



Derin Öğrenme Teknikleriyle Akciğer Röntgeninden Covid-19 Tespiti

Ahmet KORKMAZ^{*a}, Ümit ATILA^b

^{a*} Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalı, KARABÜK, TÜRKİYE

^b Gazi Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümü, ANKARA, TÜRKİYE

MAKALE BİLGİSİ

Alınma: 05.01.2021
Kabul: 10.06.2021

Anahtar Kelimeler:

Covid-19, akciğer
röntgeni, pnömani,
görüntü işleme,
derin öğrenme

*Sorumlu Yazar:

e-posta:
ahmetkorkmaz82.ak@
gmail.com

ÖZET

2019 yılı aralık ayında Çin'in Wuhan kentinde ortaya çıktığı tespit edilen Covid-19 hastalığı çok kısa bir süre içinde tüm dünyayı etkisi altına almıştır. Hastalığın ölümcül sonuçları olduğu ve halen bilinen bir tedavisi olmadığı için yayılmasının önlenmesi amacıyla hasta olan kişilerin erkenden belirlenmesi ve karantinaya alınması hayati önem taşımaktadır. Günümüzde virüsün tespiti için asıl tanı kiti olarak PCR (Polymerase Chain Reaction) testleri kullanılmaktadır. Ancak farklı araştırma sonuçları, hastalığın erken ve geç dönemlerinde PCR testinin negatif çıkabileceğini ve PCR testine alternatif olarak göğüs röntgeninin de hastalığın teşhisinde kullanılabileceğini göstermiştir. Araştırmacılar, Covid -19 belirtileri olan hastaların akciğerlerinde buzlu cam opasitelerine benzer bazı görsel işaretler olduğunu saptamışlardır. Derin öğrenme teknikleri ve bilgisayar donanımlarının her geçen gün daha da gelişmesiyle tıbbın birçok alanında kullanılan derin öğrenme, Covid -19 hastalığının teşhisinde de kullanılabilir. Bu çalışmanın amacı derin öğrenme teknikleri kullanarak göğüs röntgeninden Covid -19 kaynaklı akciğer enfeksiyonu veya farklı bir sebeple var olan pnömani tespiti yapabilmektir. Çalışmada veri seti olarak Covid-19 ve Pnömani (zatürre) hastaları ile sağlıklı bireylerden alınan göğüs röntgenleri kullanılmıştır. Üç farklı sınıfta her birinden 1000'er adet olmak üzere toplam 3000 adet resim dosyası bulunmaktadır. Eğitimin sonunda elde edilen model ortalama %97 doğrulukla sınıflandırma yapabilmektedir.

DOI: 10.30855/AIS.2021.01.01

Detection Of Covid-19 From Chest X-ray Images Using Deep Learning Techniques

ARTICLE INFO

Received: 05.01.2021
Accepted: 10.06.2021

Keywords:

Covid-19, chest x-ray,
pneumonia,
image processing,
deep learning

*Corresponding

Authors

e-mail:
ahmetkorkmaz82.ak@
gmail.com

ABSTRACT

Covid -19 disease, which has been detected in Wuhan, China in December 2019, has affected the whole world in a very short time. Since the disease has fatal consequences and there is currently no known cure, it is vital that people who are sick are identified and quarantined early to prevent its spread. Today, PCR tests are used as the main diagnostic kit for the detection of the virus. However, according to different research results, it shows that the PCR test may be negative in the early and late stages of the disease and that chest X-ray can be used in the diagnosis of the disease as an alternative to the PCR test. Researchers have found that patients with symptoms of Covid -19 have some visual signs in their lungs similar to ground glass opacities. With the development of deep learning techniques and computer equipment, deep learning, which is used in many areas of medicine, can also be used in the diagnosis of Covid -19. The aim of this study is to detect Covid -19-induced lung infection or pneumonia with a different cause from chest X-ray using deep learning techniques. Chest X-rays taken from Covid-19 and Pneumonia patients and healthy individuals were used as data set in the study. There are a total of 3000 picture files, 1000 of each, in three different classes. The model obtained at the end of the training can classify with an average accuracy of 97%.

DOI: 10.30855/AIS.2021.01.01

1. GİRİŞ (INTRODUCTION)

2019 yılı sonu, kısa zamanda tüm dünyayı etkisi altına alıp yıllar sürecek bir pandeminin başlangıcı olarak tarih sayfalarına geçmiştir. Çin’de ortaya çıkan yeni tip bir koronavirüs, insanların evden işe, okuldan restoranlara kadar birçok alanda hayatlarının seyrini değiştirmiştir. Bir tarafta maskesiz birini gördüğünde insanlar o kimseden uzak durmaya çalışırken diğer yandan normalde hastalık derecesinde sayılan temizlik alışkanlıkları rutin hale gelmiştir. Günümüzde farklı ülkelerde geliştirilen aşı türleri mevcut olsa da halen etkili bir tedavi yöntemi bulunmadığından ve dahi virüsün de sürekli yeni varyantları ortaya çıktığından hastalık halen insanlık için fazlasıyla tehlikeli olmaya devam etmektedir. Bu süreçte hastalığın yayılmasını engellemenin en önemli yolu hasta bireylerin çok hızlı bir şekilde sağlıklı bireylerle temasının kesilmesinden geçmektedir.

Hasta olan bireylerin tespiti için farklı yöntemler mevcutsa da günümüzde Sağlık Bakanlığımızın hastalığın teşhisi için kabul ettiği asıl tanı kiti PCR testleridir. Bu testler boğaz ve burundan alınan sürüntüde virüsün izinin aranması şeklinde uygulanmaktadır. Ancak Covid-19 hastalığının bulaşma ve ilerleme süresinde hastalık ilk olarak ağız ve burun yoluyla bulaşırken daha sonraları solunum yolunu kullanarak akciğerlere inmektedir. Akciğerlere indiğinde araştırmalara göre PCR testleri negatif çıkabilmektedir [1]. Bu nedenle hastalığın belirtilerini taşıdığı halde PCR testi negatif çıkan hastalardan doktorlar akciğer röntgeni istemekte ve teşhisini bu röntgene bakarak koyabilmektedir. Araştırmalara göre Covid-19 hastalığı akciğerlerde buzlu cam opasitelerine benzer görüntülerin oluşmasına sebep olmaktadır [2].

Çalışmanın amacı Covid -19 hastalığının akciğer röntgeninden teşhis edilmesine yardımcı olabilecek yüksek doğruluk oranına sahip bir yöntem geliştirmektir. Çalışma neticesinde elde edilen yöntem, üç farklı sınıfta ortalama %97 doğrulukla tespit yapabilmektedir. Hastalığın teşhisinde hali hazırda kullanılan PCR testleri maliyetli olduğundan, her hastanede PCR testi verme imkânı bulunmadığından ve sonucu nispeten uzun sürede çıktığından, bu yöntem karar vericilere yardımcı olabilir.

1.1. Literatür Taraması (Literature Review)

Covid -19 hastalığının güncel bir konu olması ve tüm dünyayı etkilemesi sebebiyle bu alanda birçok çalışma yapılmış ve her geçen gün bu çalışmalara bir yenisi daha eklenmektedir. Derin öğrenme teknikleriyle akciğer tomografisi ve/veya akciğer röntgeninden hastalığı tespit etmeye çalışan Ohata vd., Mobilenet ve Densenet mimarileri ile tasarlanmış iki yapıyı ayrı ayrı eğitilmiş ve transfer learning metoduyla birleştirilmiştir [3]. Ozturk vd., DarkCovidNet ismini verdikleri Darknet’in daha az katman ve filtre içeren bir model geliştirmişlerdir [4]. Khan vd., Coronet adı verdikleri modellerini derinlemesine ayrıştırılabilir artık bağlantılar içeren convolüsyon katmanlarından oluşan Xception üzerine kurulu bir model olarak tasarlamışlardır [2]. Li vd., Resnet50 üzerine kurulmuş yerel iki boyutlu ve global üç boyutlu özellik çıkartabilen modellerine Covnet adını vermişlerdir [5]. Brunese vd., öncelikle akciğer röntgeninden kişide akciğer hastalığı olup olmadığını daha sonra eğer varsa bu hastalığın Covid-19 mu başka bir hastalık mı olduğunu, eğer Covid-19 ise hastalığın etkilediği bölgeleri görselleştirmeyi amaçlayan bir model geliştirmişlerdir [6]. İlk iki işlem VGG16 temelli bir yapıyla sağlanırken üçüncü işlem Gradcam yapısıyla sağlanmaktadır [6]. Wang vd., Covid-Net adını verdikleri, Covid-19 için özel tasarlanmış, mimari çeşitliliği yüksek, uzun menzilli seçici bağlantıları olan bir model tasarlamışlardır [7].

Tablo-1 Literatürde Covid-19 tespiti için önerilen derin öğrenme yöntemleri (*Deep learning methods proposed for detection of Covid-19 in the literature*)

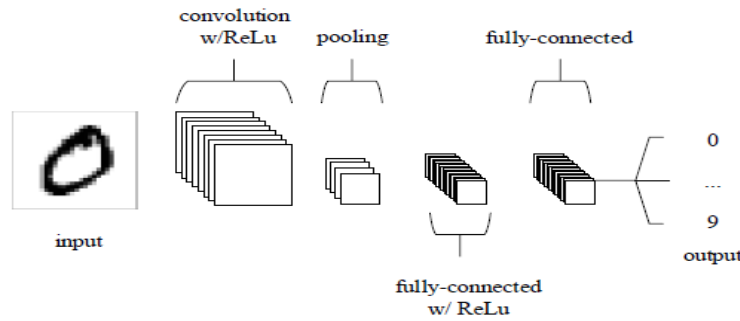
	Model Adı	Yazar	Sınıf Sayısı	Veri Seti	Başarı
1	--	Ohata vd.	2	390 akciğer röntgeni	96%
2	DarkCovidNet	Ozturk vd.	2,3	1125 akciğer röntgeni	2 sınıf 98% 3 sınıf 87%
3	Coronet	Khan vd.	2,3,4	1300 akciğer röntgeni	2 sınıf 99% 3 sınıf 89,6% 4 sınıf 83,5%
4	COVNet	Li vd.	3	4356 akciğer tomografisi	96%
5	--	Brunese vd.	3	6523 akciğer röntgeni	97%
6	COVID-Net	Wang vd.	3	13,975 akciğer röntgeni	93.3%

2. MATERYAL VE YÖNTEMLER (*MATERIAL and METHODS*)

Uygulama Python dilinde yazılmış ve GPU kullanılarak model eğitilmiştir. Modelin tasarımında son zamanlarda görüntü dosyalarını sınıflandırmada etkin bir şekilde yararlanılan Konvolüsyonel Sinir Ağları kullanılmıştır.


2.1. Konvolüsyonel Sinir Ağları (*Convolutional Neural Networks*)

KSA'lar çok katmanlı algılayıcıların bir türü olarak düşünülebilir. Çok katmanlı sinir ağlarına ilave olarak özellik çıkartma (feature extension) yeteneği olan yapay sinir ağlarıdır. Bunu konvolüsyon ve biriktirme(pooling) işlemleriyle gerçekleştirmektedirler [9]. Sistemin genel yapısı şekildeki gibidir.




Şekil 1 KSA temel yapısı (*CNN base structure*) [8]

Burada girdi olarak diğer yapay sinir ağlarında olduğu gibi resmin piksel değerleri yer almaktadır. Daha sonra gelen konvolüsyon katmanında resim üzerine bazı filtreler uygulanarak bazı özellikler tespit edilmeye çalışılır. Burada belirlenen çekirdekler resmin üzerinde kaydırılarak skaler çarpım yapıp özellik haritaları çıkartılır.



Şekil 2 Konvolüsyon katmanı (Convolutional layer) [9]

Birçok KSA temelli yapıda Konvolüsyon katmanından sonra havuzlama adı verilen bir katman gelmektedir. Bu katmanın amacı işlenecek veri miktarını verinin özelliklerini kaybetmeden azaltmaktır.



Şekil 3 Havuzlama katmanı (Pooling layer) [9]

KSA yapılarının sonuna doğru tam bağlantılı katmanlar kullanılır. Bu katmanın amacı daha önceki bölümlerde tespit edilen farklı özelliklerin toplanarak resmi daha güçlü bir şekilde ifade eden bir çıktı alınmasıdır [10].

2.2. Veriseti (Dataset)

Yapılan çalışmada veri seti olarak Covid-19 ve Pnömani hastaları ile sağlıklı bireylerin akciğer röntgen görüntülerinden oluşan üç farklı sınıfta her bir sınıftan 1000 adet olmak üzere toplamda 3000 adet akciğer röntgeni kullanılmıştır [11,12,13]. Görüntü dosyaları işlem süresini kısaltmak amacıyla 224*224*3 boyutunda yeniden boyutlandırılmış ve piksel yeşinlik değerleri 0-1 arasına çekilerek normalize edilmiştir.

Modelinin eğitiminde ve değerlendirilmesinde 5-katlamalı çapraz doğrulama yöntemi kullanılmıştır. Buna göre veri kümesi 5 alt kümeye ayrılmış ve her defasında 1 alt küme test için kalan 4 alt küme ise eğitim için kullanılmıştır. Böylece 5 defa eğitim ve test işlemleri gerçekleştirilmiş ve her birinde 2400 görüntü eğitim 600 görüntü ise test amacıyla kullanılmıştır.

Tablo-2 5-katlamalı çapraz doğrulama için eğitim ve test verileri düzeni (Training and test data scheme for 5-fold cross validation)

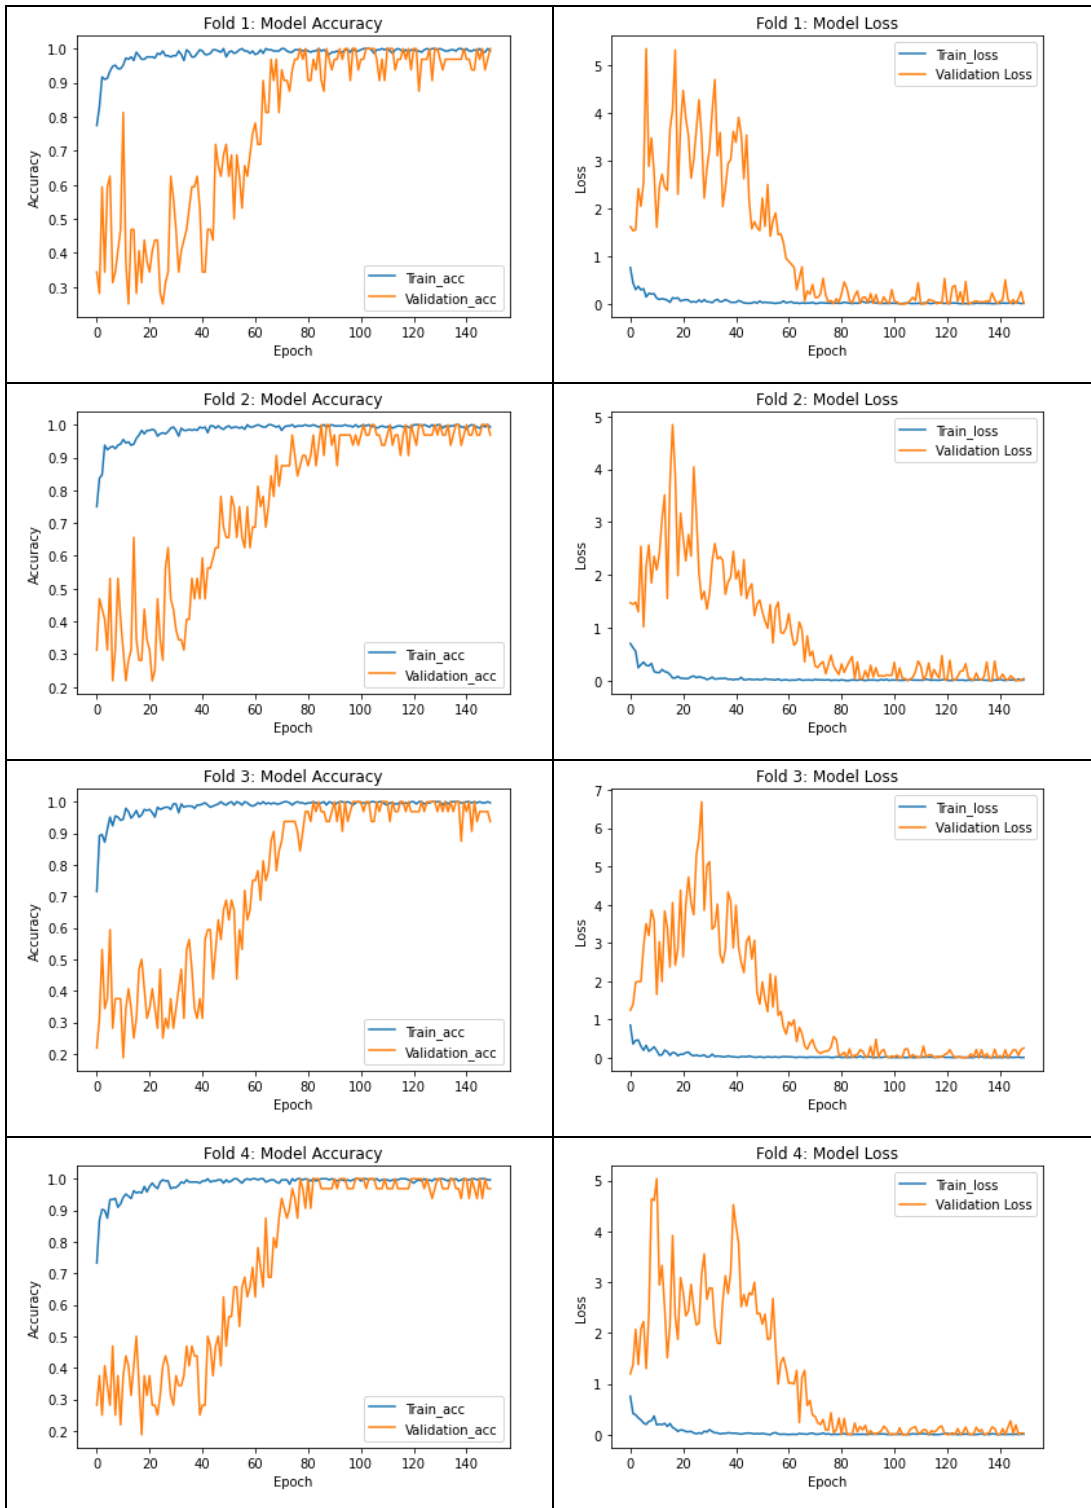
Katlama-1	Test (600)	Eğitim (600)	Eğitim (600)	Eğitim (600)	Eğitim (600)
Katlama-2	Eğitim (600)	Test (600)	Eğitim (600)	Eğitim (600)	Eğitim (600)
Katlama-3	Eğitim (600)	Eğitim (600)	Test (600)	Eğitim (600)	Eğitim (600)
Katlama-4	Eğitim (600)	Eğitim (600)	Eğitim (600)	Test (600)	Eğitim (600)
Katlama-5	Eğitim (600)	Eğitim (600)	Eğitim (600)	Eğitim (600)	Test (600)

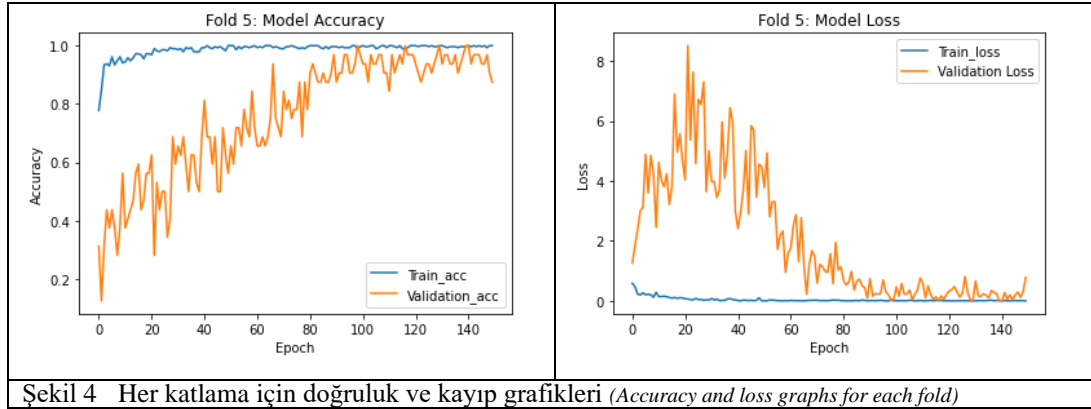
3. Önerilen Yöntem (Proposed Method)

Tasarlanan KSA yapısında 7 konvolüsyon katmanı ve 1 tam bağlantılı katman bulunmaktadır. İlk üç konvolüsyon katmanındaki filtre sayısı 32, kernel ölçüleri sırasıyla 3*3, 3*3 ve 5*5'tir sonraki dört katmandaki filtre sayısı 128, kernel ölçüleri sırasıyla 3*3, 3*3, 5*5, 4*4'tür. Aşırı öğrenmeyi engellemek için her üç konvolüsyon katmanından ve en son konvolüsyon katmanından sonra 0.4 oranında iletim sönümü yapılmıştır. Kayıp fonksiyonu olarak categorical crossentropy, optimizer olarak Adam kullanılmıştır. Eğitim esnasında belli sayıda iterasyon boyunca herhangi bir gelişme olmadığı durumda eğitimin durdurulması için erken durdurma uygulanmıştır. Ayrıca her bir iterasyonda kayıp fonksiyonunun minimum değerini veren model kaydedilmiştir. Konvolüsyon katmanlarında kaybolan eğitim problemi yaşamamak için aktivasyon fonksiyonu olarak Relu, tam bağlantılı son katmanda ise aktivasyon fonksiyonu olarak Softmax kullanılmıştır. Çalışma Kaggle ortamında GPU kullanılarak gerçekleştirilmiştir. Tasarlanan yapıda toplamda yaklaşık 932 bin eğitilebilir parametre bulunmaktadır. Modelin özeti aşağıda yer almaktadır.

Katman (tip)	Çıktı Boyutu	Parametre #
conv2d (Conv2D)	(None, 222, 222, 32)	896
batch_normalization (BatchNo	(None, 222, 222, 32)	128
conv2d_1 (Conv2D)	(None, 220, 220, 32)	9248
batch_normalization_1 (Batch	(None, 220, 220, 32)	128
conv2d_2 (Conv2D)	(None, 110, 110, 32)	25632
batch_normalization_2 (Batch	(None, 110, 110, 32)	128
max_pooling2d (MaxPooling2D)	(None, 55, 55, 32)	0
dropout (Dropout)	(None, 55, 55, 32)	0
conv2d_3 (Conv2D)	(None, 53, 53, 128)	36992
batch_normalization_3 (Batch	(None, 53, 53, 128)	512
conv2d_4 (Conv2D)	(None, 51, 51, 128)	147584
batch_normalization_4 (Batch	(None, 51, 51, 128)	512
conv2d_5 (Conv2D)	(None, 26, 26, 128)	409728
batch_normalization_5 (Batch	(None, 26, 26, 128)	512
max_pooling2d_1 (MaxPooling2	(None, 13, 13, 128)	0
dropout_1 (Dropout)	(None, 13, 13, 128)	0
conv2d_6 (Conv2D)	(None, 10, 10, 128)	262272
batch_normalization_6 (Batch	(None, 10, 10, 128)	512
flatten (Flatten)	(None, 12800)	0
dropout_2 (Dropout)	(None, 12800)	0
dense (Dense)	(None, 3)	38403
=====		
Toplam parametreler: 933,187		
Eğitilebilir parametreler: 931,971		
Eğitilemez parametreler: 1,216		

Önerilen model için her bir katlamada 150 iterasyonluk eğitim gerçekleştirilmiştir. Modelin elde ettiği doğruluk ve kayıp değerlerine ait grafikler Şekil-4'te yer almaktadır.





Şekil 4 Her katlama için doğruluk ve kayıp grafikleri (Accuracy and loss graphs for each fold)

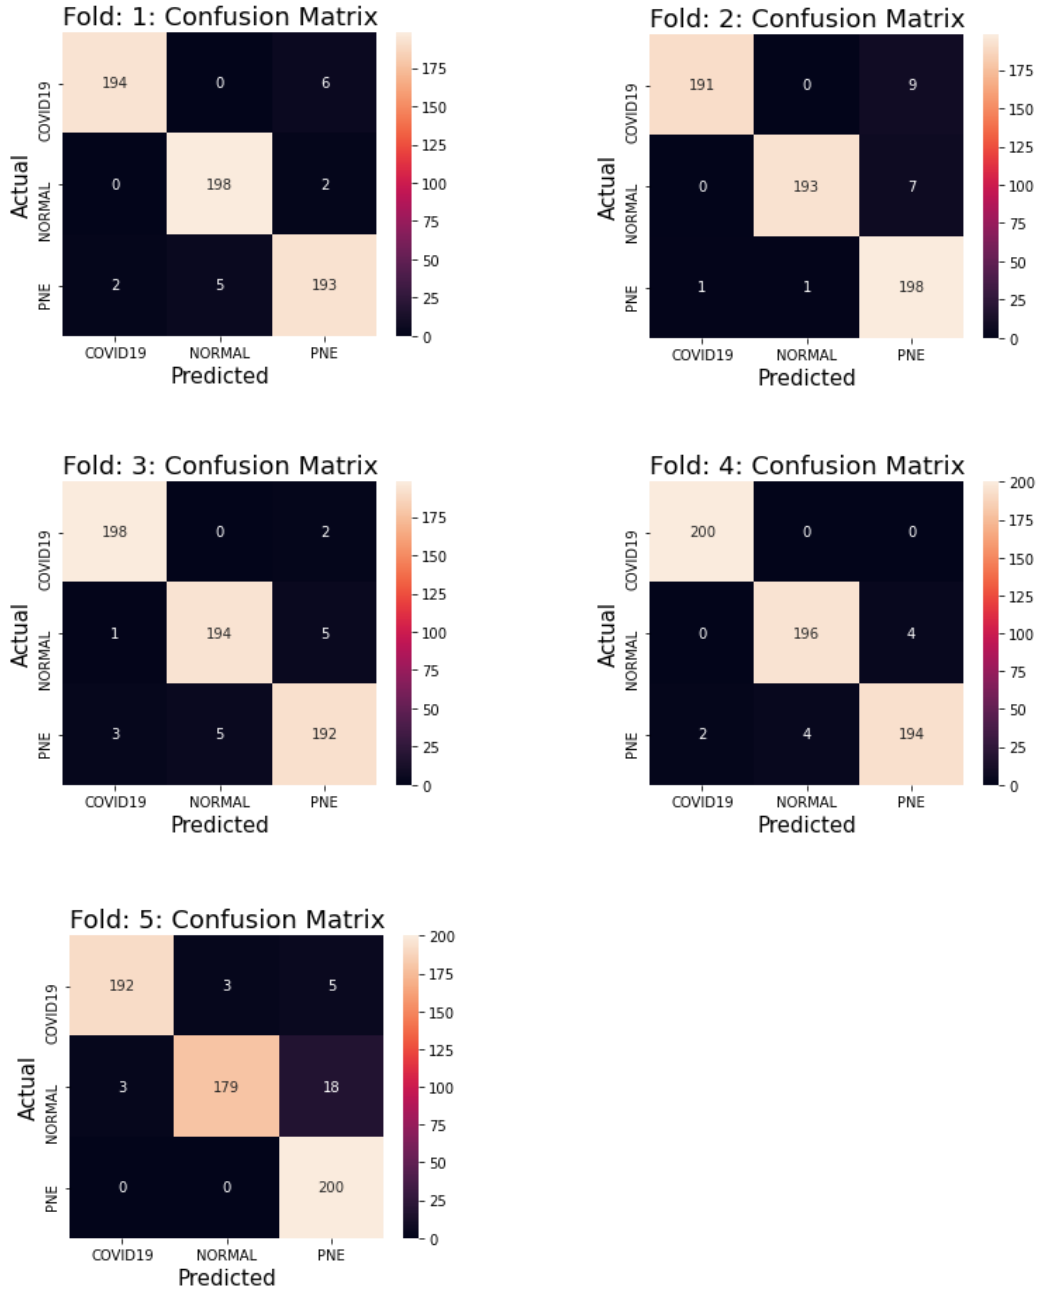
3. SONUÇ VE TARTIŞMA (RESULTS and DISCUSSIONS)

Önerilen yöntemin haricinde, mevcut veri seti üzerinde literatürde başarılı görülen 5 farklı model yine 5-katlamalı çapraz doğrulama yöntemi ile eğitilmiş ve performansları değerlendirilmiştir. Tüm sonuçlar Çizelge-3'te yer almaktadır.

Tablo 3 Uygulama sonuçları (Application Results)


		Önerilen Yöntem	Alexnet [14]	VGG16 [15]	Resnet50 [16]	Inception V3 [17]	Densenet121 [18]
Katlama 1	Acc	0,975	0,967	0,333	0,98	0,973	0,973
	Precision	0,975	0,967	0,167	0,98	0,973	0,973
	Recall	0,975	0,967	0,333	0,98	0,973	0,973
	F1-Score	0,975	0,967	0,167	0,98	0,973	0,973
Katlama 2	Acc	0,97	0,963	0,972	0,985	0,987	0,987
	Precision	0,972	0,964	0,972	0,985	0,987	0,987
	Recall	0,97	0,963	0,972	0,985	0,987	0,987
	F1-Score	0,97	0,963	0,972	0,985	0,987	0,987
Katlama 3	Acc	0,973	0,967	0,963	0,958	0,973	0,973
	Precision	0,973	0,967	0,963	0,959	0,974	0,974
	Recall	0,973	0,967	0,963	0,958	0,973	0,973
	F1-Score	0,973	0,967	0,963	0,958	0,973	0,973
Katlama 4	Acc	0,983	0,97	0,975	0,992	0,985	0,985
	Precision	0,983	0,97	0,975	0,992	0,985	0,985
	Recall	0,983	0,97	0,975	0,992	0,985	0,985
	F1-Score	0,983	0,97	0,975	0,992	0,985	0,985
Katlama 5	Acc	0,952	0,945	0,93	0,953	0,967	0,967
	Precision	0,955	0,947	0,933	0,956	0,969	0,969
	Recall	0,952	0,945	0,93	0,953	0,967	0,967
	F1-Score	0,952	0,945	0,93	0,953	0,967	0,967
Ortalama	Acc	0,9706	0,9624	0,8346	0,9736	0,977	0,977

Uygulama sonucunda her bir katlama için elde edilen karmaşıklık matrisleri Şekil-9'da yer almaktadır.

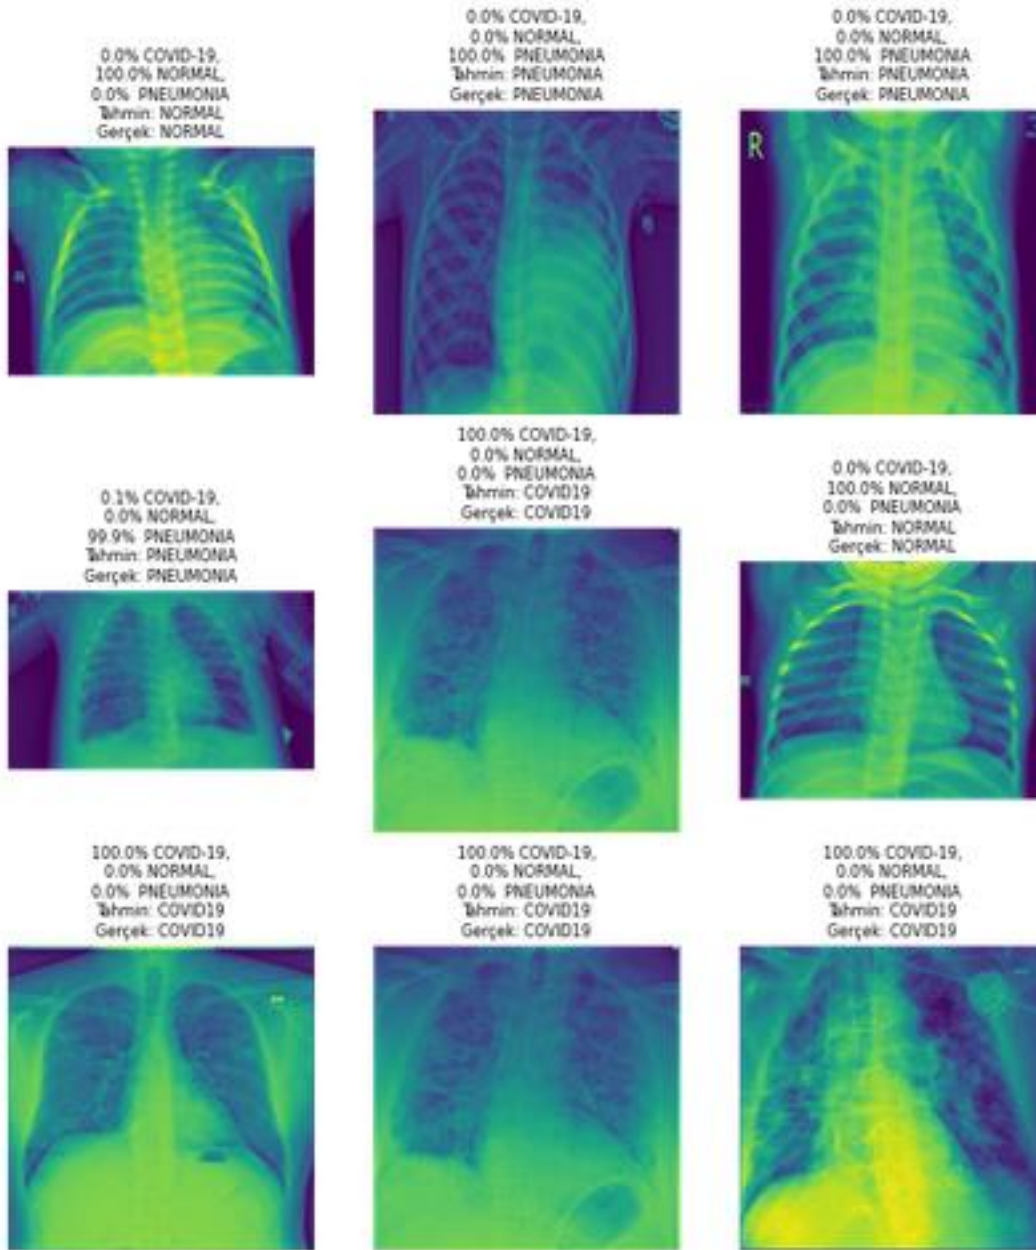


Şekil 9 Her bir katlama için elde edilen karmaşıklık matrisleri (*Confusion matrices obtained for each fold*)

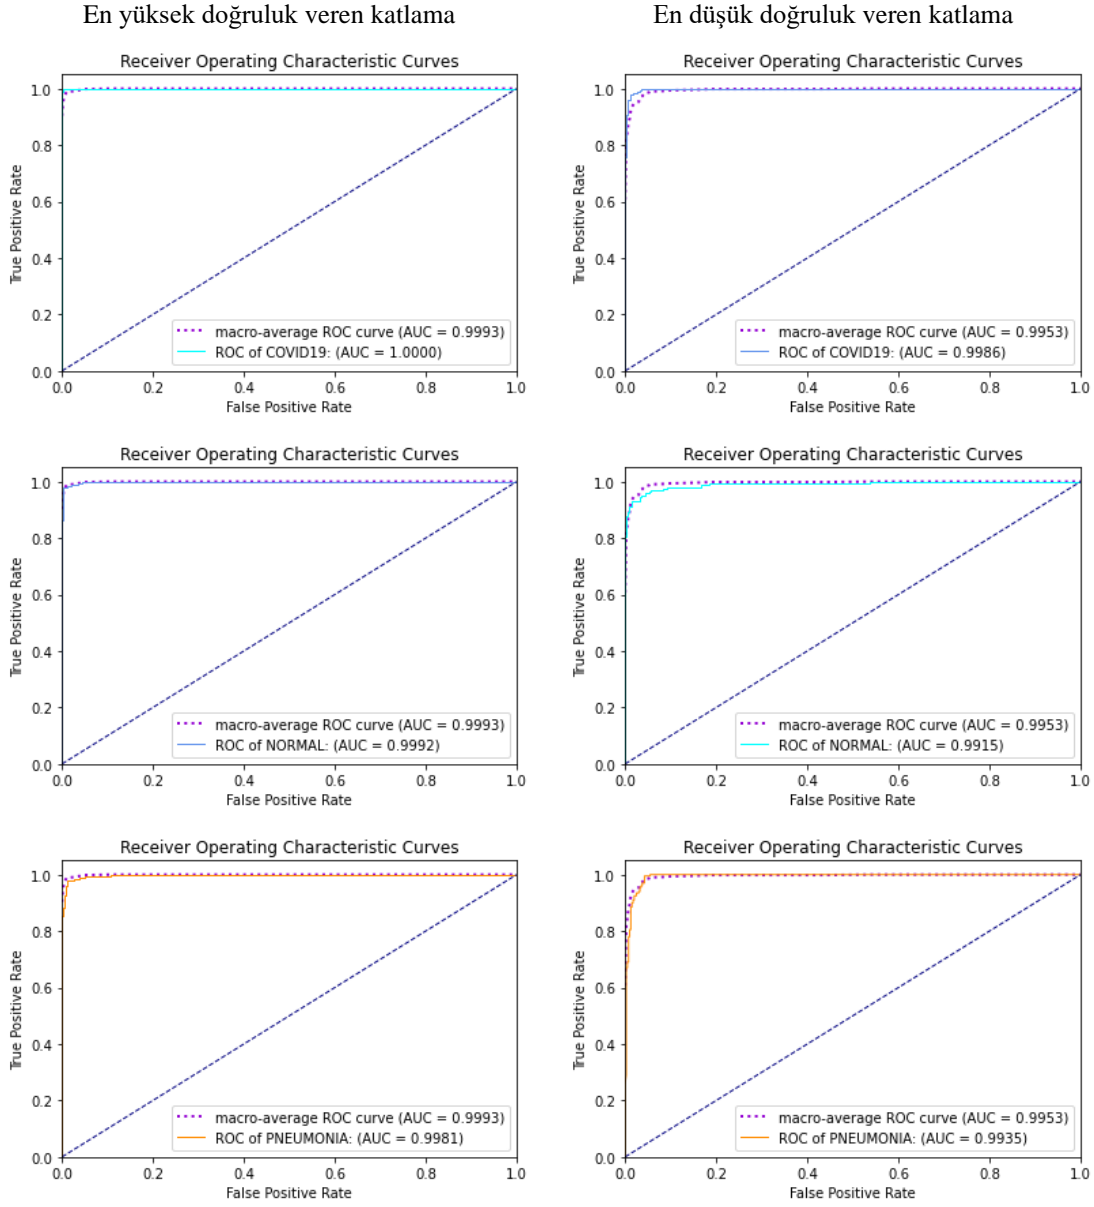
Her bir katlamada elde edilen modeller, 600 resimden 10 ila 29'unu hatalı tahmin etmiştir. Hatalı ve doğru sınıflandırılan bazı resimler Şekil-10 ve Şekil-11'te verilmiştir.



Şekil 10 Hatalı sınıflandırılan bazı resimler (*Some misclassified images*)



Şekil 11 Doğru sınıflandırılan bazı resimler (*Some true classified images*)



Şekil 12 ROC eğrileri ve AUC değerleri (ROC curves and AUC values)

Şekil-12'de her bir sınıf için en düşük ve en yüksek doğruluk değeri veren katlamalardaki ROC eğrileri ve AUC değerleri verilmiştir.

Çalışmada, günümüzde tüm dünyayı etkisi altına alan ve hızla yayılan Covid -19 hastalığının teşhis edilmesinde yardımcı olabilecek yüksek doğruluk oranına sahip bir yöntem geliştirmek amaçlanmıştır. Çalışmalar neticesinde elde edilen yöntem, üç farklı sınıfta ortalama %97 doğrulukla Covid -19 hastalığı ve zatürre tespiti yapabilmektedir. Hastalığın ilk safhalarında akciğerde Covid -19 semptomları görülmediğinden ve çalışma tıp ana bilim dalında yapılmadığından kesin teşhis aracı olarak kullanılamasa da hali hazırda hastalığının teşhisinde kullanılan PCR testleri ile kıyaslandığında daha yüksek doğruluk oranı, düşük maliyet ve kısa işlem süresi dikkate alındığında yardımcı bir yöntem olarak kullanılabilir. Örneğin acile gelen hastaların ön muayene sonrasında istenecek bir röntgen görüntüsü üzerinden saniyeler içinde verdiği sonuçla, karar verecek olan doktora bir fikir verebilir. Ayrıca günümüzde her hastanede PCR testi verme imkânı bulunmamasına rağmen neredeyse tüm

hastanelerde röntgen cihazı bulunmaktadır. Bu açıdan da bakıldığında yine hastalığın teşhisinde karar vericilere yardımcı olabilir

KAYNAKLAR (REFERENCES)

- [1] "COVID-19 Nedir ?", *Covid19.saglik.gov.tr*, 2021. [Online]. Available: <https://covid19.saglik.gov.tr/TR-66300/covid-19-nedir-.html>. [Accessed: 07- Dec- 2020].
- [2] A. Khan, J. Shah and M. Bhat, "CoroNet: A deep neural network for detection and diagnosis of COVID-19 from chest x-ray images", *Computer Methods and Programs in Biomedicine*, vol. 196, p. 105581, 2020. Available: 10.1016/j.cmpb.2020.105581.
- [3] E. Ohata et al., "Automatic detection of COVID-19 infection using chest X-ray images through transfer learning", *IEEE/CAA Journal of Automatica Sinica*, pp. 1-10, 2020. Available: 10.1109/jas.2020.1003393.
- [4] T. Ozturk, M. Talo, E. Yildirim, U. Baloglu, O. Yildirim and U. Rajendra Acharya, "Automated detection of COVID-19 cases using deep neural networks with X-ray images", *Computers in Biology and Medicine*, vol. 121, p. 103792, 2020. Available: 10.1016/j.combiomed.2020.103792.
- [5] L. Li et al., "Using Artificial Intelligence to Detect COVID-19 and Community-acquired Pneumonia Based on Pulmonary CT: Evaluation of the Diagnostic Accuracy", *Radiology*, vol. 296, no. 2, pp. E65-E71, 2020. Available: 10.1148/radiol.2020200905.
- [6] L. Brunese, F. Mercaldo, A. Reginelli and A. Santone, "Explainable Deep Learning for Pulmonary Disease and Coronavirus COVID-19 Detection from X-rays", *Computer Methods and Programs in Biomedicine*, vol. 196, p. 105608, 2020. Available: 10.1016/j.cmpb.2020.105608.
- [7] L. Wang, Z. Lin and A. Wong, "COVID-Net: a tailored deep convolutional neural network design for detection of COVID-19 cases from chest X-ray images", *Scientific Reports*, vol. 10, no. 1, 2020. Available: 10.1038/s41598-020-76550-z.
- [8] O'Shea, K., & Nash, R. An introduction to convolutional neural networks. arXiv preprint (2015).
- [9] CS 230 - Evrişimli Sinir Ağları El Kitabı", Stanford.edu, 2020. [Online]. Available: <https://stanford.edu/~shervine/l/tr/teaching/cs-230/cheatsheet-convolutional-neural-networks#overview>. [Accessed: 10- Dec- 2020].
- [10] Wu, J., Introduction to convolutional neural networks. National Key Lab for Novel Software Technology. Nanjing, 2-3 (2017).
- [11] M. Chowdhury et al., "Can AI Help in Screening Viral and COVID-19 Pneumonia?", *IEEE Access*, vol. 8, pp. 132665-132676, 2020. Available: 10.1109/access.2020.3010287.
- [12] T. Rahman et al., "Exploring the Effect of Image Enhancement Techniques on COVID-19 Detection using Chest X-rays Images", *arXiv: Image and Video Processing*, 2020. [Accessed 14 December 2020].
- [13] D. Kermany et al., "Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning", *Cell*, vol. 172, no. 5, pp. 1122-1131.e9, 2018. Available: 10.1016/j.cell.2018.02.010 [Accessed 7 October 2020].
- [14] A. Krizhevsky, I. Sutskever and G. Hinton, "ImageNet classification with deep convolutional neural networks", *Communications of the ACM*, vol. 60, no. 6, pp. 84-90, 2017. Available: 10.1145/3065386.
- [15] S. Karen, A. Zisserman, Very deep convolutional networks for large-scale image recognition. *arXiv preprint*, 2014, arXiv:1409.1556

- [16] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition", in *IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [17] Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 2818-2826.
- [18] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q., Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 4700-4708.

Ahmet KORKMAZ

Ahmet Korkmaz 1982 yılında Karabük İli Safranbolu İlçesinde doğdu; ilk ve orta öğrenimini aynı şehirde tamamladı. 2000 yılında Erciyes Üniversitesi Nevşehir İİBF İşletme Bölümüne başlayıp 2005 yılında fakülte birincisi olarak mezun oldu. 2006 yılında askerlik hizmetini tamamladı. Aynı yıl Türkiye Finans Katılım Bankası'nda işe başladı. 2008 yılında Türk Telekomünikasyon A.Ş.'de çalışmaya başladı. 2013 yılında Karabük Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümüne başlayıp 2017 yılında iyi bir derece ile mezun oldu. 2019 yılında Karabük Üniversitesi Lisansüstü Eğitim Enstitüsünde Bilgisayar Mühendisliği Anabilim Dalı'nda yüksek lisans eğitimine başladı. Ahmet Korkmaz evli ve üç çocuk babasıdır.

Ümit ATİLA

Ümit Atila 1979 yılında Tarsus'ta doğdu. Lisans ve Yüksek Lisans derecelerini 2002 ve 2007 yıllarında Gazi Üniversitesi'nden, doktora derecesini ise 2013 yılında Karabük Üniversitesi'nden aldı. 2013-2021 yılları arasında Karabük Üniversitesi Bilgisayar Mühendisliği Bölümünde görev yaptı. 2021 yılı içerisinde Gazi Üniversitesi Bilgisayar Mühendisliği Bölümünde göreve başladı ve halen bu kurumda görevine devam etmektedir. Ümit ATİLA evli ve üç çocuk babasıdır.