



X-Ray Görüntülerinden COVID-19 Tespiti için Derin Öğrenme Temelli Bir Yaklaşım

Feyzanur Banu DEMİR^{1*}, Ersen YILMAZ²

^{1*} Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Bursa, Türkiye, (ORCID: 0000-0001-8921-896X), feyzanurdemir@uludag.edu.tr

² Bursa Uludağ Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Bursa, Türkiye, (ORCID: 0000-0002-6620-655X), ersen@uludag.edu.tr

(International Conference on Design, Research and Development (RDCONF) 2021 – 15-18 December 2021)

(DOI: 10.31590/ejosat.1039522)

ATIF/REFERENCE: Demir, F.B., Yılmaz, E. (2021). X-Ray Görüntülerinden COVID-19 Tespiti için Derin Öğrenme Temelli Bir Yaklaşım. *Avrupa Bilim ve Teknoloji Dergisi*, (32), 627-632.

Öz

SARS-CoV-2 virüsü kaynaklı COVID-19 hastalığının yayılma seyirinin kontrol altına alınmasında erken tespiti önemli rol oynamaktadır. Ters transkripsiyon-polimeraz zincir reaksiyonu (RT-PCR) koronavirüsün teşhisinde sıklıkla kullanılmaktadır. Ancak testler hastalığın her evresinde doğru sonuç verememektedir ve sonuçların çıkması için geçen süre hastalığın yayılması sürecini kolaylaştırmaktadır. Erken evrelerde COVID-19 tanısı koymak için X-ışını (X-Ray) Bilgisayarlı Tomografi (BT) gibi daha az temasa bağlı ve daha hızlı sonuç verebilecek tıbbi radyolojik görüntüleme yöntemleri kullanılmaktadır. Radyolojik görüntüler üzerinden hastalık tespitinde derin öğrenme yaklaşımlarının kullanımı son yıllarda çok ilgi görmektedir. Bu çalışmada akciğer radyolojik görüntülerinden COVID-19'un hızlı ve doğru teşhisi amacıyla derin öğrenme temelli bir yaklaşım kullanılmıştır. Yaklaşımın başarım incelemesi açık kaynaklı bir COVID-19 veri kümesi üzerinde gerçekleştirilmiştir.

Anahtar Kelimeler: COVID-19, Derin Öğrenme, Evrimsel Sinir Ağları(CNN), Akciğer X-Ray.

A Deep Learning-Based Approach for Detection of COVID-19 from X-Ray Images

Abstract

COVID-19 is a disease caused by the SARS-CoV-2 virus. Early detection and diagnosis of COVID-19 play an important role in controlling the spread of the disease. Reverse transcription-polymerase chain reaction (RT-PCR) is frequently used in the diagnosis of coronavirus. However, tests cannot give accurate results at every stage of the disease. The time taken for test results facilitates the spread of the disease. Medical radiological imaging methods such as X-ray (X-Ray) and Computed Tomography (CT) are used to diagnose COVID-19 in the early stages, which are less contact-dependent and can provide faster results. The use of deep learning approaches in disease detection through radiological images very popular in recent years. In this study, a deep learning-based approach was used for rapid and accurate diagnosis of COVID-19 from lung radiological images. The performance of the approach was examined on an open-source COVID-19 dataset.

Keywords: COVID-19, Deep Learning, Convolutional Neural Network(CNN), Chest X-Rays.

* Sorumlu Yazar: feyzanurdemir@uludag.edu.tr

1. Giriş

Koronavirüs (COVID-19), 2019 yılının son aylarında ilk kez Çin’de başlayan ve kısa bir sürede dünyaya yayılarak pandemi haline gelen ciddi bir salgın hastalıktır (COVID-19 Bilgilendirme Platformu, 2021). Virüs, pek çok ülkede sağlık sistemlerinin yetersiz kalmasının yanı sıra, psikolojik, ekonomik ve sosyal alanlarda da olumsuz etkisini göstermiştir. 29 Kasım 2021 itibari ile dünya genelinde aktif enfekte vaka sayısı 20,162,381, ölüm vaka sayısı 5,216,801 ve iyileşen vaka sayısı 236,358,111’tür (COVID-19 Coronavirus Pandemic, 2021). Bu rakamlar salgının yayılımcı ve şiddetli seyrinin devam ettiğini gözler önüne sermektedir. Dolayısıyla hem hızla artan enfekte vaka sayısını yavaşlatabilmek ve hatta durdurabilmek hem de hayatımızı tüm alanlarıyla olumsuz etkilerinden kurtarabilmek için hızlı ve doğru bir şekilde virüsü taşıyanları tespit edip izolasyonlarını sağlamak gerekmektedir. Teşhis amacıyla günümüzde az sayıda doku hücrelerinden mRNA’nın hassas olarak saptanabilmesi nedeniyle yoğun olarak kullanılan yöntem RT-PCR yöntemidir (Bustin, 2000). Fakat bu yöntem hasta ile yakın temas halinde elle örnek alınarak yapılan ve her yeni hasta için yeni bir test kiti gerektiren maliyetli bir işlemdir. Aynı zamanda başarımları metrikleri ile ilgili sorunları mevcuttur (Bustin, 2000). RT-PCR testinin hastalığın erken evrelerinde yüksek oranda yanlış negatif sonuç vermesi yöntemin erken COVID-19 teşhis ve tedavisine uygun olmadığını göstermektedir. Dolayısıyla, hastalığın ilk evrelerinde COVID-19 teşhisi yapmak için Bilgisayarlı Tomografi (BT) ve X-Ray benzeri tıbbi görüntüleme yöntemleri kullanılmaktadır (Öztürk, ve diğerleri, 2020). Bu teknikler enfekte hastayla daha az temas gerektirdiğinden daha az bulaş riski taşımaktadır. X-Ray görüntüsünden teşhis işlemi nispeten daha hızlıdır ve BT taramalarına göre daha az maliyetlidir (Ghaderzadeh & Asadi, 2021). Göğüs X-Ray görüntüleri düşük maliyet, düşük radyasyon ve yüksek kullanılabilirlik gibi sebepler nedeniyle epidemolojik çalışmalarda BT taramasının yerine tercih edilir hale gelmektedir.

Göğüs radyolojik görüntüleri akciğer hastalıkları ile ilgili önemli ayrıntıları içermektedirler. COVID-19 hastalığının tespit edilmesinde bu görüntülerdeki ayrıntılar oldukça etkili olmaktadır. COVID-19, göğüs görüntülerinde diğer akciğer hastalıklarıyla benzer bulgular göstermektedir. Bu nedenle radyolojik görüntüler üzerindeki incelemelerin hassasiyetle yapılması gerekmektedir. Bu inceleme bir uzman doktor, radyolog tarafından yapılırken süreç uzun ve yüksek doğrulukta gerçekleşmeyebilir. Dolayısıyla son yıllarda radyolojik görüntüler üzerinden taramaların yapılmasında derin öğrenme yöntemlerine başvurulmaktadır. Bu yöntemlere dayanan yaklaşımlar hızlı, güvenilir ve otomatik analizlere olanak sağlamaktadır (Panwar, ve diğerleri, 2020).

Literatürde, X-Ray görüntüleri üzerinden COVID-19’un tespitinde derin öğrenme temelli yaklaşımlar kullanan pek çok çalışma yer almaktadır. Yaklaşımlar kendi içerisinde sınıflandırma için kullandıkları modeller açısından ayrılmaktadır. Kullanılan modellerde ikili sınıflandırma (COVID-19/Normal) ve

çoklu sınıflandırma (COVID-19/Normal/Pnömoni) gibi farklı kategorizasyonlar ile COVID-19 tespiti gerçekleştirilmektedir. Özellikle ikili sınıflandırmada COVID-19 pozitif ve COVID-19 negatifin ayrımını yapmak yaygındır. Öztürk ve arkadaşları, X-Ray görüntülerinden COVID-19 tespiti için ikili ve çoklu sınıflandırma modeli kullanmışlardır. İkili sınıflar için %98.08 başarı oranı elde ederken çoklu sınıflandırma için %87.02 başarı oranı elde etmişlerdir (Öztürk, ve diğerleri, 2020). Narin ve arkadaşları, problemi dört sınıflı (COVID-19/Normal/Viral/Pnömoni/ Bakteriyel Pnömoni) olarak ele almışlardır. COVID-19 ile diğer üç sınıfı ikili kombinasyonlar biçiminde sınıflandırmak için beş evrimsel sinir ağı tabanlı model kullanmışlardır. COVID-19/Normal sınıflandırmasında %96.1; COVID-19/Viral Pnömoni sınıflandırmasında %99.5; COVID-19/Bakteriyel Pnömoni sınıflandırmasında ise %99.7 doğruluk oranı elde etmişlerdir (Narin, ve diğerleri, 2021). Apostolopoulos ve arkadaşları problemi iki sınıflı ve yedi sınıflı olarak ele alarak iki sınıflı durum da COVID-19 tespitinde %99.18; yedi sınıflı durumda ise %87.66 doğruluk elde etmişlerdir (Apostolopoulos, ve diğerleri, 2020). Literatürde bu çalışmada kullanılan veri kümesini ele alan üç farklı çalışma incelenmiş ve kullandıkları yaklaşım ile başarımları sonuçları özetlenmiştir. Condaragiu ve Ciocoiu, problemi dört sınıflı (COVID-19/Akciğer opasitesi/Pnömoni/ Normal) olarak ele almışlar ve önceden eğitilmiş beş farklı CNN modeli ile sınıflandırma yapmışlardır. En iyi doğruluk oranını Resnet 50 ağı tarafından %96.7 olarak elde etmişlerdir (Condaragiu & Ciocoiu, 2021). Hussain ve Shiren, ikili sınıflandırma (COVID-19/Normal) için farklı katman sayılarına sahip CNN modelleri kullanmışlardır. Bir, üç ve dört evrim katmanlı üç farklı mimariyi karşılaştırmış ve üç evrim katmanlı CNN ile %96 doğruluk oranı elde etmişlerdir (Hussain & Ye, 2021). Aynı veri kümesi üzerinde çalışan bir başka grup Aparna ve diğerleri VGG-16 ve MobileNet için %93.3 ve %91.6 doğruluk oranlarını elde etmişlerdir. Yazarlar önerilen CNN modeli ile %98.3’lük bir doğruluk oranına ulaşmışlardır (Aparna, ve diğerleri, 2021).


Bu çalışmada COVID-19’un akciğer X-Ray görüntülerinden hızlı ve doğru teşhisi amacıyla derin öğrenme temelli bir yaklaşım sunulmuştur. Problem iki sınıflı olarak ele alınmıştır. Kullanılan yaklaşım, Evrimsel Sinir Ağları (CNN) üzerinde temellendirilmiştir. Başarımların incelemesi açık kaynaklı bir COVID-19 veri kümesi üzerinde gerçekleştirilmiştir.

2. Materyal ve Metot

2.1. Veri Kümesi

Bu çalışmada klinik COVID-19 tanılarında radyologlar tarafından yaygın bir şekilde kullanılan posteroanterior (AP) ve anteroposterior (PA) göğüs röntgenlerini içeren bir veri kümesi kullanılmıştır (Chowdhury, ve diğerleri, 2020; Rahman, ve diğerleri, 2021). Göğüs röntgeni veri tabanları içerisinde oldukça popüler olan açık kaynaklı Kaggle COVID-19 radyografi veri tabanı ile çalışılmıştır. Bu veri tabanı içerisinde 3616 adet COVID-19 pozitif, 10192 adet Normal akciğer göğüs röntgeni

mevcuttur. Radyolojik görüntüler taşınabilir ağ grafikleri (PNG) dosya biçiminde olup 299x299 piksel boyutundadır. COVID-19 pozitif ve Normal sınıflara ait 4 adet örnek radyolojik görüntü Şekil 1’de verilmiştir.



Şekil 1. Veri Kümesinden Etiketli X-Ray Örnekleri

2.2. Derin Öğrenme

Derin öğrenme, girişten başlayarak bir veya daha fazla gizli katman ile her bir seviyedeki temsili daha yüksek ve daha soyut bir seviyede temsile dönüştüren bir makine öğrenmesi sınıfıdır. Temsil öğrenimi, bir sistemin ham haldeki giriş verilerinden algılama veya sınıflandırma yapabilmesi için gereken temsili yani öznitelikleri otomatik olarak keşfetmesini sağlayan yöntem dizisidir (LeCun, ve diğerleri, 2015). Bir görüntü için temsil, görüntüdeki belirli konumlardaki kenar bilgileri, piksel yoğunluk özellikleri, görüntü içerisindeki motifler ve bu motiflerin daha büyük kombinasyonları gibi görüntüye ait karakteristik özelliklerdir (Şeker, ve diğerleri, 2017; LeCun, ve diğerleri, 2015). Derin sinir ağları (DNN), derin inanç ağları (DBN), tekrarlayan sinir ağları (RNN), evrimsel sinir ağları (CNN) klasik derin öğrenme mimarileridir. Metin, ses, görüntü ve video gibi veriler derin öğrenmede girdi olarak kullanılmaktadır (Liu, 2021). Özellikle tıp alanında göğüs röntgenleri, beyin MRG görüntüleri gibi görüntü veri kümelerinde derin öğrenme teknikleri kullanılarak yüksek doğrulukta sonuçlar alınabilmektedir (Mahmud M. , ve diğerleri, 2018; Mahmud M. , ve diğerleri, 2021; Harsono, ve diğerleri, 2020). Derin öğrenme mimarileri arasında CNN’lerin, görüntü verileri üzerinde özellik çıkarma ve öğrenmede gösterdikleri yüksek başarı nedeniyle bu alanda benimsenmiştir (Liu, 2021; Krizhevsky ve diğerleri, 2012; Hussain & Ye, 2021). Evrişim, matematiksel konvolüsyon işlemine karşılık gelir ve görüntülerdeki bu karakteristik özellikleri çıkarma işlevini gerçekleştirir (Liu, 2021). Çıkarılan özelliklerin tamamı veya bazıları veriyi kendisinden daha iyi temsil etmektedir (Şeker, ve diğerleri, 2017).

Son zamanlarda yapılan araştırmalar, CNN tabanlı derin öğrenme yöntemlerinin COVID-19’un akciğer radyolojik görüntülerinden tespit edilmesi işleminde başarılı sonuçlar verdiğini göstermektedir (Ghaderzadeh & Asadi, 2021; Lu, ve diğerleri, 2019). Yukarıda bahsedilmiş olan derin öğrenmenin sahip olduğu özellikler ve CNN’lerin sahip olduğu öznitelik çıkarımı yeteneği bu başarılı sonuçları desteklemektedir.

2.2.1. Evrişimsel Sinir Ağları (CNN)

Görüntü verilerindeki başarılarından dolayı en yaygın kullanılan sinir ağlarından (Liu, 2021). Bu avantajı ile tıbbi görüntüler üzerinden tespit yaklaşımlarında sıklıkla tercih edilmektedir. Temel bir CNN mimarisi evrişim katmanı, düzleştirilmiş doğrusal birim katmanı, havuzlama katmanı ve tam bağlı katmandan oluşmaktadır (Yılmaz & Kaya, Derin Öğrenme, 2019).

Evrişim Katmanı (CL): Evrişim katmanı, CNN’lerin temelini oluşturan ve görüntünün özniteliklerinin çıkarıldığı katmandır. Giriş görüntülerine Denklem 1’de ifade edilen konvolüsyon (evrişim) işlemi uygulanmaktadır. Evrişim, bir filtrenin görüntü matrisi üzerinde gezdirilmesi ile gerçekleştirilir. Bu işlem sonucunda elde edilen öznitelik haritası ise Denklem 2’de verilmiştir (Ciresan, ve diğerleri, 2011; Özbay & Özbay, 2021; İnik & Ülker, 2017; Yılmaz A. , 2021).

$$(f * g)(t) = \int_{-\infty}^{+\infty} f(T)g(t - T)dT \quad (1)$$

$$F_x^r = \frac{F_x^{r-1} - L_x^r}{S_x^r} + 1, F_y^r = \frac{F_y^{r-1} - L_y^r}{S_y^r} + 1 \quad (2)$$

Denklem 2’de (F_x, F_y) öznitelik haritasının genişliği ve yüksekliğini; (L_x, L_y) çekirdek boyutunu; (S_x, S_y) çekirdek adım büyüklüğünü ve r ise katman sayısını ifade etmektedir.

Düzleştirilmiş Doğrusal Birim Katmanı (ReLU): Evrişim katmanlarının çıkış verilerine Düzleştirilmiş Doğrusal Birim (ReLU) aktivasyon fonksiyonunun uygulandığı katmandır. Denklem 3’te matematiksel olarak tanımlandığı gibi öznitelik haritalarındaki negatif değerleri sıfıra sabitlemektedir (İnik & Ülker, 2017).

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3)$$

Havuzlama Katmanı (PL): CNN mimarilerinde önemli bir işlev olan boyut azaltmanın gerçekleştirildiği katmandır. Tanımlanan filtreler ile görüntüdeki piksel değerleri üzerinde maksimum değer alma (maksimum havuzlama), ortalama değer alma (ortalama havuzlama) gibi işlemlerle havuzlanmış öznitelik haritası oluşturulmaktadır. Böylece bir sonraki katman için hesaplama yükünü azaltmaktadır. Yeni öznitelik haritası tam bağlı katmana iletilmeden önce düzleştirme işlemi ile tek boyutlu bir vektör haline getirilmektedir. (Özbay & Özbay, 2021; İnik & Ülker, 2017)


Tam Bağlı Katman (FCL): Kendinden önceki katmanın tüm nöronlarına bağlantısı bulunan bir yapay sinir ağından oluşmaktadır.

Tam bağlı katmanın ardından son tahmin, sınıflandırma problemine özgü olarak tercih edilen aktivasyon fonksiyonu yardımıyla gerçekleştirilmektedir. Birden fazla sınıfın bulunduğu sınıflandırma problemlerinde Denklem 4’te verilen Softmax aktivasyon fonksiyonu kullanılmaktadır (İnik & Ülker, 2017).

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{k=1}^K e^{x_k}} \quad (4)$$

CNN mimarisi oluşturulduktan sonra ağı eğitimi gerçekleştirilir. Eğitim sonucunda alınan tahmin verileri doğru etiketli veriler ile karşılaştırılarak bir hata değeri hesaplanır. Geriye yayılım algoritması ile her eğitim adımında ağıdaki ağırlık değerleri güncellenerek hatanın minimize edilmesi sağlanmaktadır.

X-Ray görüntülerinden COVID-19 tespiti için kullanılan temel bir CNN mimarisi Şekil 2’de verilmiştir.



Şekil 2. COVID-19 tespiti için temel bir CNN mimarisi

2.3. Başarım Ölçütleri

Gerçekleştirilen çalışmada kullanılan mimarilerin kıyaslanabilmesi ve değerlendirilebilmesi amacıyla başarımlar ölçütü olarak doğruluk, kesinlik, duyarlılık, özgüllük ve F1-skor ölçütleri kullanılmıştır. Bir tahmin modeli için başarımlar ölçütlerinin hesaplanmasında Tablo 1’de verilen karışıklık matrisi kullanılmaktadır. Bu matristen başarımlar ölçütlerinin hesabı Denklem 5-9’de sunulmuştur (Yılmaz E. , 2016).

Tablo 1. Karışıklık Matrisi

		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Doğru Sınıf	Pozitif	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Negatif	Yanlış Pozitif (YP)	Doğru Negatif (DN)

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

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (6)$$

$$\text{Duyarlılık} = \frac{DN}{DN+YN} \quad (7)$$


$$\text{Özgüllük} = \frac{DN}{DN+YP} \quad (8)$$

$$\text{F1-Skor} = \frac{2*DP}{YN+YP+2*DP} \quad (9)$$


3. Deneysel Sonuçlar

Açık kaynaklı veri kümesindeki 3616 COVID-19 ve 10192 Normal göğüs röntgeni üzerinden 2 farklı evrişimsel sinir ağı ile sınıflandırma çalışması gerçekleştirilmiştir. İlk olarak basit bir CNN ağı mimarisi ele alınmıştır. Krizhevsky ve arkadaşlarının

önerdiği Alexnet mimarisine benzer biçimde oluşturulmuştur, Şekil 3 (Krizhevsky, ve diğerleri, 2012) . Ardından Simonyan ve Zisserman tarafından önerilen temel derin öğrenme ağı modellerinden olan VGG16 evrişimsel sinir ağı kullanılmıştır (Simonyan & Zisserman, 2015). Bu mimaride görüntüler her bir konvolüsyon bloğunda tek bir evrişim katmanı yerine bir evrişim katman yığını içerisinde geçirilmektedir. Kullanılan ağı mimarisi Şekil 4’te gösterilmiştir. Bu iki temel CNN ile derinliğin doğruluğa etkisi incelenmiştir.



Şekil 3. Basit-CNN Mimarisi



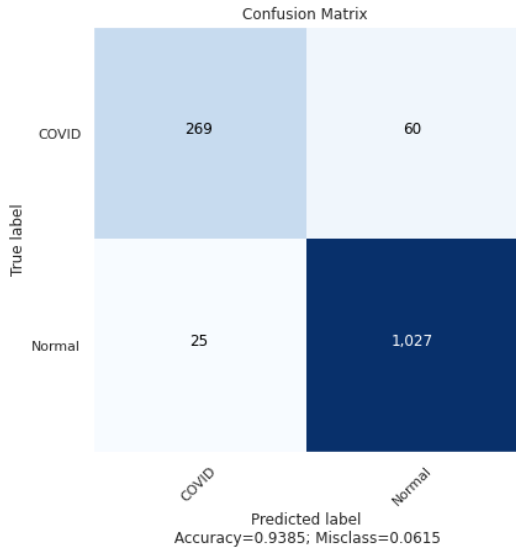
Şekil 4. VGG16 Mimarisi (Simonyan & Zisserman, 2015)

Her iki mimaride de evrişimsel katmanlarda “ReLU” ve çıktı katmanında ise “Softmax” aktivasyon fonksiyonu kullanılmıştır. Ağı optimizasyonunda Adam Optimizasyon algoritması tercih edilmiştir. Aşırı öğrenmeyi engellemek için erken durdurma yöntemi kullanılmıştır. Veriler test, eğitim ve doğrulama olarak üç kümeye bölünmüştür. Kullanılan CNN mimarilerinin eğitim ve test sürecine ait doğruluk ve kayıp oranları Tablo 2’de sunulmuştur.

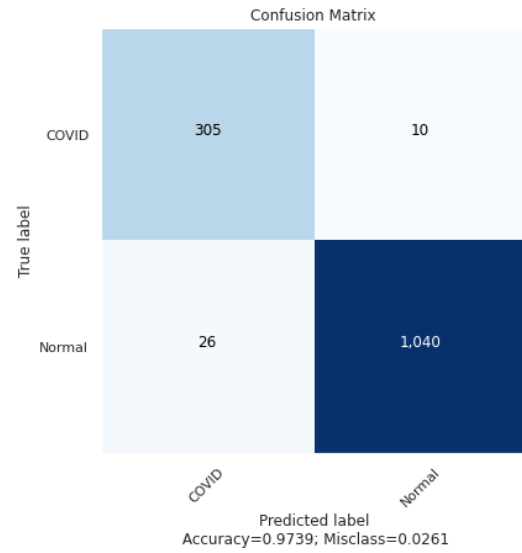
Tablo 2. CNN Mimarileri için Eğitim ve Test Sonuçları

Sonuçlar	CNN Mimarileri	
	Basit-CNN	VGG16
Eğitim Sonuçları:		
Doğruluk	0,9212	0,9768
Kayıp	0,2048	0,0761
Test Sonuçları:		
Doğruluk	0,9385	0,9739
Kayıp	0,1738	0,0960

Katman yapısının derinliğinin sınıflandırma başarımı üzerindeki etkisini gösteren karışıklık matrisleri Şekil 5’te verilmiştir. DP, DN, YP, YN değerleri ile elde edilen doğruluk, kesinlik, duyarlılık, özgüllük ve F1-Skor ölçütlerine ait sonuçlar Tablo 3’te yer almaktadır. Bununla birlikte, literatürde yer alan benzer çalışmaları içeren bir karşılaştırma tablosu Tablo 4’te sunulmuştur. Bu tabloda çalışmalarda kullanılan veri kümesi, sınıf sayısı, kullanılan yaklaşım ve yaklaşımın doğruluk oranı verilmiştir.



Şekil 5a. Basit-CNN Karışıklık Matrisi



Şekil 5b. VGG-16 Karışıklık Matrisi

Şekil5. Basit-CNN ve VGG-16 Mimarilerine Ait Karışıklık Matrisleri

Tablo 3. CNN Mimarileri için Elde Edilen Başarım Ölçütleri

CNN Mimarileri	Sonuçlar	
	Basit-CNN	VGG16
Doğruluk	0,9385	0,9739
Kesinlik	0,9149	0,9214
Duyarlılık	0,8176	0,9682
Özgüllük	0,9762	0,9756
F1-Skor	0,8635	0,9442

Tablo 4. COVID-19 Tespiti Yapan Çalışmaların Doğruluk Sonuçları

Çalışma	Veri Kümesi	Veri Tipi	Model	Sınıf Sayısı	Sonuç
Ozturk ve diğerleri	-COVID-19 Image Data Collection	X-Ray	DarkCovidNet	CxN	0,98
	-ChestX-Ray8			CxNxP	0,87
Narin ve diğerleri	-COVID-19 Image Data Collection	X-Ray	InceptionV3	CxN	0,96
	-ChestX-Ray8		ResNet50	CxV	0,99
	-Chest X-ray Images (Pneumonia).		ResNet101	CxB	0,99
			ResNet152		
			Inception-ResNetV2		
Apostolopoulos ve diğerleri	-COVID-19 Image Data Collection	X-Ray	Mobile Net v2	CxN	0,99
				CxPxNxÖxExAxF	0,87
Condaragiu & Ciocoiu	-COVID-19 Radiography Database	X-Ray	Resnet50	CxOxPxN	0,96
			VGG-16		0,95
			Densenet-201		0,96
			Inceptionv3		0,96
			NasNetMobile		0,95
Hussain & Ye	-COVID-19 Radiography Database	X-Ray	1 katman CNN	CxN	0,95
			3 katman CNN		0,96
			4 katman CNN		0,94
Aparna ve diğerleri	-COVID-19 Radiography Database	X-Ray	VGG16	CxN	0,93
			MobileNet		0,91
			Önerilen CNN		0,98
Bu çalışma	-COVID-19 Radiography Database	X-Ray	5 katman CNN	CxN	0,93
			VGG16		0,97

4. Tartışma ve Sonuç

COVID-19 salgınının ortaya çıktığı günden beri günümüzde dahil olmak üzere hastalığın teşhisinde RT-PCR yöntemi kullanılmaktadır. Bu yöntemin maliyetli olması, başarımleri ile ilgili sorunlarının bulunması ve hastalığın erken evrelerinde yüksek oranda yanlış negatif sonuç vermesi gibi dezavantajları bulunmaktadır. Derin öğrenme yöntemleri ve göğüs radyolojik verileri bu dezavantajların ve sınırlamaların üstesinden gelebilmektedir. Bu çalışmada COVID-19'un akciğer X-Ray görüntülerinden hızlı ve doğru teşhisi amacıyla iki farklı evrimsel sinir ağı mimarisi kullanılmıştır. Elde edilen deneysel sonuçlara göre VGG16 mimarisinin Basit-CNN mimarisine göre daha yüksek başarımlerine sahip olduğu ve literatürde aynı veri kümesini kullanan benzer çalışmalarla yakın sonuçlar verdiği gözlemlenmiştir.

Kaynakça

- Aparna, G., Gowri, S., Bharathi, R., S, V. J., J, J., & P, A. (2021). COVID-19 Prediction using X-Ray Images. *2021 5th International Conference on Trends in Electronics and Informatics (ICOEI)* (pp. 903-908). IEEE.
- Apostolopoulos, I. D., Aznaouridis, S., & Tzani, M. (2020). Extracting possibly representative COVID-19 Biomarkers from X-Ray images with Deep Learning approach and image data related to Pulmonary Diseases. *Journal of Medical and Biological Engineering*.
- Bustin, S. (2000). Absolute quantification of mRNA using real-time reverse transcription polymerase chain reaction assays. *Journal of molecular endocrinology*.
- Chowdhury, M. E., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., . . . Islam, T. I. (2020). Can AI help in screening Viral and COVID-19 pneumonia? *IEEE Access*, 132665-132676.
- Ciresan, D. C., Meier, U., Masci, J., Gambardella, L. M., & Schmidhuber, J. (2011). Flexible, High Performance Convolutional Neural Networks for Image Classification. *International Joint Conference on Artificial Intelligence IJCAI-2011*, (pp. 1237-1242). Barcelona.
- Condaragiu, S., & Ciocoiu, I. B. (2021). Evaluation of Convolutional Neural Networks for COVID-19 Detection from Chest X-Ray Images. *2021 International Symposium on Signals, Circuits and Systems*, (pp. 1-4).
- COVID-19 Bilgilendirme Platformu. (2021, Kasım 22). Retrieved from T.C. Sağlık Bakanlığı COVID-19 Bilgilendirme Platformu: <https://covid19.saglik.gov.tr/TR-66300/covid-19-nedir-.html>
- COVID-19 Coronavirus Pandemic. (2021, Kasım 29). Retrieved from Worldometers: <https://www.worldometers.info/coronavirus/>
- Ghadezadeh, M., & Asadi, F. (2021). Deep Learning in the Detection and Diagnosis of COVID-19 Using Radiology Modalities: A Systematic Review. *Hindawi Journal of Healthcare Engineering*.
- Harsono, I. W., Liawatimena, S., & Cenggoro, T. W. (2020). Lung nodule detection and classification from Thorax CT-scan using RetinaNet with transfer learning. *Journal of King Saud University - Computer and Information Sciences*.
- Hussain, M. G., & Ye, S. (2021). Recognition of COVID-19 Disease Utilizing X-Ray Imaging of the Chest Using CNN. *2021 International Conference on Computing, Electronics & Communications Engineering (iCCECE)*, (pp. 71-76).
- İnik, Ö., & Ülker, E. (2017). Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 85-104.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Advances in Neural Information Processing Systems 25 (NIPS 2012)*.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 436-44.
- Liu, J. (2021). Review of Deep Learning-based Approaches for COVID-19 Detection. *2021 2nd International Conference on Computing and Data Science (CDS)* (pp. 366-371). Stanford, CA, USA: IEEE.
- Lu, M. T., Lu, M. T., Lu, M. T., Aerts, H. J., & Hoffmann, U. (2019). Deep Learning to Assess Long-term Mortality From Chest Radiographs. *JAMA Netw Open* vol. 2,7, 7416.
- Mahmud, M., Kaiser, M. S., Hussain, A., & Vassanelli, S. (2018). Applications of Deep Learning and Reinforcement Learning to Biological Data. *IEEE transactions on neural networks and learning systems*, 29(6), 2063-2079.
- Mahmud, M., Kaiser, M. S., McGinnity, T. M., & Hussain, A. (2021). Deep Learning in Mining Biological Data. *Cognitive computation*, 1-33.
- 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*.
- Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O., & Acharya, U. R. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in biology and medicine*.
- Özbay, E., & Özbay, F. A. (2021). Covid-19 Detection from CT images with Deep Learning and Classification Approaches. *Dicle University Journal of Engineering: Vol. 12*.
- Panwar, H., Gupta, P., Siddiqui, M. K., & Morales-Menendez, R. (2020). Application of deep learning for fast detection of COVID-19 in X-Rays. *Chaos, Solitons and Fractals*.
- Rahman, T., Chowdhury, M., & Khandakar, A. (2021). *COVID-19 Radiography Database*. Retrieved from Kaggle: <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>
- Rahman, T., Khandakar, A., Qiblawey, Y., Tahir, A., Kiranyaz, S., Kashem, S. B., . . . Chowdhury, M. E. (2021). Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images. *Computers in Biology and Medicine*, 132, 104319.
- Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. *Computer Science*.
- Şeker, A., Diri, B., & Balık, H. H. (2017). Derin Öğrenme Yöntemleri Ve Uygulamaları Hakkında Bir İnceleme. *Gazi Mühendislik Bilimleri Dergisi (GMBD)*, 47-64.
- Yılmaz, A. (2021). Çok kanallı CNN mimarisi ile X-Ray görüntülerinden COVID-19 tanısı. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi* , 1761-1774.
- Yılmaz, A., & Kaya, U. (2019). *Derin Öğrenme*.
- Yılmaz, E. (2016). Fetal State Assessment from Cardiotocogram Data Using Artificial Neural Networks. *Journal of Medical and Biological Engineering* 36(6).