



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 kullanılabileceğini 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, Internet 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°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 ölçümleyebilecek 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

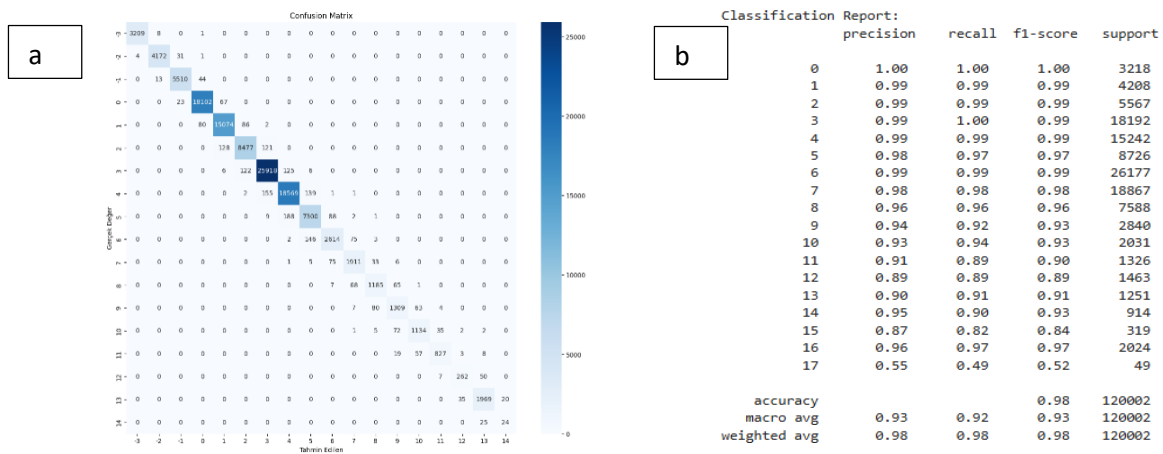
Veri setimiz Kaggle sunucusu kullanılarak SVM, KNN, LSTM ve XGBOOST modelleri ile tahmin işlemini gerçekleştirildi. Veri setinde yaklaşık 600.000 veri ve on adet öznitelik değeri bulunmaktadır. Öznitelik değerlerinden hedef değer olarak "sıcaklık" bilgisi seçilmiştir. Yani çalışmada kullanılan modeller 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.

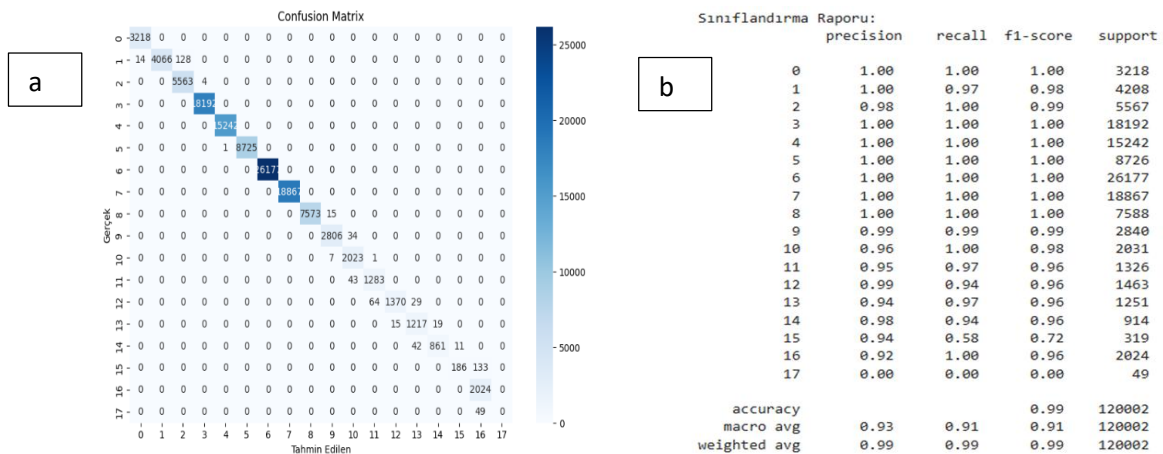


Şekil 9. a. SVM Modeli Confusion Matrix'i b. SVM Modeli Sınıflandırma Raporu



Şekil 10. a. KNN Modeli Confusion Matrix'i b. KNN Modeli Sınıflandırma Raporu

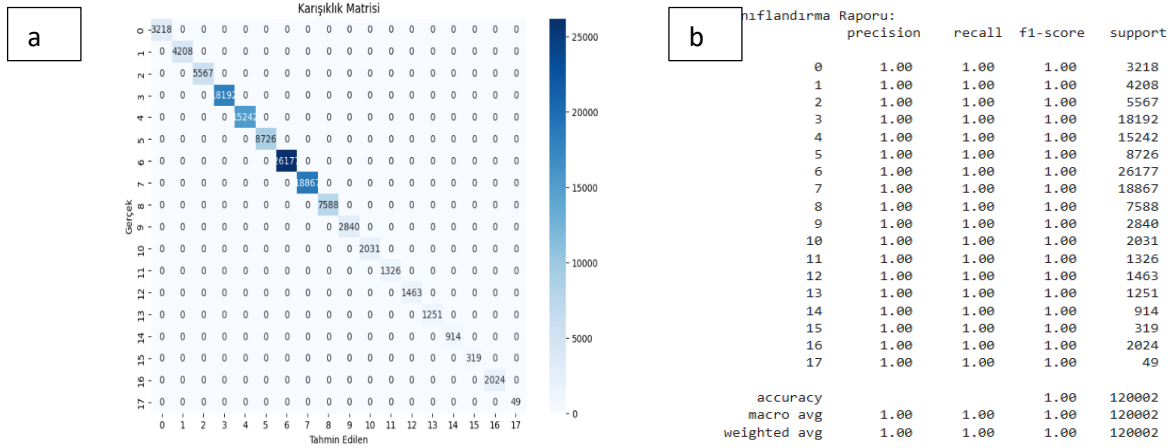
Şekil 11. a.'da LSTM modelinin confusion matrix' i görülmektedir. Şekil 11. b.'de LSTM modelinin tahmin edilen sınıflandırma raporunu görülmektedir.



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>