas: Process optimization and dynamic control. *Energy Reports*, 7(Supplement 3), 293-307. <https://doi.org/10.1016/j.egy.2021.06.048>
- Suwidji, P., Chung, H. Y., & Ng, Y. H. (2020). Progress in practical hydrogen production and utilization in East Asia. *The Hong Kong Institution of Engineers*, 28(2), 88-101. <https://doi.org/10.33430/V28N2THIE-2020-0047>
- Vallejos-Romero, A., Cordoves-Sanchez, M., Cisternas, C., Saez-Ardura, F., Rodriguez, I., Aledo, A., Boso, A., Prades, J., & Alvarez, B. (2022). Green Hydrogen and Social Sciences: Issues, Problems, and Future Challenges. *Sustainability*, 15(1), 303. <https://doi.org/10.3390/su15010303>
- Vidas, L., & Castro, R. (2021). Recent Developments on Hydrogen Production Technologies: State-of-the-Art Review with a Focus on Green-Electrolysis. *Applied Sciences*, 11, 11363. <https://doi.org/10.3390/app112311363>
- Wu, N., Lan, K., & Yao, Y. (2023). An Integrated Techno-Economic and Environmental Assessment for Carbon Capture in Hydrogen Production by Biomass Gasification. *Resources, Conservation and Recycling*, 188, 106693. <https://doi.org/10.1016/j.resconrec.2022.106693>
- Yu, M., Wang, K., & Vredenburg, H. (2021). Insights into low-carbon hydrogen production methods: Green, blue and aqua hydrogen. *International Journal of Hydrogen Energy*, 46(41), 21261-21273. <https://doi.org/10.1016/j.ijhydene.2021.04.016>
- Zhang, L., Jia, C., Bai, F., Wang, W., An, S., Zhao, K., ... & Sun, H. (2024). A comprehensive review of the promising clean energy carrier: Hydrogen production, transportation, storage, and utilization (HPTSU) technologies. *Fuel*, 355, 129455. <https://doi.org/10.1016/j.fuel.2023.129455>
- Zhiznin, S.Z., Timokhov, V.M., & Gusev, A.L. (2020). Economic aspects of nuclear and hydrogen energy in the world and Russia. *International Journal of Hydrogen Energy*, 45, 31353–31366. <https://doi.org/10.1016/j.ijhydene.2020.08.260>
- Zohuri, B. (2016). *Hydrogen Energy: Challenges and Solutions for a Cleaner Future*. Springer Book. <https://doi.org/10.1007/978-3-319-93461-7>.



Kahramanmaraş Sütçü İmam University

Journal of Engineering Sciences



Geliş Tarihi : 03.12.2024
Kabul Tarihi : 27.12.2024

Received Date : 03.12.2024
Accepted Date : 27.12.2024

A LITERATURE REVIEW OF LASER ENGINEERED NET SHAPING IN ADDITIVE MANUFACTURING USING ARTIFICIAL NEURAL NETWORKS

YAPAY SİNİR AĞLARI KULLANILARAK KATMANLI ÜRETİMDE LAZERLE TASARLANMIŞ AĞ ŞEKİLLENDİRME ÜZERİNE BİR LİTERATÜR İNCELEMESİ

Filiz KARAOMERLIOGLU^{1,2*} (ORCID: 0000-0002-4677-4365)
Mustafa UCAR² (ORCID: 0000-0002-1851-2317)

¹Department of Electrical Electronics Engineering, Mersin University, Mersin, Turkey
²Department of Nanotechnology and Advanced Materials, Mersin University, Mersin, Turkey

*Sorumlu Yazar / Corresponding Author: Filiz KARAOMERLIOGLU, filizkrm@mersin.edu.tr

ABSTRACT

This review explores the integration of machine learning (ML) and artificial neural networks (ANNs) in optimizing alloy production modeling and print control within Laser Engineered Net Shaping (LENS), a key additive manufacturing process. It investigates theoretical foundations, methodologies, case studies, and emerging trends to enhance process efficiency, improve product quality, and accelerate production cycles. A comprehensive literature review was conducted across academic databases and industry reports using keywords such as “machine learning,” “artificial neural networks,” and “Laser Engineered Net Shaping.” Both theoretical and experimental perspectives were analyzed to provide a well-rounded discussion. Findings indicate that ML and ANN models enhance understanding of alloy production, optimizing configurations and reducing defects. Real-time ML-driven optimization enables adaptive adjustments to process parameters, ensuring improved quality and accuracy. ANNs effectively predict key alloy microstructure properties, supporting informed decision-making and process refinement. Integrating ML and ANNs into LENS facilitates adaptive manufacturing, dynamically responding to changing conditions and alloy compositions.

Keywords: Artificial neural networks, laser engineered net shaping, 3d print control, process optimization

ÖZET

Bu derleme, makine öğrenimi (ML) ve yapay sinir ağlarının (YSA), önemli bir eklemeli üretim süreci olan Laser Engineered Net Shaping (LENS) içinde alaşım üretim modellemesi ve baskı kontrolünü optimize etmek amacıyla entegrasyonunu incelemektedir. Süreç verimliliğini artırmak, ürün kalitesini iyileştirmek ve üretim döngülerini hızlandırmak için teorik temeller, metodolojiler, vaka çalışmaları ve yeni ortaya çıkan trendler araştırılmıştır. Akademik veri tabanları ve endüstri raporları üzerinde kapsamlı bir literatür taraması gerçekleştirilmiş, “makine öğrenimi”, “yapay sinir ağları” ve “Laser Engineered Net Shaping” gibi anahtar kelimeler kullanılmıştır. Konuya dengeli bir bakış açısı sunmak amacıyla hem teorik hem de deneysel çalışmalar analiz edilmiştir. Bulgular, ML ve YSA modellerinin alaşım üretim süreçlerini daha iyi anlamayı sağladığını, konfigürasyonları optimize ettiğini ve kusurları azalttığını göstermektedir. Gerçek zamanlı ML tabanlı optimizasyon, işlem parametrelerinin adaptif olarak ayarlanmasını sağlayarak kaliteyi ve doğruluğu artırır. YSA'lar, alaşım mikro yapısına ilişkin temel özellikleri başarılı bir şekilde tahmin ederek bilinçli karar alma ve süreç iyileştirmeye katkıda bulunur. ML ve YSA'ların LENS'e entegrasyonu, değişen koşullara ve alaşım bileşimlerine dinamik olarak uyum sağlayan adaptif üretimi mümkün kılar.

Anahtar Kelimeler: Yapay sinir ağları, lazerle tasarlanmış net şekillendirme, 3d baskı kontrolü, süreç optimizasyonu

ToCite: KARAOMERLIOGLU, F., & UCAR, M., (2025). A LITERATURE REVIEW OF LASER ENGINEERED NET SHAPING IN ADDITIVE MANUFACTURING USING ARTIFICIAL NEURAL NETWORKS. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 551-582.

INTRODUCTION

Additive manufacturing (AM), commonly referred to as 3D printing, has been experiencing a surge in popularity in recent years due to its numerous advantages over traditional manufacturing methods. Among the leading AM techniques, Laser Engineered Net Shaping stands out as a versatile tool capable of producing complex components with fine-tuned geometries for various industrial applications (Sames et al., 2016; Bennett et al., 2016; Gorunov, 2018). However, the quality of parts produced by LENS is strongly influenced by process parameters such as laser power, scanning speed, beam spot size and powder feed rate. If these parameters are not optimised, they can lead to defects such as porosity and cracks, causing problems with the mechanical properties and structural integrity of the final components (Grasso and Colosimo, 2017; Fu et al., 2016; Sterling et al., 2016).

Based on expertise and experience, traditional optimisation methods often struggle to provide a comprehensive understanding of the relationships between process parameters and part properties, given the inherent complexity of the AM process (Kumar et al., 2022).

The advent of machine learning techniques, in particular Artificial Neural Networks, offers a promising solution to overcome these challenges. ANNs excel at recognising complex patterns and developing deterministic relationships, thus eliminating the need for physical models. Unlike traditional approaches, machine learning-based optimisation facilitates decision-making processes, allowing informed choices to be made about critical factors such as component and support structure design.

The wide range of applications and increasing applicability of machine learning techniques, previously considered impractical, have facilitated their integration into the modern era. With its adoption in manufacturing, industries have started to use machine learning more frequently to realise economic benefits. Today, the manufacturing sector is undergoing significant transformations driven by smart manufacturing and Industry 4.0. Despite this progress, some sectors, especially mid and low-capitalisation companies, continue to show reluctance due to the costs associated with implementation and concerns about training.

Recent studies have shown the effectiveness of machine learning in optimizing AM process parameters and predicting the properties of printed parts. Chen et al. (2021) used machine learning to develop a model for predicting the porosity of LENS printed parts, while Zhang et al. (2021) and Yang et al. (2015) used machine learning to predict fatigue life and crack growth rate, respectively. These studies highlight the growing interest and potential of machine learning in improving the quality, reliability, and efficiency of the AM process.

This review paper aims to comprehensively analyse the current state-of-the-art machine learning-based optimisation of AM processes. By synthesising findings from various studies, it explores the benefits offered by these advanced techniques, including reduced manufacturing time and cost, improved part quality and reliability, improved support structure design and part orientation. The insights gained from this review will serve as valuable guidance for researchers and practitioners seeking to utilise machine learning to improve the efficiency, quality and sustainability of AM production.

RATIONALE

This study is needed to explore the application of machine learning (ML) and artificial neural networks (ANNs) to enhance alloy production modelling and print control within Laser Engineered Net Shaping (LENS), an additive manufacturing process. The objective is to investigate theoretical foundations, methodologies, case studies, and emerging trends in leveraging ML and ANNs to optimize process parameters, improve product quality, and accelerate production cycles in LENS technology.

THE AUDIENCE IT IS INTENDED FOR

The target audience for this study includes researchers, practitioners, and industry professionals interested in the application of machine learning and artificial neural networks to enhance alloy production modelling and print control within Laser Engineered Net Shaping (LENS), an additive manufacturing process. The study aims to provide valuable insights and guidance for those seeking to leverage ML and ANNs to optimize process parameters, improve product quality, and accelerate production cycles in LENS technology.

SURVEY METHODOLOGY

The objective of this survey is to provide a comprehensive overview of the current state of research on the integration of Machine Learning (ML) techniques in Additive Manufacturing (AM). To achieve this, a systematic approach was employed to gather, analyze, and synthesize relevant literature, ensuring an unbiased representation of the field.

LITERATURE SEARCH STRATEGY

A multi-faceted literature search strategy was implemented to identify pertinent studies. The following steps were undertaken:

Database Selection: Key academic databases were selected for the literature search, including IEEE Xplore, ScienceDirect, SpringerLink, Google Scholar, and Web of Science. These databases were chosen due to their extensive collections of peer-reviewed articles, conference papers, and technical reports relevant to both Machine Learning and Additive Manufacturing.

Keyword Identification: A comprehensive list of keywords and phrases was developed to capture the breadth of the topic. Keywords included “Machine Learning”, “Additive Manufacturing”, “3D printing”, “process optimization”, “quality control”, “intelligent manufacturing”, “artificial neural networks”, “Laser Engineered Net Shaping”, “alloy production modelling”, “3D print control”, “real-time monitoring”, “adaptive manufacturing” and “metal 3D printing”. Boolean operators (AND, OR) were utilized to refine the search results and ensure that relevant articles were not overlooked.

Inclusion and Exclusion Criteria: Clear inclusion and exclusion criteria were established to filter the literature. Studies were included if they:

- Focused on the application of Machine Learning techniques in Additive Manufacturing.
- Were published in peer-reviewed journals or reputable conference proceedings.
- Provided empirical data, case studies, or theoretical frameworks relevant to the topic.

Conversely, studies were excluded if they:

- Were not published in English.
- Focused on traditional manufacturing processes without an emphasis on Additive Manufacturing.
- Did not include a significant discussion of Machine Learning applications.

DATA EXTRACTION AND ANALYSIS

Systematic Review Process: The literature was reviewed systematically, with each study evaluated for its relevance, methodology, findings, and contributions to the field. A standardized data extraction form was used to capture key information from each article, including authorship, publication year, research focus, ML techniques employed, and outcomes related to AM.

Thematic Analysis: The extracted data were subjected to thematic analysis to identify common themes, trends, and gaps in the literature. This analysis facilitated the categorization of studies into various domains, such as process parameter optimization, quality control, material discovery, and predictive modeling.

Quality Assessment: To ensure the reliability and validity of the included studies, a quality assessment was conducted using established criteria, such as the rigor of the methodology, the robustness of the results, and the clarity of the conclusions. This assessment helped to mitigate bias and enhance the credibility of the survey findings.

ENSURING COMPREHENSIVE AND UNBIASED COVERAGE

To ensure comprehensive and unbiased coverage of the literature, several strategies were employed:

Diverse Sources: The literature search encompassed a wide range of sources, including journals from different disciplines (engineering, computer science, materials science) to capture interdisciplinary perspectives on the integration of ML in AM.

Timeframe Consideration: The search included both recent studies and seminal works in the field, allowing for a thorough understanding of the evolution of research on ML applications in AM.

Citation Tracking: The reference lists of key articles were examined to identify additional relevant studies that may not have been captured in the initial search. This snowballing technique helped to uncover influential works and ensure a more exhaustive literature review.

Expert Consultation: Feedback from academic peers and advisors with expertise in Machine Learning and Additive Manufacturing was sought to validate the relevance and comprehensiveness of the literature included in the survey.

ADDITIVE MANUFACTURING TECHNIQUES

ISO/ASTM 52900:2021, a comprehensive standard for additive manufacturing, categorises the various additive manufacturing techniques under 7 headings in alphabetical order in section "3.2 Process Categories". These categories cover a range of innovative processes that transform the production environment:

Binder Jetting (BJT) (Standard Heading No: 3.2.1): Binder Spraying involves the selective release of a liquid binder to join powder materials and offers a versatile approach to forming complex components.

Directed Energy Deposition (DED) (Standard Heading No: 3.2.2): Directed Energy Deposition utilises focused thermal energy, such as a laser or electron beam, to melt and fuse materials as they are deposited, enabling precise and efficient production.

Material Extrusion (MEX) (Standard Heading No: 3.2.3): Material Extrusion is a process in which material is selectively dispensed through a nozzle or orifice, allowing complex structures to be formed layer by layer.

Material Jetting (MJT) (Standard Heading No: 3.2.4): Material Spraying involves selectively depositing droplets of raw materials such as photopolymer resin and wax to form the desired object with high precision and detail.

Powder Bed Fusion (PBF) (Standard Heading No: 3.2.5): Powder bed fusion selectively fuses regions of a powder bed using thermal energy and offers a method for producing complex and functional parts with high accuracy.

Sheet Lamination (SHL) (Standard Heading No: 3.2.6): Sheet Lamination provides a cost-effective and efficient way to produce components with varying geometries by combining layers of material to form a part.

Vat Photopolymerisation (VPP) (Standard Heading No: 3.2.7): Vat Photopolymerisation involves the selective curing of liquid photopolymer in a container through light-activated polymerisation, enabling the creation of detailed and complex parts at high resolution.

These standardised processes play an important role in the development of additive manufacturing technologies, offering diverse capabilities to meet the evolving needs of modern manufacturing industries.

DIRECTED ENERGY DEPOSITION (DED)

Directed Energy Deposition (DED) is a revolutionary additive manufacturing process that harnesses the power of high-energy beams to precisely join metal powders or wires layer by layer on a substrate. This innovative technique has emerged as a game-changer in the manufacturing environment, offering unique capabilities in the production of complex parts with exceptional strength and surface quality.

Main features

Accelerated Deposition Speed: DED's ability to deposit material quickly allows for significant reductions in production time and costs, making it an attractive option for manufacturers looking to streamline their operations.

Unparalleled Geometric Complexity: The versatility of DED enables the creation of complex parts with features that are impossible or extremely challenging to produce using conventional manufacturing methods, opening up new possibilities for designers and engineers.

Improved Material Properties: The resulting parts exhibit superior strength and surface finish. This makes them ideal for applications where performance and reliability are paramount.

Material Diversity: DED's compatibility with a wide range of materials, including metals, composites and ceramics, expands its potential applications in various industries.

Industry applications

Aviation: DED is used in the production of critical aircraft components such as turbine blades, landing gear and structural components where high strength, low weight and precise surface finish are required.

Automotive: This technology is well suited to the production of complex automotive parts where high performance and durability are paramount, including engine blocks, transmission components and suspension parts.

Medical: DED is ideal for creating medical devices such as implants, prostheses and surgical instruments where biocompatibility, precision and surface quality are critical.

Benefits

Cost Savings: DED offers manufacturers significant cost-saving opportunities by enabling the production of complex parts with less material wastage and accelerated production cycles.

Improved Part Quality: The ability of the technology to produce parts with consistent properties, high strength and excellent surface quality ensures that the final product meets the highest quality and performance standards.

Freedom of Design: The capabilities of DED allow designers to push the boundaries of part design, creating complex geometries that are not possible or practical to produce by conventional methods.

Environmental Benefits: WIA contributes to a more sustainable production environment by reducing material wastage and energy consumption.

Challenges and limitations

Initial Investment Cost: The high cost of HIA equipment can be a significant barrier to entry for small businesses or start-ups.

Operator Training: The technology requires specialised training which may limit the availability of qualified operators.

Process Control: Ensuring consistent quality and performance in the complex HIA process can be challenging and requires careful process control and monitoring.

Material Availability: The limited availability of certain materials in powder or wire form can limit the application range of DED.

Despite these challenges, Directed Energy Deposition is a technology with enormous potential, offering manufacturers a powerful tool for creating complex parts with exceptional properties. As technology continues to develop, it is likely to play an increasingly important role in shaping the future of manufacturing.

LASER ENGINEERED NET SHAPING (LENS)

LENS is a versatile additive manufacturing technique that uses directed energy deposition to produce complex metal parts, repair high-value components and enable hybrid manufacturing approaches. Developed and patented by Optomec Inc., LENS has been widely adopted in various industries due to its unique capabilities.

Main features

The LENS process involves the controlled exposure of metal powder to a high-energy laser beam. The powder is melted and fused with a substrate or pre-deposited layers to form a three-dimensional structure. The coaxial powder delivery system used in LENS provides precise control over material deposition, enabling increased part quality and accuracy.

An important feature of the LENS technology is the coaxial powder distribution system. In this configuration, metal powder is fed directly into the laser beam through a coaxial nozzle. This setup ensures a consistent and accurate powder flow, enabling the production of complex geometries and high-quality parts.

The LENS technology is compatible with a wide range of metal powders, including stainless steel, titanium alloys and nickel-based superalloys. These powders are carefully selected and designed to have specific properties, such as particle size distribution and flowability, to optimise the material deposition process and provide the desired part properties.

The LENS process uses a high-power laser to create a focused beam that provides the heat necessary to melt and fuse the metal powder. The laser system includes advanced controls for precise power modulation, scanning speed and beam diameter, allowing fine-tuning of process parameters to achieve the desired results.

The LENS technology offers several advantages over traditional manufacturing techniques. The ability to produce near-net shape parts reduces material wastage and the need for extensive machining. In addition, LENS provides excellent material properties, improved part accuracy and the flexibility to integrate multiple materials into a single structure.

Industry applications

Some examples of industrial products that can be produced using LENS technology in additive manufacturing are as follows:

Aviation Components: The LENS technology can be used in the manufacture of complex components such as turbine blades, engine parts and structural components for the aerospace industry. The ability to produce complex geometries and high-quality metal parts makes LENS suitable for aerospace applications.

Power Transmission Parts: Industrial products such as power transmission components such as gears, shafts and housings can be manufactured using LENS technology. The precision and material properties offered by LENS make it ideal for producing durable and high-performance parts for power transmission systems.

Heavy Industry Equipment: LENS technology is applicable in the production of heavy industrial equipment, including specialised machine parts, tooling components and wear-resistant surfaces. The versatility of LENS in the manufacture of large-scale parts with complex geometries makes it valuable in heavy industry applications.

Precision Components: LENS technology can be used to produce precision components for a variety of industrial sectors, including automotive, medical and instrumentation. The high accuracy and material properties achievable with LENS make it suitable for manufacturing components that require tight tolerances and complex designs.

In summary, industrial products such as aerospace components, power transmission parts, heavy industrial equipment, optical components and precision parts can be effectively manufactured using LENS technology in additive manufacturing processes.

LENS technology has been applied in various industrial sectors, including

Aerospace: LENS technology has been used in the repair and manufacture of aerospace components such as compressor blades and exhaust ducts.

Power Generation: LENS technology is applied in the power generation sector for the manufacture of components such as enclosures and other parts.

Oil and Gas: LENS technology is used in the oil and gas industry for the repair and manufacture of components such as pipes and valves.

Medical: LENS technology is applied in the medical sector for the manufacture of specialised implants and other medical devices.

Automotive: LENS technology is used in the automotive industry for the repair and manufacture of components such as engine parts and other vehicle components.

Heavy Industry: LENS technology has been applied in the heavy industry sector for the manufacture of large, complex components such as gears and other mechanical parts.

Smart Technologies: LENS technology has been applied in the smart technologies sector to manufacture components such as sensors and other electronic devices.

Electronics: LENS technology is used in the electronics industry for the manufacture of components such as printed circuit boards and other electronic devices.

Defence: LENS technology is applied in the defence sector in the manufacture of components such as military equipment and other defence-related devices.

These examples demonstrate the versatility and industrial applicability of LENS technology in additive manufacturing, which can be used in the manufacture of a wide range of components and products in various industries.

Benefits

The main benefits of using LENS technology in additive manufacturing for industrial applications are as follows:

Reduced Production and Material Costs: LENS technology offers lower manufacturing and material costs compared to conventional manufacturing methods. The DED process used in LENS can be more cost-effective than other additive manufacturing techniques.

Compared to other additive manufacturing techniques, the cost of LENS technology is advantageous in terms of depositing different materials in a single structure and adding metal at a lower cost. LENS and other DED technologies offer cost advantages over conventional manufacturing methods in terms of material deposition efficiency and potentially reduced overall costs. This cost efficiency can be attributed to the ability of LENS technology to deposit different materials in a single structure, increasing manufacturing flexibility and cost-effectiveness.

Reduced Processing Time: The LENS process can enable faster production of parts and components by reducing the overall production time compared to conventional methods.

Reduced Environmental Impact: LENS technology has less environmental impact compared to conventional manufacturing as it can lead to less material wastage and more efficient production processes.

Improved Product Performance: LENS technology is capable of producing parts with superior material properties such as high density, minimal heat-affected zones and the ability to process a wide range of metals, including non-reactive and reactive materials. This will result in improved performance of final industrial products.

Ability to Produce Complex Geometries: The LENS process enables the manufacture of parts with complex geometries and intricate designs that can be useful for industrial applications requiring customised or specialised components.

Repair and Refurbishment Capabilities: LENS technology can be used to repair and refurbish high-value industrial components, extending their life and reducing the need for replacement. This will be cost-effective for industrial operations.

Challenges and limitations

Limitations of LENS Technology can be summarised as follows;

Optimising Material Properties: One of the limitations of LENS technology is the challenge of optimising material properties to meet specific requirements that can affect the final quality and performance of the manufactured parts.

Residual Stresses and Distortion: LENS technology faces challenges in reducing residual stresses and distortion during the manufacturing process that can affect the structural integrity and dimensional accuracy of manufactured components.

Ensuring Consistent Part Quality: Maintaining consistent part quality throughout the additive manufacturing process can be a limitation of LENS technology and requires meticulous attention to detail and precise control over various parameters.

Process Optimisation: The need for continuous process optimisation is a major limitation of LENS technology, as fine-tuning parameters such as laser power, scanning speed and powder distribution is necessary to achieve the desired results.

Control over Powder Distribution: Effective control over powder distribution, especially with complex geometries or intricate parts, can be challenging with LENS technology and is important enough to affect the uniformity and integrity of the final product.

Heat Management: Proper heat management is crucial in LENS technology to avoid problems such as overheating, warping or inconsistent material properties, emphasising the importance of precise temperature control throughout the process.

Compatible Material Range: While LENS technology offers versatility in material selection, there will be limitations in the range of compatible materials that can be used effectively, restricting the applicability of this technology in certain industries or applications.

Consequently, while LENS technology offers numerous advantages in additive manufacturing, including precision material deposition and the fabrication of complex geometries, addressing these limitations through careful management of material properties, process optimisation and quality control measures is essential to maximise its effectiveness and applicability in production.

BENEFITS OF ON-SITE PROCESS MONITORING

LENS requires on-site process monitoring techniques to ensure quality control. These techniques will include thermal imaging, spectroscopy and real-time feedback systems, allowing the detection of defects and adjustment of process parameters. Ongoing research at LENS focuses on achieving full process control, improving material properties and expanding the range of compatible materials. With advances in powder dispensing systems, in-situ monitoring and hybrid manufacturing approaches, the future of LENS is promising.

LENS technology has revolutionised the field of metal additive manufacturing, offering a unique combination of precision, accuracy and material properties. Its wide range of applications and advantages over conventional manufacturing techniques make it an attractive solution for industries looking to produce complex metal parts.

EFFECTS OF LENS TECHNOLOGY ON THE ACCURACY OF THE FINAL PRODUCT

The LENS technology significantly impacts the accuracy of the final product by offering precise control over material deposition and enabling complex geometries to be produced with high accuracy. The technology's ability to create a focused laser beam that melts and fuses metal powder onto a substrate allows parts with tight tolerances and complex designs to be produced. In addition, LENS technology provides advanced controls for power modulation, scan speed and beam diameter, improving the accuracy of the manufacturing process. The surface finish, microstructure and mechanical properties of the final product are influenced by the optimisation of the LENS technology, ensuring that the manufactured components meet the required specifications with high precision and accuracy.

COST-SAVING MEASURES BY USING LENS TECHNOLOGY

Efficient Material Accumulation: Optimising the material deposition process in LENS technology will help to reduce material wastage and improve efficiency, leading to cost savings in additive manufacturing. Achieving precise control over material usage and deposition will help to minimise material costs.

Reduced Finishing: Minimising the need for extensive post-processing steps will contribute to cost savings when using LENS technology. By producing parts with high surface quality and precision directly from the additive manufacturing process, the dependency on costly finishing processes will be reduced.

Supply Chain Optimisation: Utilising the capabilities of LENS technology to streamline production and reduce the number of parts to be stored and transported will lead to cost savings in the supply chain. This optimisation will lead to lower storage and transportation costs, contributing to overall efficiency and expense reduction.

Efficient Production of Low-Volume Parts: LENS technology is particularly beneficial for low-volume and small-scale production, where the benefits of additive manufacturing can outweigh the costs associated with mass production. Cost savings can be achieved by focusing on efficiently producing customised, low-volume parts.

Design Flexibility and Innovation: Taking advantage of the design flexibility offered by LENS technology can lead to cost savings through innovative part designs that optimise material utilisation and production efficiency. Designing parts specifically for additive manufacturing will help reduce costs associated with traditional manufacturing constraints.

In summary, the application of measures such as efficient material deposition, reduced post-processing, supply chain optimisation, focus on low-volume production and exploiting design flexibility using LENS technology can help to achieve cost savings in additive manufacturing processes.

POTENTIAL OF USING ML AND ARTIFICIAL NEURAL NETWORK (ANN) FOR PRINT CONTROL IN LENS

The manufacturing process in DED methods has emerged as a promising additive manufacturing technique, offering the ability to produce complex geometries and functional parts directly from computer-aided design (CAD) models. However, maintaining precise control over the printing process remains a significant challenge. Factors such as laser power, scanning speed, powder feed rate and flap gap can significantly affect the quality and consistency of printed parts (Gu, 2018). Improper adjustment of these parameters can lead to defects such as porosity, lack of fusion and residual stresses. These are conditions that can jeopardise the mechanical properties and performance of the final product (Vaezi et al., 2013).

To overcome these challenges, researchers have investigated the potential of ML and ANNs to improve print control in DED. Machine learning algorithms can learn from data and identify models that can be used to optimise process parameters and predict part quality (Tapia and Elwany, 2017). For example, Gobert et al. (2018) demonstrated the use of convolutional neural networks (CNNs) to detect defects in real-time during the LENS process, enabling immediate corrective measures to be taken.

Inspired by the structure and function of the human brain, ANNs also hold promise for improving print control in LENS. ANNs can learn complex relationships between input parameters and output responses, making them well-suited for modelling and predicting the behaviour of the LENS process. Researchers have used ANNs to optimise process parameters such as laser power and scanning speed to achieve desired part features (Ding et al., 2016). In addition, ANNs have been used to predict melt pool geometry and temperature distribution in LENS, which are critical factors in determining the quality and integrity of printed parts (Heralić et al., 2012).

Despite these developments, the integration of ML and ANN into LENS systems is still in its infancy. Challenges such as the need for large datasets, computational complexity, and model interpretability need to be addressed before these technologies can be widely adopted in industrial settings (Caiazzo and Caggiano, 2018). Furthermore, the development of robust and reliable in situ monitoring systems is crucial to provide the necessary data for ML and ANN models to learn and adapt to changing process conditions (Everton et al., 2016).

In conclusion, the feasibility of print control in LENS is significantly improved by the application of ML and ANNs. These technologies offer the potential to optimise process parameters, predict part quality and enable real-time process control, ultimately leading to increased consistency and reliability of parts produced by LENS. However, further research and development is needed to overcome the challenges associated with the application of ML and ANNs in LENS systems.

OPTIMISING PROCESSES, INCREASING PRODUCTIVITY AND QUALITY WITH MACHINE LEARNING IN ADDITIVE MANUFACTURING

The manufacturing industry, especially the Additive manufacturing (AM) and 3D printing sectors is generating large amounts of data during this fourth industrial revolution, often referred to as "Industry 4.0" (Alabi, 2018; Xing et al., 2020). AM technologies are important elements of the Industry 4.0 concept and enable the creation of physical objects from 3D modelling data by layering or solidifying materials (Guo and Leu, 2013; Kulkarni et al., 2000). As shown in Table 1, AM has been successfully used in the development of 3D structures using various materials. However, optimising AM processes in design, manufacturing and process control requires significant knowledge transfer from operators and designers (Wang et al., 2020). To fully utilise the benefits of AM, design, process and manufacturing are becoming increasingly complex (Jia et al., 2021; Wang et al., 2020). Major design changes often require an in-depth understanding of variables and their corresponding effects on part behaviour, which is time-consuming and computationally intensive.

Table 1. Metals/Alloys Commonly Used For Commercial Use Of AM (Frazier, 2014)

Titanium	Aluminum	Tool Steels	Super Alloys	Stainless Steel	Refractory
Ti-6Al-4V	Al-Si-Mg	H13	IN625	316 ve 316L	MoRe
ELI Ti	6061	Cermets	IN718	420	Ta-W
CP Ti			Stellite	347	CoCr
γ -TiAl				PH 17-4	Alümina

Limited orthogonalisation (steepening) is reported in AM processes, where increasing one parameter can adversely affect another. For example, increasing extrusion temperatures can improve layer adhesion but also increase shrinkage. Fine-tuning workflow variables for specific parts or innovative materials can be time-consuming and uneconomical (Qi et al., 2019). In industries that support AM integration, such as aerospace, component consistency is crucial. However, variations in component quality will prevent wider acceptance. Managing and evaluating large amounts of data and information is part of these challenges. Machine Learning (ML) algorithms have the potential to help alleviate these issues by reducing the amount of human or computational work required to achieve satisfactory results (Kumar et al. 2023).

Compared to conventional manufacturing methods, AM offers several advantages for the manufacture of components with increasingly complex structures and designs at macro, medium and micro scales, and the ability to adapt to mass-produced parts (Ahlens et al., 2019). Despite these advantages, there are also some disadvantages such as the lack of basic consistency (Dowling et al., 2020). This has made certification problematic in various industries (Thompson et al., 2016). Another limitation is the lack of accurate and sufficient information on design guidelines (Thompson et al., 2016).

Beyond the ability to generate predefined predictions through data modelling, experts are exploring creative and novel techniques to incorporate ML algorithms into AM processes (Kumar et al., 2023). ML techniques, applications and frameworks are used by AM professionals to improve quality, optimise manufacturing processes and reduce costs (Sutton and Barto, 2015).

Although AM has been around since the 1980s, it gained popularity after the expiry of important patents (20 years of patent protection), especially for consumer-grade 3D printing technology. Research in machine learning has been conducted since around 1960 (Widrow and Lehr, 1990). However, it has recently gained attention due to the outstanding results produced by research organisations and commercial organisations such as Google. Different studies are now specialising in additive manufacturing research that can address fundamental and complex challenges through machine learning approaches. This era is witnessing the creation of large databases as a significant amount of information is generated daily in various networks, including manufacturing, online networks, pharmaceuticals, aerospace, 3D printing, automotive and telecommunications.

Machine Learning (ML), a discipline of Artificial Intelligence (AI), enables devices to learn from various datasets and perform intelligent tasks by leveraging existing data rather than following pre-programmed instructions (Kumar et al., 2023). ML has a crucial role in managing the large amount of data collected during the Additive Manufacturing (AM) creation process. As the demand for industrial additive machines and 3D desktop printing devices increases,

there are challenges in producing defect-free components or finished products that meet high-quality standards. Recent studies have identified parameter variations during construction as factors influencing defects in the AM sector. Addressing these variations can help to identify potential problem areas in the final product and improve construction procedures and cost reduction strategies. Computer vision, estimation and information retrieval are key components directly applicable to AM processes. Advances in graphics hardware have facilitated in-depth investigations and enabled rapid optimisation of machine learning algorithms on extensive datasets (Shinde and Shah, 2018). These developments pave the way for the effective use of ML solutions in AM to increase productivity.

Figure 1a shows the ML taxonomy and its applications in AM. Among the machine learning approaches, Artificial Neural Networks (ANNs) have grown tremendously in importance with the advances in processing power, especially with the use of GPUs for improved computational capabilities. An ANN consists of multiple layers, each containing elementary neurons (Figure 1b).




Figure 1. (a) Shows The Classification Of Machine Learning Applications In The AM Domain (Meng et al., 2020). $X_1; X_2; \dots; X_n$ Represents The Input Vector Containing Various Input Features And Y Represents The Output. (b) An ANN With An Input Layer, 2 Hidden Layers And A Fully Connected Output Layer (Grierson and Quayle, 2021).

The perceptron developed by Rosenblatt in 1958 is one of the pioneering works in the field of ANN (Rosenblatt, 1958). The Heaviside step function serves as an activation function that calculates responses based on input values and identifies neurons according to their weights. During the training phase of a multilayer ANN, backpropagation is used to adjust neuron weights by changing the gradient of the loss function, which represents the difference between the output of the ANN and the training data. This process makes it possible to create feed-forward neural networks (FNN) or recurrent neural networks (RNN) if backward connections exist between layers. Long short-term memory networks (LSTMs) are used in the training of RNNs to solve the problem of gradients lost in backpropagation. Deep learning is based on multilayer ANNs, including hidden layers, convolutional layers and pooling layers. Neurons are arranged in layers, and CNNs are formed by connecting these layers together. In the current AM industry, variability in component functionality, depending on various processing variables such as print speed and layer thickness, poses a significant challenge. Several review papers have investigated the relationship between process, structure and property (Kumar and Kar, 2021; Kumar and Kishor, 2021; Singh et al., 2017). High-fidelity simulations or experiments are options that can be used to overcome this challenge, obtain reliable data, and assist in tuning processing parameters. However, these methods can be time-consuming or costly (Kumar et al., 2022).

In-situ monitoring systems offer another approach to ensure part quality and process reliability. However, effective defect detection based on data, such as images, requires robust and accurate data processing tools. These challenges are addressed by machine learning, a branch of artificial intelligence. With reliable datasets, ML algorithms are able to extract information from training sets to make informed decisions. Trained ML algorithms can predict and identify

optimal operational settings and detect defects in real time using in-situ data. Recent studies have tested various ML applications, including geometric variation control, cost estimation, and quality analysis (Jin et al., 2020; Razvi et al., 2019). In essence, ML applications can be considered as a form of data processing, which makes ML integration an important component of Industry 4.0.

To better understand the benefits of ML in manufacturing processes, three broad categories are proposed and illustrated in Figure 2. These categories aim to show how they influence successful AM integration, information preservation planning and planning. As compiled by Shinde and Shah (2018), the main application areas of machine learning techniques include computer vision, prediction, semantic analysis, natural language processing and information retrieval.

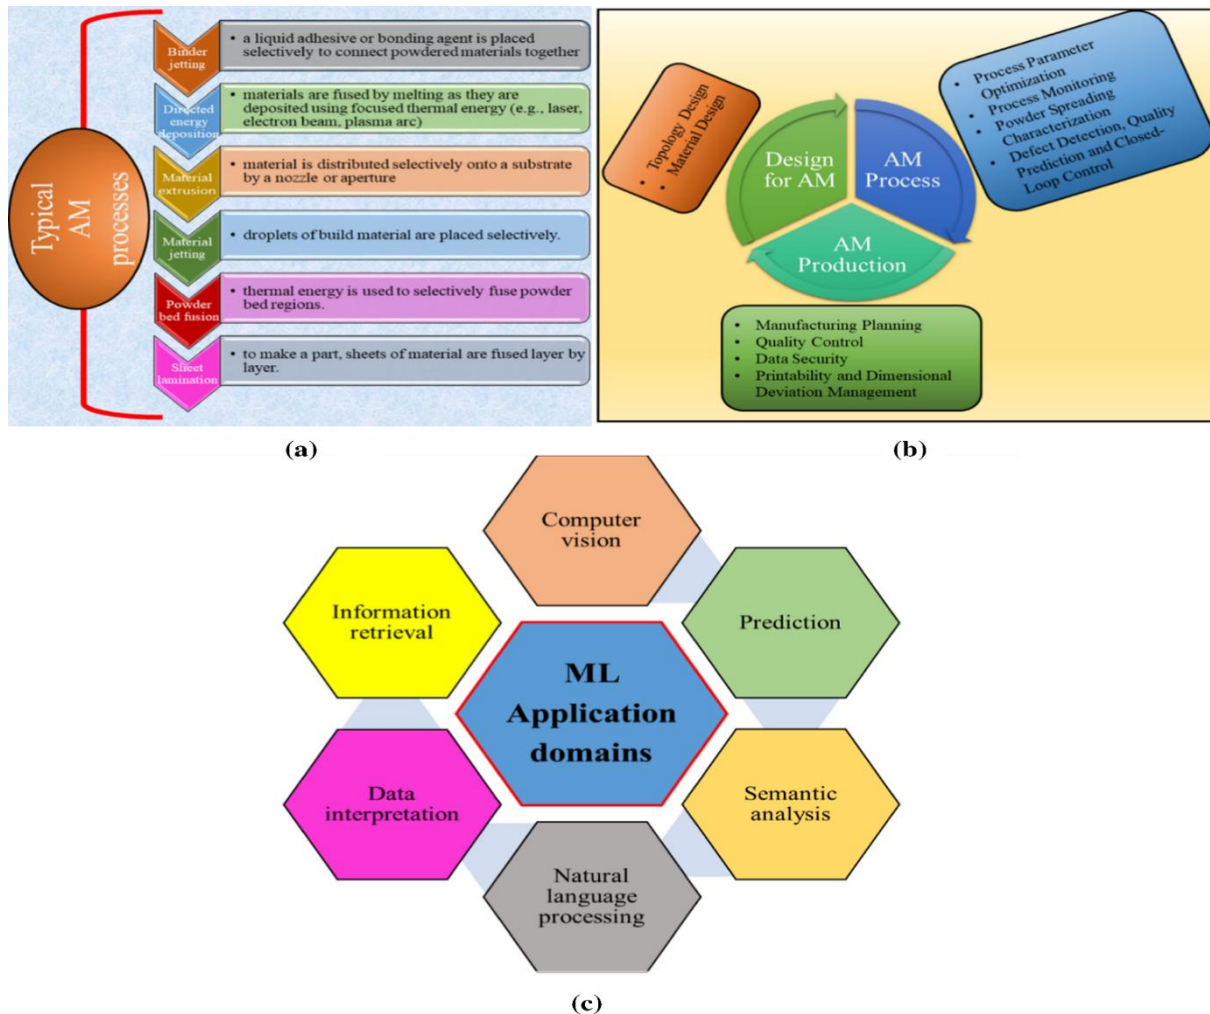


Figure 2. (a) Classification Of Typical AM Processes According To STM F42. (b) Application Of ML Techniques In Numerous AM Domains. (c) Major Application Areas For Machine Learning

The data that can be evaluated and used for the Process-Structure-Property (PSP) relationship chain is shown in Figure 3. In Figure 3, the data available for machine learning is represented by the text in the boxes. Some known machine learning applications in AM are indicated by the highlighted text. The source and terminal of each arrow reflect the source and outgoing values respectively (Meng et al., 2020)

In conclusion, the integration of machine learning into additive manufacturing holds significant promise for increasing productivity, improving quality and driving innovation in the manufacturing sector. By leveraging ML algorithms to optimise processes, manufacturers will be able to overcome challenges, reduce costs and remain competitive in the evolving additive manufacturing landscape.

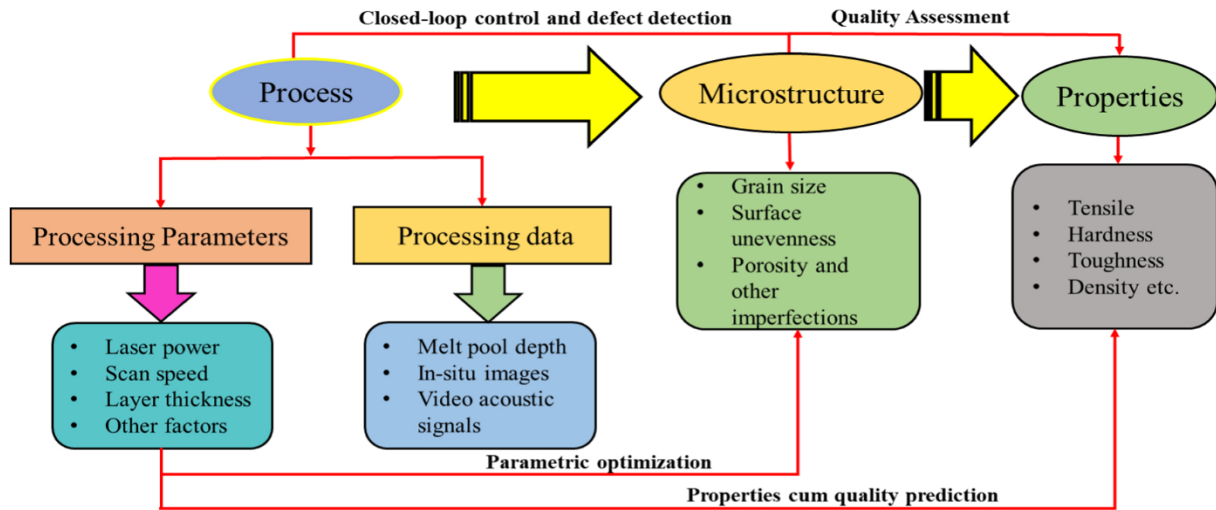


Figure 3. The Link Between Process, Structure And Feature In Additive Manufacturing (Meng et al., 2020).

Topology design and optimisation

Topology Optimisation (TO) is a method used in the design of structures to optimise the material distribution within a given region, taking into account specific stresses and constraints (Bendsoe, 1999). MTR processes often involve multiple design iterations and prototyping, making them technologically intensive, especially for large-scale and complex components. Machine Learning (ML) models offer a promising way to improve CTR procedures by complementing the traditional CTR approach, offering innovative ideas without starting from scratch. Although research on ML for topology design in AM applications is limited, Yao et al. (2017) introduced an integrated ML methodology for AM design feature recommendations using a clustering algorithm in the design phase.

Advanced machine learning techniques in topology optimisation

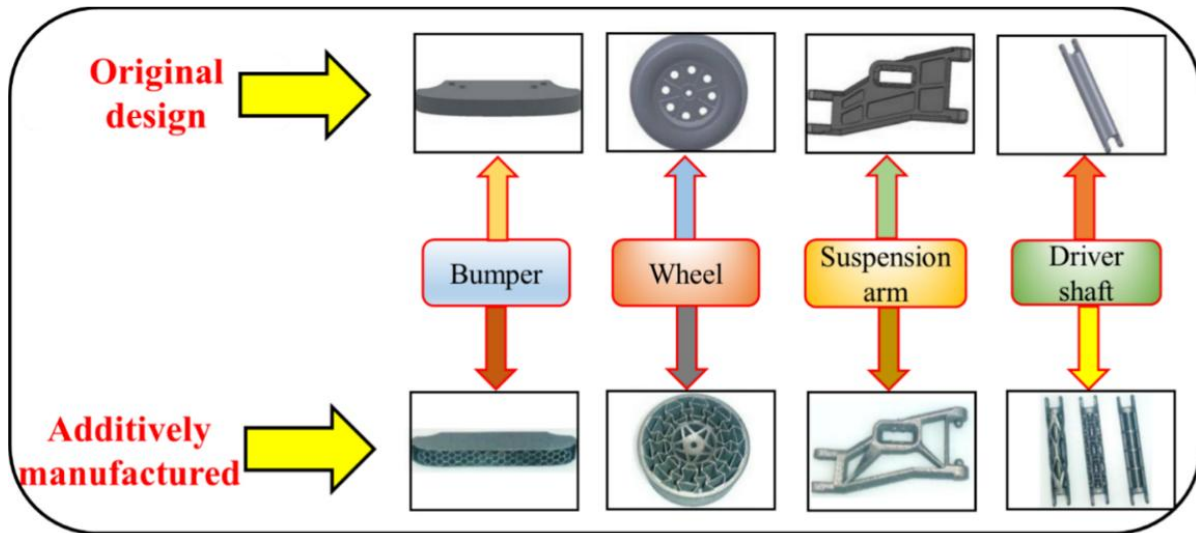
Recent studies have found that Convolutional Neural Networks (CNN) and Generative Adversarial Networks (GAN) have the optimal integration in topology optimisation for AM applications. CNN models are trained to predict optimal designs at an intermediate stage. This significantly speeds up the optimisation process compared to conventional methods such as Solid Isotropic Material with Penalty (SIMP). GAN, a generative programming approach incorporating deep learning techniques, is able to predict optimised structures without the need for extensive TO iterations (Figure 4). This technology will allow the creation of complex designs that efficiently meet specifications (Kumar et al., 2022).

Future directions and challenges


Although ML cannot completely replace traditional MTR techniques, it serves as a valuable tool to reduce the number of iterations and speed up the optimisation process in "Design for Manufacturing and Assembly" (DfMA). ML-centred CTR techniques improve the efficiency of the design process by providing fast and approximate predictions of the initial data. However, further research and experimentation are required to fully explore the potential of ML in additive manufacturing and its ability to streamline and optimise design and manufacturing processes. The integration of Machine Learning into Additive Manufacturing Design offers exciting opportunities to revolutionise the design process, optimise structures and improve the efficiency of additive manufacturing technologies (Kumar et al., 2022). By utilising advanced machine learning techniques, designers will be able to push the boundaries of traditional manufacturing and experience new possibilities in product design and manufacturing.

Material design and machine learning


Materials experts and researchers have made significant progress in the creation of metamaterials, which are composites with unique and distinguishable properties. The traditional manual development of metamaterials using the Edison method is laborious and challenging. However, modern Machine Learning (ML) approaches have revolutionised the synthesis of metamaterials, significantly accelerating the process (Gu et al., 2018). Recent advances in ML are empowering materials experts and researchers to predict material properties and develop new metamaterials. In addition, Additive manufacturing (AM) techniques have enabled the realisation of previously unattainable design concepts.



(a)



(b)



(c)

(d)

Figure 4. (a) Redesigned SLM-Built Components With Existing Target Component Design After A Guideline For Hybrid Machine Learning (Wang et al, 2020; Yao et al, 2017). (b) Use of CNN To Predict The Best Structures From Intermediate Topologies Serving As Input (Wang et al, 2020). (c) A Similar Approach Is Also Used For 3D Structures (Banga et al, 2018). (d) Using GAN To Generate TO Structures (Rawat and Shen, 2018)

Automated metamaterial design

Chen et al. (2017) introduced a fully automated method for determining optimal meta-material designs, which was experimentally validated using the PEBA2301 elastic material and selective laser sintering (SLS) process (Figure 5). The system uses ML techniques to generate customised microstructures that meet the desired specifications by determining elastic material parameters such as Young's modulus, Poisson's ratio and shear modulus. Gu et al. (2018) investigated the creation of 100,000 microstructures using three types of unit cells on an 8 by 8 lattice structure, representing a very small fraction of all possible combinations. Convolutional Neural Networks (CNN) were used to train a database containing mechanical parameters calculated through the Finite Element Method (FEM). This resulted in innovative microstructural models for a composite meta-material that is twice as strong and forty times stiffer. Their concept was validated using the multi-material spray AM method (Figure 6). Notably, FEM simulations

required about five days for mechanical characteristic calculations, while CNN took only ten hours to learn and a few seconds to generate output (Kumar et al., 2023).

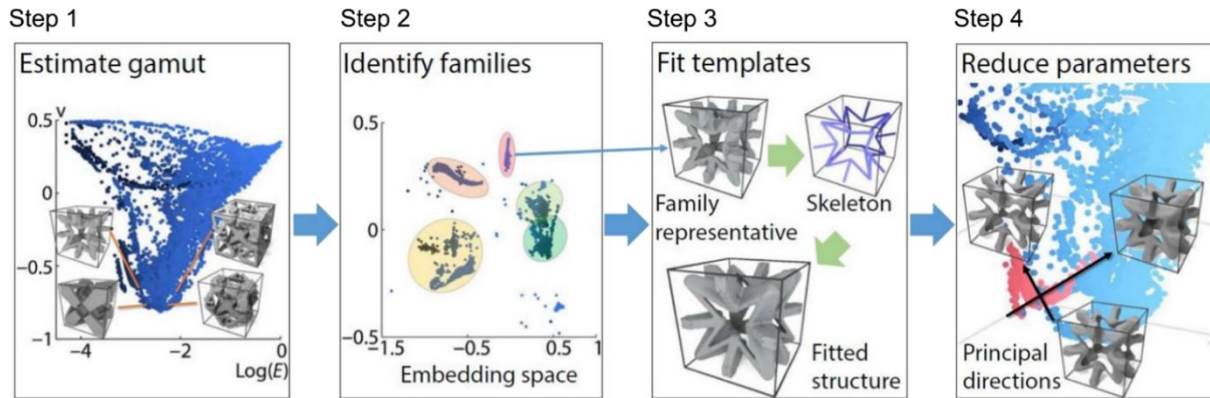


Figure 5. Computational Workflow Defining Extreme Microstructure Families Based On Elastic Material Parameters (Desai et al., 2018; Wang et al., 2020)




Figure 6. Optimisation Of Microstructure With Machine Learning (Gu et al., 2018; Wang et al., 2020).

Machine learning for additive manufacturing processes

Processing parameters such as extruder temperature in Material Extrusion (ME), laser power in Laser Powder Bed Fusion (L-PBF), printing speed and layer thickness significantly affect the quality, reliability and productivity of printed components (Figure 3). Structural design plays an important role in production costs and geometrical variations in manufactured products. In-situ images and acoustic emissions (AE) can be utilised by monitoring systems for real-time identification and elimination of problems (Meng et al., 2020).

By training ML models on datasets containing interconnected categories of data within the PSP network, conclusions can be drawn from the input data. This approach is widely used in ML model applications to effectively analyse and optimise additive manufacturing processes.

The integration of ML into material design, and additive manufacturing processes has provided new opportunities for innovation, efficiency and quality improvement in the manufacturing industry. By leveraging ML techniques, researchers and engineers will be able to improve material design, optimise manufacturing processes and support advances in additive manufacturing technologies.

Process parameter optimisation

In additive manufacturing, developers often lack the ability to predict the quality of a part produced with a given set of machining parameters until that part is actually produced. This uncertainty necessitates several steps to guarantee

product performance, such as printing samples and verifying their efficiency. This makes the design process costly, time-consuming and unpredictable. Therefore, it would be highly advantageous to establish a direct link between management variables and product performance. While tests and calculations are valuable tools to establish this link, it is difficult to determine the most appropriate variables when multiple input parameters are intertwined. To improve operational efficiency, Machine Learning (ML) techniques can be utilised in the form of substitution models (Wang et al, 2018b, 2019).

Traditionally, process parameter development and optimisation for additive manufacturing of new materials has been performed using the design of experiments or simulation methods. However, developing an experimental strategy in the case of metal Additive Manufacturing (AM) often requires a long and costly research process (Wang et al., 2018b, 2019). Physics-based simulations can demonstrate the theoretical basis for the production of various properties during machining. However, macro-scale models such as Finite Element Method (FEM) may contain errors in experimental results due to their simplified assumptions. More advanced approaches, such as computational fluid dynamics, often focus on single tracks or several tracks and layers. This makes it difficult to predict the mechanical properties of parts on a macro scale or on a continuum (Kumar et al., 2023).

Several researchers have investigated the potential of using ML to overcome the aforementioned challenges in metal AM process optimisation as shown in Table 2. ML has primarily been used as a link between process parameters and quality criteria at two levels, mid-scale and macro-scale. Some academics have considered process maps as a means of identifying process windows. These process maps can be valuable tools for further analyses (Kumar et al., 2023). At the medium scale of high-energy AM, singular pathways are the main structural elements. The topology of the melt pool can significantly influence the final quality of the product, such as its shape, continuity and consistency. Due to insufficient empirical observations, powder-based or wire-based Directed Energy Deposition (DED) processes were estimated using a Multilayer Perceptron (MLP). Process variables were found to be inextricably linked to melt pool morphologies. This indicates that a specific geometry can be obtained by adjusting the parametric combinations in the opposite direction (Kumar et al., 2023). Tapia et al. (2017) used a Gaussian Process-based (GP) surrogate model to generate 3D response maps of process settings versus melt pool depths, allowing the identification of parametric combinations to eliminate the occurrence of keyhole melting (Figure 7 a-c). Their approach utilised the combination of an empirical dataset and two additional literature datasets consisting of 139 data points (Kumar et al., 2023). Several custom filters were applied to reduce anomalies, resulting in 96 valid data points with an acceptable preview error of 6.023 μm . In AM-made parts, medium-scale porosity is another major issue. Since the mechanical behaviour of components is strongly influenced by porosity, especially fatigue, total density is the main target in metal AM. The Multilayer Perceptron (MLP) is able to predict complex, non-linear interactions, although it provides little information on how the predictions are generated. In Figure 7(d-e), MLP and GP combined with Bayesian approaches were used to predict porosity in Selective Laser Melting (SLM) based on combinations of process factors (Tapia et al., 2016). Support Vector Machines (SVM) and MLP algorithms were also used to predict the open porosity of PLA samples during the Selective Laser Sintering (SLS) process.

Machine Learning techniques can also be used to investigate macro-scale properties of AM-made objects. Adaptive neuro-fuzzy inference systems (ANFIS) can usually only handle partial values. However, since there are too many unknowns in the fatigue process, it is useful to analyse the fatigue characteristics. Zhang et al. (2019) obtained 139 SS316L fatigue data produced under 18 different treatment configurations on the same SLM equipment. ANFIS was effectively used with the "process-based" model and "feature model" to predict high cyclic fatigue, with a mean root mean square error of 11-16%. When they used the training set containing 66 data points to predict fatigue life, the performance of their algorithm decreased due to the variability from machine to mechanical systems. Therefore, it is recommended to use both empirical and bibliographic inputs in model training to improve generalisation ability (Kumar et al., 2023).

Wang et al. (2018b) emphasised that studying the surface morphology can help narrow the Electron Beam Melting (EBM) process window. Support Vector Machines (SVM) work well in cases where the closeness between classes is evident. However, overfitting (memorisation) is easy to occur.

Aoyagi et al. (2019) proposed a simple method to create EBM flowcharts using only 11 datasets. It should also be noted that in this study, SVM was only used to fit the data to determine decision boundaries. Since the training dataset was very small, it was a problem to assign a training dataset to evaluate the accuracy of the model.

Table 2. Machine Learning Approaches To Optimise Parameters In The AM Process (Wang et al., 2020)

AM Processes	Materials	Builds	Sensors	Input Features	ML Methods	Output targets	References
Acoustic –Based Monitoring							
SLM	SS304	Single tracks	Microphone	Acoustic signals	DBN,MLP,SVM	Classify melting states	Ye et al., 2018a)
SLM	SS	10 × 10 x 20mm ³ cubes	Fibre Bragg grating sensor	Acoustic signals	Special CNN	Classify of build qualities	Shevchik et al., 2018)
FDM	ABS	-	Acoustic emission sensor	Acoustic signals	K-means clustering	Identify failure mode	Wu & Yu, 2016)
FDM	-	-	Acoustic emission sensor	Acoustic signals	Hidden semi-Markov model	Identify extruder state	Wu et al., 2016a)
Optical-Based Monitoring							
SLM	SS316 L	Single tracks	High-speed camera	Layer-wise images of melt pools, plume and spatter	SVM,CNN	Detect anomalies of melt tracks	Zhang et al., 2018)
SLM	Zinc	5 × 5 x 5mm ³ cubes	IR camera	IR images(plumes and laser-heated zones)	Unsupervised ML	Detect unstable melting conditions	Grasso et al., 2018)
SLM	In718	Single Tracks, unsupported overhangs	High-speed camera, optical microscope (ex-situ)	In-situ and ex-situ morphologies of the melt pool	SVM	Detect keyhole porosities and balling instabilities	Scime & Beuth, 2019)
SLM	SS	Step cylinder	Digital single lens reflex camera, CT scan (ex-situ)	Layer-wise images under 8 lighting conditions, ex-situ CT scan data	SVM	Detect and locate anomalies	Gobert et al., 2018)
SLM	In625	40.5 “ unsupported overhangs	Photodetector, high-speed camera, IR camera	Intensity, morphology, thermal profile of melt pools	MLP,SVM,KNN	Distinguish between the overhang and bulk build states	Montazeri & Rao, 2018)
SLM	SS304	Single tracks	Near –IR camera	Plume and spatter signatures	DBN,CNN,MLP	Classify melting states	Ye et al., 2018b)
SLM	SS304	8.5 × 8.5 x 4mm ³ cubes	High- speed camera	Images and locations of melt pools	DBN	Classify MP images concerning laser power	Kwon et al., 2018)
SLM	In718	Tensile Bars	Visible light and IR photodiode sensors	Plasma emission and thermal radiation of melt pools	Gaussian mixture model	Detect faulty bars	Okaro et al., 2019)
SLM	SS316 L	Ø16 × 44 mm ³ cylinder,50 × 50 × 50 mm ³ lattice structure	High- speed camera	Intensity profile of melt pools	K-means clustering	Detect and locate defects due to overheating	M. G, V. L, Q. S, B.M C. xxxx)
SLM	-	Hollow cylinders	Optical camera	Layer-wise surface images before and after powder coating	RF,SVM	Detect elevated regions after laser exposure	Jacobsmühlen & zur, 2015)
SLM	In718	Ø40 × 20 mm ³ cylinder	Digital single-lens reflex camera	Layer-wise surface images before and after powder coating	CNN,SVM	To recognize defects induced by process non-conformities	Caggiano et al., 2019)
DED	Ti-6Al-4 V	Thin walls	Pyrometer, IR camera, CT scan(ex-situ)	Thermal profile and location of the melt pool	SOM	Detect the location and size of pores	Jafari-Marandi et al., 2019)
DED	Ti-6Al-4 V	Thin walls	Pyrometer, IR camera, CT scan(ex-situ)	Morphological and thermal characteristics of the melt pool	SOM	Detect location of pores	Khazadeh et al., 2019)
FDM	PLA,ABS	DNA model	Optical camera	Images of parts at specified checkpoints	SVM	Classify good and defective parts	Delli & Chang, 2018)
FDM	-	Parts with different types of infills	Cameras mounted on both extruder and frame of printer	Simulated images from software, real images from camera	KNN, RF, unsupervised ML	Detect malicious infill structure	Wu et al., 2017)

Recurrent Neural Networks (RNN) are used to predict time series. Mozaffar et al. (2018) used RNN for training FEM data to determine the high thermal history of the complex components of the DED process, considering the time dependence of the inputs. In addition, both MLP and SVM were used to predict thin wall deposits for DED. The study focused on the mechanical properties of macroscopic dimensions in the AM extrusion material process. For carefully examined process parameters, Fused Deposition Modelling (FDM) includes layer thickness, temperature and structure guidance. Here MLP is the most widely used methodology. A sufficiently trained MLP is preferred for

the accuracy and prediction of the nonlinear data of the system. The use of compressive strength, wear rate, elasticity dynamics, creep and restorative properties in the prediction of material shrinkage parameters of PLA and PC-ABS materials has been extensively evaluated.

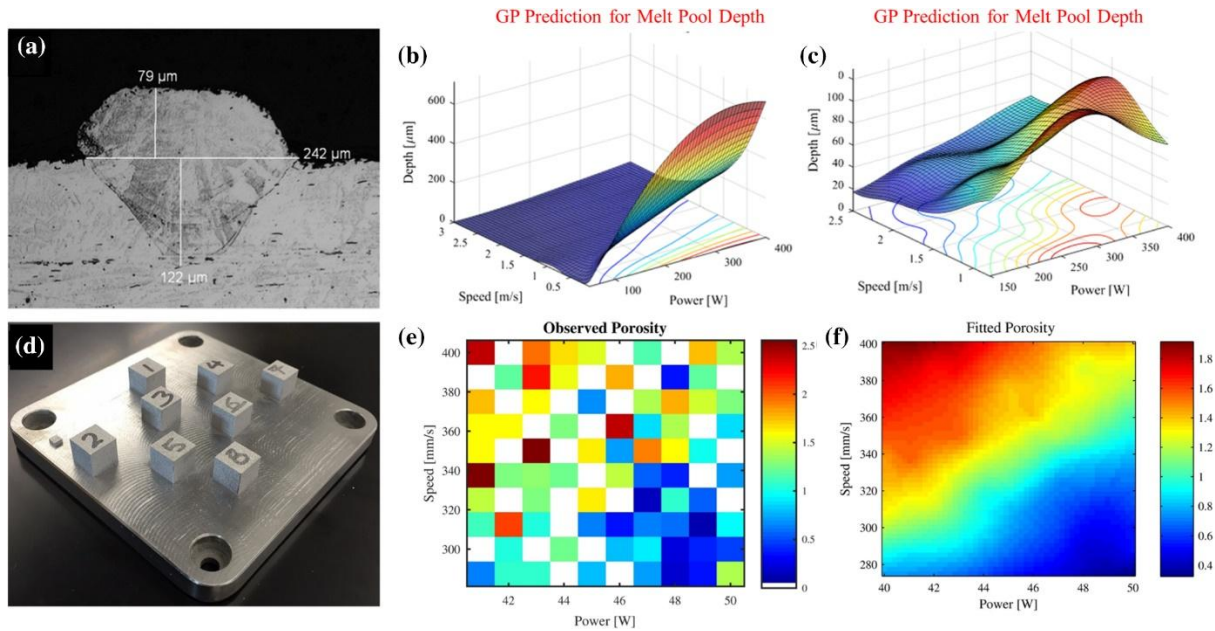


Figure 7. A GP-Based Model For Predicting Medium-Scale Properties Of SLM Fabricated Parts (Wang Et Al., 2020). SS316L Samples: (a) Single Trace Optical Micrograph. (b) Predictions Of Melt Pool Depth From Experiments, (c) Modelling. PH Samples From SS17-4 (Tapia et al., 2016). (d) Samples With Exactly The Desired Shape. (e) Spatial Behaviour Of The Observation Along The Process Parameter Table. (f) Porosity Prediction For Power-Speed Combination (Tapia et al., 2017)

Process monitoring

Although parameter optimisation can improve process predictability, it cannot completely eliminate defects (Kwon et al., 2018). Since printing issues contribute significantly to the cost of Additive manufacturing (AM) parts, process monitoring approaches that can detect build errors and defects are crucial. To overcome this challenge, several Machine Learning (ML) solutions have been developed (Kumar et al., 2023), categorised according to the type of input data (optical and acoustic monitoring).

Optical Tracking: Optical monitoring solutions utilising data from digital, high-speed or infrared cameras are widely used in AM processes. Monitoring the melt pool, a critical aspect in Powder Bed Fusion (PBF) operations, has been the focus of much monitoring research. Kwon et al. (2018) used melt pool thermal data to train a Convolutional Neural Network (CNN) based software to distinguish between high and low-quality structures. In this study, a failure rate of less than 1.1% was achieved, potentially saving time and cost. Zhang et al. (2018b) integrated melt pool, smoke and splash data to effectively categorise component quality. Long Short-Term Memory (LSTM) networks have demonstrated improved prediction capabilities in this context (Zhang et al., 2021). Optical monitoring has also been useful in other AM techniques such as binder spraying and material extrusion. Gunther et al. (2020) used an optical tool to analyse defects in binder jet parts, while Wu et al. (2016b) achieved an accuracy of 95% using optical tracking to detect filler print defects in material extrusion.

Acoustic Monitoring: Acoustic monitoring, a newer and cost-effective method, is based on acoustic signals related to part porosity and melt states in PBF and material extrusion processes. Compared to optical monitoring, acoustic monitoring systems use cheaper sensors. The machine learning algorithms used range from supervised CNNs to clustering solutions. Acoustic monitoring effectively detects problematic structures, reducing the need for post-print inspection, and has achieved confidence levels of up to 89% for porosity classification and 94% for defects related to the melt pool. Wu et al. (2015b) used acoustic monitoring and a Support Vector Machine (SVM) classifier to assess material extrusion and achieved 100% accuracy in detecting material extrusion and 92% accuracy in identifying extruder obstacles.

Powder spreading characterisation and defect detection

In Powder Bed Fusion (PBF) processes, the consistency of powder distribution is critical to the quality of the final products. Improper powder distribution can lead to a variety of problems, such as warping and swelling, which can cause the entire structure to fail. Examples of powder dispersion problems include recoater impact on curled or bumpy components, recoater entrainment of foreign material, recoater blade damage and debris on the powder bed. It is highly desirable to eliminate the need for man-made detectors for certain anomalies. In this work, a mechanism for independently detecting and classifying dust propagation defects during the construction process is introduced to address this problem. Scime and Beuth used modern computer vision techniques such as k-means clustering (Scime and Beuth, 2018a) and multiscale Convolutional Neural Networks (CNN) (Scime and Beuth, 2018b) to learn the algorithm accurately. Using photographs recorded during the Selective Laser Melting (SLM) process, they classified image fragments into seven types. This technology also enabled in-process repair of defects in the AM process when a feedback control system was used (Kumar et al., 2023).

Defect detection, quality prediction and closed loop control

In-situ monitoring devices have been developed to the extent that real-time data can be collected for defect detection and closed-loop control in additive manufacturing. Real information such as spectroscopy, images, Acoustic Emission (AE) and computed tomography (CT) can be used in various ways with machine learning models;

- Faulty (potentially with categories of defects) or error-containing data are identified by experimental testing or human expertise. Supervised learning models are then trained to detect defects and project real-time performance, a common application of ML classification techniques.
- For clustering of abnormal data, cluster analysis is performed with unsupervised learning approaches and defects are detected without labelling.
- ML regression models are built using data from some real-time adjustable process conditions to vary these processing parameters in real time. This approach is illustrated by voltage level control in the Material Jetting (MJ) process. The charge-coupled device (CCD) camera first captures dynamic photographs of the droplet. Second, the images are used to extract four droplet features (satellite, bond, quantity and velocity), which are then combined with current-voltage to form a neural network (NN), ML algorithm. Finally, the trained ML model is used to determine the appropriate voltage level and send it to the voltage modification system that regulates the droplet spray pattern (Figure 8) (Meng et al., 2020; Wang et al., 2018a).

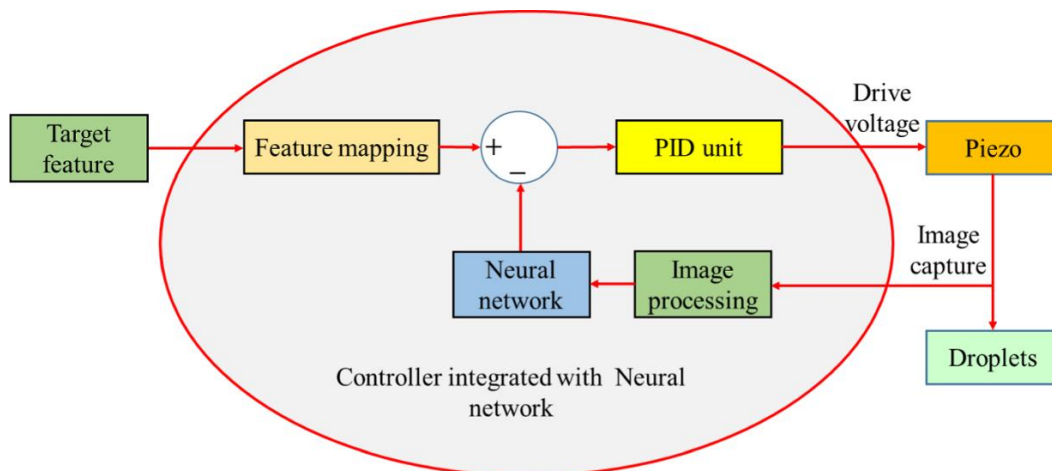


Figure 8. Closed-Loop Voltage Regulation Architecture Of The MJ Programme (Meng et al., 2020; Wang et al., 2018a).

The integration of Machine Learning into powder dispersion characterisation, defect detection, quality prediction and closed-loop control in additive manufacturing processes plays a crucial role in improving product quality, reducing waste and optimising production efficiency. By utilising advanced machine learning techniques, researchers will be able to develop robust, appropriate, monitoring systems and feedback control mechanisms to ensure consistent powder distribution, detect defects in real-time, and adapt process parameters accordingly.

Geometric deviation control and cost estimation

Additive manufacturing (AM) parts often exhibit low geometric accuracy and surface integrity, causing challenges in various industries such as aerospace and pharmaceuticals (Grasso, 2017). To address these geometric

imperfections, machine learning (ML) models have the potential to play an important role in recognising geometric defects, quantifying deviations, and providing recommendations for correcting these defects. Francis et al. (2019) developed a geometric error compensation framework for the Laser Powder Bed Fusion (L-PBF) process using a Convolutional Neural Network (CNN) ML model. This framework predicts degradation by analysing thermal data and process variables and feeds the degradation results back to the Computer-Aided Design (CAD) model for defect detection and correction. By adjusting the CAD model based on ML predictions, the geometric accuracy of the produced items can be significantly improved, as shown in Figure 9. The geometric error compensation approach for Ti-6Al-4 V in the L-PBF process is shown (Meng et al., 2020). The distortion predicted using the deep learning model is the output data. The distortion in the CAD model is reversed to compensate for errors. CAMP-BD is a convolutional and ANN for predicting Additive manufacturing using big data (Francis and Letters, 2019)




Figure 9. Input Data (a) Thermal History, (b) Processing Parameters (Francis and Letters, 2019)

Cost Estimate: Understanding the costs and time required for 3D printing is crucial for manufacturers, customers and supply chain stakeholders. While the dimensions of a proposed shape can provide some estimates, a precise and effective cost estimation technique is still required. Chan et al. (2018) presented an innovative cost estimation framework outlined below:

- A customer submits a production order containing a three-dimensional model.
- The three-dimensional model is converted into an input vector and fed to machine learning algorithms trained for cost estimation using clustering analysis based on similar workloads.
- If requested by the customer or in case there is not enough data available for training the ML algorithm, the 3D model is processed using modelling techniques to predict the costs that serve as a training source for the ML algorithms.
- After integrating the ML estimates, the gross expected cost is calculated.
- The final cost estimate is presented to the customer.

This cost estimation framework, shown in Figure 10, enables accurate and effective cost estimates for 3D printing projects. It increases transparency and facilitates informed decision-making for all stakeholders involved in the additive manufacturing process (Chan and Lu, 2018; Meng et al., 2020)

Planning and quality control

Additive manufacturing (AM) is recognised as a costly manufacturing process and many end users demand a significant return on their investment. A precise pre-production strategy is needed for the manufacturing process, from Computer-Aided Design (CAD) to final product quality testing. As a result, some projects have utilised machine learning (ML) to assist in AM planning. Tang et al. (2016) showed that the manufacturability of a component for

Fused Deposition Modelling (FDM) printed grid structures can be assessed using ML in pre-fabrication. They also designed a multimodal learning system combining Convolutional Neural Networks (CNN) and Multilayer Perceptron (MLP). This system was constructed based on concepts, materials and process parameters for the successful production of the metal part by Selective Laser Melting (SLM).

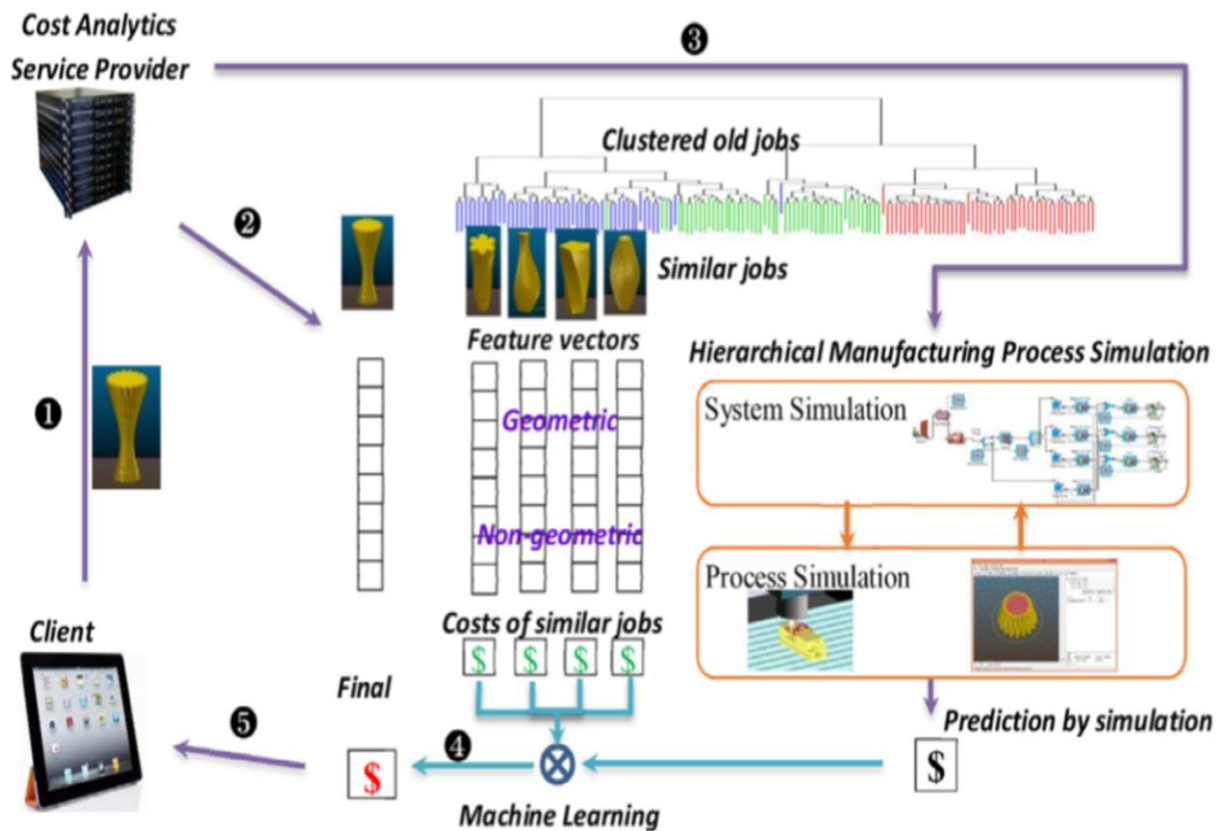


Figure 10. A Framework For Cost Analysis Due To Geometry And Process Similarities (Chan and Lu, 2018; Meng et al., 2020)

Additive manufacturing quality control

A significant barrier to AM quality assurance is the variability in production quality between different machines in the same process, even from production to production. Differences in dimensional accuracy, density, process stability and material properties can result from these disparities (Kumar and Wu, 2020, 2021b; Kumar et al., 2020b). As a result, numerous studies have attempted to use ML algorithms to establish quality in AM parts. The three methods of eliminating geometric errors are rescaling all components, replacing their original CAD, and using quality measures. Before production, MLP or CNN can be used to estimate the scaling ratio and change the overall size of the components. Shape-dependent geometric changes due to heat stress can be modelled using ML algorithms that allow appropriate geometric adjustments to the CAD model. MLP was used to correct geometric distortion to reduce the thermal consequences caused by SLM (Chowdhury et al, 2018). Finite Element Method (FEM) modelling output was generated to predict the distorted regions and modify the available CAD data (Figure 11).

Noriega et al. (2013) used a similar method in FDM printing and replaced simulated data with test results. To achieve process control, Self-Organising Maps (SOM) are able to link different geometric deviations with specific process parameters. Compared to many existing supervised machine learning algorithms, this method, when combined with a laser scanner, will be able to reduce the point cloud data required to measure the dimensional accuracy of additively manufactured components. In addition, single traces can be modified on a macro-scale by adjusting the Directed Energy Deposition (DED) process parameters to minimise geometric imperfections. After laser exposure of each layer formed in the Powder Bed Fusion (PBF) process, the acquired surface images can train ML algorithms to quickly recognise deformed parts before powder coating (Kumar et al., 2023).




Figure 11. ML Approach To Minimise Thermal Degradation In The SLM Process (Chowdhury et al, 2018; Wang et al, 2020)

In-process inspection involving various sensors and cameras is used to improve the quality of additively manufactured components. Signal emissions, mainly visual and auditory, can be recorded and analysed to train multiple ML systems to manage the 3D structure. ML has the potential to help diagnose printing status and failure mechanisms, melting conditions, porosity detection, shrinkage property prediction and surface roughness prediction in AM.

Additive manufacturing data security and dimensional deviation management

Intellectual property (IP) protection is vital in the manufacturing sector, where companies invest heavily in the protection of their data. The cyber and physical domains are two important parts of digital manufacturing, as shown in Figure 12a. Data theft most commonly occurs in the cyber domain, but can also occur in the physical domain (such as side channels) as Additive manufacturing (AM) technology emits various signals when creating 3D structures. It is possible to use Machine Learning (ML) techniques to monitor outgoing channels in IP surveillance and extract Computer Aided Design (CAD) data. Until recently, ML could only record acoustic signals during printing to reconstruct 3D models with data from side channels. But now, thanks to transducers, it can capture acoustic signals from stepper motors in Melt Deposition Modelling (FDM), as seen in Figure 12b, similar to G-code in that it leaks data on the FDM process, including axis motion, nozzle speed, temperature and material discharge. Al Faruque et al. (2016) were able to utilise features extracted from these captured sound files to develop ML algorithms. They were able to reconstruct a model with 78% prediction accuracy and 18% prediction error for axis prediction. In the case of IP theft, the thief can even place the mobile phone close to the device to capture audio data. As an example, these data were used in the study by Hojjati et al. (2016) to accurately reconstruct an aircraft model of about one mm in length with an angular error of one degree.

PRINTABILITY AND DIMENSIONAL DEVIATION MANAGEMENT

Convolutional neural networks (CNNs) and support vector machines (SVMs) can be used to create models for the determination of part printability in material extrusion processes and Powder Bed Fusion (PBF). The use of Neural Networks (NNs) can reduce print time estimates for PBF processes from 20-35% to 2-15% and allow for better equipment control. In AM systems, material, machine and layer production are all three-dimensional elements. In the process of converting a CAD model to STL file format, for example, the resolution will be reduced. In PBF, ML was initially used to correct these by optimising the orientation of components, reducing the mismatch due to the machine and adjusting the computer design to the thermal effects of the material. Khanzadeh et al. (2019) used Self-Organising Maps (SOM), an unsupervised learning algorithm, to analyse and evaluate point cloud data for dimensional deviation of components produced by extrusion procedures. Their application allowed partial differences to be classified into discrete clusters based on the severity of the differences present, allowing the identification of sub-optimal conditions in the process. Noriega et al. (2013) used NNs to compensate for dimensional variation by varying the size of the part for material extrusion. The two NN implementations were able to reduce the deviation by 50 per cent for the outer dimensions and 30 per cent for the inner dimensions, respectively. Charalampous et al. (2021) used AM of T4 spine vertebrae as a case study and achieved a 25% reduction in dimensional deviation at a 1:1 scale and a 33% reduction at a 3:1 scale. Numerous studies have investigated how to limit geometric deviation

in Directed Energy Deposition (DED) and binder jetting. Rawat & Shen (2018) conducted a study using CNNs to predict and compensate for geometric deviation by tilting, resizing and rotating the CAD geometry of a dental crown to be made using bond sputtering procedures. During the operational study, the CNN used a voxel-based method where each voxel was rated as reliable or defective. The average of the F1 scores, a single-valued metric used to assess prediction accuracy, was found to be 94%. However, despite these results, no actual samples were produced, making these results unreliable. The most typical method used for dimensional bias correction in DED is to use process parameter optimisation to optimise the geometric properties of individual traces. However, although this method partially corrects component and machine problems, it cannot solve document formatting problems. Caiazzo and Caggiano (2018) created an optimisation model to analyse the results.

The integration of Machine Learning into Additive manufacturing data security and dimensional deviation management will offer significant benefits in protecting intellectual property, improving product quality and optimising manufacturing processes. By leveraging advanced machine learning techniques, researchers and industry professionals will be able to detect potential IP theft, identify printability issues and compensate for dimensional deviations, enabling safer and more efficient AM operations.




Figure 12. (a) A Cyber And Physical Attack Model In The AM System Development Process. (b) Side Channel Acoustic Model Attack (Al Faruque et al., 2016; Wang et al., 2020)

EMERGING TECHNOLOGIES IN ADDITIVE MANUFACTURING AND MACHINE LEARNING

Generative design (GD)

Generative design is an emerging approach that utilises computational algorithms and Machine Learning to explore a large design space and generate a large number of innovative solutions that meet specific performance criteria. In

the context of additive manufacturing, Generative design is very powerful as it can create highly complex, organic shapes that are difficult or impossible to produce using traditional methods. By integrating generative design with machine learning, researchers can further enhance the design process by training ML models to recognise patterns in successful designs and guide generative algorithms towards optimal solutions.

For example, a study by Umetani and Schmidt combined generative design and deep learning to create structures optimised for additive manufacturing. The researchers developed a convolutional neural network (CNN) trained on a dataset of successful and unsuccessful 3D printed structures. The trained CNN was then integrated into the generative design workflow and provided real-time feedback on the printability of the generated designs. This allowed generative algorithms to explore a wider design space and enabled the generated structures to be manufacturable using AM. The resulting designs exhibited complex and organic shapes with improved mechanical performance compared to conventional designs. This case study highlights the synergistic potential of generative design and machine learning for what can be achieved in additive manufacturing.

Explainable artificial intelligence (XAI)

As machine learning is more widely adopted in additive manufacturing, there is a growing need for AI models that are transparent, interpretable, and allow users to understand the logic behind the model's predictions and decisions. This concept, known as Explainable Artificial Intelligence (XAI), is particularly important in regulated industries such as aviation and healthcare, where decisions made by AI systems can have significant consequences.

In the AM context, XAI will help build confidence in machine learning algorithms by providing insights into the factors that influence the model's predictions. For example, in the case of predicting part defects during the AM process, an XAI model will be able to identify the specific process parameters or material properties that contribute most to the probability of a defect occurring. This information will help AM operators make informed decisions about process adjustments and enable more effective troubleshooting.

Furthermore, XAI will facilitate regulatory compliance by providing a transparent audit trail of decisions made by AI systems throughout the AM process. This is especially important in industries with stringent quality standards to demonstrate the reliability and safety of AM parts. By incorporating XAI into AM workflows, manufacturers will improve their ability to meet regulatory requirements and build confidence in the use of Machine Learning technologies in additive manufacturing.

REGULATORY CONSIDERATIONS AND ETHICAL IMPLICATIONS

Data privacy and security

As machine learning becomes more prevalent in additive manufacturing, the collection and use of large amounts of data raises concerns about data privacy and security. AM processes generate vast amounts of data, including part designs, process parameters, and sensor data, which can be sensitive and proprietary. Ensuring the protection of this data is vital to maintaining competitive advantage and preventing the theft of intellectual property.

Regulatory frameworks, such as the General Data Protection Regulation (GDPR) in the European Union, have been established to protect personal data and ensure its responsible use. While these regulations primarily focus on personal data, they emphasise the importance of data privacy and security in the digital age. In the AM context, similar principles should be applied to protect sensitive production data and ensure its ethical use.

Measures such as data anonymisation, access control, and secure data storage can help mitigate risks associated with data collection and use in AM processes. In addition, establishing clear data management policies and training employees on data privacy best practices will help foster a culture of responsible data management in AM organisations. By prioritising data privacy and data security, AM companies will be able to build trust with their customers, business partners and regulators and ensure the responsible use of machine learning technologies in their production processes.

Protection of intellectual property

The integration of Machine Learning and additive manufacturing poses new challenges in intellectual property protection. As AM technologies enable the rapid production of complex parts, they also increase the risk of unauthorised copying and distribution of designs. Moreover, the use of ML algorithms in the AM process can lead

to the creation of new designs or modifications to existing designs, blurring the boundaries of ownership and ownership.

To overcome these challenges, AM companies and researchers need to adopt a multi-pronged approach to intellectual property protection. Legal frameworks such as patents, copyrights and trade secrets can provide a basis for the protection of AM-related intellectual property. However, in the face of rapidly evolving technologies and new business models, these traditional methods will not be sufficient. Technological solutions such as digital watermarking, blockchain and secure data storage can help trace the origin of AM designs and prevent unauthorised access or modification. AM companies can also experiment with new business models that prioritise IP protection, such as design licensing, subscription-based services and collaborative design platforms.

By proactively addressing IP protection challenges, AM stakeholders can foster innovation, collaborations, and ensure the sustainable growth of the additive manufacturing sector in the era of AI-driven manufacturing.

SECTOR ADOPTION AND FUTURE TRENDS

Barriers to Implementation: Despite the promising potential of machine learning in additive manufacturing, several obstacles prevent its widespread adoption. One of the main challenges is the quality and availability of data needed to train effective machine learning models. AM processes generate vast amounts of data, but much of it is unstructured, incomplete, or of low quality. Addressing these data quality issues requires significant investment in data cleaning, pre-processing and optimisation.

Another barrier is the skills gap between AM professionals in terms of machine learning expertise. Bridging this gap requires targeted training programmes, collaboration with academic institutions and the development of user-friendly machine-learning tools specifically designed for AM applications.

Infrastructure limitations such as insufficient computing power, storage capacity and network bandwidth can also hinder the application of ML in AM. Upgrading hardware and software infrastructure, leveraging cloud computing resources and optimising data processing workflows can help overcome these limitations.

To overcome these barriers, AM companies and research institutions must take a holistic approach combining targeted investments, skills development and collaborative efforts. By working together to overcome these challenges, the AM industry will be able to unlock the full potential of machine learning and drive the next generation of smart manufacturing.

Future Developments: As machine learning and additive manufacturing continue to evolve, many exciting developments are on the horizon that could shape the future of smart manufacturing. One potential trend is the integration of ML with emerging AM technologies such as multi-material printing, in-situ monitoring and closed-loop control systems. By leveraging ML algorithms to optimise these advanced AM processes, manufacturers will be able to achieve unprecedented levels of precision, efficiency and flexibility in part production.

Another promising area is the development of self-learning and adaptive AM systems that can autonomously adjust process parameters based on real-time feedback from on-site sensors and machine learning algorithms. These intelligent systems will revolutionise the way we think about manufacturing by enabling highly complex, customised parts to be produced with minimal human intervention.

The convergence of machine learning and additive manufacturing is also expected to drive the development of new materials and material systems tailored for specific AM processes and applications. Researchers using machine learning to analyse the relationships between material composition, microstructure and performance will be able to accelerate the discovery and optimisation of new materials for AM, opening up new possibilities in aerospace, biomedical, energy, etc.

As these developments unfold, the integration of machine learning and additive manufacturing will continue to push the boundaries of what is possible in smart manufacturing. By embracing these emerging technologies and fostering a culture of innovation, the AM industry will lead the transition to Industry 4.0 and create a more sustainable, efficient and personalised manufacturing ecosystem.

CONCLUSION AND FUTURE RESEARCH DIRECTIONS

In today's data-rich environment, vast amounts of data are generated every day from a variety of sources, including planning statistics, sensor readings, financial records, Additive Manufacturing (AM) data, medical information and mobility data. Extracting meaningful insights from this extensive and interconnected data environment is crucial. Machine Learning (ML) algorithms are effective in leveraging existing knowledge to explore new research areas by analysing heterogeneous data. In the context of smart manufacturing, the synergy between AM and ML, as emphasised by Kang et al. (2016), points to significant progress leading to Industry 4.0, known as the fourth industrial revolution.

This study investigated the effectiveness of ML techniques and their application in basic AM processes. Machine learning has demonstrated its effectiveness in improving the quality of 3D structures in AM, improving printer productivity, discovering new materials and establishing important feature-structure relationships. While current ML applications in manufacturing focus primarily on processing-related procedures such as process parameter optimisation, there is an urgent need to develop more streamlined and efficient approaches. The future direction of ML in AM is expected to be towards new materials, optimised manufacturing strategies and automated in-process feedback systems to further develop intelligent AM applications.

Despite the transformative potential and increasing value of ML in the AM, many ML solutions in the AM field have yet to undergo real-world testing. Future efforts should focus on increasing the applicability of these tools to tackle concrete industrial challenges and providing concrete industrial examples that will increase confidence in their effectiveness.

Investigating the optimisation of machine variables based on raw material constraints, process settings and past machining results, as exemplified by Weiss et al. (2014), has the potential to pave the way to achieving high-quality standards. This optimisation paradigm can be extended from part-specific stages to machine- and plant-specific stages. This would increase overall productivity while taking into account resource efficiency, energy savings and operational constraints.

Another promising research topic will be to simplify equipment and extend the limits of raw material constraints. Machine learning-driven optimisation strategies can meet the increasing demands of processing stages, guaranteeing consistent quality while reducing machine and raw material costs.

The integration of Machine Learning into Additive manufacturing processes has enormous potential to revolutionise the industry, improve efficiency and drive innovation. Future research should focus on improving ML applications, addressing real-world challenges and optimising AM processes to unlock the full capabilities of smart manufacturing in the Industry 4.0 era.

REFERENCES

- Ahlers, D., Wasserfall, F., Hendrich, N., & Zhang, J. (2019). 3D printing of nonplanar layers for smooth surface generation. *IEEE International Conference Automotive Science Engineering*. <https://doi.org/10.1109/COASE.2019.8843116>
- Al Faruque, M. A., Chhetri, S. R., Canedo, A., & Wan, J. (2016). Acoustic Side-Channel Attacks on Additive Manufacturing Systems. *2016 ACM/IEEE 7th Int Conf Cyber-Physical Syst ICCPS 2016-Proceedings 2016*. <https://doi.org/10.1109/ICCPS.2016.7479068>
- Alabi, M. O. (2018). Big data, 3D printing technology, and industry of the future. *International Journal of Big Data and Anal Healthcare*, 2, 1–20. <https://doi.org/10.4018/ijbdah.2017070101>
- Aoyagi, K., Wang, H., Sudo, H., & Chiba, A. (2019). Simple method to construct process maps for additive manufacturing using a support vector machine. *Additive Manufacturing*, 27, 353–362. <https://doi.org/10.1016/J.ADDMA.2019.03.013>
- Banga, S., Gehani, H., & Bhilare, S. (2018). 3D topology optimization using convolutional neural networks. *ArxivOrg*. <https://doi.org/10.48550/arXiv.1808.07440>
- Bendsoe, M. (1999). *Material interpolation schemes in topology optimization*. Amsterdam: Springer. <https://doi.org/10.1007/s004190050248>

- Bennett, J., Dudas, R., Jian Cao, J. and Ehmann, K. (2016). "Control of heating and cooling for direct laser deposition repair of cast iron components." Northwestern University, Evanston, IL uluslararası esnek otomasyon sempozyumu (ISFA) , IEEE (2016). <https://doi.org/10.1109/ISFA.2016.7790166>
- Caggiano, A., Zhang, J., Alfieri, V., Caiazzo, F., Gao, R., & Teti, R. (2019). Machine learning-based image processing for on-line defect recognition in additive manufacturing. *CIRP Annals*, 68, 451–454. <https://doi.org/10.1016/J.CIRP.2019.03.021>
- Caiazzo, F., & Caggiano, A. (2018). Laser Direct metal deposition of 2024 al alloy: Trace geometry prediction via machine learning. *Materials*, 11, 444. <https://doi.org/10.3390/MA11030444>
- Chan, S., & Lu, Y. (2018). Data-driven cost estimation for additive manufacturing in cybermanufacturing. Amsterdam: Elsevier. <https://doi.org/10.1016/j.jmsy.2017.12.001>
- Charalampous, P., Kostavelis, I., Kontodina, T., & Tzovaras, D. (2021). Learning-based error modeling in FDM 3D printing process. *Rapid Prototyping Journal*, 27, 507–517. <https://doi.org/10.1108/RPJ-03-2020-0046>
- Chen, C., Chen, G.X., Yu, Z.H. and Wang, Z.H. (2014). "A new method for reproducing oil paintings based on 3D printing." *Appl. Mech. Mater.* Pages 644–650, pp. 2386–2389. <https://doi.org/10.3390/polym12112536>
- Chen, Q., Guillemot, G., Gandin, C.A. and Bellet, M. (2017). "Three-dimensional finite element thermomechanical modeling of additive manufacturing by selective laser melting for ceramic materials." *Addit. Manuf.* 2017, 16, pp. 124–137. <https://doi.org/10.1016/j.addma.2017.02.005>
- Chowdhury, S., Mhapsekar, K., & Anand, S. (2018). Part build orientation optimization and neural network-based geometry compensation for additive manufacturing process. *Journal of Manufacturing Science and Engineering*, 1, 140. <https://doi.org/10.1115/1.4038293>
- Ding, N., Benoit, C., Foggia, G. Bésanger, Y. & Wurtz, F. (2016). Neural Network-Based Model Design for Short-Term Load Forecast in Distribution Systems. *IEEE Transactions on Power Systems*, Volume: 31, Issue: 1, Page(s): 72 – 81. <https://doi.org/10.1109/TPWRS.2015.2390132>
- Dowling, L., Kennedy, J., O’Shaughnessy, S., & Trimble, D. (2020). A review of critical repeatability and reproducibility issues in powder bed fusion. *Materials and Design*, 186, 108346. <https://doi.org/10.1016/j.matdes.2019.108346>
- Dumais, S. T. (2004). Latent semantic analysis. *Annual Review of Information Science and Technology*, 38, 188–230. <https://doi.org/10.1002/aris.1440380105>
- Everton, S.K., Hirsch, M., Stavroulakis, P.I., Leach, R.K. & Clare, A.T. Review of in-situ process monitoring and in-situ metrology for metal additive manufacturing *Mater. Des.*, 95 (2016), pp. 431-445. <https://doi.org/10.1016/j.matdes.2016.01.099>
- Francis, J., & Letters, L.B.-M. (2019). Deep learning for distortion prediction in laser-based additive manufacturing using big data. Amsterdam: Elsevier. <https://doi.org/10.1016/j.mfglet.2019.02.001>
- Frazier, W. E. (2014). Metal additive manufacturing: A review. *Journal of Materials Engineering and Performance*, 23, 1917–1928. <https://doi.org/10.1007/S11665-014-0958-Z/FIGURES/9>
- Fu, F., Zhang, Y. Chang, G. and Dai, J. (2016). "Analysis on the physical mechanism of laser cladding crack and its influence factors." *Optik* Volume 127, Issue 1, January 2016, pp. 200-202. <https://doi.org/10.1016/j.ijleo.2015.10.043>
- Gobert, C., Reutzel, E. W., Petrich, J., Nassar, A. R., & Phoha, S. (2018). Application of supervised machine learning for defect detection during metallic powder bed fusion additive manufacturing using high resolution imaging. *Additive Manufacturing*, 21, 517–528. <https://doi.org/10.1016/J.ADDMA.2018.04.005>
- Gorunov, A. (2018) "Complex refurbishment of titanium turbine blades by applying heat-resistant coatings by direct metal deposition." *Eng Fail Anal*, 86 (2018), pp. 115-130. <https://doi.org/10.1016/j.engfailanal.2018.01.001>

- Grasso, M. and Colosimo, B.M. (2017). "Process defects and in situ monitoring methods in metal powder bed fusion." a review[J] Meas Sci Technol, 28 (4) (2017), Article 044005. <https://doi.org/10.1088/1361-6501/aa5c4f>
- Grasso, M., Demir, A. G., Previtali, B., & Colosimo, B. M. (2018). In situ monitoring of selective laser melting of zinc powder via infrared imaging of the process plume. Robot Computer Integrating Manufacturing, 49, 229–239. <https://doi.org/10.1016/J.RCIM.2017.07.001>
- Grasso, M., Laguzza, V., Semeraro, Q., & Colosimo, B. M. (2017). In-process monitoring of selective laser melting: spatial detection of defects via image data analysis. American Society Mechanical Engineering, 2017, 139(5). <https://doi.org/10.1115/1.4034715>
- Grierson, D. R., & Quayle, S. D. (2021). Machine learning for additive manufacturing. Encyclopedia, 3, 1541–1556. <https://doi.org/10.1016/j.matt.2020.08.023>
- Gu, G. X., Chen, C. T., Richmond, D. J., & Buehler, M. J. (2018). Bioinspired hierarchical composite design using machine learning: Simulation, additive manufacturing, and experiment. Material Horizons, 5, 939–945. <https://doi.org/10.1039/C8MH00653A>
- Gunther, D., Pirehgalin, M. F., Weis, I., Vogel-Heuser, B. (2020). Condition monitoring for the Binder Jetting AM-process with machine learning approaches. Proceedings - 2020 IEEE Conference Industrial Cyberphysical Systems ICPS 2020 2020:417–20. <https://doi.org/10.1109/ICPS48405.2020.9274716>
- Guo, N., & Leu, M. C. (2013). Additive manufacturing: Technology, applications and research needs. Frontiers of Mechanical Engineering, 8, 215–243. <https://doi.org/10.1007/s11465-013-0248-8>
- Heralić, A., Christiansson, A.K. & Lennartson, B. (2012). "Height control of laser metal-wire deposition based on iterative learning control and 3D scanning". Optics and Lasers in Engineering. Volume 50, Issue 9, September 2012, Pages 1230-1241. <https://doi.org/10.1016/j.optlaseng.2012.03.016>
- Hojjati, A., Adhikari, A., Struckmann, K., Chou, E. J., Ngoc, T., Nguyen, T., Madan, K., Winslett, M.S., Gunter, C.A., King, W.P., (2016). Leave Your Phone at the Door: Side Channels that Reveal Factory Floor Secrets. In: Proceedings of 2016 ACM SIGSAC Conference on Computer Communications Security. <https://doi.org/10.1145/2976749>
- Jia, C. B., Liu, X. F., Zhang, G. K., Zhang, Y., Yu, C. H., & Wu, C. S. (2021). Penetration/keyhole status prediction and model visualization based on deep learning algorithm in plasma arc welding. International Journal of Advanced Manufacturing Technology, 117, 3577–3597. <https://doi.org/10.1007/s00170-021-07903-9>
- Jin, Z., Zhang, Z., Demir, K., & Gu, G. X. (2020). Machine learning for advanced additive manufacturing. Matter, 3, 1541–1556. <https://doi.org/10.1016/j.matt.2020.08.023>
- Kang, H. S., Lee, J. Y., Choi, S., Kim, H., Park, J. H., Son, J. Y., et al. (2016). Smart manufacturing: Past research, present findings, and future directions. International Journal of Precision Engineering Manufacturing - Green Technology, 3, 111–128. <https://doi.org/10.1007/s40684-016-0015-5>
- Khazadeh, M., Rao, P., Jafari-Marandi, R., Smith, B. K., Tschopp, M. A., & Bian, L. (2018). Quantifying geometric accuracy with unsupervised machine learning: Using self-organizing map on fused filament fabrication additive manufacturing parts. Journal of Manufacturing Science and Engineering. <https://doi.org/10.1115/1.4038598>
- Kulkarni, P., Marsan, A., & Dutta, D. (2000). Review of process planning techniques in layered manufacturing. Rapid Prototyp J, 6, 18–35. <https://doi.org/10.1108/13552540010309859>
- Kumar, S. (2016). Ultrasonic assisted friction stir processing of 6063 aluminum alloy. Archives of Civil and Mechanical Engineering, 16, 473–484. <https://doi.org/10.1016/j.acme.2016.03.002>
- Kumar, S., & Kar, A. (2021). A review of solid-state additive manufacturing processes. Transactions on Indian Natational Academic Engineering, 6, 955–973. <https://doi.org/10.1007/S41403-021-00270-7>

- Kumar, S., & Kishor, B. (2021). Ultrasound added additive manufacturing for metals and composites: Process and control. Singapore: Springer. https://doi.org/10.1007/978-981-16-3184-9_3
- Kumar, S., & Wu, C. (2021a). Strengthening effects of tool-mounted ultrasonic vibrations during friction stir lap welding of Al and Mg alloys. *Metallurgical and Materials Transactions a, Physical Metallurgy and Materials Science*, 52, 2909–2925. <https://doi.org/10.1007/s11661-021-06282-w>
- Kumar, S., & Wu, C. (2021b). Eliminating intermetallic compounds via Ni interlayer during friction stir welding of dissimilar Mg/Al alloys. *Journal of Material Research and Technology*, 15, 4353–4369. <https://doi.org/10.1016/J.JMRT.2021.10.065>
- Kumar, S., & Wu, C. S. (2018). A novel technique to join Al and Mg alloys: Ultrasonic vibration assisted linear friction stir welding. *Materials Today Proceedings*, 5, 18142–18151. <https://doi.org/10.1016/j.matpr.2018.06.150>
- Kumar, S., & Wu, C. S. (2020a). Suppression of intermetallic reaction layer by ultrasonic assistance during friction stir welding of Al and Mg based alloys. *Journal of Alloys and Compounds*, 827, 154343. <https://doi.org/10.1016/j.jallcom.2020.154343>
- Kumar, S., Wu, C. S., & Shi, L. (2020b). Intermetallic diminution during friction stir welding of dissimilar Al/Mg alloys in lap configuration via ultrasonic assistance. *Metallurgical and Materials Transactions a: Physical Metallurgy and Materials Science*, 51, 5725–5742. <https://doi.org/10.1007/s11661-020-05982-z>
- Kumar, S., Wu, C. S., & Song, G. (2020c). Process parametric dependency of axial downward force and macro- and microstructural morphologies in ultrasonically assisted friction stir welding of Al/Mg alloys. *Metallurgical and Materials Transactions a: Physical Metallurgy and Materials Science*, 51, 2863–2881. <https://doi.org/10.1007/s11661-020-05716-1>
- Kumar, S., Wu, C. S., Padhy, G. K., & Ding, W. (2017). Application of ultrasonic vibrations in welding and metal processing: A status review. *Journal of Manufacturing Processes*, 26, 295–322. <https://doi.org/10.1016/j.jmapro.2017.02.027>
- Kumar, S., Wu, C. S., Sun, Z., & Ding, W. (2019). Effect of ultrasonic vibration on welding load, macrostructure, and mechanical properties of Al/Mg alloy joints fabricated by friction stir lap welding. *International Journal of Advanced Manufacturing Technology*, 100, 1787–1799. <https://doi.org/10.1007/s00170-018-2717-z>
- Kumar, S., Gopi, T., Harikeerthana, N., Gupta, M.K., Gaur, V., Krolczyk, G. & Wu, C.S. (2022). Machine learning techniques in additive manufacturing: a state of the art review on design, processes and production control. *Journal of Intelligent Manufacturing*, Volume 34, pages 21–55. <https://doi.org/10.1007/s10845-022-02029-5>
- Kwon, O., Kim, H. G., Ham, M. J., Kim, W., Kim, G.-H., Cho, J.-H., et al. (2018). A deep neural network for classification of melt-pool images in metal additive manufacturing. *Journal of Intelligence Manufacturing*, 31, 375–386. <https://doi.org/10.1007/S10845-018-1451-6>
- Meng, L., McWilliams, B., Jarosinski, W., Park, H. Y., Jung, Y. G., Lee, J., et al. (2020). Machine learning in additive manufacturing: a review. *JOM Journal of the Minerals Metals and Materials Society*, 72, 1. <https://doi.org/10.1007/s11837-020-04155-y>
- Mozaffar, M., Paul, A., Al-Bahrani, R., Wolff, S., Choudhary, A., Agrawal, A., et al. (2018). Data-driven prediction of the high-dimensional thermal history in directed energy deposition processes via recurrent neural networks. *Manufacturing Letters*, 18, 35–39. <https://doi.org/10.1016/J.MFGLET.2018.10.002>
- Noriega, A., Blanco, D., Alvarez, B. J., & Garcia, A. (2013). Dimensional accuracy improvement of FDM square cross-section parts using artificial neural networks and an optimization algorithm. *International Journal of Advanced Manufacturing Technology*, 69, 2301–2313. <https://doi.org/10.1007/S00170-013-5196-2>
- Qi, X., Chen, G., Li, Y., Cheng, X., & Li, C. (2019). Applying neural-network-based machine learning to additive manufacturing: Current applications, challenges, and future perspectives. *Engineering*, 5, 721–729. <https://doi.org/10.1016/J.ENG.2019.04.012>

- Rawat, S., & Shen, M. H. H. (2018). A novel topology design approach using an integrated deep learning network architecture. <https://doi.org/10.48550/arXiv.1808.02334>
- Razvi, S. S., Feng, S., Narayanan, A., Lee, Y. T. T., & Witherell, P. (2019). A review of machine learning applications in additive manufacturing. Proceedings ASME Design Engineering Technical Conference. <https://doi.org/10.1115/DETC2019-98415>
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65, 386–408. <https://doi.org/10.1037/h0042519>
- Sames, W.J. and Pannala, S. (2016). “The metallurgy and processing science of metal additive manufacturing” [J] *Int Mater Rev*, 61 (5), pp. 315 – 360. <https://doi.org/10.1080/09506608.2015.1116649>
- Scime, L., & Beuth, J. (2018a). Anomaly detection and classification in a laser powder bed additive manufacturing process using a trained computer vision algorithm. *Additive Manufacturing*, 19, 114–126. <https://doi.org/10.1016/J.ADDMA.2017.11.009>
- Scime, L., & Beuth, J. (2018b). A multi-scale convolutional neural network for autonomous anomaly detection and classification in a laser powder bed fusion additive manufacturing process. *Additive Manufacturing*, 24, 273–286. <https://doi.org/10.1016/J.ADDMA.2018.09.034>
- Scime, L., & Beuth, J. (2019). Using machine learning to identify in-situ melt pool signatures indicative of flaw formation in a laser powder bed fusion additive manufacturing process. *Additive Manufacturing*, 25, 151–165. <https://doi.org/10.1016/J.ADDMA.2018.11.010>
- Shinde, P. P., & Shah, S. (2018). A Review of Machine Learning and Deep Learning Applications. In: Proceedings - 2018 4th International Conference Computer Communication Control Autom ICCUBEA 2018. <https://doi.org/10.1109/ICCUBEA.2018.8697857>
- Singh, S., Ramakrishna, S., & Singh, R. (2017). Material issues in additive manufacturing: A review. *Journal of Manufacturing Processes*, 25, 185–200. <https://doi.org/10.1016/j.jmapro.2016.11.006>
- Sterling, A.J., Torries, B., Shamsaei, N., Thompson, S.M. and W.Seely, D.W. (2016). “Fatigue behavior and failure mechanisms of direct laser deposited Ti–6Al–4V.” *Materials Science and Engineering: A Volume 655*, 8 February 2016, pp. 100-112. <https://doi.org/10.1016/j.msea.2015.12.026>
- Sutton, R. S., & Barto, A. G. (2015). *Reinforcement Learning* (2nd ed.). New York: The MIT Press.
- Tapia, G., Elwany, A. H., & Sang, H. (2016). Prediction of porosity in metal-based additive manufacturing using spatial Gaussian process models. *Additive Manufacturing*, 12, 282–290. <https://doi.org/10.1016/J.ADDMA.2016.05.009>
- Tapia, G., Khairallah, S., Matthews, M., King, W. E., & Elwany, A. (2017). Gaussian process-based surrogate modeling framework for process planning in laser powder-bed fusion additive manufacturing of 316L stainless steel. *International Journal of Advanced Manufacturing Technology*, 94, 3591–3603. <https://doi.org/10.1007/S00170-017-1045-Z>
- Thompson, M. K., Moroni, G., Vaneker, T., Fadel, G., Campbell, R. I., Gibson, I., et al. (2016). Design for additive manufacturing: Trends, opportunities, considerations, and constraints. *CIRP Annals - Manufacturing Technology*, 65, 737–760. <https://doi.org/10.1016/j.cirp.2016.05.004>
- Vaezi, M., Seitz, H. & Yang, S. (2013). A review on 3D micro-additive manufacturing technologies. *The International Journal of Advanced Manufacturing Technology*. Volume 67, pages 1721–1754. <https://doi.org/10.1007/s00170-012-4605-2>
- Wang, C., Tan, X. P., Tor, S. B., & Lim, C. S. (2020). Machine learning in additive manufacturing: State-of-the-art and perspectives. *Additive Manufacturing*, 36, 101538. <https://doi.org/10.1016/j.addma.2020.101538>

- Wang, C., Tan, X., Liu, E., & Tor, S. B. (2018b). Process parameter optimization and mechanical properties for additively manufactured stainless steel 316L parts by selective electron beam melting. *Materials and Design*, 147, 157–166. <https://doi.org/10.1016/J.MATDES.2018.03.035>
- Wang, L., Törngren, M., & Onori, M. (2015). Current status and advancement of cyber-physical systems in manufacturing. *Journal of Manufacturing Systems*, 37, 517–527. <https://doi.org/10.1016/J.JMSY.2015.04.008>
- Wang, T., Kwok, T. H., Zhou, C., & Vader, S. (2018a). In-situ droplet inspection and closed-loop control system using machine learning for liquid metal jet printing. *Journal of Manufacturing Systems*, 47, 83–92. <https://doi.org/10.1016/J.JMSY.2018.04.003>
- Wang, Y. and Li, X. (2020). “An accurate finite element approach for programming 4D-printed self-morphing structures produced by fused deposition modeling.” *Mech. Mater.* 2020, 151, pp. 103628. <https://doi.org/10.1016/j.mechmat.2020.103628>
- Weiss, S. M., Dhurandhar, A., Baseman, R. J., White, B. F., Logan, R., Winslow, J. K., et al. (2014). Continuous prediction of manufacturing performance throughout the production lifecycle. *Journal of Intelligent Manufacturing*, 27, 751–763. <https://doi.org/10.1007/S10845-014-0911-X>
- Widrow, B., & Lehr, M. A. (1990). 30 years of adaptive neural networks: perceptron, madaline, and backpropagation. *Proceedings of the IEEE*, 78, 1415–1442. <https://doi.org/10.1109/5.58323>
- Wu, D., Jennings, C., Terpenney, J., Gao, R. X., & Kumara, S. (2017). A comparative study on machine learning algorithms for smart manufacturing: Tool wear prediction using random forests. *Journal of Manufacturing Science and Engineering Transactions on ASME*, 2017, 139. <https://doi.org/10.1115/1.4036350>
- Wu, D., Rosen, D. W., Wang, L., & Schaefer, D. (2015a). Cloud-based design and manufacturing: A new paradigm in digital manufacturing and design innovation. *Computer Design*, 59, 1–14. <https://doi.org/10.1016/J.CAD.2014.07.006>
- Wu, H., Wang, Y., & Yu, Z. (2015b). In situ monitoring of FDM machine condition via acoustic emission. *International Journal of Advanced Manufacturing Technology*, 84, 1483–1495. <https://doi.org/10.1007/S00170-015-7809-4>
- Wu, H., Yu, Z., & Wang, Y. (2016a). Real-time FDM machine condition monitoring and diagnosis based on acoustic emission and hidden semi-Markov model. *International Journal of Advanced Manufacturing Technology*, 90, 2027–2036. <https://doi.org/10.1007/S00170-016-9548-6>
- Wu, H., Yu, Z., et al. (2016b). A new approach for online monitoring of additive manufacturing based on acoustic emission. *Asmedigitalcollection*. <https://doi.org/10.1115/MSEC2016-8551>
- Wu, M., Phoha, V. V., Moon, Y. B., & Belman, A. K. (2016). Detecting malicious defects in 3D printing process using machine learning and image classification. *ASME International Mechanical Engineering & Congress and Exposition Proceedings*. <https://doi.org/10.1115/IMECE201667641>
- Wu, M., Song, Z., & Moon, Y. B. (2017). Detecting cyber-physical attacks in CyberManufacturing systems with machine learning methods. *Journal of Intelligence and Manufacturing*, 30, 1111–1123. <https://doi.org/10.1007/S10845-017-1315-5>
- Wu, X., Xu, C., Zhang, Z. and Guo, C. (2020). “Modeling and visualization of layered curing conversion profile in ceramic mask projection stereolithography process.” *Ceram. Int.* 2020, 46, pp. 25750–25757. <https://doi.org/10.1016/j.ceramint.2020.07.053>
- Xing, C., Jia, C., Han, Y., Dong, S., Yang, J., & Wu, C. (2020). Numerical analysis of the metal transfer and welding arc behaviors in underwater flux-cored arc welding. *International Journal of Heat and Mass Transfer*, 153, 119570. <https://doi.org/10.1016/J.IJHEATMASSTRANSFER.2020.119570>

Yang, J., Li, F., Wang, Z. and Zeng, X. (2015). "Cracking behavior and control of Rene 104 superalloy produced by direct laser fabrication." *Journal of Materials Processing Technology* Volume 225, November 2015, Pages 229-239. <https://doi.org/10.1016/j.jmatprotec.2015.06.002>

Yao, X., Moon, S. K., & Bi, G. (2017). A hybrid machine learning approach for additive manufacturing design feature recommendation. *Rapid Prototyping Journal*, 23, 983–997. <https://doi.org/10.1108/RPJ-03-2016-0041>

Zhang, H.-C., & Huang, S. H. (1995). Applications of neural networks in manufacturing: A state-of-the-art survey. *International Journal of Production Research*, 33, 705–728. <https://doi.org/10.1080/00207549508930175>

Zhang, Y. and Chou, Y.K. (2006). "Three-dimensional finite element analysis simulations of the fused deposition modelling process." *Proc. Inst. Mech. Eng. Part B J. Eng. Manuf.*, 220, pp. 1663–1671. <https://doi.org/10.1243/09544054JEM572>

Zhang, Y., Hong, G. S., Ye, D., Zhu, K., & Fuh, J. Y. H. (2018b). Extraction and evaluation of melt pool, plume and spatter information for powder-bed fusion AM process monitoring. *Materials and Design*, 156, 458–469. <https://doi.org/10.1016/J.MATDES.2018.07.002>

Zhang, Y., Jarosinski, W., Jung, Y.G. and Zhang, J. (2018). "Additive manufacturing processes and equipment. In *Additive Manufacturing: Materials, Processes, Quantifications and Applications.*" Elsevier: Amsterdam, The Netherlands. pp. 39–51. <https://doi.org/10.1016/B978-0-12-812155-9.00002-5>

Zhang, Z., Liu, Z., & Wu, D. (2021). Prediction of melt pool temperature in directed energy deposition using machine learning. *Additive Manufacturing*, 37, 101692. <https://doi.org/10.1016/J.ADDMA.2020.101692>