

Derin Öğrenme ile Göğüs Röntgeni Görüntülerinden COVID-19 ve Viral Pnömoni Tespiti

Pınar TÜFEKÇİ*¹, Burak GEZİCİ²

^{1,2} Tekirdağ Namık Kemal Üniversitesi, Çorlu Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 59860, Tekirdağ, Türkiye.

Sorumlu yazar e-posta *¹:ptufekci@nku.edu.tr

ORCID ID: <https://orcid.org/0000-0003-4842-2635>

e-posta ²:burakgezici333@gmail.com

ORCID ID: <https://orcid.org/0000-0001-8976-0185>

Geliş Tarihi: 02.08.2022

Kabul Tarihi: 18.01.2023

Öz

Günümüz şartlarında her ne kadar pandemi etkilerini kaybetmiş ve bitme sürecinde olsa da, COVID-19 halen etkilerini insanlar üzerinde hafif olarak göstermektedir. Yapay Zeka ve görüntü işleme teknolojilerindeki gelişmelerle birlikte, bu tür virüslerin erken aşamalarda doğru bir şekilde tespit edilmesi, hem doğru tedavinin uygulanarak hastalığın iyileşme sürecine hızlı bir şekilde yardımcı olacak hem de sağlık sistemlerinin üzerindeki yükü hafifletmiş olacaktır. Bu çalışmada, göğüs röntgeni görüntülerinden, COVID-19 ve viral pnömoni hastalıklarını ayırt etmeye çalışan, yüksek doğruluklu ve güvenilir bir model oluşturulmaya çalışılmıştır. Bu amaçla, derin öğrenme algoritmalarından olan Evrişimli Sinir Ağlarının AlexNet ve GoogleNet özel mimarilerinin, doğrudan orijinal halleri ve transfer öğrenmeyle geliştirilmiş halleri uygulanarak, geniş kapsamlı bir modelleme çalışması yapılmıştır. Modelleme sürecinde kullanılan veri seti (COVID-19 Radiography Database) popüler bir veri seti olup, 3 sınıflı ve her sınıfta farklı sayıda örnek bulunduran dengesiz bir veri setidir. Bu veri setine, veri azaltma ve arttırma yöntemleri uygulanarak, her sınıfta eşit sayıda örnek içeren dengeli 2 yeni veri seti oluşturulmuştur. Orijinal veri seti ve yeni oluşturulan veri setleri, 80-20 oranında eğitim ve test veri setine bölünerek ve aynı zamanda 3, 5 ve 10 kez çapraz doğrulamaya göre bölünerek, model performansları ölçülmüştür ve en iyi performansa sahip model bulunmaya çalışılmıştır. Sonuç olarak, en iyi model, veri arttırma yöntemiyle dengeli hale getirilmiş veri setinin, 10 kez çapraz doğrulamaya göre bölünerek, transfer öğrenme ile geliştirilmiş AlexNet mimarisinin uygulandığı model olarak, % 99.90 doğruluk başarısı ile bulunmuştur.

Anahtar kelimeler

COVID-19;
Viral pnömoni;
Derin öğrenme;
AlexNet;
GoogleNet

Detection of COVID-19 and Viral Pneumonia from Chest X-Ray Images with Deep Learning

Abstract

In today's conditions, although the pandemic has lost its effects and is in the process of ending, COVID-19 still shows its effects on people as mild. With the developments in image processing and Artificial Intelligence technologies, the correct detection of such viruses in the early stages will both help the healing process of the disease quickly by applying the right treatment, and will alleviate the burden on health systems. In this study, it has been tried to create a high-accuracy and reliable model that tries to distinguish COVID-19 and viral pneumonia diseases from chest X-ray images. For this purpose, a comprehensive modeling study has been carried out by applying the AlexNet and GoogleNet special architectures of convolutional neural networks, which are deep learning algorithms, directly to their original versions and to their improved versions with transfer learning. The data set used in the modeling process (COVID-19 Radiography Database) is a popular data set and an unbalanced data set with 3 classes and a different number of samples in each class. By applying data reduction and increase methods to this data set, 2 new balanced data sets containing equal number of samples in each class were created. By dividing the original dataset and newly created datasets into training and test datasets at a rate of 80-20, and also by cross validating 3, 5, and 10 times, model performances were measured and the model with the best performance was tried to be found. As a result, the best model was found

Keywords

COVID-19;
Viral pneumonia;
Deep learning;
AlexNet;
GoogleNet

1. Giriş

COVID-19, bir koronavirüs türü olan şiddetli akut solunum sendromu koronavirüs 2'nin (SARS-CoV-2) neden olduğu bulaşıcı bir hastalıktır. Bu hastalık, 2019'da çıkmış ve 11 Mart 2020'de Dünya Sağlık Örgütü (WHO) tarafından resmi olarak bir pandemi olarak ilan edilmiştir. Tıbbi görüntülerin Yapay Zekada (AI) kullanılması, COVID-19 ile enfekte olmuş hastaların hızlı bir şekilde tespit edilip tedavisine başlanması açısından faydalı olmuştur. Bu nedenle, COVID-19'un, sınırlı verilerle kısa sürede, AI'nın görüntü sınıflandırma araçları ile teşhis edilmesi mevcut pandemi ile mücadele için acil bir ihtiyaç haline dönüşmüştür. Yakın geçmişte yapılan bir çalışmada, tüberküloz hastalığının teşhisi için göğüs röntgen görüntüleri kullanılarak derin öğrenme (DL) algoritmaları ile modeller geliştirilmiştir. Benzer çalışmaların, COVID-19'un erken teşhisinde de uygulanabileceği ve doktorlara tedavi sürecinde yardımcı olabileceği önerilmiştir (Yi *et al.* 2020).

COVID-19, görüntü sınıflandırma için oluşturulmuş modeller ile hastanelerde, röntgen görüntülerinden kolaylıkla teşhis edilebilir. Polimeraz Zincir Reaksiyonu (Polymerase Chain Reaction – PCR) testinin sonuçlarının alınmasına göre, çekilen bir göğüs röntgen görüntüsünün bir DL modeline girdi olarak verilip sonucunun alınması işlemi daha hızlı olabilecektir ve bu sayede klinik durum ve model çıktısı normal ise hasta PCR testinin sonuçları beklenirken eve gönderilebilecektir. Ancak, röntgen patolojik bulgular gösteriyorsa, hasta yakın takip için hastaneye yatırılacaktır. Genel olarak, göğüs röntgeninde patolojik bulguların yokluğu veya varlığı, hastayı eve gönderme veya hastayı daha fazla gözlem için hastanede tutma konusunda klinik bir karar vermenin temelini oluşturmaktadır.

Röntgen görüntülerinin yorumlanması ve görüntülerde bulunan ince görsel detayların tespit edilmesi, radyologların kapasitesiyle sınırlıdır. AI, göğüs röntgenlerinde normalde radyologlar tarafından tanınmayacak görüntüleri keşfedebildiğinden (Kim *et al.* 2019), literatürde

COVID-19'u ayırt etmek için Evrişimli Sinir Ağları (ESA) kullanan Derin Öğrenme modellerindeki yeni gelişmeler hakkında birçok çalışma yer almaktadır. Loey *et al.*(2020), Çekişmeli Üretici Ağlar (Generative Adversarial Networks - GAN) ve Derin Transfer Öğrenmesine dayalı modelleme çalışmaları ile COVID-19'u teşhis etmeye çalışmışlardır. Bu çalışmada, 4 öznitelik ve toplam 306 örnekten oluşan 'COVID-19 Image Data Collection' veri seti kullanılmıştır. AlexNet, GoogleNet ve ResNet18 mimarileri ile geliştirilen modellerin sonuçları, sırasıyla, %52, %52.8, %50 olarak paylaşılmıştır. Pham (2020) ise derin öğrenme ile COVID-19'un teşhisi için, 3 farklı veri seti içeriğinden verileri ayrı ayrı toplayarak, 6 farklı veri setine dönüştürmüştür. Dönüştürülen bu veri setleri üzerinde yapılan çalışmalarda, AlexNet, GoogleNet ve SqueezeNet ile modeller geliştirilmiştir ve model sonuçları, sırasıyla, %99.14, %99.70, %99.85 olarak elde edilmiştir.

Minaee *et al.*(2020), Derin Transfer Öğrenmesini kullanarak COVID-19'u teşhis etmeye çalışmışlardır. Bu çalışmada, 2 özniteliği bulunan 'Covid-Xray-5k-Dataset' veri seti kullanılmış olup, bu veri seti toplam 5,000 örnek içermektedir. Modelleme çalışmaları sonucunda, ResNet18, ResNet50, SqueezeNet ve DenseNet-121 ile alınan sonuçlar, sırasıyla %98.30, %98.40, %98.30 ve %98.90 olarak elde edilmiştir. Farooq ve Hafeez'in (2020) birlikte geliştirdikleri COVID-ResNet ve COVID-Net modelleri ile COVID-19 hastaları ile Pnömoni hastalarına ait akciğer görüntülerinden, hastalık teşhisi yapılmaya çalışılmıştır. Kullandıkları veri seti, internet üzerinden farklı yerlerden toplanmış olup, toplam 2,862 örnek görüntü içermektedir. Geliştirilen COVID-ResNet ve COVID-Net modelleri ile, sırasıyla, %96.23 ve %83.5 doğruluk başarıları elde edilmiştir.

Adedigba *et al.*(2021), göğüs röntgeni görüntülerinden COVID-19 teşhisinde bulunmaya çalışmışlardır. Kullandıkları 'COVID-19 Image Data Collection Tuberculosis chest x-ray' adlı veri seti dengesiz olduğu için, öncelikle bu veri setini

uyguladıkları veri arttırma yöntemiyle dengeli hale getirmişlerdir. Daha sonra, dengesiz ve dengeli veri setlerini ResNet ve DenseNet mimarileri ile modelleme çalışmalarında kullanarak, dengesiz veri setiyle, %94.17 ve %94.17 doğruluk başarısını, dengeli veri seti ile de %95.43 ve %96.83 doğruluk başarısı sonuçlarını elde etmişlerdir. Umer *et al.*(2021), göğüs röntgeni görüntülerinden COVID-19'u teşhis etmeye çalışmışlardır. Kullandıkları 'COVID-19 Patients Lungs X-ray Images' adlı veri seti, dengesiz olduğu için öncelikle veri arttırma ile bu veri setini dengeli hale getirmişlerdir. Ardından VGG-16 ve AlexNet mimarilerini dengeli veri setine uygulayarak, modeller geliştirmişlerdir ve sonuç olarak da sırasıyla, %97.76 ve %67.76 doğruluk başarılarını elde etmişlerdir. Elshennawy ve Ibrahim (2020), yaptıkları çalışmada, derin öğrenme ile, önceden eğitilmiş modelleri (ResNet152V2 ve MobileNetV2) tranfer öğrenme ile kendi modelleme çalışmalarında kullanmışlardır. Bu çalışmada, 'Chest X-Ray Images' adlı veri setinin toplam veri sayısı, veri arttırma yolu ile 5,856 adet veriden 30,855'e çıkarılmıştır. Önceden eğitilmiş iki model (ResNet152V2 ve MobileNetV2) ile birlikte, ESA ve 'Long Short Term Memory' (LSTM) derin öğrenme algoritmaları da kullanılmıştır. ResNet152v2, MobileNetV2, ESA ve LSTM'den alınan sonuçlar, sırasıyla, %99.22, %96.48, %92.19 ve %91.80 olarak paylaşılmıştır.

Chouhan *et al.*(2020), transfer öğrenme ile pnömoni teşhisi için yeni bir derin öğrenme modeli geliştirmişlerdir. Kullanılan 'Guangzhou Women and Children's Medical Center' adlı veri seti, toplam 5,232 veri içermektedir. AlexNet, DenseNet121, InceptionV3, GoogleNet ve ResNet18 modelleri uygulanarak alınan sonuçlar sırasıyla, %92.86, %92.62, %92.01, %93.12 ve %94.23 olarak bulunmuştur. Uçar ve Korkmaz da (2020), hafif ağ tasarımı ile öne çıkan SqueezeNet modelini Bayesian optimizasyon katkısı ile COVID-19 teşhisi için uyarlamışlardır. Bu çalışmada kullanılan ve 5,949 adet veri içeren 'COVID-19 Cases from Chest Radiography Images' adlı veri setinin, veri arttırma yolu ile sayıca verileri arttırılmış ve SqueezeNet modeline uygulanmıştır. Model başarısı, %98.30 olarak paylaşılmıştır.

Khan *et al.*(2020), ise COVID-19 tespitini, CoroNet mimarisini kullanarak, 2 ve 3 sınıflı modellemeler ile gerçekleştirmişlerdir. 967 örnek görüntü içeren 'COVID-19 X-Ray Images' adlı veri seti ile %99.00 performans başarısı elde edilmiştir. Öztürk vd. (2020) de göğüs röntgen görüntülerini kullanarak, COVID-19 tespiti için yeni bir model sunmuşlardır. Kullandıkları 'Covid-Chestxray-Dataset' adlı veri setinde toplam 625 görüntü bulunurken, sundukları bu modelde, ESA'dan üretilmiş ve üzerinde bazı değişiklikler yapıldığı bildirilmiştir. DarkCovidNet adını verdikleri bu modelde, ikili ve çok sınıflı sınıflandırma için ortalama doğruluk %98.08 ve %87.02 olarak bulunmuştur.

Apostolopoulos ve Mpesiana (2020), COVID-19'un teşhisini, ESA mimarileri üzerinde gerçekleştirmişlerdir. Kullanılan 'COVID-19 X Rays' adlı veri seti, toplam 1,428 örnek veri içermekte olup, modellerin (VGG-19, MobileNetV2, Inception, Xception ve Inception ResNetV2) sonuçları, sırasıyla, %98.75, %97.40, %86.13, %85.57, %84.38 doğruluk başarısı olarak paylaşılmıştır. Rahman *et al.*(2020), ise COVID-19 tanısında toplam 5,247 örnek içeren, 'Chest X-Ray Images' adlı veri setini kullanarak, 2 ve 3 sınıflı, AlexNet, ResNet18, DenseNet201 ve SqueezeNet mimarileri ile modeller oluşturmuşlardır. Transfer öğrenme ile 3 sınıflı modellemelerden alınan sonuçlar sırasıyla, %88.40, %87.70, %93.30 ve %86.10 doğruluk başarısı olarak elde edilmiştir.

Al-Bawi *et al.*(2020), COVID-19 tanısı amacıyla CCBLOCK adlı bir model geliştirmişlerdir. Kullanılan 'COVID-19 Image Data' adlı veri setinde toplam 1,828 örnek görüntü yer almakta olup, CCBLOCK adlı modelden elde edilen sonuç %98.86 doğruluk başarısı olarak paylaşılmıştır. Majeed *et al.*(2020), COVID-19'u normal göğüs röntgenlerinden teşhis etmek için, daha iyi performans üretecek olan az sayıda parametreye sahip bir ESA mimarisi geliştirmeye çalışmışlardır. Kullanılan 'COVID19-X-Rays' adlı veri setinde toplam 5,840 örnek görüntü olmakla birlikte geliştirdikleri model olan CNN-X ile elde edilen sonuç %99.35 doğruluk başarısı olarak bulunmuştur. Rajpurkar *et al.*(2017), CheXNet modeli ile göğüs röntgenlerinden Pnömoni teşhisi yapmaya çalışmışlardır. Kullanılan 'Hospital-Scale Chest X-Ray Database' adlı veri seti toplam 105,408

örnek veri içermektedir ve CheXNet modelinden elde edilen sonuç %76.80 doğruluk başarısı olarak kaydedilmiştir. Alhudhaif *et al.*(2021), 1,218 görüntü içeren 'Covid-Chestxray-Dataset' adlı veri setini kullanarak COVID-19 ve Pnömoniyi, teşhis etmeye çalışmışlardır. DenseNet201, ResNet18 ve SqueezeNet modelleri ile ikili sınıflandırma performansları, sırasıyla, %94.96, %91.60 ve %89.92 doğruluk başarısı olarak elde edilmiştir.

Vaid *et al.*(2020), COVID-19'un ikili sınıflandırmasının doğruluğunu artırmak için VGG19 mimarisini kullanarak bir model önermişlerdir. Kullanılan veri seti toplam 364 X-ray taraması içermektedir. Modelleme çalışmaları sonucunda, %96.30 doğruluk başarı sonucu alınmıştır. Panwar *et al.*(2020), COVID-19 teşhisi için, nCOVNet'e dayalı bir model önermişlerdir. Bu çalışmada kullanılan veri seti, toplam 337 örnek göğüs röntgeni görüntüsü içermektedir. Modelin performansı, veri seti eğitim için %70 ve test için %30 bölünerek, rastgele örnekleme kullanılarak, ikili sınıflandırma için %88.10 doğruluk başarısı olarak bulunmuştur. Toraman *vd.*(2020), COVID-19 tespiti için Convolutional CapsNet'e dayalı yeni bir model önermişlerdir. Kullanılan veri seti, toplam 3,150 örnek görüntü içermektedir. Sonuçlar, ikili ve çok sınıflı sınıflandırma için %97.24 ve %84.22 doğruluk başarısı ile elde edilmiştir.

Nour *vd.*(2020) da klinik uygulamaları desteklemek için yeni bir COVID-19 tıbbi tanı için derin öğrenme ve Bayes optimizasyonuna dayanan bir model önermişlerdir. Kullanılan veri seti, COVID-19 pozitif 135, negatif 939 ve pnömoni pozitif 941 örnek olmak üzere toplam 2,033 örnek röntgen görüntüsü içerirken, COVID-19 sınıfına ilişkin örneklerin sayısını artırmak için veri arttırma yöntemi kullanılmıştır. Önerilen sistemin performansı, veri setinin eğitim ve test için, %70 ve %30 olarak bölünmesiyle, %97.40 doğruluk başarısı olarak bulunmuştur. Ahuja *et al.*(2020), durağan dalgacıklar yöntemini ile eğitim veri setinin boyutunu artırmak için büyütme kullanmış ve transfer öğrenme ile de farklı ESA mimarilerini karşılaştırmışlardır. Kullanılan veri seti, COVID-19 pozitif için 349 örnek ve negatif için de 397 örnek görüntü içermektedir. Aynı zamanda her iki sınıf için örnek sayısını artırmak için veri büyütme teknikleri uygulanmıştır. Bu çalışmada, örneklerin

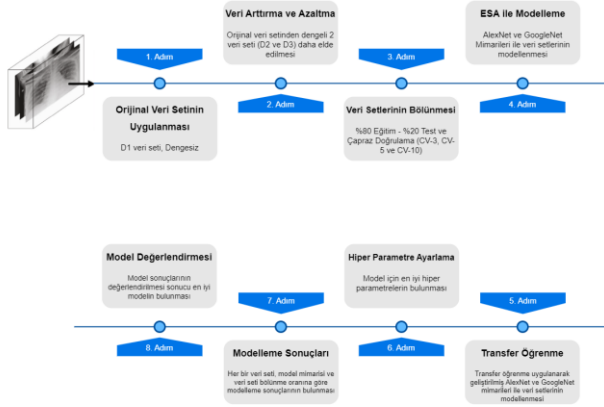
%70'i eğitim, %30'u da test performansını ölçmede kullanılmıştır. En iyi performans, %99.04'lük ikili sınıflandırma başarısı ile ResNet18 modelinden alınmıştır. Konar *et al.*(2021), COVID-19'un otomatik teşhisi için, %93.10 doğruluk başarısıyla yarı denetimli bir sığ sinir ağı modeli önermişlerdir.

Bu çalışmada, popüler bir veri seti olan 'COVID-19 Radiography Database' (CRD) (Int Kyn. 1), kullanılarak COVID-19'un ve Viral Pnömoninin saptanmasına yönelik bir modelleme çalışmasına yer verilmiştir. CRD veri setinde toplam 15,153 örnek akciğer görüntüsü bulunmakta olup, 3,616 görüntü COVID-19 hastalığına yakalanan bireylere, 10,200 görüntü hastalığı bulunmayan bireylere ve 1,345 görüntü ise Viral Pnömoni hastası kabul edilen bireylere ait görüntülerdir. Bu veri setinin, her bir sınıfın farklı sayıda görüntü içermesinden dolayı, dengesiz bir veri seti olduğu saptanmıştır. Bunu bertaraf etmek için, veri azaltma ve arttırma yöntemleri kullanılarak, her bir sınıfta eşit sayıda görüntü olacak şekilde, dengeli veri setleri oluşturulmuştur. Daha sonra dengesiz ve dengeli veri setleri, derin öğrenmenin Evrimsel Sinir Ağlarının en popüler olan özel mimarilerinden, AlexNet ve GoogleNet mimarilerine uygulanarak, geniş kapsamlı deneysel modelleme çalışmaları yapılmıştır. Modelleme çalışmaları, Python programlama dilinin 3. versiyonu kullanılarak geliştirilmiştir. Modelleme çalışmaları esnasında, AlexNet ve GoogleNet mimarilerinin, orijinal ve transfer öğrenmeyle geliştirilmiş hallerini kullanan modeller oluşturulmuştur. Ayrıca, veri setleri, 80-20 oranında eğitim ve test veri seti olarak ve çapraz doğrulamaya (3,5 ve 10 kez) göre bölünerek, model performansları ölçülmüştür ve en iyi performansa sahip model bulunmaya çalışılmıştır. Sonuç olarak, en iyi model, veri arttırma yoluyla oluşturulan dengeli veri setine 10 kez çapraz doğrulama uygulanarak, transfer öğrenmeye dayanarak geliştirilmiş AlexNet mimarisinin kullanıldığı model olarak, % 99.90 doğruluk başarısı ile bulunmuştur.

2. Materyal ve Metot

Bu çalışmada COVID-19 ve Viral Pnömoni tespiti için gerçekleştirilen modelleme sürecinin tüm adımları, Şekil 1'de gösterildiği gibidir ve her bir adım, bu bölümde açıklanmıştır.

Bu çalışma, Intel Core i7 9th Gen@4.50 GHz turbo işlemci, 16 GB RAM ve 4 GB NVIDIA GeForce GTX 1650Ti ekran kartı (GPU) içeren Windows 10 64 bit işletim sisteminde, Google CoLab uygulaması üzerinde, Python tensorflow, timeit, numpy, pandas, os, sklearn, keras, PIL, cv2 ve matplotlib kütüphaneleri kullanılarak gerçekleştirilmiştir. Python'da her işlem için kullanılan kütüphaneler Çizelge 1'de belirtilmiştir.



Şekil 1. Modelleme süreci.

2.1 Veri seti tanıtımı

Bu çalışmada, halka açık olarak paylaşılan 'COVID-19 Radiography Database' kullanılmıştır (Int Kyn. 1) ve D1 olarak adlandırılmıştır. Bu veri seti, COVID-19 (3,616 örnek), Viral Pnömoni (1,345 örnek) ve Normal (10,192 örnek) olmak üzere 3 sınıf ve toplamda 15.153 akciğer röntgen görüntüsü içermektedir. Bu veri setinin, her bir sınıfta farklı sayıda görüntü içermesinden dolayı, dengesiz bir veri seti olduğu görülmüştür.

D1 veri setinden, her bir sınıfta eşit sayıda örnek içeren 2 yeni, dengeli veri seti (D2 ve D3 olarak adlandırılan) türetilmiştir. D1 veri setinin, en düşük ve en yüksek örnek içeren sınıfları 'Viral Pnömoni' (1.345 örnek) ve 'Normal' (10.192 örnek) olduğu görülmüştür. D1 veri setindeki, 'COVID-19' ve 'Normal' sınıflarından rastgele 1.345 örnek ve 'Viral Pnömoni' sınıfının da tamamı seçilerek, D2 veri seti oluşturulmuştur. Ayrıca, D1 veri setinin 'COVID-19' (3.616 örnek) ve 'Viral Pnömoni' (1.345 örnek) sınıflarındaki örnek görüntü sayıları, bu sınıflardaki görüntülere rastgele döndürme veri arttırma yöntemi (Shorten and Khoshgoftaar 2019), 50, 60, 70, 80, 90 ve 100 derece döndürme açıları ile uygulanarak, 'Normal' sınıfının örnek sayısına

(10.192 örnek) yükseltilecek D3 veri seti elde edilmiştir.

Çizelge 1. Çalışmada kullanılan Python kütüphaneleri.

Kütüphane	Açıklama	Aşama
Drive	Google Colab Drive erişimi	
Time	Kod satır zaman sayacı	
OS	Klasör yönetimi işlemleri	Veri setinin okunması ve işlenmesi
Shuffle	Veri setinin karışık işlenmesi	
StratifiedKFold	Kfold çapraz geçerlilik işlemi	
Numpy	Matris işlemleri	
Pandas	Veri Yapısı	
PIL	Görüntüleme Kitaplığı	Görüntü işleme yeteneği
Tensorflow	Modelleme	Model oluşturma
Sklearn.model_selection	Eğitim ve Test Bölümlemesi	Eğitim ve Test verilerini bölümlenme
Tensorflow.keras		
Tensorflow.keras.models		
Tensorflow.keras.layers	CNN Mimarileri	Modelleme çalışmaları
Tensorflow.keras.optimizers		
Tensorflow.keras.losses		
Matplotlib.pyplot	Görselleştirme	Model sonuçları

Çizelge 2'de D1, D2 ve D3 veri setlerinin örnek sayıları belirtilmiştir.

Çizelge 2. Veri setleri.

Veri Seti	Sınıf Adı	Her Bir Sınıftaki Örnek Sayısı	Toplam Örnek Sayısı
D1	Viral Pnömoni	1.345	15.153
	COVID-19	3.616	
	Normal	10.192	
D2	Viral Pnömoni	1.345	4.035
	COVID-19	1.345	
	Normal	1.345	
D3	Viral Pnömoni	10.192	30.576
	COVID-19	10.192	
	Normal	10.192	

2.2 Veri setinin bölünmesi

Göğüs röntgeni görüntülerinden COVID-19 ve Viral Pnömoni tespiti için, orijinal veri seti (D1) ve yeni oluşturulan veri setleri (D2 ve D3), önce, 80-20 oranında eğitim ve test veri seti olarak ayrılmıştır. Daha sonra da, veri setlerine, 3, 5 ve 10 kez çapraz doğrulama uygulanarak modelleme çalışmalarına başlanmıştır. 3 kez çapraz doğrulama ile veri seti, rastgele olarak 3 eşit parçaya bölünmekte ve sonrasında 3 farklı aşamada sırasıyla bu parçalardan

biri test veri seti, diğer 2 parça da eğitim veri seti olarak kullanılmaktadır. Bu sayede her bir alt küme en az bir kez test amacıyla kullanılmış olmaktadır (Kalaycı 2018). Sınıflandırma işlemi, ayrılan her bir eğitim ve test verisi için 3 kez tekrarlanmış olmaktadır. Bu işlem aynı şekilde 5 ve 10 kez çapraz doğrulama için de gerçekleştirilmiştir.

2.3 Modellemede kullanılan CNN mimarileri

Veri setleri, evrişimli sinir ağlarının özel bir mimarisi olan AlexNet ve GoogleNet mimarilerine uygulanarak modeller geliştirilmiştir. AlexNet ve GoogleNet ile Covid-19 hastalığının teşhisinde birçok çalışmada başarılı sonuçlar elde edilmesinden dolayı bu çalışmada da tercih edilmiştir. Modellemenin ilk safhasında, orijinal AlexNet ve GoogleNet mimarileri eğitilip, performansları ölçülmüştür. Daha sonra ise, transfer öğrenme uygulanarak geliştirilmiş AlexNet ve GoogleNet mimarileri ile eğitilip, performansları tekrar ölçülmüştür.

Literatüre göre derin öğrenmeyle alakalı ilk makalenin Lecun *et al.*(1998) tarafından yayınlanmış olduğu söylenece de küresel çapta fark edilmesi 2012 yılında gerçekleştirilen ImageNet ILSRVC 17 yarışmasıyla olmuştur. Bu yarışmayı derin öğrenme mimarisi ile tasarlanan AlexNet modeli kazanmıştır. AlexNet, aktivasyon fonksiyonu olarak ReLu, ortaklama katmanlarında da maksimum ortaklama kullanılmaktadır. Yaklaşık 60 milyon parametrenin kullanıldığı AlexNet, paralel olarak çift grafik işlem birimi (GPU) üzerinde çalışan ilk model olma özelliğini de taşımaktadır. ImageNet ILSRVC 17 yarışmasında sınıflandırma doğruluk oranı %74,3'ten %83,6'ya çıkarılmıştır (Krizhevsky *et al.*2012).

GoogleNet de evrişimli bir sinir ağıdır ve yaklaşık 1.000 görüntüden oluşan desenleri sınıflandırma kapasitesine sahiptir. Alexnet'ten 12 kat daha az parametre kullanır. Bilgisayarla görü uygulamalarında kullanılan diğer sinir ağlarına benzer şekilde, bu model görüntüleri girdi olarak kabul eder ve çıktı olarak güven düzeyi ile birlikte öğrenilen sınıflardan birinin etiketlerini üretir. GoogleNet'in mimarisi, 9 başlangıç modülü dahil olmak üzere 22 katmandan oluşur. Başlangıç modülü, (1x1) ile (5x5) arasında değişen boyutlarda

öğrenilebilir filtreler kullanır ve bu da farklı ayrıntı düzeylerinin özelliklerini yakalamaya yardımcı olan paralel olarak evrişim gerçekleştirir (Szegedy *et al.*2015).

2.4 Performans ölçütü

Bu çalışmada, karmaşıklık matrisi sonuçlarından duyarlılık, özgüllük ve doğruluk metriklerini elde etmek için öncelikle doğru pozitif (DP), doğru negatif (DN), yanlış pozitif (YP), yanlış negatif (YN) değerleri elde edilmiştir. Sonrasında aşağıda verilen eşitlikler kullanılarak metrik değerler Eşitlik 1, Eşitlik 2 ve Eşitlik 3'de verilmiştir.

$$\text{Duyarlılık} = \frac{DP}{DP+DN} \quad (1)$$

$$\text{Özgüllük} = \frac{DN}{DN+DP} \quad (2)$$

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3)$$

2.4 Modelleme

Orijinal AlexNet mimarisi ile oluşturulan modelde, giriş değeri 227x227x3 olarak seçilmiştir. AlexNet mimarisi, toplamda 5 evrişim katmanından oluşmakta olup 'padding' olarak 'same' değeri verilerek, modelin görüntüler üzerindeki tarama boyutu standart tutulmuştur. Katmanlar arasında kullanılan aktivasyon fonksiyonları ReLu'dur. Bu modelde, 3 tane maksimum havuzlama katmanı, 5 evrişim katmanı ve son olarakta 3 tane tam bağlantılı katman ve 2 tane 0.4 değerli 'dropout' (seyreltme) katmanı kullanılmıştır. Çıkış katmanı olarak AlexNet'in orijinal nöron boyutu 1.000 olarak sabit tutulmuş ve sınıflandırıcı olarak 'Softmax' kullanılmıştır. Bu modelde 'optimizer' olarak 'adam'; 'batch_size' parametresi olarak 64; 'loss' fonksiyonu olarak 'categorical_crossentropy' seçilmiştir. Transfer öğrenme uygulanmasıyla geliştirilmiş AlexNet modelinde, orijinal AlexNet modelinin 'dropout' ve çıkış katmanlarındaki 2 değer değiştirilmiştir. Buna göre, orijinal AlexNet modelinin 2 'dropout' katmanındaki, 0.4 olan değerler, 0.2 yapılmıştır. Ayrıca, orijinal AlexNet modelinin çıkış katmanındaki 1.000 olan nöron sayısı, veri setlerindeki sınıf sayısı olan 3'e sabitlenmiştir.

Orijinal ve tranfer öğrenmeyle geliştirilmiş AlexNet modellerinde, veri setleri (D1, D2 ve D3), önce 80-20

oranında eğitim ve test seti olarak bölünmüştür. Daha sonra da, veri setleri, 3, 5 ve 10 kez çapraz doğrulama uygulanarak bölünmüştür. Modellemede kullanılan en uygun döngü sayısı (DS) değerleri bulunurken, minimum döngü sayıları olan, 10, 20 ve katlarıyla birlikte modelin bu döngülere vereceği cevaplar analiz edilmiştir. Yapılan analizlerde, her modelin en yüksek başarıya ulaştığı bir nokta olmuş ve sonrasındaki döngülerde bu sonuçların daha iyisi saptanamamıştır. Dolayısı ile döngü sayısı belirlenirken, modelin sonuçlarının en yüksek başarıya ulaştığı noktadan sonra bir yükselim eğrisi yok ise en yüksek başarının alındığı nokta, döngü sayısı olarak kabul edilmiştir. Buna göre, DS değeri, D1 ve D2 veri setleri için 250, D3 veri seti için de 220 olarak bulunmuştur.

Orijinal GoogleNet mimarisi, 9 başlangıç modülü kullanır ve 7x7x1024'ten 1x1x1024'e gitmek için ortalama havuzlamayı kullanarak tamamen bağlı tüm katmanları ortadan kaldırırken çok önemli olan, görünmeyen çok sayıda parametreyi ortadan kaldırır. Ortalama havuzlama katmanı, son başlangıç modülü tarafından üretilen tüm özellik haritalarında bir ortalama alır ve giriş yüksekliği ile genişliğini 1x1'e düşürmektedir. 0.4 değerli 'dropout' katmanı kullanılmıştır. Çıkış katmanı olarak GoogleNet'in

orijinal nöron boyutu (1.000) sabit tutulmuş, sınıflandırıcı olarak 'Softmax' kullanılmıştır. Bu modelde 'optimizer' olarak 'adam'; 'batch_size' parametresi olarak 64; 'loss' fonksiyonu olarak 'sparse_categorical_crossentropy' seçilmiştir. Transfer öğrenme uygulanmasıyla geliştirilmiş GoogleNet modelinde, orijinal GoogleNet modelinin çıkış katmanındaki 1.000 olan nöron sayısı, veri setlerindeki sınıf sayısı olan 3'e sabitlenmiştir. Orijinal ve transfer öğrenmeyle geliştirilmiş GoogleNet modellerinde, veri setleri, önce 80-20 oranında eğitim ve test seti olarak bölünmüştür. Daha sonra da, veri setleri, 3, 5 ve 10 kez çapraz doğrulama uygulanarak bölünmüştür. Modellemede kullanılan en uygun DS değerleri, D1 veri seti için 150, D2 veri seti için 200 ve D3 veri seti için de 190 olarak bulunmuştur. COVID-19 ve Viral Pnömoni tespiti için, D1, D2 ve D3 veri setleri için, orijinal (AlexNet_O ve GoogleNet_O) ve transfer öğrenme ile geliştirilmiş (AlexNet_TÖ ve GoogleNet_TÖ) modeller, 80-20, CV-3, CV-5 ve CV-10 için eğitilip performansları ölçülmüştür ve her bir veri seti için oluşturulan modellere ait doğruluk, duyarlılık, özgüllük değerleri ve model çalışma süreleri Çizelge 3, 4 ve 5'de verilmiştir.

Çizelge 3. D1 Veri seti için modelleme sonuçları.

Veri Setinin Bölünmesi	Model	DS	Doğruluk Başarısı (%)		Duyarlılık (%)		Özgüllük (%)		Çalışma Süresi (sa:dk)
			Eğitim	Test	Eğitim	Test	Eğitim	Test	
80-20	AlexNet_O	250	100.00	98.16	99.86	97.13	99.80	98.40	3:16
	AlexNet_TÖ	250	100.00	98.52	99.74	97.59	99.76	98.63	3:29
	GoogleNet_O	150	99.59	97.63	98.03	97.80	99.68	98.27	2:43
	GoogleNet_TÖ	150	99.60	97.49	98.47	97.94	99.32	97.24	3:05
CV-3	AlexNet_O	250	98.80	96.02	99.01	95.15	99.73	97.10	4:09
	AlexNet_TÖ	250	99.13	96.38	99.36	95.92	99.79	96.85	3:56
	GoogleNet_O	150	100.00	98.94	99.08	98.24	99.60	99.25	3:21
	GoogleNet_TÖ	150	100.00	98.62	98.22	95.67	99.37	99.38	3:40
CV-5	AlexNet_O	250	99.05	96.57	99.85	97.81	98.64	97.05	4:28
	AlexNet_TÖ	250	99.19	96.64	99.27	97.76	99.41	98.13	4:41
	GoogleNet_O	150	99.94	99.02	99.53	98.18	99.83	99.08	3:55
	GoogleNet_TÖ	150	99.83	98.57	99.73	98.49	99.28	99.62	3:40
CV-10	AlexNet_O	250	99.13	96.62	99.28	97.26	99.40	95.42	4:57
	AlexNet_TÖ	250	99.16	96.70	99.77	95.53	99.94	98.71	4:39
	GoogleNet_O	150	100.00	99.07	99.87	98.13	99.58	99.37	4:03
	GoogleNet_TÖ	150	99.97	98.71	100.00	99.48	100.00	97.58	3:46

Çizelge 4. D2 Veri seti için modelleme sonuçları.

Model	DS	Doğruluk Başarısı (%)	Duyarlılık (%)	Özgüllük (%)
-------	----	-----------------------	----------------	--------------

Veri Setinin Bölünmesi	Model	DS	Eğitim		Test		Eğitim		Test		Çalışma Süresi (sa:dk)
			Doğruluk (%)	Doğruluk (%)	Duyarlılık (%)	Duyarlılık (%)	Özgüllük (%)	Özgüllük (%)			
80-20	AlexNet_O	250	100.00	96.90	99.73	96.92	99.81	97.75	2:27		
	AlexNet_TÖ	250	100.00	96.28	99.91	97.04	99.60	98.24	2:19		
	GoogleNet_O	200	100.00	94.55	98.83	95.79	99.26	94.83	1:50		
	GoogleNet_TÖ	200	100.00	93.80	100.00	94.65	99.95	93.27	1:57		
CV-3	AlexNet_O	250	100.00	99.04	99.17	97.05	100.00	99.48	2:56		
	AlexNet_TÖ	250	100.00	99.27	99.73	96.70	98.54	97.16	3:01		
	GoogleNet_O	200	100.00	99.34	98.85	98.46	100.00	99.46	2:43		
	GoogleNet_TÖ	200	99.93	98.71	99.55	97.59	99.42	99.67	2:38		
CV-5	AlexNet_O	250	100.00	98.96	99.30	99.28	99.65	99.50	3:05		
	AlexNet_TÖ	250	100.00	99.30	99.59	99.25	98.77	99.16	3:19		
	GoogleNet_O	200	100.00	99.48	99.63	99.18	100.00	98.38	3:04		
	GoogleNet_TÖ	200	99.97	98.82	99.01	97.48	99.35	99.06	2:51		
CV-10	AlexNet_O	250	100.00	99.23	100.00	97.80	99.44	97.36	3:48		
	AlexNet_TÖ	250	100.00	99.38	99.72	97.99	99.10	99.83	3:35		
	GoogleNet_O	200	100.00	99.63	99.17	98.45	99.91	99.68	3:27		
	GoogleNet_TÖ	200	100.00	99.09	99.10	99.21	99.53	99.51	3:38		

Çizelge 5. D3 Veri seti için modelleme sonuçları.


Veri Setinin Bölünmesi	Model	DS	Doğruluk Başarısı (%)		Duyarlılık (%)		Özgüllük (%)		Çalışma Süresi (sa:dk)
			Eğitim	Test	Eğitim	Test	Eğitim	Test	
80-20	AlexNet_O	220	100.00	98.45	99.34	97.65	99.40	98.61	5:29
	AlexNet_TÖ	220	100.00	98.76	99.61	98.09	99.57	98.84	5:04
	GoogleNet_O	190	100.00	98.14	98.92	98.43	99.13	97.72	4:31
	GoogleNet_TÖ	190	100.00	94.27	99.18	95.68	99.44	98.15	4:57
CV-3	AlexNet_O	220	100.00	99.76	99.84	98.46	100.00	99.47	5:45
	AlexNet_TÖ	220	100.00	99.79	99.91	98.35	99.96	99.93	5:33
	GoogleNet_O	190	100.00	99.46	100.00	97.74	99.82	99.66	4:47
	GoogleNet_TÖ	190	100.00	94.85	99.83	98.05	99.98	98.73	4:32
CV-5	AlexNet_O	220	100.00	99.79	98.49	97.52	100.00	98.94	5:19
	AlexNet_TÖ	220	100.00	99.84	100.00	98.26	99.65	99.20	4:52
	GoogleNet_O	190	100.00	99.53	99.06	97.91	99.89	99.68	4:26
	GoogleNet_TÖ	190	100.00	95.24	99.44	96.85	98.58	92.14	4:38
CV-10	AlexNet_O	220	100.00	99.87	99.95	98.73	100.00	99.91	5:51
	AlexNet_TÖ	220	100.00	99.90	99.88	98.96	100.00	99.86	5:43
	GoogleNet_O	190	100.00	99.74	98.77	98.4	99.99	99.36	5:14
	GoogleNet_TÖ	190	100.00	95.48	97.34	92.72	99.51	97.94	4:58

3. Bulgular

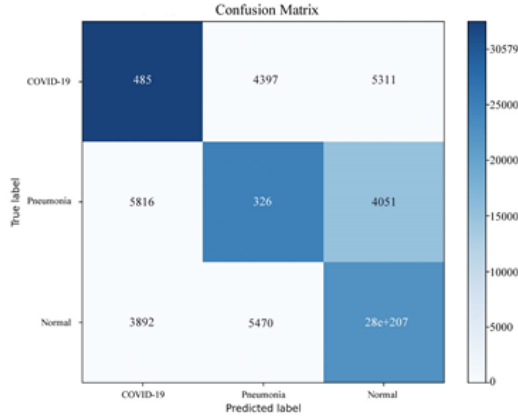
Çizelge 3, 4 ve 5'deki sonuçlar karşılaştırıldığında, tüm veri setleri için, transfer öğrenmeye dayanarak geliştirilmiş AlexNet modelleri ile, orijinal AlexNet modellerine göre daha başarılı sonuçlar alınmıştır. Benzer şekilde, genel olarak, orijinal GoogleNet modelleri ile de transfer öğrenmeye dayanan GoogleNet modellerine göre daha iyi sonuçlar alındığı görülmüştür.

COVID-19 ve Pnömoni tespiti yapabilen en iyi model, veri arttırma yapılarak örnek sayısı arttırılmış olan D3 veri seti kullanılarak elde edilmiştir. Bu modelde transfer öğrenme ile geliştirilmiş AlexNet mimarisi, 10 kez çapraz doğrulama (CV-10) uygulandığında, 220 DS için çalıştırılarak, en yüksek test performansı olan %99,90 doğruluk başarısına ulaşmıştır. D3 veri setinin kullanılması sonucu elde edilen bu en iyi modele ait, doğruluk grafiği ve eğitim sonrasında

sınıflara ait performans metriklerinin elde edildiği karmaşıklık matrisi Şekil 2 ve 3’de verilmiştir.



Şekil 2. En iyi modelin doğruluk grafiği.



Şekil 3. En iyi modelin karmaşıklık matrisi.

4. Tartışma

Günümüz şartlarında her ne kadar pandemi etkilerini kaybetmiş ve bitme sürecinde olsada, COVID-19 halen etkilerini insanlar üzerinde hafif olarak göstermektedir. Yapay Zeka’daki gelişmelerle, özellikle Derin Öğrenme mimarileri ile akciğer röntgen görüntüleri kullanılarak, bu tür virüslerin erken aşamalarda tespiti, hızlı iyileşmeye ve sağlık sistemlerinin üzerindeki yükü hafifletmeye yardımcı olacaktır. Bu nedenle, COVID-19’u yüksek performansla ve kısa sürede tespit edebilen modellere ihtiyaç vardır.

Ayrıca, COVID-19 ve Viral Pnömoni en çok yanlış teşhisin yapıldığı, iki hastalıktır ve teşhislerin doğru yapılmaması durumunda yanlış tedavi süreci, hastalığın daha da çok artmasına ve yayılmasına sebebiyet verebilmektedir. Hastalığın kaynağı, COVID-19 mu yoksa Viral Pnömoni mi, bunu doğru bir şekilde ayırt etmek bu açıdan önem arz etmektedir. Aynı zamanda, akciğer röntgen görüntülerinden COVID-19’un teşhisi, PCR testine göre daha kısa sürede yapılabileceği düşünülmektedir. Bu sayede, hem uygulanacak

doğru tedavi açısından, hem de sürecin daha erken kontrol altına alınması açısından da fayda sağlanmış olacaktır.

Çizelge 6. Bu çalışmada önerilen modelin, literatürdeki diğer çalışmalarla karşılaştırılması.

Sınıflandırıcı	Doğruluk Başarı (%)	Yazarlar
AlexNet	52.00	Loey and et al., 2020
GoogLeNet	52.80	
ResNet18	50.00	
AlexNet	99.14	Tuan D. Pham
GoogLeNet	99.70	
SqueezeNet	99.85	
ResNet18	98.30	Minaee and et al., 2020
ResNet50	98.40	
SqueezeNet	98.30	
DenseNet-121	98.90	Farooq and Hafeez, 2020
COVID-ResNet	96.23	
COVID-Net	83.50	
ResNet	94.17	Adedigba and et al., 2021
DenseNet	94.17	
ResNet+DA	95.43	
DenseNet+DA	96.83	Umeer and et al., 2021
VGG-16	97.76	
AlexNet	67.76	
ResNet152V2	99.22	Elshennawy and Ibrahim, 2020
MobileNetV2	96.48	
CNN	92.19	
LSTM-CNN	91.80	Singh and et al., 2020
AlexNet	92.86	
DenseNet121	92.62	
InceptionV3	92.01	Ucar and Korkmaz, 2020
GoogLeNet	93.12	
ResNet18	94.23	
SqueezeNet	98.30	Khan and et al., 2020
CoroNet	99.00	
DarkCovidNet	98.08	
VGG-19	98.75	Apostolopoulos and Mpesiana, 2020
MobileNetV2	97.40	
Inception	86.13	
Xception	85.57	Rahman and et al., 2020
Inception	84.38	
ResNetV2	88.40	
AlexNet	88.40	Al-Bawi and et al., 2020
ResNet18	87.70	
DenseNet201	93.30	
SqueezeNet	86.10	Majeed and et al., 2020
CCBlock	98.86	
CNN-X	99.35	
CheXNet	76.80	Rajpurkar and et al., 2017
DenseNet_201	94.96	Alhudaif and et al., 2021
ResNet_18	91.60	
SqueezeNet	89.92	
AlexNet_TÖ	99.90	Önerilen Model

Çizelge 6’da literatürdeki benzer çalışmalarda alınan sonuçlar ve bu çalışmada önerilen model sonucu yer almaktadır. Çizelge 6’daki sonuçlar karşılaştırıldığında, bu çalışmada önerilen model sonucunun %99.90 doğruluk başarısı ile en iyi

performansa sahip model olduğu görülmüştür ve bu sonuç da modelin başarısını ve güvenilirliğini ortaya koymaktadır.

5. Sonuç

Bu çalışmada, göğüs röntgen görüntüleri kullanılarak, COVID-19 ve viral pnömoni teşhisi için derin öğrenme algoritmalarından olan evrişimli sinir ağlarının AlexNet ve GoogleNet özel mimarileri ile geniş kapsamlı bir modelleme çalışması yapılmıştır. Modelleme sürecinde, her bir mimarinin önce orijinal model parametreleri ile denemeler yapılmış ve daha sonra da transfer öğrenme ile bazı parametreler değiştirilerek denemeler yapılmıştır. Çalışmanın temel amacı, evrişimli sinir ağlarını kullanan farklı modeller oluşturmak ve bu modellerin performanslarını karşılaştırıp, en iyi modeli belirlemektir. Modelleme de kullanılan orijinal veri seti, 'COVID-19 Radiography Database' veri seti olup, 3 sınıflı ve her sınıfta farklı sayıda örnek bulunduran dengesiz bir veri setidir. Bu veri setine, veri azaltma ve arttırma yöntemleri uygulanarak, 2 adet dengeli veri seti oluşturulmuştur. Orijinal veri seti ve yeni oluşturulan veri setleri, 80-20 oranında eğitim ve test veri setine bölünerek ve aynı zamanda 3, 5 ve 10 kez çapraz doğrulamaya göre bölünerek, model performansları ölçülmüştür.

Çizelge 3, 4 ve 5'deki model sonuçları değerlendirildiğinde, tüm veri setleri (D1, D2 ve D3) için, en iyi performansların 10 kez çapraz doğrulama uygulanan modellerden (sırasıyla, 99.07, 99.63 ve 99.90) alındığı görülmüştür. Genel olarak, dengeli veri setlerinden, dengesiz veri setine göre daha iyi sonuçlar alınmıştır. Bununla birlikte, veri arttırma yoluyla dengeli veri seti oluşturmanın, veri azaltma ile dengeli veri seti oluşturmaya göre daha iyi olduğu da, alınan sonuçlardan anlaşılmaktadır. Ayrıca, D1 ve D2 veri setleri için en iyi modellerin, GoogleNet orijinal mimarisini kullanan modeller olduğu, D3 veri seti içinse transfer öğrenmeye dayanan AlexNet mimarisi olduğu görülmüştür.

Sonuç olarak, veri arttırma yöntemiyle dengeli hale getirilmiş olan veri setinin (D3), 10 kez çapraz doğrulamaya göre bölünerek, transfer öğrenme ile geliştirilmiş AlexNet mimarisine uygulanması sonucu elde edilen modelin, en iyi ve güvenilir model olduğu, bulunan model performansı % 99,90 doğruluk başarısı ile de gösterilmiştir.

6. Kaynaklar

- Adedigba, A.P., Adeshina, S.A., Aina, O.E. ve A. M. Albinu, A.M., 2021. Optimal hyperparameter selection of deep learning models for COVID-19 chest X-ray classification. *Intelligence-Based Medicine*, vol. 5, pp. 2666-5212.
- Ahuja, S., Panigrahi, B.K., Dey, N., Rajinikanth, V. ve Gandhi, T.K., 2021. Deep transfer learning-based automated detection of COVID-19 from lung CT scan slices. *Applied Intelligence*, vol. 51, pp. 571-585.
- Al-Bawi, A., Al-Kaabi, K., Jeryo, M. ve Al-Fatlawi, A., 2022. CCBLOCK: An Effective Use of Deep Learning for Automatic Diagnosis of COVID-19 Using X-Ray Images. *Research on Biomedical Engineering*, vol. 38, pp. 49-58.
- Alhudhaif, A., Polat, K. ve Karaman, O., 2021. Determination of COVID-19 Pneumonia based on generalized convolutional neural network model from chest X-ray images. *Expert Systems with Applications*, vol. 180, pp. 0957-4174.
- Apostolopoulos, I.D. ve Mpesiana, T.A., 2020. Covid-19: automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, vol. 43, pp. 2662-4737.
- Chouhan, V., Singh, S.K., Khamparia, A., Gupta, D., Tiwari, P., Moreira, C., Damaseviclus, R. ve Albuquerque, V.H.C.D., 2020. A Novel Transfer Learning Based Approach for Pneumonia Detection in Chest X-Ray Images. *Applied Sciences*, vol. 10, pp. 2076-3417.
- Elshennawy, N.M. ve Ibrahim, D.M., 2020. Deep-Pneumonia Framework Using Deep Learning Models Based on Chest X-Ray Images. *Diagnostics*, vol. 10, pp. 1-16.
- Farooq, M. ve Hafeez, A., 2020. COVID-ResNet: A Deep Learning Framework for Screening of COVID-19 from Radiographs. *arXiv eese arXiv:2003.14395*.
- Kalaycı, T.E., 2018. Comparison of Machine Learning Techniques for Classification of Phishing Web Sites. *Pamukkale University Journal of Engineering Sciences*, vol. 24(5), pp. 870-878.

- Khan, A.I., Shah, J.L. ve Bhat, M.M., 2020. 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, pp. 169-2607.
- Kim, T.K., Yi, P.H., Hager, G.D. ve Lin, C.T., 2019. Refining dataset curation methods for deep learning-based automated tuberculosis screening. *Journal of Thoracic Disease*, vol. 12, pp. 2077-6624.
- Konar, D., Panigrahi, B.K., Bhattacharyya, S. ve Dey, N., 2021. Auto-Diagnosis of COVID-19 using Lung CT Images With Semi-Supervised Shallow Learning Network. *IEEE Access*, vol. 9, pp. 28716-28728.
- Krizhevsky, A., Sutskever, I. ve Hinton, G., 2012. ImageNet Classification with Deep Convolutional Neural Networks. *NIPS'12 Proceedings of the 25th International Conference on Neural Information Processing Systems*, cilt 1, pp. 1097-1105.
- Lecun, Y., Bottou, L., Bengio, Y. ve Haffner, P., 1998. Gradient-based learning applied to document recognition. *Proceeding of the IEEE*, cilt 86, pp. 2278-2324.
- Loey, M., Smarandache, F. ve Khalifa, N.E.M, 2020. Within the Lack of Chest COVID-19 X-ray Dataset: A Novel detection Model Based on GAN and Deep Transfer Learning. *Journal of Symmetry*, vol. 12, pp. 2073-8994.
- Majeed, T., Rashid, R., Ali, D. ve Asaad, A., 2020. Covid-19 detection using CNN transfer learning from X-ray Images. *Physical and Engineering Sciences in Medicine*, vol. 43, pp. 1289–1303
- Minaee, S., Kafieh, R., Sonka, M., Yazdani, S. ve Soufi, G.J., 2020. Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning. *Medical Image Analysis*, vol. 65, pp. 1361-8415.
- Nour, M., Cömert, Z. ve Polat, K., 2020. A Novel Medical Diagnosis model for COVID-19 infection detection based on Deep Features and Bayesian Optimization. *Applied Soft Computing*, vol. 97, pp. 1568-4946.
- Ozturk, T., Talo, M., Yildirim, E.A., Baloglu, U.B., Yildirim, O. ve Acharya, U.R., 2020. Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine*, vol. 121, pp. 0010-4825.
- Panwar, H., Gupta, P.K., Siddiqui, M.K., Menendez, R.M. ve Singh, V., 2020. Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet. *Chaos, Solitions & Fractals*, vol. 138, pp. 0960-0779.
- Pham, T.D., 2020. Classification of COVID-19 chest X-rays with deep learning: new models or fine tuning. *Health Information Science and Systems*, vol. 9, pp. 2047-2501.
- Rahman, T., Chowdhury, M.E.H., Khandakar, A., Islam, K.R., Islam, K.F., Mahbub, Z.B., Kadir, M.A. ve Kashem, S., 2020. Transfer Learning with Deep Convolutional Neural Network (CNN) for Pneumonia Detection using Chest X-ray. *Applied Sciences*, vol. 10, pp. 2076-3417.
- Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., Ding, D., Bagul, A., Ball, R.L., Langlotz, C., Shpanskaya, K., Lungren, M.P. ve Ng, A.Y., 2017. CheXNet: Radiologist-Level Pneumonia Detection on Chest X-Rays with Deep Learning. *arXiv cs arXiv:1711.05225*.
- Ucar, F. ve Korkmaz, D., 2020. COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. *Med Hypotheses*, vol. 140, pp. 1532-2777.
- Umer, M., Ashraf, I., Ullah, S., Mahmood, A. ve G. S. Choi, G.S., 2022. COVINet: A Convolutional neural network approach for predicting COVID-19 from chest X-ray images. *Journal of Ambient Intelligence and Humanized Computing*, vol. 13, pp. 535–547.
- Shorten, C. ve Khoshgoftaar, T.M., 2019. A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, vol. 6, pp. 2196-1115.
- Szegedy, C., et al., 2015. Going deeper with convolutions. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 1-9.
- Toraman, S., Alakus, T.B. ve I. Türkoğlu, I., 2020. Convolutional capsnet: A novel artificial neural network approach to detect COVID-19 disease from X-ray images using capsule networks. *Chaos, Solitions & Fractals*, vol. 140.

Vaid, S., Kalantar, R. ve Bhandari, M., 2020. Deep learning COVID-19 detection bias: accuracy through artificial intelligence. *International Orthopaedics*, vol. 44, pp. 1432-5195.

Chest Radiographs: New Tricks for an Old Algorithm? *Journal of Thoracic Imaging*, vol. 35, pp. 102-104.

İnternet kaynakları

Yi, P.H., Kim, T.K. ve Lin, C.T., 2020. Generalizability of Deep Learning Tuberculosis Classifier to COVID-19

1-<https://www.kaggle.com/tawsifurrahman/covid19-radiography-database> (15.03.2021)