



Detection of new coronavirus disease from chest x-ray images using pre-trained convolutional neural networks

Ali Narin¹ , Yalçın İşler^{2*}

¹Zonguldak Bülent Ecevit University, Faculty of Engineering, Department of Electrical and Electronics Engineering, 67100, Zonguldak, Turkey
²İzmir Katip Çelebi University, Faculty of Engineering and Architecture, Department of Biomedical Engineering, 35620, Çiğli, İzmir, Turkey

Highlights:

- Automatic detection of COVID-19 patients
- Use of pre-trained deep learning models
- The obtained highest classification performance is 99.3%.

Keywords:

- Diagnosis
- COVID-19
- Coronavirus
- X-ray images
- Deep learning
- ResNet models

Article Info:

Received: 18.11.2020
Accepted: 06.04.2021

DOI:

10.17341/gazimmfd.827921

Correspondence:

Author: Yalçın İşler
e-mail: islerya@yahoo.com
phone: +90 232 329 3535

Graphical/Tabular Abstract

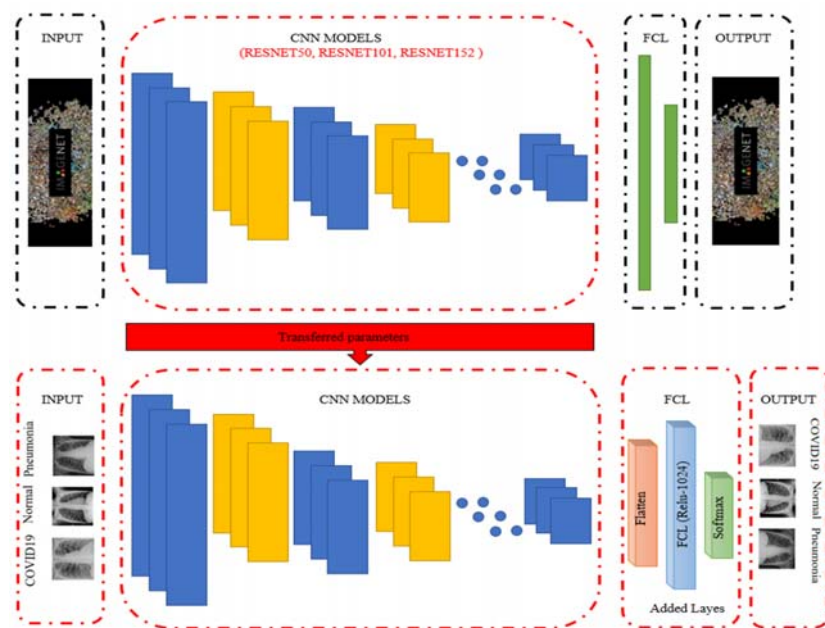


Figure A. Overview of parameter transferring from the pre-trained CNN models

Purpose: The COVID-19 viruses have affected seriously and caused death especially for older people and patients with chronic diseases. Rapid and accurate early diagnosis has a key role to reduce the mortality and to decrease the economic cost of this pandemic. For this purpose, diagnostic kits, diagnostic aids, and diagnosis using medical imaging methods have been investigated. Although the chest imaging using Computed Tomography (CT) has been accepted as a golden standard among them, there is big challenge to reach this equipment in general. Hence, the diagnosis using more accessible devices like X-rays is very crucial. In this study, it is aimed to show the effectiveness of deep learning models based on parameter transferring in the diagnosis of COVID-19 among normal subjects and patients with Viral Pneumonia.

Theory and Methods:

Kaggle's chest X-ray images called the "COVID-19 radiography database" were used in this study. Three different ResNet models (ResNet-50, ResNet-101, and ResNet-152) were investigated (a) to discriminate patients with COVID-19 from normal subjects, (b) to discriminate patients with COVID-19 from patients with Viral Pneumonia, and (c) to discriminate patients with COVID-19, patients with Viral Pneumonia, and normal subjects.

Results:

ResNet-50 model gave the highest performances among these three models. We achieved the accuracy of 99.3% to discriminate COVID-19 and Normal, the accuracy of 99.3% to discriminate COVID-19 and Viral Pneumonia, and the accuracy of 97.3% to discriminate COVID-19, Normal, and Viral Pneumonia.

Conclusion:

The pre-trained ResNet-50 model has a big potential to detect the patients with COVID-19 quickly and accurately using chest X-Ray images only. Since X-ray devices are relatively more accessible devices in health organizations, the proposed model has a big potential, which may help defeating this pandemic.



Yeni Koronavirüs hastalığının önceden eğitilmiş evrişimli sinir ağları kullanılarak göğüs röntgen görüntülerinden tespiti

Ali Narin¹, Yalçın İşler^{2*}

¹Zonguldak Bülent Ecevit Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü, 67100, Zonguldak, Türkiye

²İzmir Katip Çelebi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Biyomedikal Mühendisliği Bölümü, 35620, Çiğli, İzmir, Türkiye

Ö N E Ç İ K A N L A R

- COVID-19 hastalarının otomatik tespiti
- Önceden eğitilmiş derin öğrenme modellerinin kullanımı
- En yüksek %99,3 sınıflandırma başarımının elde edilmesi

Makale Bilgileri

Araştırma Makalesi
Geliş: 18.11.2020
Kabul: 06.04.2021

DOI:

10.17341/gazimmfd.827921

Anahtar Kelimeler:

Teşhis,
COVID-19,
Koronavirüs,
röntgen görüntüleri,
derin öğrenme,
ResNet modelleri

ÖZ

COVID-19 yüksek ölüm oranına sahip hızlı yayılan bir virüsdür. Hızlı ve doğru bir erken teşhis ölüm oranını düşürmede ve bu salgının ekonomik maliyetini azaltmada anahtar bir role sahiptir. Bu amaçla, teşhis kitleri ve tıbbi görüntüleme araçları kullanılarak otomatik tespit mekanizmaları geliştirilmektedir. Tıbbi görüntüleme araçları arasında bilgisayarlı tomografi ve röntgen cihazı görüntüleri yardımıyla teşhis konulması oldukça önem kazanmaktadır. Üç farklı ResNet modeli (ResNet 50, ResNet 101 ve ResNet 152) (a) COVID-19 hastalarının sağlıklı bireylerden ayırt edilmesi, (b) COVID-19 hastalarının zatürre hastalarından ayırt edilmesi ve (c) COVID-19 hastalarının zatürre hastaları ve sağlıklı bireylerden ayırt edilmesi için denenmiştir. Bu modeller arasında en yüksek sonuçları ResNet 50 modeli vermiştir. Elde edilen sonuçlara göre, COVID-19 hastalarının sağlıklı bireylerden ayırt edilmesinde %99,3 başarıya, COVID-19 hastalarının zatürre hastalarından ayırt edilmesinde %99,2 başarıya ve COVID-19 hastalarının hem normal bireylerden hem de zatürre hastalarından ayırt edilmesinde %97,3 başarıya ulaşılmıştır. Sonuç olarak, önceden eğitilmiş ResNet 50 modeli COVID-19 hastalarının sadece göğüs röntgen görüntülerinden hızlı ve doğru bir şekilde tespit edilmesinde büyük bir potansiyele sahiptir. Gerçekleştirilen bu çalışmanın salgını yenme konusunda yardımcı olacağına inanıyoruz.

Detection of new coronavirus disease from chest x-ray images using pre-trained convolutional neural networks

H I G H L I G H T S

- Automatic detection of COVID-19 patients
- Use of pre-trained deep learning models
- Obtaining the highest classification performance was 99.3%.

Article Info

Research Article
Received: 18.11.2020
Accepted: 06.04.2021

DOI:

10.17341/gazimmfd.827921

Keywords:

Diagnosis,
COVID-19,
Coronavirus,
x-ray images,
deep learning,
ResNet models

ABSTRACT

The COVID-19 is a virus that spreads quickly with a high mortality rate. Rapid and accurate early diagnosis has a key role to reduce the mortality and to decrease the economic cost of this pandemic. For this purpose, diagnostic kits and diagnosis using medical imaging methods have been investigated. Among the medical imaging tools, diagnosis with the help of Computed Tomography and X-ray images is very important. Three different ResNet models (ResNet 50, ResNet 101, and ResNet 152) were investigated (a) to discriminate patients with COVID-19 from normal subjects, (b) to discriminate patients with COVID-19 from patients with Pneumonia, and (c) to discriminate patients with COVID-19, patients with Pneumonia, and normal subjects. ResNet 50 model gave the highest performances among these three models. As a result, we achieved the accuracy of 99.3% to discriminate COVID-19 and Normal, the accuracy of 99.2% to discriminate COVID-19 and Pneumonia, and the accuracy of 97.3% to discriminate COVID-19, Normal, and Pneumonia. In conclusion, the pre-trained ResNet 50 model has a big potential to detect the patients with COVID-19 quickly and accurately using chest X-Ray images only. We believe that this study will help to defeat the epidemic.

1. GİRİŞ (INTRODUCTION)

Aralık 2019 sonlarında, ciddi akut solunum yetmezliği koronavirüsünün (SARS-CoV-2) yol açtığı COVID-19 bulaşıcı hastalığı Çin'in Wuhan eyaletinden tüm dünyaya yayıldı [1]. Hastalık kısa sürede akciğerlere saldırdığı için ciddi zatürre sebeptir. Virüs ateş, kuru öksürük ve nefes almada güçlük gibi bazı belirgin belirtiler göstermektedir. Bu hastalık hızlı bir şekilde önce Çin'e yayılmış ve kısa sürede tüm dünyayı etkisi altına almıştır. Yayılma hızı yüzünden Dünya Sağlık Örgütü (WHO) tarafından salgın hastalık olarak ilan edilmiştir [2]. WHO tarafından 11 Kasım 2020 itibarıyla rapor edilen tüm dünyadaki hasta sayısı 53.164.803'e ve ölü sayısı 1.300.576'ya ulaşmıştır [3] ve giderek artmaktadır.

WHO tarafından ölü sayısını ve vaka sayısını düşürmek için COVID-19 salgınıyla mücadeleye yönelik etkin yöntemlerin yer aldığı bir rehber kitap yayınlandı [4, 5]. Çünkü konjestif kalp yetmezliği teşhisi [6], astım teşhisi [7], kanser hücrelerinin tespit edilmesi [8, 9] ve diğer yaygın hastalıklarda olduğu gibi, virüsün etkisini azaltmak için erken teşhis çok önemli bir yere sahiptir. COVID-19 teşhisinde solunum yollarından virüs nükleik asitlerini bulmaya yönelik "gerçek zamanlı tersine transkriptaz-polimeraz zincir reaksiyonu" (RT-PCR) test kiti kullanılmaktadır [10, 11]. Fakat bu yöntem test yapılacak kişi için zorlayıcı, zaman alıcı ve maliyetlidir [12]. Bu kit COVID-19 hastalarına doğru bir teşhis konulmasında zaman zaman hatalı sonuçlara sebep olabildiğinden, röntgen ve bilgisayarlı tomografi (BT) gibi tıbbi görüntüleme yöntemleri doktorların başvurduğu alternatif yaklaşımlar arasında olmuştur [13]. %98 gibi yüksek bir hassasiyete sahip olduğu için BT altın standart haline gelmiştir [14, 15]. Öte yandan, birçok bölgede röntgen cihazları BT cihazlarından daha kolay ulaşılabilir olduğundan dolayı, göğüs röntgeni filmleri hem teşhiste hem tedavinin gelişiminin takibinde faydalı olabileceği ifade edilmiştir [16].


Bununla birlikte hasta sayısı artmasıyla birlikte artacak olan iş yükü nedeniyle, medikal görüntülerin gözle incelenmesi doğru teşhisi zorlayıcı olmaktadır [17, 18]. Aynı zamanda gözle incelemede hastalığın bulaşmasından ancak 10-12 gün sonra, radyologlar tarafından göğüs röntgeni gibi görüntülerden hastalığın rahat teşhis edilebilir olduğu rapor edilmiştir [19]. Bu süre hastalıkla mücadelede geç kalınmaya sebep olabilecek kadar uzundur. Çeşitli hastalıkların teşhisinde bu olumsuzlukların üstesinden gelmek için makine öğrenmesi tabanlı bilgisayar destekli teşhis sistemleri geliştirilmiştir [20, 21]. Son zamanlarda, makine öğrenmesi yöntemleri arasında derin öğrenme yöntemleri beyin hastalıklarının tespiti [22], tiroid bozukluklarının teşhisi [23], kapsül endoskopi görüntülerinin sınıflandırılması [24], beyin tümörlerinin bulunması [25] ve işaret dili tanıma [26] gibi çok çeşitli uygulamalarda birçok araştırmacının ilgi odağı haline gelmiştir. Bunun başlıca sebepleri arasında bu yöntemlerin öznitelik çıkarma, öznitelik seçimi ve histogram eşitleme gibi birçok ön işlem yöntemine ihtiyaç duymaması sayılabilir [27]. Literatürde, göğüs röntgeni filmlerinden COVID-19 teşhisine

yönelik çeşitli derin öğrenme yaklaşımları yer almaya başlamıştır. Öztürk ve arkadaşları, 17 evrişim katmanının yer aldığı DarkNet derin öğrenme modeli kullanarak hem COVID-19 hastalarını sağlam bireylerden hem de COVID-19 ve zatürre hastaları ile sağlam bireylerden teşhis etmeye çalışmışlardır [28]. Başka bir çalışmada Li ve arkadaşları, 2239 röntgen görüntüsünü (239 COVID-19 hastası, 1000 zatürre hastası, 1000 sağlıklı denek) kullanarak bu üç gruba ayırt edici maliyet duyarlı öğrenme (discriminative cost-sensitive learning, DCSL) modeli ile teşhis etmeye çalışmışlardır [29]. Apostolopoulos ve Mpesiana ise iki farklı göğüs röntgeni görüntüsü seti (birincisi 224 COVID-19 hastası, 700 zatürre hastası ile 504 sağlıklı bireyden oluşan ve diğeri 224 COVID-19 hastası, 714 zatürre hastası ile 504 sağlam denekten oluşan) üzerinden MobileNet v2 modelini denemişlerdir [30]. Narin ve arkadaşları ise önceden eğitilmiş ResNet 50 derin öğrenme modelini kullanarak COVID-19 hastalarını sağlıklı bireylerden ayırt etmeye çalışmışlardır [31]. Bir diğer çalışmada Wang ve Wong, COVID-Net isimli yeni bir derin öğrenme modeli kullanarak 53 COVID-19 hastasını, 5526 COVID-19 temasını ve 8066 normal kişiyi tespit etmeye çalışmışlardır [32]. Son olarak, Sethy ve Behera ResNet 50 derin öğrenme modeli kullanarak 25 COVID-19 hastası ve 25 sağlıklı bireye ait röntgen görüntülerinden öznitelikler çıkarmışlar ve bu öznitelikleri Destek Vektör Makineleri (SVM) algoritması ile sınıflandırmaya çalışmışlardır [33]. Bu çalışmada, COVID-19 hastalarını zatürre hastalarından ve normal bireylerden ayırt etmek için röntgen filmi görüntülerinin uygulandığı üç farklı önceden eğitilmiş ResNet derin öğrenme modeli denenmiştir. Açık kaynak erişimli verisetlerinin kullanıldığı bu çalışma boyunca, COVID-19 hastaları normal bireylerden, COVID-19 hastaları zatürre hastalarından, COVID-19 hastaları normal bireylerden ve zatürre hastalarından olmak üzere üç farklı veriseti durumu için derin öğrenme algoritmaları tekrar edilmiştir.

2. MATERYAL VE YÖNTEM (MATERIAL AND METHOD)

2.1. Veri Seti (Data Set)

Bu çalışmada Kaggle tarafından erişime sunulan "COVID-19 radiography database" olarak da bilinen röntgen görüntüleri veritabanı kullanılmıştır [34]. Bu veritabanında 4 farklı veriseti toplu bir şekilde bulunmaktadır: (1) İtalyan Medikal ve Girişimsel Radyoloji Topluluğu (SIRM) tarafından sunulan "COVID-19 Database", (2) Cohen, Morrison ve Dao tarafından GitHub üzerinden sunulan "Novel Corona Virus 2019 Dataset", (3) 43 farklı bilimsel makaleden derlenen "COVID-19(+) Chest X-ray Images", ve (4) Kaggle göğüs röntgen görüntülerinden oluşan "Kaggle chest X-ray database" [35-37]. Bu şekilde toplam 219 COVID-19 hasta görüntüsü, 1345 zatürre hastası görüntüsü ve 1341 normal bireylerin görüntüsü derlenmiştir. Derlenen bu görüntülerin çözünürlüğü literatürdeki benzer çalışmalarda olduğu gibi 224 x 224 boyutuna dönüştürülmüştür. Şekil 1'de bu üç gruba ait örnek görüntülere yer verilmiştir.



Şekil 1. Bir (a) COVID-19 hastasına, (b) zatürre hastasına ve (c) ve sağlıklı bireye ait örnek röntgen görüntüleri
(Example x-ray images of (a) a patient with COVID-19, (b) a patient with Pneumonia, and (c) a normal subject.)

2.2. Evrişimli Sinir Ağları (Convolutional Neural Networks)

Evrişimli sinir ağları (CNN) uygulanan veriyi doğrudan işleyerek sonuç elde etmek için kullanılan bir makine öğrenme modelidir [38]. CNN özellikle sınıflandırma, tespit ve bölütleme amaçlı olarak görüntü işlemede etkileyici sonuçlar sergilediğinden son zamanlarda oldukça popüler hale gelmiştir [39].

Standart bir CNN modeli evrişim katmanı, havuzlama katmanı ve tam bağlı katmanlarından oluşmaktadır [40]. Evrişim katmanı, modelin en temel katmanı olup modele de ismini vermektedir. Geleneksel makine öğrenmesindeki öznitelikler bu evrişim katmanları sayesinde elde edilir. Havuzlama katmanı, öznitelik ve parametre sayısını düşürmekte kullanılır, böylece hesaplama maliyeti düşürülür. Tam bağlı katmanlar ise geleneksel makine öğrenmesindeki çok katmanlı yapay sinir ağı gibi çalışır. Bu katmanlarda Destek Vektör Makineleri (SVM) ve k-Yakın Komşuluk (KNN) gibi çeşitli sınıflandırıcı algoritmalarına da yer verilebilir. Özellikle, tam bağlı hesaplama katmanlarında Relu aktivasyon fonksiyonu (Eş. 1) kullanılır ve CNN çıkışına SoftMax aktivasyon fonksiyonu (Eş. 2) eklenir. Böylece çıkışa ait olasılıksal bir değer elde edilir.

$$\text{Relu}(x) = \begin{cases} x & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (1)$$

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^k e^{x_j}} \quad (2)$$

Burada x giriş verisini, i ve j verilerin indislerini ve k ise toplam sınıf sayısını göstermektedir.

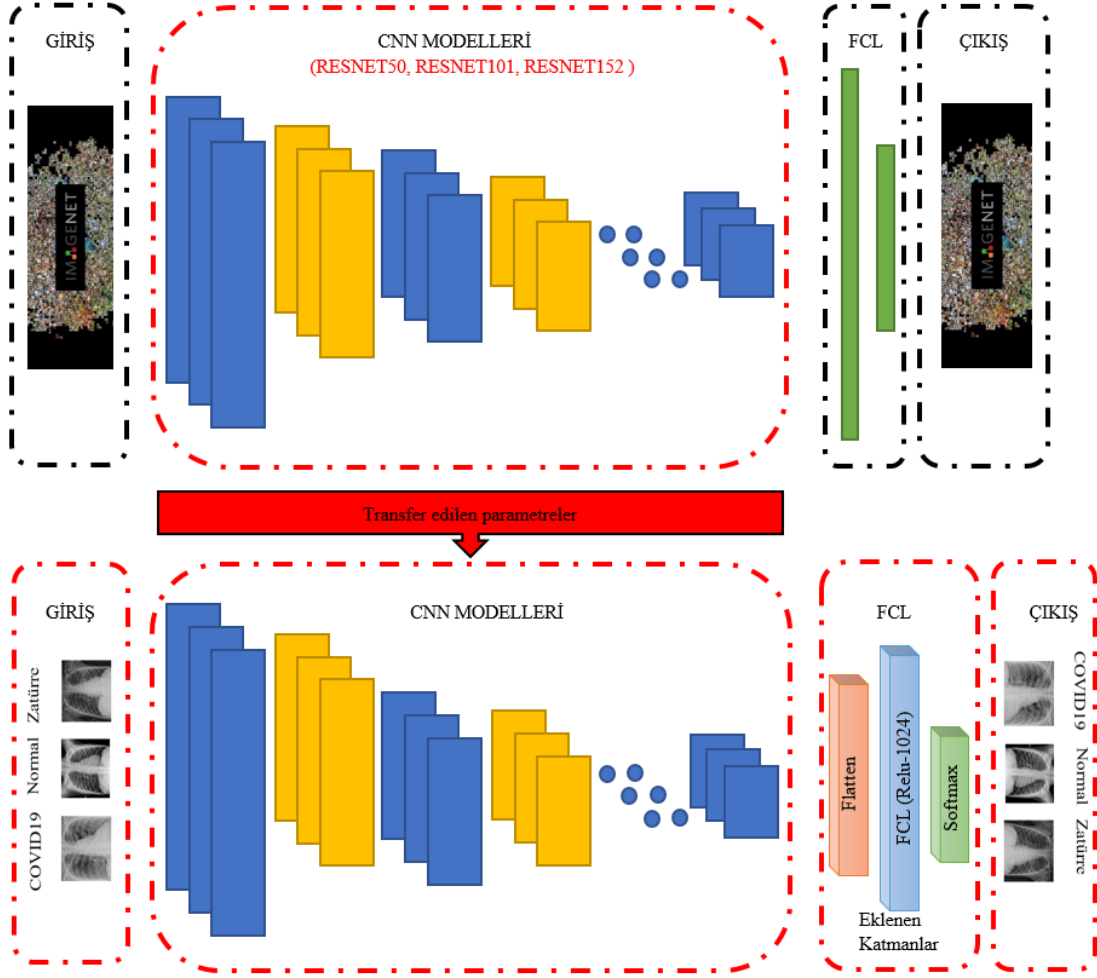
CNN modelinin eğitiminde model yapısına ve seçilen eğitim parametrelerine bağlı olarak bazı sorunlar ortaya çıkabilmektedir. CNN kullanan bazı çalışmalarda, ağın eğitimdeki kararlılığını sağlayabilmek için evrişim ve havuzlama katmanları arasına bir normalizasyon katmanı da eklenmektedir [41]. Benzer şekilde, öğrenme katsayısı ve iterasyon sayısı gibi model parametrelerinin seçimi de CNN modelinin eğitiminde önemli rol oynamaktadır. Örneğin, iterasyon sayısının çok yüksek seçilmesi halinde modelin veriyi ezberlemesine sebep olabilmektedir.

Yukarıda bahsedilen katmanların farklı sayı ve kombinasyonlarının düzenlenmesiyle AlexNet, VGG ve ResNet gibi derin öğrenme CNN modelleri geliştirilmiştir [42, 43]. Bununla birlikte, bu modeller kendi parametrelerini girişe uygulanan verilerden doğrudan öğrendikleri için, CNN derin öğrenme modellerinin eğitimi için çok yüksek miktarda veriye ihtiyaç duyulmaktadır [44]. Oysaki çok büyük miktarda veri toplamak genellikle olanaksız veya aşırı maliyetli olabilmektedir. Bu problemin üstesinden gelebilmek için ise öğrenme aktarımı yöntemi (veya parametre aktarımı yöntemi olarak da bilinmektedir) geliştirilmiştir [45]. Bu yöntemde, farklı bir büyük veriseti kullanılarak eğitilmiş bir modelin parametreleri ilgilenilen modele aktarılmaktadır. Daha sonra bu yeni CNN modeli az miktardaki probleme özgü veriye uygunlaştırılmaktadır. Bu türdeki derin öğrenme modelleri “önceden eğitilmiş modeller” olarak tanımlanmaktadır.

Bu çalışmada, 1000 farklı sınıfa ait 1 milyon görüntüden oluşan ImageNet veriseti kullanılarak eğitilen, oldukça popüler olan ResNet 50, ResNet 101 ve ResNet 152 önceden eğitilmiş CNN derin öğrenme algoritmaları kullanılmıştır [46]. 2016 yılında geliştirilmiş olan bu ön eğitilmiş ResNet mimarilerinin genel yapıları Şekil 2’de gösterilmektedir [43]. ResNet 50 yapısındaki CNN modeli içinde 23 milyondan fazla parametre bulunmaktadır. ILSVRC-2015 ImageNet yarışmasında [47], AlexNet ve VGG gibi iyi bilinen derin öğrenme modellerinden daha iyi başarımlar elde etmesiyle ResNet modelleri dikkatleri üzerine çekmiştir. 101 katmana sahip ResNet 101 modeli ve 152 katmana sahip ResNet 152 modeli ile ResNet modelleri çeşitlendirilmiştir.

2.3. Veri Artırma (Data Augmentation)

Derin öğrenme modellerinin yüksek performans sergilemesi için veri sayısının fazla olması gerekmektedir [44]. Eğer veri miktarı az ise, sınıflandırıcıların eğitimi sırasında sıklıkla aşırı öğrenme (yani ezberleme) ortaya çıkmaktadır. Bu durumda, sınıflandırıcının eğitim hatası sürekli düşmeye devam ederken, test hatası belirli bir süre düşer fakat sonra yükselmeye başlar. Bu durumda modelin aşırı öğrenme (yani ezberleme) durumu meydana gelir. Aşırı öğrenmeyi engellemek için, veri sayısının artırılabilmesi için mevcut



Şekil 2. Önceden eğitilmiş CNN modellerinden parametre transferinin genel görünümü
(Overview of parameter transferring from the pre-trained CNN models.)

verilere benzeyen sentetik veriler eklenir. Bu işleme veri artırma denir. Verilerin artırılması için her bir veri üzerinde eksenlere göre simetri alınması, çeşitli açılarla görüntülerin döndürülmesi, görüntüye ait renklerin değiştirilmesi, görüntüye gürültü eklenmesi (Gauss vb.), görüntülerin belli bir kısmının kırılması, görüntülerin belli oranlarda yakınlaştırılması veya uzaklaştırılması ve görüntülerin ölçeklenmesi gibi işlemler uygulanır [48]. Bu işlemler sonucunda görümlerin sayısı artırılmış ve daha fazla veri ile modellerin eğitimi gerçekleşmiş olmaktadır.

2.4. Performans Değerlendirme (Performance Evaluation)

Sınıflandırıcıların tahmin performanslarının değerlendirilmesinde literatürde sık kullanılan dört ölçek Accuracy (Eş. 3), Recall (Eş. 4), Precision (Eş. 5) ve F1-score (Eş. 6)'da verilmiştir [49, 50]:

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (3)$$

$$Recall = \frac{TP}{TP+FN} \quad (4)$$

$$Precision = \frac{TP}{TP+FP} \quad (5)$$

$$F1 - score = \frac{Precision \times Recall}{Precision+Recall} \quad (6)$$

Burada TP doğru olarak sınıflandırılan pozitif hasta sayısını, FN yanlışlıkla hasta değil diye sınıflandırılan pozitif hasta sayısını, TN doğru olarak sınıflandırılan hasta olmayan sayısını ve FP ise yanlışlıkla hasta diye sınıflandırılan fakat aslında hasta olmayan kişi sayısını göstermektedir [51, 52].

2.5. K-Katlamalı Çapraz Değerlendirme (K-Fold Cross Validation)

Bilindiği üzere sınıflandırma çalışmalarında, sınıflandırıcının yüksek eğitim başarımı göstermesi, daha önce görmediği test verileri karşısında da yüksek başarımla göstereceği anlamına gelmemektedir [49]. Bu nedenle, tüm sınıflandırıcı çalışmalarında veriseti, eğitim ve test diye ikiye ayrılır. K-katlamalı çapraz değerlendirme yönteminde, veriseti k parçaya ayrılır. Bunlardan k-1 parçası eğitim için kullanılırken 1 tanesi test için kullanılır. Bu işlem tüm parçalar test için kullanılıncaya kadar tekrar edilir.

Sınıflandırıcı başarımları ise eğitim ve test için yarı yarıya ortalamaları alınarak sınıflandırıcı eğitim başarımları ve sınıflandırıcı test başarımları olarak hesaplanmış olur [53]. Bu çalışmada, k katlama değeri 3 olarak alınmıştır.

2.6. Google Colaboratory Kullanarak Uygulama (Implementation Using Google Colaboratory)

Google Colaboratory (kısaca Colab olarak da bilinir), Google tarafından sağlanan ücretsiz bir bulut hizmetidir [54]. Google Colab ile normal işlemci (CPU), grafik işlemci (Tesla K80 GPU) veya tensör hesaplama (TPU, Tensor Processing Unit) ile algoritmalar koşturulabilir. TPU, Google tarafından büyük boyutlu verilerle çalışmak üzere geliştirilmiştir. TPU biriminin, GPU veya CPU birimlerinden ortalama olarak 15 - 30kat daha hızlı olduğu rapor edilmektedir [55]. Google Colab platformunda, Python programlama dili ve Keras, TensorFlow, PyTorch ve OpenCV gibi popüler kütüphaneler kullanılarak derin öğrenme uygulamaları kolaylıkla geliştirilebilmektedir. Bu çalışmada kullanılan tüm algoritmalar Google Colaboratory platformunda geliştirilmiştir.

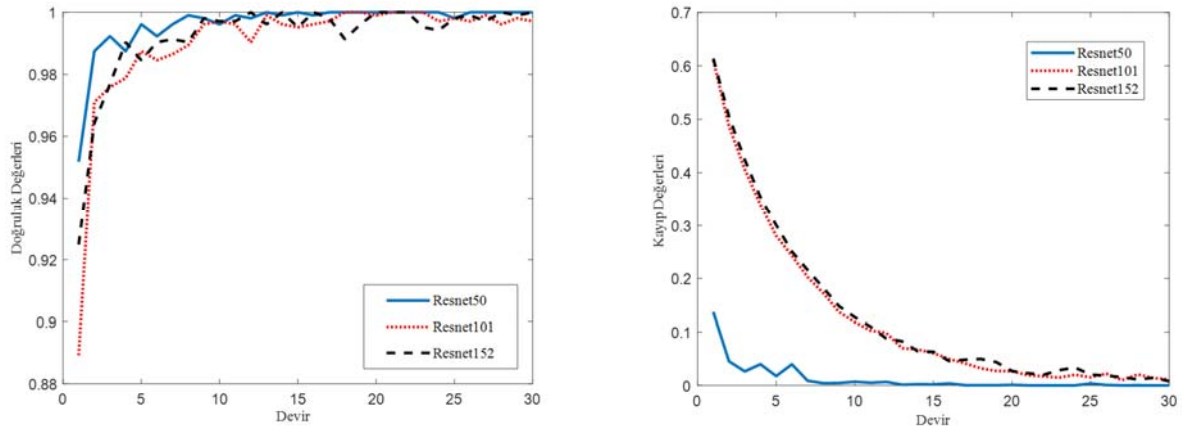
3. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)

Bu çalışmada kullanılan tüm algoritmalar ve hesaplamalar Python programlama dili [56] ile Tensorflow Keras kütüphanesi [57] kullanılarak Google Collaboratory [54] ortamında gerçekleştirilmiştir. Bahsi geçen üç önceden eğitilmiş ResNet derin öğrenme modelinin sınıflandırıcı başarımlarını karşılaştırabilmek için, veriseti ve sınıflandırıcı kombinasyonlarına 3-katlı çapraz değerlendirme yöntemi uygulanmıştır [58, 59]. Yani, her seferinde verisetinin 2/3'ü eğitim ve 1/3'ü test için kullanılmıştır. Bu yöntemle, her model üç defa eğitilmiş ve ortalama başarımları hesaplanmıştır. Röntgen görüntülerinin sayısı kısıtlı olduğundan, veri artırımı işlemlerinden yeniden ölçekleme (1/255), kesme (0.1), yakınlaştırma (0.1) ve yatay yer değiştirme yöntemleri uygulanmıştır [60].

Uyarlamalı moment tahmini (ADAM) optimizasyon algoritması modelin eğitim sırasında parametrelerin güncellenmesinde kullanılmıştır [61]. Aktarılan modellere ilave olarak, eğitime tabi tutulacak 3 yeni katman eklenmiştir. Bunlar: Düzleştirme (Flatten) katmanı, Relu aktivasyon fonksiyonuna sahip tam bağlı katman ve Softmax aktivasyon fonksiyonuna sahip tam bağlı katman şeklindedir. Ayrıca, algoritmaların eğitiminde öğrenme hızı $1e-5$ ve küme büyüklüğü (batch size) 3 olarak seçilmiştir. Yapılan ön denemelerde aşırı öğrenme (yani ezberleme) durumunun 30 iterasyondan sonra ortaya çıkmaya başladığı görüldüğünden maksimum iterasyon sayısı 30 ile kısıtlanmıştır.

Bu çalışma üç veriseti kombinasyonu için tekrarlanmıştır: (a) COVID-19 hastalarından ve normal bireylerden alınan göğüs röntgeni görüntüleri, (b) COVID-19 hastalarından ve zatürre hastalarından alınan göğüs röntgeni görüntüleri, (c) COVID-19 hastalarından, zatürre hastalarından ve normal bireylerden alınan göğüs röntgeni görüntüleri. Önceden eğitilmiş üç adet ResNet modeli (ResNet 50, ResNet 101 ve ResNet 152) bu üç veriseti kombinasyonu ile eğitilmiştir. Her veriseti kombinasyonuna ait eğitim başarımları ve kayıp değerleri grafik haline getirilmiştir. Bununla birlikte, yüksek eğitim başarımları gerçek hayattaki sınıflandırıcı performansının da yüksek olacağı anlamına gelmemektedir [49]. Bu çalışmada incelenen derin öğrenme modellerinin test verileri üzerindeki başarımları da tablolar halinde kayıt edilmiştir. Takip eden paragraflarda elde edilen sonuçlar sunulmaktadır.

İlk veriseti kombinasyonunda, COVID-19 hastalarının normal bireylerden ayırt edilmesine çalışılmıştır. Üç ResNet modeli için eğitim doğruluğu ve kayıp değerleri Şekil 3'de verilmiştir. ResNet 50 modelinin bu üç model arasında en yüksek eğitim başarımına sahip olduğu görülmüştür. 8 iterasyon sonunda kayıp grafiğinde daha az salınım olduğundan ResNet 50'nin daha kararlı bir sonuç ürettiği söylenebilir. Bu üç ResNet derin öğrenme modelleri kullanılarak ilk verisetinin test setindeki başarımları



Şekil 3. Önceden eğitilmiş üç ResNet modelleri kullanılarak COVID-19 hastalarının sağlıklı bireylerden ayırt edilmesinde eğitim doğrulukları (solda) ve kayıpları (sağda) (The training accuracies (left) and training losses (right) in discriminating the patients with COVID-19 from normal subjects using three pre-trained ResNet models.)

araştırılmıştır. Tablo 1’de özetlenen sonuçlara göre, COVID-19 hastalarının sağlıklı bireylerden ayırt edilmesine ResNet 50 modeli ile %99,3, ResNet 101 modeli ile %97,7 ve ResNet 152 modeli ile %96,1 sınıflandırıcı başarımlarına ulaşılmıştır. En yüksek sınıflandırıcı başarımlarına ResNet 50 modeli ile ulaşıldığı görülmektedir.

İkinci veriseti kombinasyonunda, COVID-19 hastalarının zatürre hastalarından ayırt edilmesine çalışılmıştır. Üç ResNet modeli için eğitim doğruluğu ve kayıp değerleri Şekil 4’de verilmiştir. İlk kombinasyonundakine benzer şekilde, ResNet 50 modelinin bu üç model arasında en yüksek eğitim başarımına sahip olduğu görülmüştür. 11 iterasyon sonunda kayıp grafiğinde daha az salınım olduğundan ResNet 50’nin daha kararlı bir sonuç ürettiği söylenebilir.

Benzer şekilde, bu üç ResNet derin öğrenme modelinin ikinci veriseti kombinasyonu test setindeki başarımları araştırılmıştır. Tablo 2’de özetlenen sonuçlara göre, COVID-19 hastalarının zatürre hastalarından ayırt edilmesine ResNet 50 modeli ile %99,2, ResNet 101 modeli ile %96,0 ve

ResNet 152 modeli ile %94,4 sınıflandırıcı başarımlarına ulaşılmıştır. En yüksek sınıflandırıcı başarımlarına yine ResNet 50 modeli ile ulaşıldığı görülmektedir.

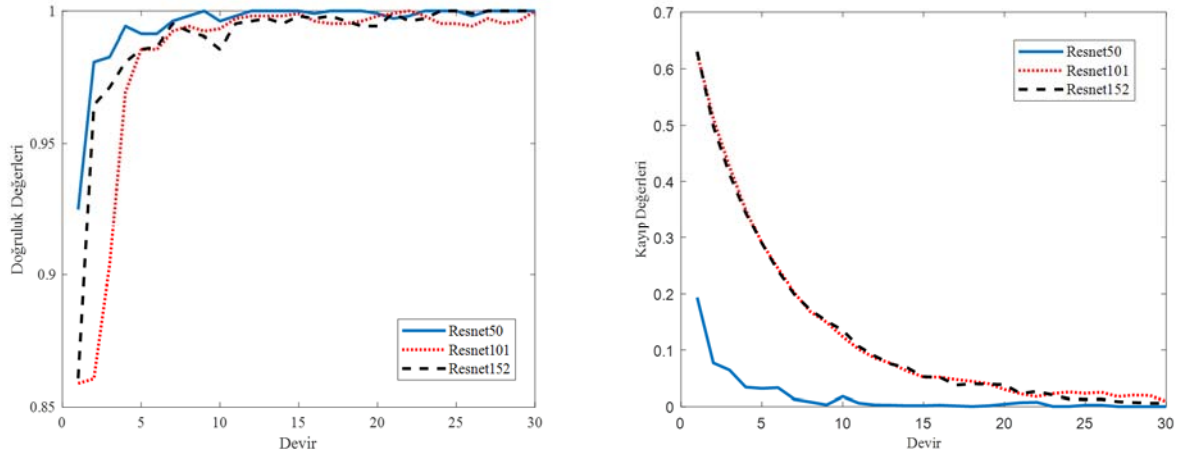
Üçüncü ve son veriseti kombinasyonunda, COVID-19 hastalarının sağlıklı bireylerden ve zatürre hastalarından ayırt edilmesine çalışılmıştır. Üç ResNet modeli için eğitim doğruluğu ve kayıp değerleri Şekil 5’de verilmiştir. Yukarıda bahsedilen diğer kombinasyonlardakine benzer şekilde, ResNet 50 modelinin bu üç model arasında en yüksek eğitim başarımına sahip olduğu görülmüştür. 16 iterasyon sonunda kayıp grafiğinde daha az salınım olduğundan ResNet 50’nin daha kararlı bir sonuç ürettiği söylenebilir.

Son olarak, bu üç ResNet derin öğrenme modelinin üçüncü ve son veriseti kombinasyonu test setindeki başarımları araştırılmıştır. Tablo 3’de özetlenen sonuçlara göre, COVID-19 hastalarının, normal bireylerin ve zatürre hastalarının teşhisinde ResNet 50 modeli ile %99,0, ResNet 101 modeli ile %96,7 ve ResNet 152 modeli ile %96,3 sınıflandırıcı başarımlarına ulaşılmıştır. En yüksek sınıflandırıcı

Tablo 1. COVID-19 hastalarının sağlıklı bireylerden ayırt edilmesinde üç ayrı önceden eğitilmiş ResNet modelinin tahmin performansları

(Prediction performances in discriminating the patients with COVID-19 from normal subjects using three different pre-trained ResNet models)

Model	Accuracy (%)	Recall (%)	Precision (%)	F1-Measure (%)
ResNet 50	99,3	96,8	98,2	97,4
ResNet 101	97,7	85,4	97,9	91,2
ResNet 152	96,1	74,0	97,2	82,6



Şekil 4. Önceden eğitilmiş üç ResNet modelleri kullanılarak COVID-19 hastalarının zatürre hastalarından ayırt edilmesinde eğitim doğrulukları (solda) ve kayıpları (sağda) (The training accuracies (left) and training losses (right) in discriminating the patients with COVID-19 from patients with Pneumonia using three pre-trained ResNet models.)

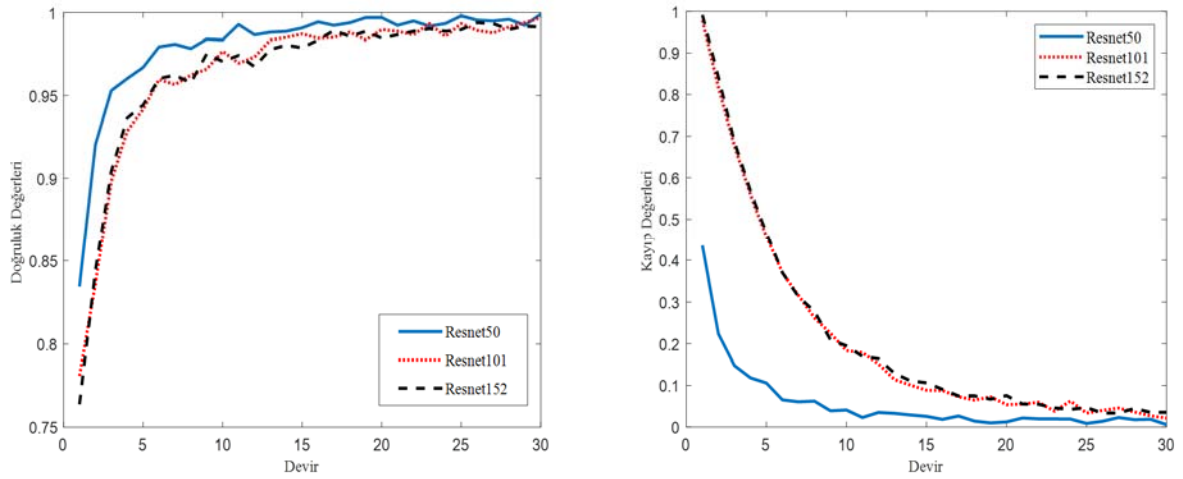
Tablo 2. COVID-19 hastalarının zatürre hastalarından ayırt edilmesinde üç ayrı önceden eğitilmiş ResNet modelinin tahmin performansları

(Prediction performances in discriminating the patients with COVID-19 from patients with Pneumonia using three different pre-trained ResNet models)

Model	Accuracy (%)	Recall (%)	Precision (%)	F1-Measure (%)
ResNet 50	99,2	97,3	97,0	97,0
ResNet 101	96,0	80,4	91,0	85,3
ResNet 152	94,4	67,1	92,8	75,7

başarımına yine ResNet 50 modeli ile ulaşıldığı görülmektedir. Çalışmada elde edilen sonuçlar oldukça yüksek olmasına rağmen, bu sonuçların literatürdeki benzer çalışmalar ile kıyaslanması da gerekmektedir. Tablo 4 ile COVID-19 hastalarının normal bireylerden veya zatürre hastalarından ayırt edilmesi için güncel derin öğrenme modellerini kullanan çalışmalarda elde edilen sonuçlar ile bu çalışmada elde edilen sonuçlar özetlenmiştir. Bu tabloda sadece göğüs röntgen filmlerinden teşhis için geliştirilen çalışmalara yer verilmiştir. Öztürk ve arkadaşları 17 evrişim katmanına sahip DarkNet modelini kullanarak %98,08 doğrulukla COVID-19 hastalarını normal bireylerden ayırt etmeyi başarmışlardır [28]. Başka bir çalışmada, Apostolopoulos ve Mpesiana MobileNet v2 yapısındaki derin öğrenme modelini kullanarak %96,78 doğrulukla COVID-19 hastalarını normal bireylerden ayırt edebilmiştir

[30]. Narin ve arkadaşları Inception V2, Inception V3 ve ResNet 50 yapılarındaki derin öğrenme modellerini denemişler ve COVID-19 hastalarını normal bireylerden ayırt etmede ResNet 50 modeli ile %98,0 başarıya ulaşmışlardır [31]. Sethy ve Behera ise ResNet 50 modelini sadece öznetelik çıkarmada kullanmışlardır. Bu şekilde elde edilen öznetelikleri SVM sınıflandırıcısına uygulayarak %95,00 başarıyla COVID-19 hastalarını normal bireylerden ayırt edebilmişlerdir [33]. Literatürdeki iki sınıflı gerçekleştirilen bir başka çalışmada, Tiwari ve Jain kapsül ağırlar tabanlı VGG modeli ile %97,0 doğruluk değerine ulaşmışlardır [62]. Sonuç olarak, bu çalışmada elde edilen COVID-19 hastalarını normal bireylerden ayırt etmede %99,30 ve zatürre hastalarından ayırt etmede %99,20 sınıflandırıcı başarımları bizim bildiğimiz kadarıyla literatürdeki en yüksek değerlerdir.



Şekil 5. Önceden eğitilmiş üç ResNet modelleri kullanılarak COVID-19 hastalarının, zatürre hastalarının ve sağlıklı bireylerin teşhisinde eğitim doğrulukları (solda) ve kayıpları (sağda)
(The training accuracies (left) and training losses (right) in the diagnosis of the patients with COVID-19, the patients with Pneumonia, and normal subjects using three pre-trained ResNet models.)

Tablo 3. COVID-19 hastalarının sağlıklı bireylerden ve zatürre hastalarından ayırt edilmesinde üç ayrı önceden eğitilmiş ResNet modelinin tahmin performansları
(Prediction performances in discriminating the patients with COVID-19 from patients with Pneumonia and normal subjects using three different pre-trained ResNet models)

Model	Sınıflar	Accuracy (%)	Recall (%)	Precision (%)	F1-Measure (%)
ResNet 50	COVID-19	99,0	96,3	91,5	93,8
	Zatürre	96,2	96,2	96,0	96,0
	Sağlıklı	96,7	95,8	97,1	96,4
	Ortalama	97,3	96,1	94,9	95,4
ResNet 101	COVID-19	98,9	90,9	94,8	92,7
	Zatürre	95,9	94,9	96,2	95,5
	Sağlıklı	96,4	97,1	95,3	96,2
	Ortalama	97,1	94,3	95,4	94,8
ResNet 152	COVID-19	97,7	86,8	84,4	85,3
	Zatürre	93,4	96,4	90,3	93,2
	Sağlıklı	93,4	89,0	96,6	92,5
	Ortalama	94,8	90,7	90,4	90,3

Benzer şekilde, Tablo 5 ile COVID-19 hastalarının zatürre hastalarından ve sağlam bireylerden ayırt edilmeye çalışıldığı çalışmaların sonuçları ile bu çalışmada elde edilen

sonuçlar özetlenmiştir. Tabloda sadece röntgen görüntüleri kullanılarak yapılan çalışmalara yer verilmiştir. Öztürk vd. 17 evrişim katmanına sahip DarkNet modelini kullanarak

Tablo 4. COVID-19 hastalarının göğüs röntgen görüntülerinden teşhisine yönelik sadece iki sınıfın kullanıldığı literatür taraması sonuçları ve bu çalışmanın sonuçlarıyla sınıflandırıcı başarımlarının karşılaştırılması

(The literature search results and performance comparison of classifiers performances with results of this study to classify COVID-19 cases using Chest X-ray images when only two classes were compared)

Çalışma	CNN modeli	Kullanılan görüntü kümesi	Başarım (%)
[28]	DarkNet	125 COVID-19 (+) 500 COVID-19 (-)	98,08
[30]	MobileNet v2	224 COVID-19 (+) 714 Zatürre	96,78
[31]	ResNet 50	50 COVID-19 (+) 50 Normal	98,00
[33]	ResNet 50 + SVM	25 COVID-19 (+) 25 Normal	95,00
[62]	VGG-CapsNet	219 COVID-19 (+) 2686 Non-COVID-19	97,00
<i>Bu çalışma</i>	<i>ResNet 50</i>	<i>219 COVID-19 (+)</i> <i>1341 Normal</i>	<i>99,30</i>
<i>Bu çalışma</i>	<i>ResNet 50</i>	<i>219 COVID-19 (+)</i> <i>1345 Zatürre</i>	<i>99,20</i>

Tablo 5. COVID-19 hastalarının göğüs röntgen görüntülerinden teşhisine yönelik üç sınıfın birlikte kullanıldığı literatür taraması sonuçları ve bu çalışmanın sonuçlarıyla sınıflandırıcı başarımlarının karşılaştırılması

(The literature search results and performance comparison of classifiers performances with results of this study to classify COVID-19 cases using Chest X-ray images when three different classes were used together)

Çalışma	CNN modeli	Kullanılan görüntü kümesi	Başarım (%)
[28]	DarkNet	125 COVID-19 (+) 500 COVID-19 (-) 500 Zatürre	87,02
[29]	DCSL	239 COVID-19 (+) 1000 Zatürre 1000 Normal	97,01
[30]	MobileNet v2	224 COVID-19 (+) 714 Zatürre 504 Normal	94,72
[32]	COVID-Net	53 COVID-19 (+) 5526 COVID-19 (-) 5066 Normal subjects	92,60
[62]	VGG-CapsNet	219 COVID-19 (+) 1345 Zatürre 1341 Normal	92,00
[63]	WOA-BAT based CNN	219 COVID-19 (+) 1345 Zatürre 1341 Normal	97,00
[64]	TLCoV-ResNet-50	219 COVID-19 (+) 1345 Zatürre 1341 Normal	94,41
[65]	DeTraC	105 COVID-19 (+) 11 SARS 80 Normal	93,10
<i>Bu çalışma</i>	<i>ResNet 50</i>	<i>219 COVID-19 (+)</i> <i>1345 Zatürre</i> <i>1341 Normal</i>	<i>97,33</i>

%87,02 sınıflandırıcı başarımına ulaşmışlardır [28]. Başka bir çalışmada, Li ve arkadaşları ise maliyet duyarlı öğrenme modelini kullanarak %97,01 sınıflandırıcı doğruluğuna ulaşmışlardır [29]. Apostolopoulos ve Mpesiana ise MobileNet v2 mimarisindeki derin öğrenme modelini kullanarak %94,72 doğruluğa ulaşmışlardır [30]. Diğer bir çalışmada, Wang ve Wong COVID-Net adını verdikleri yeni bir model kullanarak %92,60 sınıflandırıcı başarımına ulaşmışlardır [32]. Tiwari ve Jain iki sınıflı çalışmaya ek olarak gerçekleştirilen üç sınıflı çalışmalarında %92,0 başarımlarını bulmuşlardır [62]. Pathan ve arkadaşları balina optimizasyon ve BAT algoritması yardımıyla optimize ettikleri evrişimli sinir ağı modeli ile %97,00 başarımlarına ulaşmışlardır [63]. Das ve arkadaşları transfer öğrenme tabanlı geliştirdikleri TLCoV adını verdikleri yaklaşımı ResNet50 modeline uygulayarak %94,41 başarımlarına ulaşmışlardır [64]. Literatürdeki bir başka çalışmada, Abbas ve arkadaşları DeTraC (Decompose, Transfer, and Compose) adını verdikleri bir yöntemle az sayıda veriler üzerinde %93,1 doğruluk değeri elde etmişlerdir [65]. Bu tabloya göre, bu çalışmada ResNet 50 model yapısı kullanılarak ulaşılan %97,33 sınıflandırıcı başarımı en yüksek başarımlardan biridir.

4. KISALTMALAR (ABBREVIATIONS)

ADAM	Uyarlamalı moment tahmini
AlexNet	A. Krizhevsky, I. Sutskever ve G. Hinton tarafından geliştirilmiş derin öğrenme modeli
BT	Bilgisayarlı tomografi
CNN	Evrişimli sinir ağı
COVID-19	Koronavirüs hastalığı 2019
CPU	Merkezi işlem birimi
DCSL	Ayırt edici maliyet duyarlı öğrenme
FN	Yanlış negatif
FP	Yanlış pozitif
ILSRVC	ImageNet büyük ölçekli görsel sınıflandırma yarışması
KNN	k yakın komşu
ResNet	Artık sinir ağı
RT-PCR	Gerçek zamanlı tersine transkriptaz-polimeraz zincir reaksiyonu
SARS-CoV-2	Koronavirüs kaynaklı ciddi akut solunum yetmezliği
SIRM	İtalyan Medikal ve Girişimsel Radyoloji Topluluğu
SVM	Destek vektör makinaları
TN	Doğru negatif
TP	Doğru pozitif
TPU	Tensör hesaplama birimi
VGG	Visual Geometry Group tarafından geliştirilmiş derin öğrenme modeli
WHO	Dünya Sağlık Örgütü
X-ray	Röntgen ışını (X ışını)

5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada, açık erişimli olarak sunulan göğüs röntgen görüntülerinden COVID-19 hastalarının bilgisayar destekli

tespiti yapılmıştır. ResNet 50, ResNet 101 ve ResNet 152 yapısındaki üç farklı ResNet derin öğrenme modeli ile çalışma yürütülmüştür. Elde edilen sonuçlara göre, COVID-19 hastalarının ayırt edilmesinde ResNet 50 yapısındaki CNN derin öğrenme modeli daha başarılı olmuştur. Üstelik bu çalışmada elde edilen sonuçlar, bildiğimiz kadarıyla literatürdeki COVID-19 hastalarının sınıflandırılmasına yönelik en yüksek sınıflandırıcı başarımlarını vermektedir (Tablo 4 ve 5). Bunun nedenleri arasında kullanılan veri sayısının fazla olması, ön eğitilmiş modele eklenen yeni katmanlar, aşırı öğrenmeden kaçınmak için 30 iterasyonlu eğitimin gerçekleştirilmesi ve kullanılan parametrelerin olduğu söylenebilir. Önceden eğitilmiş ResNet 50 derin öğrenme modeli tabanlı COVID-19 teşhis aracı, tıp doktorları için umut verici bir teşhis destek sistemi olma potansiyeline sahiptir. Böyle bir aracın kullanılması halinde teşhis yapan tıp doktorlarının yoğun olan iş yüklerinin azalacağı ve yoğunluk nedeniyle gözden kaçan tanı sayısının azalacağı düşünülmektedir.

Her ne kadar bu çalışmadaki veri sayısı literatürde verilen çoğu çalışmadan fazla olsa da, böyle ölümcül bir salgınla mücadelede önerilen yöntemin etkili olup olmadığı hakkında genel bir yargıya ulaşmak için bize göre hala yetersizdir. Bu sorunu aşabilmek için bu çalışmada da yapıldığı gibi önceden eğitilmiş ağ yapısındaki derin öğrenme modelleri tercih edilmektedir. Elde edilen umut vadeci sonuçlar nedeniyle, önceden eğitilmiş ve parametre transferi tabanlı derin öğrenme modellerinin içinde bulunduğumuz pandemiyi başarılı bir şekilde yönetilmesinin yanısıra uzman radyologlara ve tıp doktorlarına yardımcı olma potansiyeline sahip olduğu görülmektedir.

ETİK BEYANI (ETHICAL DECLARATION)

Bu çalışmada etik kurul izni gerektiren bir durum söz konusu olmayıp kullanılan görüntü verileri internet üzerinden açık ve ücretsiz olarak erişime sunulan veri tabanından elde edilmiştir.

KAYNAKLAR (REFERENCES)

1. Zhu N., Zhang D., Wang W., Li X., Yang B. vd., A novel coronavirus from patients with pneumonia in China, 2019, The New England Journal of Medicine, 382, 727-733, 2020.
2. CDC COVID-19 Response Team, Severe outcomes among patients with coronavirus disease 2019 (COVID-19) - United States, MMWR Morb Mortal Wkly Rep 2020, <https://www.cdc.gov/mmwr/volumes/69/wr/mm6912e2.htm>
3. World Health Organization, Coronavirus disease (COVID-19) situation report of weekly operational update. Nov 13, 2020. <https://www.who.int/publications/m/item/weekly-operational-update-on-covid-19---13-november-2020>.
4. Verma H.K., Merchant N., Verma M.K., Kuru C.I., Singh A.N. vd., Current updates on the European and

- WHO registered clinical trials of coronavirus disease 2019 (COVID-19), *Biomedical Journal*, corrected proof, 2020.
5. World Health Organization, Framework for decision-making: implementation campaigns in the context of COVID-19, Interim Guidance, May 22, 2020.
 6. Isler Y., Discrimination of systolic and diastolic dysfunctions using multi-layer perceptron in heart rate variability analysis, *Computers in Biology and Medicine*, 76, 113-119, 2016.
 7. Badnjevic A., Gurbeta L., Custovic E., An expert diagnostic system to automatically identify asthma and chronic obstructive pulmonary disease in clinical settings, *Scientific Reports*, 8, 1-9, 2018.
 8. Zhou Z.H., Jiang Y., Yang Y.B., Chen S.F., Lung cancer cell identification based on artificial neural network ensembles, *Artificial Intelligence in Medicine*, 24, 25-36, 2002.
 9. Lin T., Yan C.R., Chen W.T., Autonomous detection of pulmonary nodules on CT images with a neural network-based fuzzy system, *Computerized Medical Imaging and Graphics*, 29, 447-58, 2005.
 10. Wang W., Xu Y., Gao R., Lu R., Han K. vd., Detection of SARS-CoV-2 in different types of clinical specimens, *JAMA*, 323, 1843-1844, 2020.
 11. Xu X., Jiang X., Ma C., Du P., Li X. vd., Deep learning system to screen coronavirus disease 2019 pneumonia, *arXiv preprint*, 2020. arXiv:2002.09334.
 12. Ardakani A.A., Kanafi A.R., Acharya U.R., Khadem N., Mohammadi A., Application of deep learning technique to manage COVID-19 in routine clinical practice using CT images: Results of 10 convolutional neural networks, *Computers in Biology and Medicine*, 121, 103795, 2020.
 13. Ai T., Yang Z., Hou H., Zhan C., Chen C. vd., Correlation of chest CT and RT-PCR testing in coronavirus disease 2019 (COVID-19) in China: a Report of 1014 cases, *Radiology*, 296 (2), E32-E40, 2020.
 14. Fang Y., Zhang H., Xie J., Lin M., Ying L. vd., Sensitivity of chest CT for COVID-19: comparison to RT-PCR, *Radiology*, 296 (2), E115-E117, 2020.
 15. Chung M., Bernheim A., Mei X., Zhang N., Huang M. vd., CT imaging features of 2019 novel coronavirus (2019-nCoV), *Radiology*, 295 (1), 202-207, 2020.
 16. Afshar P., Heidarian S., Naderkhani F., Oikonomou A., Plataniotis K.N., Mohammadi A., COVID-CAPS: A capsule network-based framework for identification of COVID-19 cases from x-ray images, *Pattern Recognition Letters*, 138, 638-643, 2020.
 17. Nihashi T., Ishigaki T., Satake H., Ito S., Kaii O. vd., Monitoring of fatigue in radiologists during prolonged image interpretation using fNIRS, *Japanese Journal of Radiology*, 37, 437-448, 2019.
 18. Taylor-Phillips S., Stinton C., Fatigue in radiology: a fertile area for future research, *The British Journal of Radiology*, 92 (1099), 20190043, 2019.
 19. Wong H.Y.F., Lam H.Y.S., Fong A.H.T., Leung S.T., Chin T.W.Y. vd., Frequency and distribution of chest radiographic findings in COVID-19 positive patients, *Radiology*, 296 (2), E72-E78, 2020.
 20. Faust O., Hagiwara Y., Hong T.J., Lih O.S., Acharya U.R., Deep learning for healthcare applications based on physiological signals: a review, *Computer Methods and Programs in Biomedicine*, 161, 1-13, 2018.
 21. Vasilakos A.V., Tang Y., Yao Y., Neural networks for computer-aided diagnosis in medicine: a review, *Neurocomputing*, 216, 700-708, 2016.
 22. Talo M., Yildirim O., Baloglu U.B., Aydin G., Acharya U.R., Convolutional neural networks for multi-class brain disease detection using MRI images, *Computerized Medical Imaging and Graphics*, 78, 101673, 2019.
 23. Zhang Y., Classification and diagnosis of thyroid carcinoma using reinforcement residual network with visual attention mechanisms in ultrasound images, *Journal of Medical Systems*, 43, 323, 2019.
 24. Szczypinski P., Klepaczko A., Pazurek M., Daniel P., Texture and color-based image segmentation and pathology detection in capsule endoscopy videos, *Computer Methods and Programs in Biomedicine*, 113, 396-411, 2014.
 25. Gurkahraman K., Karakiş R., Brain tumors classification with deep learning using data augmentation, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (2), 997-1012, 2021.
 26. Özcan T., Baştürk A., ERUSLR: A new Turkish sign language dataset and its recognition using hyperparameter optimization aided convolutional neural network, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36 (1), 527-542, 2021.
 27. Narin A., Isler Y., Investigation of the effect of histogram equalization method on the classifier performance of the convolutional neural network for Covid-19 chest radiography images, In 2nd International Conference of Applied Sciences, Engineering and Mathematics (IBU-ICASEM 2020), June 4-6, Skopje/North Macedonia, 2020.
 28. Ozturk T., Talo M., Yildirim E.A., Baloglu U.B., Yildirim O., Acharya U.R., Automated detection of COVID-19 cases using deep neural networks with X-ray images, *Computers in Biology and Medicine*, 121, 103792, 2020.
 29. Li T., Han Z., Wei B., Zheng Y., Hong Y., Cong J., Robust screening of COVID-19 from chest x-ray via discriminative cost-sensitive learning, *arXiv preprint* 2020, arXiv:2004.12592.
 30. Apostolopoulos I.D., Mpesiana T.A., Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks, *Physical and Engineering Sciences in Medicine*, 43, 635-640, 2020.
 31. Narin A, Kaya C, Pamuk Z., Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks, *Pattern Analysis and Applications*, 1-14, 2021.
 32. Wang L., Lin Z.Q., Wong A., COVID-Net: a tailored deep convolutional neural network design for detection

- of COVID-19 cases from chest X-ray images, *Scientific Reports*, 10, 19549, 2020.
33. Sethy P.K., Behera S.K., Detection of coronavirus disease (COVID-19) based on deep features, Preprints, 2020030300, 2020.
 34. Chowdhury M.E.H., Rahman T., Khandakar A., Mazhar R., Kadir M.A. vd., Can AI help in screening viral and COVID-19 pneumonia?, *IEEE Access*, 8, 132665 - 132676, 2020.
 35. Casistica Radiologica Italiana, COVID-19 Database, 2020. <https://www.sirm.org/category/senza-categoria/covid-19/>
 36. Cohen J.P., Morrison P., Dao L., COVID-19 image data collection, arXiv preprint, 2020. <https://arxiv.org/pdf/2003.11597.pdf>
 37. Mooney P., Chest X-Ray Images (Pneumonia), <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>, 2018.
 38. Acharya U.R., Oh S.L., Hagiwara Y., Hong Tan J., Adeli H., Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals, *Computers in Biology and Medicine*, 100, 270-278, 2018.
 39. Han D., Liu Q., Fan W., A new image classification method using CNN transfer learning and web data augmentation, *Expert Systems with Applications*, 95, 43-56, 2018.
 40. Goodfellow I., Bengio Y., Courville A., *Deep Learning*, MIT Press, 2016.
 41. Garbin C., Zhu X., Marques O., Dropout vs batch normalization: an empirical study of their impact to deep learning, *Multimedia Tools and Applications*, 22, 1-39, 2020.
 42. Krizhevsky A., Sutskever I., Hinton G.E., Imagenet classification with deep convolutional neural networks, In *Advances in Neural Information Processing Systems 2012*, 1097-1105, 2012.
 43. He K., Zhang X., Ren S., Sun J., Deep residual learning for image recognition, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition 2016*, 770-778, 2016.
 44. Yamashita R., Nishio M., Do R.K., Togashi K., Convolutional neural networks: an overview and application in radiology, *Insights into Imaging*, 9, 611-629, 2018.
 45. Kaur T., Gandhi T.K., Deep convolutional neural networks with transfer learning for automated brain image classification, *Machine Vision and Applications*, 31, 1-16, 2020.
 46. Deng J., Dong W., Socher R., Li L.J., Li K., Fei-Fei L., Imagenet: A large-scale hierarchical image database, In *2009 IEEE Conference on Computer Vision and Pattern Recognition 2009*, 248-255, 2009.
 47. Russakovsky O., Deng J., Su H., Krause J., Satheesh S. vd., ImageNet large scale visual recognition challenge (ILSVRC), *Int J Comput Vis*, 115, 211-252, 2015.
 48. Shorten C., Khoshgoftaar T.M., A survey on image data augmentation for deep learning, *Journal of Big Data*, 6, 60, 2019.
 49. Duda R.O., Hart P.E., Stork D.G., *Pattern Classification*, 2nd Edition, John Wiley and Sons, New York, 2001.
 50. Chicco D., Jurman G., The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation, *BMC Genomics*, 21, 1-6, 2020.
 51. Isler Y., Narin A., Ozer O., Perc M., Early prediction of paroxysmal atrial fibrillation based on short-term heart rate variability, *Physica A*, 509, 56-65, 2018.
 52. Isler Y., Narin A., Ozer O., Perc M., Multi-stage classification of congestive heart failure based on short-term heart rate variability, *Chaos, Solitons & Fractals*, 118, 145-151, 2019.
 53. Wong T., Yang N., Dependency analysis of accuracy estimates in k-fold cross validation, *IEEE Transactions on Knowledge and Data Engineering*, 29, 2417-2427, 2017.
 54. Google Colab, Colaboratory is a free Jupyter notebook environment that requires no setup and runs entirely in the cloud. <https://colab.research.google.com/notebooks/welcome.ipynb>
 55. Jouppi N.P., Young C., Patil N., Patterson D., Agrawal D. vd., In-datacenter performance analysis of a tensor processing unit, In *Proceedings of the 44th Annual International Symposium on Computer Architecture*; 1-12, June 2017.
 56. Chollet F., *Deep Learning With Python*, Shelter Island, NY, USA: Manning, 2019.
 57. Gulli A., Pal S., *Deep learning with Keras*, Packt Publishing Ltd., 2017.
 58. Isler Y., Narin A., Ozer M., Comparison of the effects of cross-validation methods on determining performances of classifiers used in diagnosing congestive heart failure, *Measurement Science Review*, 15, 196-201, 2015.
 59. Narin A., Isler Y., Ozer M., Konjestif kalp yetmezligi teshisinde kullanılan capraz dogrulama yontemlerinin siniflandirici performanslarinin belirlenmesine olan etkilerinin karsilastirilmesi, *Dokuz Eylul Universitesi Fen ve Muhendislik Dergisi*, 16, 1-8, 2014.
 60. Cubuk E.D., Zoph B., Mane D., Vasudevan V., Le Q.V., Autoaugment: Learning augmentation strategies from data, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition 2019*, 1131-23, 2019.
 61. Kingma D.P., Ba J., ADAM: A method for stochastic optimization, In *Proceedings of the International Conference on Learning Representations (ICLR)*, 2014.
 62. Tiwari S, Jain A., Convolutional capsule network for COVID -19detection using radiography images. *Int J ImagingSyst Technol*.1-15, 2021.
 63. Pathan, S., Siddalingaswamy, P. C., Ali, T., Automated Detection of Covid-19 from Chest X-ray scans using an optimized CNN architecture. *Applied Soft Computing*, 107238, 2021.

64. Das A. K., Kalam S., Kumar C., Sinha D., TLCoV-An automated Covid-19 screening model using Transfer Learning from chest X-ray images. *Chaos, Solitons & Fractals*, 144, 110713, 2021.
65. Abbas A., Abdelsamea, M. M., Gaber M. M., Classification of COVID-19 in chest X-ray images using DeTraC deep convolutional neural network. *Applied Intelligence*, 51 (2), 854-864, 2021.

