



# Kahramanmaraş Sütçü İmam University

## Journal of Engineering Sciences



Geliş Tarihi : 21.11.2022  
Kabul Tarihi : 04.03.2023

Received Date : 21.11.2022  
Accepted Date : 04.03.2023

### DALGACIK EVRİŞİMSEL SİNİR AĞI YÖNTEMİ İLE KORONAVİRÜS HASTALIĞININ TESPİTİ

#### DETECTION OF CORONAVIRUS DISEASE USING WAVELET CONVOLUTIONAL NEURAL NETWORK METHOD

Abidin ÇALIŞKAN<sup>1</sup> (ORCID: 0000-0001-5039-6400)

<sup>1</sup>Batman Üniversitesi, Bilgisayar Mühendisliği, Batman, Türkiye

\*Sorumlu Yazar / Corresponding Author: Abidin ÇALIŞKAN, abidin.caliskan@batman.edu.tr

#### ÖZET

Koronavirüs (Kovid-19), 2019 yılından itibaren dünya genelinde hissedilen ve ölümcül sonuçları olan RNA tipi bir virüs türüdür. Kovid-19 virüsü, genellikle akciğerde etkinliğini göstermekte olup, çeşitli solunum yolu enfeksiyonlarına neden olmaktadır. Bu çalışmada, Kovid-19 tanısını gerçekleştirebilen yapay zekâ tabanlı yeni bir Evrişimsel Sinir Ağı (ESA) modeli önerilmiştir. Uzamsal ve spektral yaklaşımlar, görüntü analizlerinde ve nesne tanımlama gibi işlemlerde sıkça kullanılmaktadır. ESA modellerinde genellikle görüntüler uzamsal alanlarda işlenir ve eğitim sürecini buradan elde ettikleri öznitelikleri kullanarak tamamlarlar. Bu çalışmada önerilen ESA modeline farklı bir bakış açısı katabilmek için girdi görüntülerini mekânsal ve spektral olarak işlenmesi gerçekleştirildi. Böylece çok çözünürlüklü farklı özniteliklerin çıkartılması sağlandı. Çok çözünürlüklü analiz adımlarının eksik kısımlarını dalgacık dönüşümü denilen yöntem kullanılarak tamamlandı. Sonuç olarak, önerilen yaklaşım olan Dalgacık ESA (D-ESA) ile gerçekleştirilen deneysel analizlerde %98,48 genel doğruluk başarıları elde edilmiştir.

**Anahtar Kelimeler:** Derin öğrenme, evrişimsel sinir ağı, dalgacık sinir ağı, solunum hastalıkları, koronavirüs.

#### ABSTRACT

Coronavirus (Covid-19) is a type of RNA-type virus that has been felt around the world since 2019 and has deadly consequences. The Covid-19 virus, usually shows its effectiveness in the lungs and causes various respiratory tract infections. In this study, a new artificial intelligence-based Convolutional Neural Network (CNN) model that can diagnose Covid-19 has been proposed. Spatial and spectral approaches are frequently used in image analysis and operations such as object identification. CNN models, on the other hand, generally process images in spatial areas and complete the training process by using the attributes obtained from there. In order to add a different perspective to the CNN model proposed in this study, the spatial and spectral processing of the input images was carried out. Thus, it was possible to extract different multi-resolution features. The missing parts of the multi-resolution analysis steps were completed using the so-called wavelet transform method. As a result, the overall accuracy of 98.48% was achieved in the experimental analyzes performed with the proposed approach, Wavelet CNN (W-CNN).

**Keywords:** Deep learning, convolutional neural network, wavelet neural network, respiratory diseases, coronavirus.

## GİRİŞ

Kovid-19 salgını dünyada büyük endişe kaynağı olmuş ve milyonlarca kişinin ölümüne de neden olmuştur (Le Dinh vd., 2022). Kovid-19 virüsü RNA tipli bir virüs olup, çeşitli varyantlarının zaman içerisinde ortaya çıkmasından dolayı, virüse karşı mücadele güçlendirmiştir (Muneer vd., 2022). Salgın süresinde dünyada uzun süren kapanmalar nedeniyle ülke ekonomileri zarar görmüş ve birçok insan geçim sıkıntısı yaşamıştır. Kovid-19 virüsünün genetik evrime sahip olması tanı/televi süreçlerini olumsuz etkilemiştir (Toğaçar, 2021; Alyasseri vd., 2022). Bütün bu süreçler bilim insanlarını Kovid-19 virüsünün tanı/televi sürecine odaklanmasına neden olmuştur. Kovid-19 hastalığının doğrudan etkilediği ve zarar verdiği organ akciğerlerdir (Shahin vd., 2022). Akciğerlere verdiği tahribat ile solunum yolu enfeksiyonlarına yol açmakta ve hastaların nefes alış verişlerini zayıflatmaktadır. Hastalığın tanı sürecinde genellikle akciğer görüntüleri ve polimeraz zincir reaksiyonu kullanılmıştır. Bu görüntüler, çeşitli görüntüleme teknikleri (X-ışın, Röntgen, vb.) kullanılarak elde edilmiştir (Bhardwaj & Kaur, 2021; Fan vd., 2022).


Tıbbi görüntüler son zamanlarda araştırmacılar ve bilim adamları tarafından ilgi görmeye başlamıştır ve bu ilgi disiplinler arası çalışmaların ortaya çıkmasını sağlamıştır (Jin vd., 2022). Yapay zekâ tabanlı yaklaşımlar tıbbi görüntülerde hastalığın tanı sürecine katkı sunmuştur (Yu vd., 2021). Kovid-19 hastalığının tespitinde yapay zekâ tabanlı birçok çalışma literatürde yer almıştır (Zhan & Santos-Paulino, 2021; Subramanian vd., 2022).

Bu çalışmalardan bazıları incelendiğinde; Abdulkareem vd., Kovid-19 hastalığının tespiti için ESA, yığılanmış otomatik kodlayıcı ve Derin Öğrenme (DÖ) sinir ağı modellerini kullanarak, çalışmalarında %88,30 genel doğruluk başarısı elde etmişlerdir (Abdulkareem vd., 2022). Kini vd., Kovid-19 hastalığının tespitinde topluluk öğrenme modeline dayalı hibrit bir model tasarladılar (Kini vd., 2022). Önerdikleri model, ResNet ve DenseNet mimarilerini birleştiren bir yaklaşım içermiştir. Deneysel analizlerde %98,98 genel doğruluk başarısı elde ettiler. Apostolopoulos & Mpesiana (2020), 224 Kovid-19, 700 Bakteriyel Pnömoni ve 504 Normal X-ray görüntüsünü içeren, 1427 X-ray görüntüsünün veri setini sırasıyla; %96,78, %98,66 ve %96,46 doğruluk, duyarlılık ve özgüllük ile sınıflandırmak için transfer öğrenme yaklaşımını önermişlerdir. Maghdid vd., 310 normal, 330 bakteriyel pnömoni, 327 viral pnömoni ve 284 Kovid-19 pnömoni görüntüsü üzerinde transfer öğrenme yaklaşımını uygulamışlardır (Maghdid vd., 2021). Deneylerin sonucunda, önceden eğitilmiş ağı üzerinden kullanılan modellerde; %98 doğruluk, modifiye ESA kullanılarak da %94,1 doğruluk elde etmişlerdir. Deb vd., DÖ ile dört farklı ESA modelinin özellikleri kullanılarak önerdikleri modelde %88,98 doğruluk oranı elde etmişlerdir (Deb vd., 2022). Karthik vd., Kovid-19 pnömonisi, viral pnömoni, bakteriyel pnömoni vakaları ve normal göğüs röntgenlerini kullanarak belirli pnömoni sınıflarını belirlemek için çift dallı artık ESA önererek, %99,8 doğruluk (Karthik vd., 2021), Zhang vd., kombine model, DenseNet optimizasyonu ve transfer öğrenmeye dayalı yöntem geliştirerek önerdikleri modelde %96,30 oranında doğruluk elde edilmişlerdir (Zhang vd., 2021). Narin vd., transfer öğrenme tekniği ile iki sınıf (normal ve Kovid-19) için bir sinir ağı önererek, ResNet-50 modeli kullanarak maksimum %98 tanıma oranı, önerilen diğer iki model olan InceptionV3 ve Inception-ResNetV2 ile de sırasıyla %97 ve %87 doğruluk (Narin vd., 2021), Panwar vd., çalışmalarında hastalıklı bölgeyi renklendirmek için VGG16 transfer öğrenme yöntemi ve gradyan sınıf aktivasyon haritası yöntemlerini kullanarak, %95,61 doğruluk oranı elde etmişlerdir (Panwar vd., 2020).

Makalenin deneysel analizlerinde gerçekleştirilmesi istenen hedef, X-ışınlarından elde edilmiş göğüs görüntülerini kullanarak Kovid-19 hastalığının diğer türlere (zatürre, normal) göre başarılı bir şekilde sınıflandırılmasıdır. Bu amaç doğrultusunda, ESA modellerinden farklı bir yaklaşım izlenerek tasarlanmış olan D-ESA modeli, çalışmanın deneysel analizlerinde kullanılmıştır. Bu makale şu şekilde organize edilmiştir; veri kümesi ve önerilen yaklaşım hakkında detaylı bilgiler sırasıyla Bölüm 2 ve Bölüm 3'te verilmiştir. Gerçekleştirilmiş deneysel analiz ve sonuçları Bölüm 4'te verilmiştir. Son iki bölüm sırasıyla Tartışma ve Sonuç bölümlerinden oluşmuştur.

## VERİ KÜMESİ

Veri kümesi, X-ışınlı göğüs görüntülerinden oluşan kamuya erişimi açık görüntülerden oluşmaktadır (Raikote, 2019). Verilerin sınıf türleri; Kovid-19, normal ve zatürre olmak üzere, üç tür sınıf görüntülerinden oluşmaktadır. Görüntü kümesi "jpeg" formatında sıkıştırılmış ve çözünürlük boyutları sabit değildir. Görüntüler uzman doktorlar ve radyologlar tarafından kontrol edilmiş ve sınıflandırılmıştır. Veri kümesi Montreal Üniversitesi araştırmacıları tarafından kamuya sunulmuştur ve zatürre verileri RSNA web sitesinden temin edilmiştir. Her bir görüntü derinliği 8 bittir. Veri kümesi eğitim ve test olmak üzere iki klasörden oluşmaktadır. Görüntü kümesi hakkında bilgiler Tablo 1'de verilmiştir. Veri kümesinin sınıf türlerine göre alt görüntü örnekleri Şekil 1'de gösterilmiştir.



Şekil 1. Veri kümesi türleri; (a) Kovid-19, (b) Normal ve (c) Zatürre

Tablo 1. Veri Kümesi Hakkında İstatistiki Bilgiler

Veri kümesi	Sınıftürü	Görüntü sayısı	Toplam
Eğitim	Kovid-19	111	251
	Normal	70	
	Zatürre	70	
Test	Kovid-19	26	66
	Normal	20	
	Zatürre	20	

## YAPAY ZEKÂ MODELLERİ

### *Evrşimsel Sinir Ağı*

ESA, canlıların doğal görsel algılama mekanizmasından esinlenen bir DÖ mimarisidir (Gu vd., 2018). ESA modellerinin temel bileşenleri çok benzemekle beraber, literatürde çok sayıda ESA mimarisi vardır (Wang vd., 2020; Sunitha vd., 2022). ESA; evrşimsel, havuzlama ve tam bağlantılı katmanlar gibi çoklu yapıları kullanarak, geri yayılım yoluyla özelliklerin uzamsal hiyerarşilerini uyarlanabilir ve otomatik bir şekilde öğrenmek için tasarlanmıştır (Yamashita vd., 2018; Umer vd., 2022).

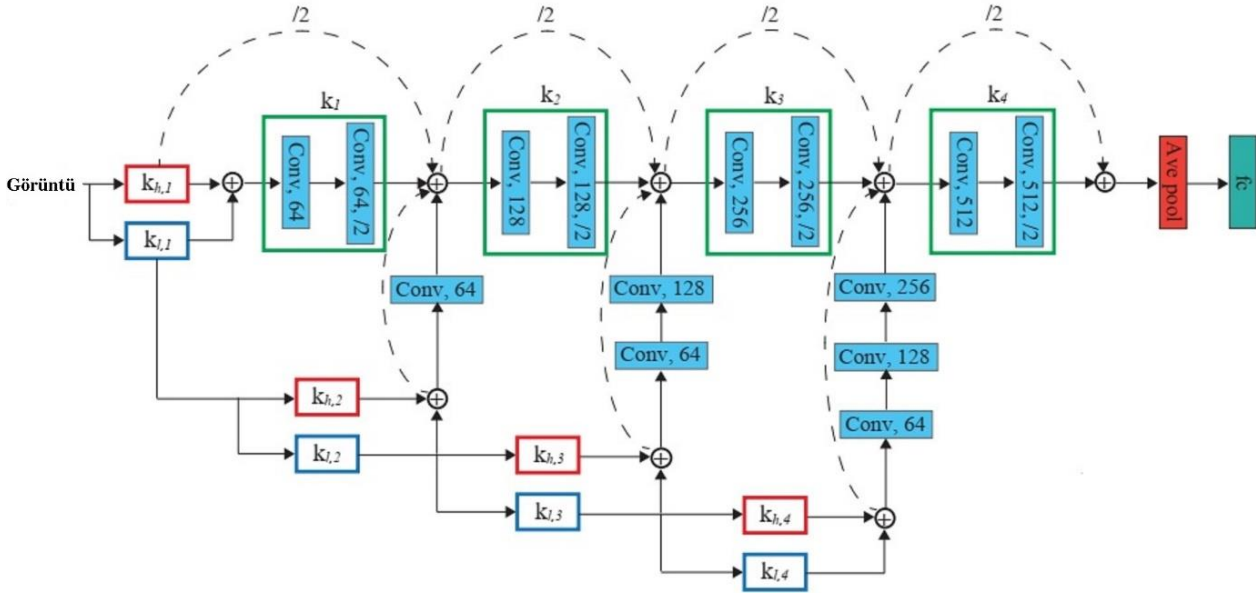
Evrşim ve havuzlama katmanları, özellik çıkarma işlemlerini gerçekleştirirken, tam bağlantılı katman da çıkarılan özellikleri sınıflandırır. Evrşim katmanı, özel bir doğrusal işlem türü olan evrşim gibi bazı matematiksel işlemlerden oluşan ESA da önemli bir rol oynar.

ESA'lar öncelikle girdinin görüntülerden oluşacağı temelini esas alarak, belirli veri türleri ile ilgilenme ihtiyacına en iyi uyacak şekilde kurulacak mimariye odaklanırlar (Sarvamangala & Kulkarni, 2021). ESA'nın temel farklılıklarından biri, ESA içindeki katmanların nöronların, girdinin yükseklik, genişlik olan uzamsal boyutluluğu ve derinlik olmak üzere üç boyutlu nöronlardan oluşmasıdır. Derinlik; Yapay Sinir Ağlarının (YSA) katman sayısı toplamını değil, aktivasyonun üçüncü boyutunu ifade etmektedir. YSA'dan farklı olarak, bir katmandaki nöronlar önceki katmanın sadece küçük bir bölgesine bağlanmaktadır (O'Shea & Nash, 2015).

### *Önerilen Yaklaşım: Dalgacık Evrşimsel Sinir Ağı Modeli*

Çok çözünürlüklü analizi ve ESA'ları tek bir modelde birleştiren yeni bir ESA mimarisi olan, D-ESA modeli önerilmiştir (Fujieda vd., 2018). Bir ESA, çok çözünürlüklü bir analizin sınırlı bir biçimi olarak görülebilir. Dalgacık dönüşümü yoluyla, çoklu çözünürlüklü analizin eksik kısımları tamamlanıp, tüm mimariye ek bileşenler olarak entegre edilebilir. D-ESA, geleneksel ESA'larda çoğunlukla kaybolan ancak, çoğu görüntü işleme görevinde faydalı olan spektral bilgiyi kullanmamıza izin verir. Deneyler, D-ESA'nın geleneksel ESA'lardan önemli ölçüde daha az parametreye sahipken, her iki görevde de mevcut modellerden daha iyi doğruluk elde edebildiğini göstermektedir (Nneji vd., 2021).

D-ESA'ların geleneksel ESA'lardan önemli ölçüde daha az sayıda eğitilebilir parametre ile daha iyi veya rekabetçi doğruluklar elde etmektedirler. Bu nedenle de modelin eğitilmesi daha kolay olup, geleneksel ESA'lardan daha az bellek tüketir ve aşırı doyuma da daha az eğilimlidirler (Singh & Singh, 2021; AbdulQader vd., 2023). Şekil 2, giriş görüntüsünün dört seviyeli ayrıştırılmasıyla D-ESA modelinin genel görünümünü göstermektedir.



Şekil 2. D-ESA Modelinin Genel Görünümü (Fujieda vd., 2018)

Şekil 2 de;  $k_l$  alçak geçiş filtre,  $k_h$  yüksek geçiren filtre,  $\oplus$  kanal bazında birleştirme,  $- \rightarrow$  projeksiyon kısayolunu ifade etmektedir.

D-ESA, girdi görüntüsünü  $3 \times 3$  çekirdekli ve  $1 \times 1$  dolgulu evrişim katmanları ile işler. Çıktının kanal sayısını evrişimden sonraki sayı belirtir. Özellik haritalarının boyutunu küçültmek için iki ve  $1 \times 1$  dolgu adımı  $3 \times 3$  evrişimli çekirdekler kullanılır. Ek olarak, girdi görüntüsü çoklu çözünürlüklü analiz yoluyla ayrıştırılır ve ayrıştırılan görüntüler kanal bazında birleştirilir. Projeksiyon kısayolları  $1 \times 1$  kıvrımlarla yapılır. Evrişim katmanlarının çıktısı, küresel ortalama havuzlama ve ardından tamamen bağlı bir katman (fc) ile vektörleştirilir. Çıktının boyutu, girdi veri kümesine dâhil edilen sınıfların sayısına eşittir (Fujieda vd., 2018).

## DENEYSSEL SONUÇLAR

Çalışmanın deneysel analizleri Jupyter Notebook arayüzü kullanılarak gerçekleştirilmiş olup, önerilen model python dilinde tasarlanmıştır. Donanımsal gereksinimler için Google Colab (2021) sunucusu kullanıldı. Deneysel analizlerin ölçümü için karmaşıklık matrisi kullanıldı. Karmaşıklık matrisinde, çeşitli metrikleri hesaplamak için, gerçek ve tahmin edilen kayıtların tutulduğu dört farklı performans metriği bulunmaktadır. Karmaşıklık matrisinin tanımlanmasında kullanılan metrikler; duyarlılık (Du), hassasiyet (Ha), özgüllük (Öz), f-skoru (F-skor) ve doğruluk (Do)'tur (Toğaçar vd. 2021). Metriklerin hesaplanmasında aşağıdaki denklemler kullanılmıştır (Denklem 1-5). Denklemler için kullanılan değişkenler şunlardır; doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP), yanlış negatif (YN)'tir (Çalışkan, 2022). Burada DP ve DN, doğru tanımlanmış pozitif ve negatif kayıtların sayısını gösterir. YP ve YN, yanlış tahmin edilen pozitif ve negatif sınıflara ait kayıt sayısını temsil eder.

Karmaşıklık matrisi Tablo 2'de, önerilen model için tercih edilen parametre değerleri de Tablo 3'te verilmiştir.

Tablo 2. Karmaşıklık Matrisi

		Tahmin	
		Normal	Hastalıklı
Gerçek	Normal	DP	YN
	Hastalıklı	YP	DN

$$D_u = \frac{DP}{(DP + YN)} \quad (1)$$

$$Ö_z = \frac{DN}{(DN + YP)} \quad (2)$$

$$H_a = \frac{DP}{(DP + YP)} \quad (3)$$


$$F - \text{skor} = \frac{(2xDP)}{(2xDP + YP + YN)} \quad (4)$$

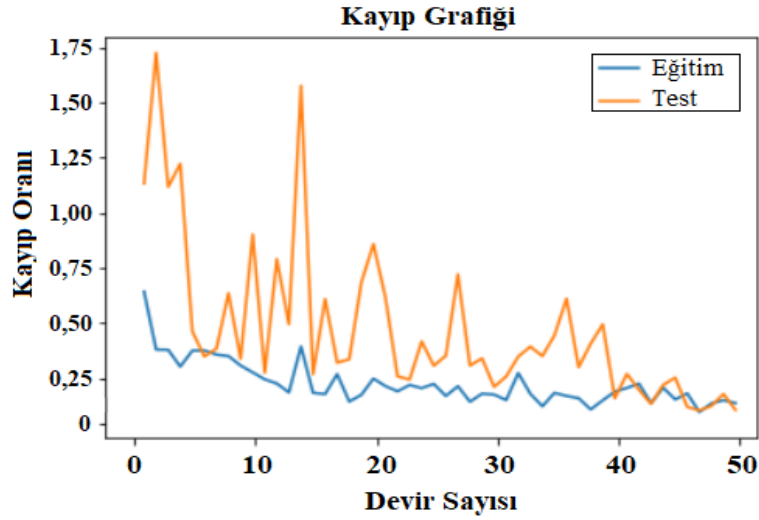
$$D_o = \frac{(DP + DN)}{(DP + DN + YP + YN)} \quad (5)$$

**Tablo 3.** D-ESA Modeli İçin Tercih Edilen Parametreler ve Tercihleri

Parametre	Değer / Tercih
Devir sayısı	50
Optimizasyon	Adam
Öğrenme oranı	10 <sup>-4</sup>
Sınıflandırma yöntemi	Softmax
Sınıflandırma metriği	Kategorik çapraz entropi
Kesme aralığı (eğitim verileri için)	0,1
Yakınlaştırma aralığı (eğitim verileri için)	0,1
Yatay flip (eğitim verileri için)	Doğru
Minimum boyut/parti değeri	8

Önerilen model ile Kovid-19 görüntülerinin tanınması için, veri setinde bulunan görüntülerin %80'i eğitim için kullanılırken, %20'si test amacıyla rastgele seçilerek kullanılmıştır. Önerilen model ile veri setinin eğitilmesi sonucu, modelin genel doğruluk oranı %98,48 olarak belirlenmiştir. Modelin eğitim ve kayıp grafiği sırasıyla Şekil 3 ve Şekil 4'te verilmiştir. Şekil 3'e bakıldığı zaman eğitim ve test verilerinin eğitiminin 40. devir sayısından sonra çok fazla değişmediği, benzer şekilde yine Şekil 4'e bakıldığı zaman 40. devir sayısından sonra yakınsama değerine ulaşıldığı görülmektedir. Dolayısıyla veri setinde belirlenmiş olan devir sayısı değerinin model eğitimi için uygun olduğu söylenebilir. Karmaşıklık matrisi ise Şekil 5'te, modelin performans sonuçları ise Tablo 4'te verilmiştir.

**Şekil 3.** Önerilen D-ESA Modelinin Genel Doğruluk Başarı Grafiği



Şekil 4. Önerilen D-ESA Modelinin Genel Doğruluk Kayıp Grafiği

		Tahmin Etiket			Gerçek Etiket
		Kovid	Normal	Zatürre	
Kovid	Kovid	25	1	0	
	Normal	0	20	0	
	Zatürre	0	0	20	
		Kovid	Normal	Zatürre	

Şekil 5. Deneysel Analizin Eğitim-Test Verilerine Ait Karmaşıklık Matrisi

Tablo 4. Deneysel Analizden Elde Edilen Karmaşıklık Matrisinin Metrik Sonuçları (%)

Önerilen yaklaşım	Tür	F-Skor	Du.	Öz.	Ha.	Do.	Genel Do.
D-ESA	Kovid-19	98,03	96,15	100	100	98,48	<b>98,48</b>
	Normal	97,56	100	97,82	95,23	98,48	
	Zatürre	100	100	100	100	100	

## TARTIŞMA

X-ışınlarından elde edilmiş göğüs görüntüleri kullanılarak; Kovid-19, normal ve zatürre olmak üzere, üç çeşit sınıf görüntülerinden oluşan veri seti kullanılmıştır. Görüntüler, uzman doktorlar ve radyologlar tarafından kontrol edilmiş ve etiketlenmiştir. Deneysel analizler gerçekleştirilerek, geleneksel ESA modellerinden farklı bir yaklaşım izlenerek tasarlanmış olan D-ESA modeli, çalışmanın deneysel analizlerinde kullanılarak Kovid-19 hastalığı, diğer türlere (zatürre, normal) göre başarılı bir şekilde sınıflandırılmıştır.

Birçok çalışma da Kovid-19, normal ve zatürre olmak üzere, üç çeşit sınıf görüntülerini kullanarak sağlıklı kişilerin otomatik sınıflandırılması için DÖ modelleri kullanılmıştır. Tablo 5 benzer veri setleri ve aynı veri seti ile gerçekleştirilmiş olan çalışmaların karşılaştırılmasını özetlemektedir. Çoğu, halka açık veri kümelerinin X-ray görüntüleri kullanılarak geliştirilmiş ve doğrulanmış olsa da, klinik vaka görüntüleri ile doğrulanmamıştır.

Shorfuzzaman & Hossain (2021), Kovid-19 vakalarının otomatik tespitinde göğüs X-ray görüntülerinin analizini hızlandırmak için derin meta öğrenmeye dayalı bir yapay zeka sistemi önermişlerdir. Kovid-19 vakalarının sınıflandırılması için bir siyam ağından yararlanmak üzere, karşılaştırmalı öğrenmeyi önceden eğitilmiş bir ConvNet kodlayıcıyla entegre etmek için sinerjik bir yaklaşım sunmuşlardır. Önerilen model ile göğüs X-ray görüntülerinin Kovid-19 teşhisinde, %95,60 doğruluk elde etmişlerdir. Nishio vd., önerdikleri modelde önceden eğitilmiş olan VGG16'yı ve veri artırma yöntemleri olarak, geleneksel yöntem ile bir kombinasyon kullanmışlardır (Nishio vd., 2020). Önceden eğitilmiş olan diğer model türleri, VGG16 tabanlı modellerle karşılaştırılarak, bilgisayar destekli sistemin üç kategorili doğruluğu, Kovid-19 pnömonisi, Kovid-19 dışı pnömoni ve sağlıklılar arasında %83,60 olarak elde etmişlerdir. Wehbe vd., referans standart olarak ters transkripsiyon polimeraz zincir reaksiyonu test sonuçları ile ön göğüs radyografilerinde Kovid-19'u saptamak için geliştirilmiş bir ESA topluluğu olan DeepCOVID-XR'ı önermişlerdir (Wehbe vd., 2021). DeepCOVID-XR'nin doğruluğunu %82 olarak elde etmişlerdir. Nasiri ve Hasani (2022), X-ışını görüntülerinden Kovid-19 hastalığının teşhisi için DenseNet169 ESA modelini kullanmışlardır. Çıkarılan öznetelikler daha sonra sınıflandırma görevini gerçekleştirmek için XGBoost algoritmasına girdi olarak verilerek, deneyler iki ve üç sınıflı problemlerde sırasıyla; %98,23 ve %89,70 doğruluk, %99,78 ve %100 özgüllük, %92,08 ve %95,20 duyarlılık göstermiştir. Tran vd. önerdikleri protokol ile MNIST veri seti ve gerçek hayattaki bir uygulama veri seti olan Kovid-19 üzerinde çalışarak, Kovid-19 veri setinde %95,02 doğruluk elde etmişlerdir (Tran vd., 2021). Önerilen modelde protokolün güvenliği sağlanmıştır. Bu çalışmada önerilen dense ağ modeli ile devir sayısı değeri verilmiş fakat ağı eğitimi önemli olan mini-batch size değeri, sinir ağınnın ağırlıklarının eğitilmesi için kullanılan optimizasyon algoritması ve öğrenme oranı gibi hiper-parametreler ile ilgili herhangi bir bilgi verilmemiştir. Dolayısıyla aynı veri seti ile yapılan bu çalışma da aynı hiper parametreler kullanılarak doğrudan bir karşılaştırma yapılamamıştır. Huang, Kovid-19 verileri üzerinde ESA ve İleri Beslemeli Sinir Ağı (İBSA) modellerini kullanarak, ESA için %100, İBSA için ise %96,88 doğruluk elde edilmiştir (Huang, 2021). Bu çalışmada aşırı uyma probleminin bir dezavantaj olduğu ve bu problemin giderilmesi için daha fazla veri toplanarak, yeni sınıflandırma algoritmaları ile problemin test edilmesi veya çapraz doğrulama testlerinin eklenmesi gerektiği söylenebilir.

**Tablo 5.** Benzer Veri Setleri ile Gerçekleştirilmiş Çalışmaların Karşılaştırılması

Makale	Yıl	Sınıftürü	Model / Yöntem	Doğruluk (%)
Shorfuzzaman & Hossain	2021	Kovid-19, normal, zatürre	Siyam sinir ağına dayalı MetaCOVID metodu	95,60
Nishio vd.	2020	Kovid-19, normal, zatürre	VGG16	83,60
Wehbe vd.	2021	Kovid-19, normal, zatürre	DeepCOVID-XR	82
Nasiri ve Hasani	2022	Kovid-19, normal, zatürre	DarkCovidNet DenseNet169 + XGBoost	89,370 89,70 - 98,24
Tran vd.	2021	Kovid-19 ve MNIST	Secure Inference Protocol	95,02
Huang	2021	Kovid-19, normal, zatürre	İBSA, ESA	96,88 - 100
<b>Bu çalışma</b>	2022	Kovid-19, normal, zatürre	D-ESA model	<b>98,48</b>

## SONUÇ

Bu çalışmada önerilen ESA modeline, farklı bir bakış açısı katabilmek için girdi görüntülerinin mekânsal ve spektral olarak işlenmesi gerçekleştirilerek, çok çözünürlüklü farklı özneliklerin çıkartılması sağlanmıştır. Çok çözünürlüklü analiz adımlarının eksik kısımları, dalgacık dönüşümü yöntemi kullanılarak tamamlandı. Sonuç olarak, önerilen yaklaşım olan D-ESA ile gerçekleştirilen deneysel analizlerde genel doğruluk başarısı %98,48 olarak elde edilmiştir.

Bir sonraki çalışmada, farklı veri setleri kullanılarak Kovid-19 hastalığının tanı sürecinde DÖ tabanlı yeni yaklaşımlar modellenecektir. Eğitim ve doğrulama sırasında modelin girdi verilerinden ne öğrendiğini daha iyi anlamak için, bir model yorumlama aracı yardımı ile nitel sonuçlar üretilerek çalışmanın genişletilmesi planlanmaktadır.

## KAYNAKLAR

- Abdulkareem, K. H., Mostafa, S. A., Al-Qudsy, Z. N., Mohammed, M. A., Al-Waisy, A. S., Kadry, S., Lee, J., & Nam, Y. (2022). Automated System for Identifying COVID-19 Infections in Computed Tomography Images Using Deep Learning Models. *Journal of Healthcare Engineering*, 1-13. <https://doi.org/10.1155/2022/5329014>
- AbdulQader, D. A., Saadoon, A. T., Naser, M. T., & Jabbar, A. H. (2023). Classification of COVID-19 from CT chest images using convolutional wavelet neural network. *International Journal of Electrical and Computer Engineering (IJECE)*, 13(1), 1078-1085. <https://doi.org/10.11591/ijece.v13i1>
- Alyasseri, Z. A. A., Al-Betar, M. A., Doush, I. A., Awadallah, M. A., Abasi, A. K., Makhadmeh, S. N., Alomari, O. A., Abdulkareem K. H., Adam A., Damasevicius R., Mohammed M. A., & Zitar R. A. (2022). Review on COVID-19 diagnosis models based on machine learning and deep learning approaches. *Expert systems*, 39(3), e12759. <https://doi.org/10.1111/exsy.12759>
- Apostolopoulos, I. D., & Mpesiana, T. A. (2020). Covid-19: automatic detection from x-ray images utilizing transfer learning with convolutional neural networks. *Physical and engineering sciences in medicine*, 43(2), 635-640. <https://doi.org/10.1007/s13246-020-00865-4>
- Bhardwaj, P., & Kaur, A. (2021). A novel and efficient deep learning approach for COVID-19 detection using X-ray imaging modality. *International Journal of Imaging Systems and Technology*, 31(4), 1775-1791. <https://doi.org/10.1002/ima.22627>
- Çalışkan, A. (2022). Classification of Tympanic Membrane Images based on VGG16 Model. *Kocaeli Journal of Science and Engineering*, 5(1), 105-111. <https://doi.org/10.34088/kojose.1081402>
- Deb, S.D., Jha, R.K., Jha, K. & Tripathi, P.S. (2022). A multi model ensemble based deep convolution neural network structure for detection of COVID19. *Biomedical Signal Processing and Control*, 71, 103126. <https://doi.org/10.1016/j.bspc.2021.103126>
- Fan, X., Feng, X., Dong, Y., & Hou, H. (2022). COVID-19 CT image recognition algorithm based on transformer and CNN. *Displays*, 72, 102150. <https://doi.org/10.1016/j.displa.2022.102150>
- Fujieda, S., Takayama, K., & Hachisuka, T. (2018). Wavelet convolutional neural networks. arXiv preprint arXiv:1805.08620. <https://doi.org/10.48550/arXiv.1805.08620>
- Google Colab Notebooks- Colaboratory, Google. (2021). <https://colab.research.google.com/notebooks/intro.ipynb/> Erişim Tarihi 09.06.2021.
- Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern recognition*, 77, 354-377. <https://doi.org/10.1016/j.patcog.2017.10.013>
- Huang, X. (2021). COVID-19 Image Diagnosis on CT Images Using Deep Learning. In *2021 2nd International Conference on Artificial Intelligence and Computer Engineering (ICAICE)*, IEEE, 77-80. <https://doi.org/10.1109/ICAICE54393.2021.00023>
- Jin, G., Liu, C. & Chen, X. (2022). An efficient deep neural network framework for COVID-19 lung infection segmentation. *Information Sciences*, 612, 745-758. <https://doi.org/10.1016/j.ins.2022.08.059>



- Karthik, R., Menaka, R., & Hariharan, M. (2021). Learning distinctive filters for COVID-19 detection from chest X-ray using shuffled residual CNN. *Applied Soft Computing*, 99, 106744. <https://doi.org/10.1016/j.asoc.2020.106744>
- Kini, A. S., Gopal Reddy, A. N., Kaur, M., Satheesh, S., Singh, J., Martinecz, T., & Alshazly, H. (2022). Ensemble deep learning and internet of things-based automated COVID-19 diagnosis framework. *Contrast Media & Molecular Imaging*, 2022, 7377502. <https://doi.org/10.1155/2022/7377502>
- Le Dinh, T., Lee, S.H., Kwon, S.G., & Kwon, K.R. (2022). COVID-19 Chest X-ray Classification and Severity Assessment Using Convolutional and Transformer Neural Networks. *Applied Sciences*, 12(10), 4861. <https://doi.org/10.3390/app12104861>
- Maghdid, H. S., Asaad, A. T., Ghafoor, K. Z., Sadiq, A.S., Mirjalili, S., & Khan, M. K. (2021). Diagnosing COVID-19 pneumonia from X-ray and CT images using deep learning and transfer learning algorithms. *In Multimodal image exploitation and learning 2021*, 11734, 99-110. <https://doi.org/10.1117/12.2588672>
- Muneer, A., Fati, S. M., Akbar, N. A., Agustriawan, D., & Wahyudi, S. T. (2022). iVaccine-Deep: Prediction of COVID-19 mRNA vaccine degradation using deep learning. *Journal of King Saud University-Computer and Information Sciences*, 34(9), 7419-7432. <https://doi.org/10.1016/j.jksuci.2021.10.001>
- Narin, A., Kaya, C., & Pamuk, Z. (2021). Automatic detection of coronavirus disease (covid-19) using x-ray images and deep convolutional neural networks. *Pattern Analysis and Applications*, 24(3), 1207-1220. <https://doi.org/10.1007/s10044-021-00984-y>
- Nishio, M., Noguchi, S., Matsuo, H., & Murakami, T. (2020). Automatic classification between COVID-19 pneumonia, non-COVID-19 pneumonia, and the healthy on chest X-ray image: combination of data augmentation methods. *Scientific reports*, 10(1), 1-6. <https://doi.org/10.1038/s41598-020-74539-2>
- Nasiri, H., & Hasani, S. (2022). Automated detection of COVID-19 cases from chest X-ray images using deep neural network and XGBoost. *Radiography*, 28, 732-738. <https://doi.org/10.1016/j.radi.2022.03.011>
- Nneji, G. U., Cai, J., Jianhua, D., Chikwendu, I. A., Oluwasanmi, A., James, E. C., & Mgbejime, G. T. (2021). Enhancing low quality in radiograph datasets using wavelet transform convolutional neural network and generative adversarial network for COVID-19 identification. In 2021 4th International Conference on Pattern Recognition and Artificial Intelligence (PRAI), IEEE, (pp. 146-151). <https://doi.org/10.1109/PRAI53619.2021.9551043>
- O'Shea, K., & Nash, R. (2015). An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458. <https://doi.org/10.48550/arXiv.1511.08458>
- Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-Menendez, R., Bhardwaj, P., & Singh, V. (2020). A deep learning and grad-CAM based color visualization approach for fast detection of COVID-19 cases using chest X-ray and CT-Scan images. *Chaos, Solitons & Fractals*, 140, 110190. <https://doi.org/10.1016/j.chaos.2020.110190>
- Raikote, P. (2019). Covid-19 Image Dataset. <https://www.kaggle.com/datasets/pranavraikokte/covid19-image-dataset/> Erişim Tarihi 20.05.2022.
- Sarvamangala, D. R., & Kulkarni, R. V. (2021). Convolutional neural networks in medical image understanding: a survey. *Evolutionary intelligence*, 1-22. <https://doi.org/10.1007/s12065-020-00540-3>
- Shahin, O. R., Abd El-Aziz, R. M. & Taloba, A. I. (2022). Detection and classification of Covid-19 in CT-lungs screening using machine learning techniques. *Journal of Interdisciplinary Mathematics*, 25(3), 791-813. <https://doi.org/10.1080/09720502.2021.2015097>
- Shorfuzzaman, M., & Hossain, M. S. (2021). MetaCOVID: A Siamese neural network framework with contrastive loss for n-shot diagnosis of COVID-19 patients. *Pattern recognition*, 113, 107700. <https://doi.org/10.1016/j.patcog.2020.107700>
- Singh, K. K., & Singh, A. (2021). Diagnosis of COVID-19 from chest X-ray images using wavelets-based depthwise convolution network. *Big Data Mining and Analytics*, 4(2), 84-93. <https://doi.org/10.26599/BDMA.2020.9020012>
- Subramanian, N., Elharrouss, O., Al-Maadeed, S., & Chowdhury, M. (2022). A review of deep learning-based detection methods for COVID-19. *Computers in Biology and Medicine*, 105233. <https://doi.org/10.1016/j.compbiomed.2022.105233>

Sunitha, G., Arunachalam, R., Abd-Elnaby, M., Eid, M. M., & Rashed, A. N. Z. (2022). A comparative analysis of deep neural network architectures for the dynamic diagnosis of COVID-19 based on acoustic cough features. *International Journal of Imaging Systems and Technology*, 32(5), 1433-1446. <https://doi.org/10.1002/ima.22749>

Toğaçar, M. (2021). X-ışınli Göğüs İmgelerini Kullanarak Solunum Yolu Hastalıklarının Tespitinde Kuantum Transfer Öğrenme Modelinin Rolü. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 9(5), 1754-1765. <https://doi.org/10.29130/dubited.903358>

Toğaçar, M., Ergen, B., & Cömert, Z. (2021). Tumor type detection in brain MR images of the deep model developed using hypercolumn technique, attention modules, and residual blocks. *Medical & Biological Engineering & Computing*, 59(1), 57-70. <https://doi.org/10.1007/s11517-020-02290-x>

Tran, A. T., Luong, T. D., Ha, C. C., Hoang, D. T., & Tran, T. L. (2021). Secure Inference via Deep Learning as a Service without Privacy Leakage. In *2021 RIVF International Conference on Computing and Communication Technologies (RIVF)*, IEEE, 1-6. <https://doi.org/10.1109/RIVF51545.2021.9642089>

Umer, M., Ashraf, I., Ullah, S., Mehmood, A., & Choi, G. S. (2022). COVINet: A convolutional neural network approach for predicting COVID-19 from chest X-ray images. *Journal of Ambient Intelligence and Humanized Computing*, 13(1), 535-547. <https://doi.org/10.1007/s12652-021-02917-3>

Yamashita, R., Nishio, M., Do, R. K. G., & Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, 9(4), 611-629. <https://doi.org/10.1007/s13244-018-0639-9>

Yu, C. S., Chang, S. S., Chang, T. H., Wu, J. L., Lin, Y. J., Chien, H. F., & Chen, R. J. (2021). A COVID-19 pandemic artificial intelligence-based system with deep learning forecasting and automatic statistical data acquisition: development and implementation study. *Journal of medical Internet research*, 23(5), e27806.

<https://doi.org/10.2196/27806>

Wang, L., Lin, Z. Q., & Wong, A. (2020). Covid-net: A tailored deep convolutional neural network design for detection of covid-19 cases from chest x-ray images. *Scientific Reports*, 10(1), 1-12. <https://doi.org/10.1038/s41598-020-76550-z>

Wehbe, R. M., Sheng, J., Dutta, S., Chai, S., Dravid, A., Barutcu, S., Wu, Y., Cantrell, D. R., Xiao, N., Allen, B. D., MacNealy, G. A., Savas H., Agrawal, R., Parekh, N., & Katsaggelos, A. K. (2021). DeepCOVID-XR: an artificial intelligence algorithm to detect COVID-19 on chest radiographs trained and tested on a large US clinical data set. *Radiology*, 299(1), E167. <https://doi.org/10.1148/radiol.2020203511>

Zhan, J. X., & Santos-Paulino, A. U. (2021). Investing in the Sustainable Development Goals: Mobilization, channeling, and impact. *Journal of International Business Policy*, 4(1), 166-183. <https://doi.org/10.1057/s42214-020-00093-3>

Zhang, Y. D., Satapathy, S. C., Zhang, X., & Wang, S. H. (2021). Covid-19 diagnosis via DenseNet and optimization of transfer learning setting. *Cognitive computation*, 1-17. <https://doi.org/10.1007/s12559-020-09776-8>