T.C.

AKSARAY ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI

TRANSFER ÖĞRENME MODELLERİ İLE AKCİĞER X-RAY GÖRÜNTÜLERİNDEN COVID-19 TESPİTİ

YÜKSEK LİSANS TEZİ

ÖZGÜR FOTO

DANIŞMAN

Prof. Dr. Hülya BAKIRTAŞ

Aksaray 2022

AKSARAY ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

YÖNETİM BİLİŞİM SİSTEMLERİ ANABİLİM DALI

TRANSFER ÖĞRENME MODELLERİ İLE AKCİĞER X-RAY GÖRÜNTÜLERİNDEN COVID-19 TESPİTİ

YÜKSEK LİSANS TEZİ

ÖZGÜR FOTO

DANIŞMAN

Prof. Dr. Hülya BAKIRTAŞ

Aksaray 2022

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU

Bu tezin tüm hakları saklıdır. Kaynak göstermek koşuluyla tezin teslim tarihinden itibaren .....(….) ay sonra tezden fotokopi çekilebilir.

YAZARIN

Adı : Özgür

Soyadı : FOTO

Bölümü : Yönetim Bilişim Sistemleri

İmza :

Teslim tarihi :

TEZİN

Türkçe Adı : Transfer Öğrenme Modelleri İle Akciğer X-Ray Görüntülerinden COVID-19 Tespiti

İngilizce Adı : COVID-19 Detection From Lung X-Ray Images With Transfer Learning Models

ETİK İLKELERE UYGUNLUK BEYANI

Tez yazma sürecinde bilimsel ve etik ilkelere uyduğumu, yararlandığım tüm kaynakları kaynak gösterme ilkelerine uygun olarak kaynakçada belirttiğimi ve bu bölümler dışındaki tüm ifadelerin şahsıma ait olduğunu beyan ederim.

Yazar Adı Soyadı: Özgür FOTO

İmza : ……..

T.C.

AKSARAY ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

JÜRİ ONAY SAYFASI

Özgür FOTO tarafından hazırlanan "Transfer Öğrenme Modelleri İle Akciğer X-Ray Görüntülerinden COVID-19 Tespiti" başlıklı tez çalışması aşağıdaki jüri tarafından oy birliği ile Aksaray Üniversitesi Yönetim Bilişim Sistemleri Anabilim Dalı'nda Yüksek Lisans Tezi olarak kabul edilmiştir.

Danışman: Prof. Dr. Hülya BAKIRTAŞ	İmza
Yönetim Bilişim Sistemleri, Aksaray Üniversitesi	……
İkinci Danışman: Doç. Dr. Kemal ADEM	
Yazılım Mühendisliği, Aksaray Üniversitesi	……
Üye: Dr. Öğr. Üyesi Tarık YILMAZ	
Yönetim Bilişim Sistemleri, Aksaray Üniversitesi	……
Üye: Dr. Öğr. Üyesi Deniz ÖZKAN	
Dahili Tıp Bilimleri, Aksaray Üniversitesi	……
Üye: Dr. Öğr. Üyesi Serhat KILIÇARSLAN	
Yazılım Mühendisliği, Bandırma On Yedi Eylül Üniversitesi	……

Tez Savunma Tarihi: 15/03/2022

Sosyal Bilimler Enstitüsü Yönetim Kurulu'nun ……tarih ve …… sayılı kararı ile onaylanmıştır.

Sosyal Bilimler Enstitüsü Müdürü

Doç. Dr. Sevilay USLU DİVANOĞLU

İmza

TEŞEKKÜR

Bu çalışmanın gerçekleşmesinde yardımlarını esirgemeyen ve yol gösteren danışman hocam Sayın Prof. Dr. Hülya BAKIRTAŞ'a, teknik kısımlardaki eleştiri ve katkılarından dolayı ikinci danışman hocam Sayın Doç. Dr. Kemal ADEM'e, tıbbi görüntü analizinde yardımlarını esirgemeyen radyoloji uzmanı Dr. Öğr. Üyesi Deniz ÖZKAN'a, değerli fikirleri ile çalışmaya katkı sunan jüri üyelerine, her daim yanımda olan ve desteklerini esirgemeyen aileme, biricik eşime ve çocuklarıma teşekkür ederim.

AKSARAY ÜNİVERSİTESİ

SOSYAL BİLİMLER ENSTİTÜSÜ

TRANSFER ÖĞRENME MODELLERİ İLE AKCİĞER X-RAY GÖRÜNTÜLERİNDEN COVID-19 TESPİTİ

(Yüksek Lisans Tezi)

Özgür FOTO, Aksaray 2022

ÖZET

2019 Aralık ayında Wuhan kentinde başlayan ve tüm dünyayı etkisi altına alan COVID-19 hastalığı pek çok insanın hayatını kaybetmesine neden olmuştur. İnsandan insana yayılım gösteren bu hastalığın hızlı bir şekilde tespit edilerek hastaların izolasyona tabi tutulması salgının kontrol altına alınması açısından önem taşımaktadır. COVID-19 hastalığını tespit etmek için kullanılan güvenilir yöntemlerin başında akciğer X-Ray görüntüleri gelmektedir. Ancak COVID-19 hastalığına benzer özellikleri taşıyan akciğer hastalıklarının olması, radyologların tanı işlemlerini zorlaştırmaktadır. Bu çalışmada, akciğer X-Ray görüntüleri ile transfer öğrenme modelleri kullanılarak COVID-19 hastalığını tespit etmek amaçlanmıştır. Oluşturulan veri seti üzerinden yapılan segmentasyon işlemlerinin ardından, VGG-16, ResNet-50, DenseNet-121 ve Inception V3 gibi son teknoloji transfer öğrenme modelleri ile deneysel çalışmalar yapılmıştır. Çalışmaların sonucunda en yüksek % 96.7 doğruluk oranı VGG-16 modelinde tespit edilmiştir.

Bilim Kodu : 92431, 92432, 10106.04

Anahtar Kelimeler : COVID-19, Derin Öğrenme, Görüntü İşleme, X-Ray, Yapay Zeka.

Sayfa Adedi : 108

Danışman : Prof. Dr. Hülya BAKIRTAŞ

İkinci Danışman : Doç. Dr. Kemal ADEM

AKSARAY UNIVERSITY

GRADUATE SCHOOL OF SOCIAL SCIENCES

COVID-19 DETECTION FROM LUNG X-RAY IMAGES WITH TRANSFER LEARNING MODELS

(M.A. Thesis)

Özgür FOTO, Aksaray 2022

ABSTRACT

The COVID-19 disease, which started in the city of Wuhan in December 2019 and affected the whole world, caused many people to die. Rapid detection of this disease, which spreads from person to person, and isolation of patients are important in terms of controlling the epidemic. Lung X-Ray images are the leading reliable methods used to detect COVID-19 disease. Due to, the presence of lung diseases with similar features to COVID-19 makes it difficult for radiologists to diagnose. In this study, it was aimed to detect COVID-19 disease by using transfer learning models with lung X-ray images. After the segmentation processes on the created dataset, experimental studies were carried out with the latest technology transfer learning models such as VGG-16, ResNet-50, DenseNet-121 and Inception V3 models. As a result of the studies, the highest accuracy rate of 96.7% was determined in the VGG-16 model.

Science Code : 92431, 92432, 10106.04

Key Words : Novel Coranavirus Diseases (COVID-19), Deep Learning, Image Processing, X-Ray, Artificial Intelligence.

Page Number : 108

Supervisor : Prof. Dr. Hülya BAKIRTAŞ

Co-supervisor : Assoc. Prof. Kemal ADEM

İÇİNDEKİLER

TELİF HAKKI VE TEZ FOTOKOPİ İZİN FORMU ..... **i**
ETİK İLKELERE UYGUNLUK BEYANI ..... **ii**
JÜRİ ONAY SAYFASI ..... **iii**
TEŞEKKÜR ..... **iv**
ÖZET ..... **v**
ABSTRACT ..... **vi**
İÇİNDEKİLER ..... **vii**
TABLOLAR LİSTESİ ..... **x**
ŞEKİLLER LİSTESİ ..... **xi**
SİMGELER VE KISALTMALAR LİSTESİ ..... **xiii**
GİRİŞ **1**
BİRİNCİ BÖLÜM **3**
COVID-19 ve TEŞHİSİ **3**
1.1. COVID-19 Hastalığı **3**
1.1.1. Belirtileri ve Bulaşma Yolları **8**
1.1.2. Teşhis Yöntemleri **10**
1.2. COVID-19 Teşhisi İçin Kullanılan Görüntüleme Teknikleri **12**
1.2.1. Bilgisayarlı Tomografi (BT) **12**
1.2.2. X-Ray Görüntüleme **14**
1.3. COVID-19 Röntgen Desen Analizleri **15**
1.4. COVID-19 Teşhisi Üzerine Yapılmış Çalışmalar **17**

İKİNCİ BÖLÜM **25**
MATERYAL VE YÖNTEM **25**
2.1. Veri Seti **25**
2.2. Yöntem **27**
2.2.1. Ön İşlemler **28**
2.2.1.1. Segmentasyon **28**
2.2.1.2. Görüntü Kırpma **29**
2.2.1.3. Kontrast Limitli Adaptif Histogram Eşitleme **30**
2.2.1.4. Medyan Filtresi **32**
2.3. Makine Öğrenmesi **33**
2.3.1. Denetimli Öğrenme **33**
2.3.2. Denetimsiz Öğrenme **34**
2.3.3. Pekiştirmeli Öğrenme **36**
2.4. Derin Öğrenme **36**
2.4.1. Derin Öğrenme Mimarileri **38**
2.4.1.1. Konvolüsyonel Sinir Ağları **38**
2.4.1.2 Aktivasyon Fonksiyonu Katmanları **42**
2.5. Çalışmada Kullanılan Parametreler **43**
2.6. Transfer Öğrenme **45**
2.6.1. Transfer Öğrenme Modelleri **46**
2.6.1.1. VGG-16 Mimarisi **46**
2.6.1.2. ResNet-50 Mimarisi **47**
2.6.1.3. DenseNet-121 Mimarisi **48**
2.6.1.4. Inception V3 Mimarisi **49**
2.7. Değerlendirme Kriterleri **50**

ÜÇÜNCÜ BÖLÜM 53
BULGULAR VE TARTIŞMA 53
3.1. Deneysel Çalışma Ortamı 53
3.2. Model Tasarımları 54
3.2.1. VGG-16 Modeli Sonuçları 55
3.2.2. ResNet-50 Modeli Sonuçları 59
3.2.3. DenseNet-121 Modeli Sonuçları 64
3.2.4. Inception V3 Modeli Sonuçları 68
3.2.5. Modellerin Ölçüm Sonuçlarının Karşılaştırılması 73
SONUÇ VE ÖNERİLER 74
KAYNAKÇA 76
EKLER 88
TEZ DEĞERLENDİRME FORMU 92

TABLOLAR LİSTESİ

Tablo 1.1. İnsanlara Bulaşabilen Koronavirüs Türleri ve Özellikleri. 4
Tablo 1.2. 20.yy ve Sonrası Dünya Genelinde Görülen Salgın Hastalıklar 5
Tablo 1.3. COVID-19 Varyantları 7
Tablo 1.4. COVID-19 Hastalarında En Sık Görülen Belirtiler 9
Tablo 1.5. COVID-19 Hastalığı Tanı Testlerinin Duyarlılıkları. 11
Tablo 1.6. Sağlık Bakanlığı BT Görüntüleri Bulguları Raporlama Yöntemi. 13
Tablo 1.7. X-Ray Görüntülerinde COVID-19 Hastalığı İçin Elde Edilen Bulgular 15
Tablo 1.8. COVID-19 Teşhisi Üzerine Yapılmış Bazı Çalışmalar 22
Tablo 2.1. Karşıtlık Matrisi 51
Tablo 3.1. Sınıf Düzeylerinde Giriş Etiketleri. 55
Tablo 3.2. VGG-16 Modeli Kullanılan Parametre Değerleri. 55
Tablo 3.3. VGG-16 Model Özeti. 56
Tablo 3.4. VGG-16 Modeli Ölçüm Parametre Sonuçları. 57
Tablo 3.5. ResNet-50 Modeli Kullanılan Parametre Değerleri. 60
Tablo 3.6. ResNet-50 Model Özeti. 60
Tablo 3.7. ResNet-50 Modeli Ölçüm Parametre Sonuçları. 62
Tablo 3.8. DenseNet-121 Modeli Kullanılan Parametre Değerleri. 64
Tablo 3.9. DenseNet-121 Model Özeti. 65
Tablo 3.10. DenseNet-121 Modeli Ölçüm Parametre Sonuçları. 67
Tablo 3.11. Inception V3 Modeli Kullanılan Parametre Değerleri. 69
Tablo 3.12. Inception V3 Model Özeti. 69
Tablo 3.13. Inception V3 Modeli Ölçüm Parametre Sonuçları 70
Tablo 3.14. Uygulanan Modellerin Ölçüm Sonuçlarının Karşılaştırılması. 73

ŞEKİLLER LİSTESİ

Şekil 1.1. Koronavirüsün Şematik Yapısı 3
Şekil 1.2. Dünya Geneli Onaylanmış Vaka Sayıları 6
Şekil 1.3. Türkiye Geneli Onaylanmış Vaka ve Ölüm Sayısı 7
Şekil 1.4. COVID-19 Hastası Akciğer BT Görüntüsü. 12
Şekil 1.5. COVID-19 Hastası X-Ray Görüntüsü. 14
Şekil 1.6. COVID-19 Belirtileri Gösteren Bir Hastaya Ait X-Ray Görüntüleri 16
Şekil 2.1. Veri Setinde Yer Alan Sınıflandırılmış X-Ray Görüntülerine Ait Örnekler 26
Şekil 2.2. Çalışmaya Ait X-Ray Veri Setinin Sınıfsal Dağılımı. 26
Şekil 2.3. COVID-19 Tespitinde Farklı Modellerin Karşılaştırılmasına Yönelik Kurulan Mimari 27
Şekil 2.4. Görüntü Üzerinde Uygulanan Segmentasyon İşlemi. 29
Şekil 2.5. Segmentasyon ve Kırpma İşlemi. 29
Şekil 2.6. Tekdüze ve Çarpık Dağılım Grafiği. 30
Şekil 2.7. Aşırı Kontrast Sonucu Oluşan Kumlanma 31
Şekil 2.8. CLAHE Uygulanmış Görüntü ve Kontrast Seviyesi. 31
Şekil 2.9. Medyan Filtresi Uygulanarak Görüntüde İyileştirme. 32
Şekil 2.10. Denetimli Öğrenme Süreci 34
Şekil 2.11. Yarı Denetimli Öğrenme Süreci 34
Şekil 2.12. Denetimsiz Öğrenme Süreci. 35
Şekil 2.13. Denetimsiz Öğrenme Gruplama Yöntemleri. 35
Şekil 2.14. Pekiştirmeli Öğrenme Süreci 36
Şekil 2.15. Çok Katmanlı Yapay Sinir Ağı 37
Şekil 2.16. Konvolüsyonel Sinir Ağının Temel Mimarisi. 39
Şekil 2.17. Konvolüsyon ve Evrişim İşleminin Temel Mimarisi 40
Şekil 2.18. Maksimum Havuzlama Katmanı Temel Mimarisi. 41
Şekil 2.19. Tam Bağlantılı Katmanı Temel Mimarisi 42

Şekil 2.20. Rectified Linear Aktivasyon Fonksiyonu (ReLU). 43
Şekil 2.21. Transfer Öğrenme Mimarisi. 45
Şekil 2.22. VGG-16 Mimarisi. 47
Şekil 2.23. ResNet-50 Mimarisi 48
Şekil 2.24. COVID-19 Tespiti İçin Geliştirilen DenseNet-121 Mimarisi. 49
Şekil 2.25. Inception V3 Mimarisi. 50
Şekil 3.1. VGG-16 Modeli Karşıtlık Matrisi 56
Şekil 3.2. VGG-16 Modeli Eğitim-Test Doğruluk Grafiği 57
Şekil 3.3. VGG-16 Modeli Eğitim-Test Kayıp Grafiği. 58
Şekil 3.4. VGG-16 Modeli Roc-Auc Değişimi. 59
Şekil 3.5. ResNet-50 Modeli Karşıtlık Matrisi. 61
Şekil 3.6. ResNet-50 Modeli Eğitim-Test Doğruluk Grafiği. 62
Şekil 3.7. ResNet-50 Modeli Eğitim-Test Kayıp Grafiği 63
Şekil 3.8. ResNet-50 Modeli Roc-Auc Değişimi 64
Şekil 3.9. DenseNet-121 Modeli Karşıtlık Matrisi. 65
Şekil 3.10. DenseNet-121 Modeli Eğitim-Test Doğruluk Grafiği. 67
Şekil 3.11. DenseNet-121 Modeli Eğitim-Test Kayıp Grafiği 67
Şekil 3.12. DenseNet-121 Modeli Roc-Auc Değişimi 68
Şekil 3.13. Inception V3 Modeli Karşıtlık Matrisi. 70
Şekil 3.14. Inception V3 Modeli Eğitim-Test Doğruluk Grafiği. 71
Şekil 3.15. Inception V3 Modeli Eğitim-Test Kayıp Grafiği. 72
Şekil 3.16. Inception V3 Modeli Roc-Auc Değişimi 72

SİMGELER VE KISALTMALAR LİSTESİ

RNA	Ribo Nükleik Asit
DSÖ	Dünya Sağlık Örgütü
RT-PCR	Gerçek Zamanlı Polimeraz Zincir Reaksiyonu
T.C.	Türkiye Cumhuriyeti
β	Beta
α	Alfa
FDA	Amerikan Gıda ve İlaç Dairesi
IDSA	Amerikan Enfeksiyon Hastalıkları Derneği
BT	Bilgisayarlı Tomografi
CNN	Konvolüsyonel Sinir Ağı
DCNN	Derin Konvolüsyonel Sinir Ağı
DBHL	Güçlendirilmiş Hibrit Derin Öğrenme
cGAN	Koşullu Çekişmeli Üretici Ağlar
CLAHE	Kontrast Limitli Adaptif Histogram Eşitleme
GPU	Grafik İşlemci Ünitesi
RBG	Kırmızı-Yeşil-Mavi
ADAM	Adaptif Moment Tahmini
RNN	Tekrarlayan Sinir Ağları
LSTM	Uzun-Kısa Vadeli Hafıza Ağları
RBM	Sınırlı Boltzman Makineleri
DBN	Derin İnanç Ağları
DAE	Derin Oto Kodlayıcılar
ReLU	Doğrultulmuş Doğrusal Aktivasyon Fonksiyonu

GİRİŞ

Çin'in Hubei eyaletine bağlı Wuhan şehrinde 2019 yılının son aylarında sebebi bilinmeyen, halk arasında zatürre (pnömoni) olarak bilinen vakaların belirmesiyle yapılan incelemelerin sonucunda, hastalarda etken maddesi RNA virüsü olan bir tür koronavirüs olduğu saptanmıştır (Wang, Horby, Hayden ve Gao, 2020). Tespit edilen virüs kısa sürede insandan insana bulaşarak başta Çin, sonra da tüm dünyada yaygın bir etki göstermiştir. İnsanlar arasında hızla yayılmasıyla birlikte derinleşen araştırmalar neticesinde hastalık etkeni virüsün, 2002'de belirlenen koronavirüs ailesine ait SARS-CoV virüsü ve 2012'de belirlenen beta koronavirüs ailesinden MERS-CoV olduğu tanımlanarak hastalık etkeninin, insanlarda solunum yollarında tutulum göstererek çeşitli enfeksiyonlara sebep olduğu belirlenmiştir (Gorbalenya vd., 2020). 2019 n-CoV olarak adlandırılan koronavirüsün, tek iplikli ve pozitif yönelimli bir RNA virüsü olduğu tespit edilmiştir. Dünya Sağlık Örgütü (DSÖ) ise aynı virüsü SARS-CoV-2 olarak tanımlanırken, klinik bulgularda "Yeni Koronavirüs (COVID-19)" olarak isimlendirmiştir (Phelan, Katz ve Gostin, 2020). DSÖ, virüsün pek çok ülkeye yayılması ve uzun kuluçka dönemlerinin ortaya çıkması sonucunda 11 Mart 2020 yılında COVID-19'u, pandemi olarak kabul etmiştir (DSÖ, 2020).

COVID-19 hastalığı; ateş, halsizlik, öksürük, eklem ağrıları, ishal, tat ve koku kaybı, nefes darlığı gibi geniş spektrum içeren hafif semptomlara yol açmaktadır (Zhu vd., 2019). Hastalığın ilerlediği durumlarda ise böbrek yetmezliği, kardiyak ve karaciğer yetmezliği, akut solunum problemi ve ani dolaşım problemleri görülmektedir. COVID-19 hastalığı, bağışıklık sistemi zayıf olanlar ile kronik rahatsızlığı olan kişilerde daha ciddi problemlere yol açmaktadır (Pereira, Bertolini, Teixeira, Silla ve Costa, 2020).

COVID-19 hastalarının erken teşhis edilmesi, izolasyon süreçlerine geçilmesi ve uygun tedavi yöntemlerinin başlatılabilmesi için, hastalıkla ilgili semptomları gösteren vakaların hızlı ve en yüksek başarı oranı ile tespit edilmesi gerekmektedir. Hastalığın hızlı tespit

edilmesi amacıyla dünya genelinde yoğun olarak kullanılan ve Türkiye Cumhuriyeti Sağlık Bakanlığı tarafından da tercih edilen gerçek zamanlı polimeraz zincir reaksiyonu (Real Time Polymerase Chain Reaction/RT-PCR) testi kullanılmaktadır. Bu test yöntemi, boğaz ve burun bölgesinden alınan sürüntülerde COVID-19 hastalığının aranması şeklinde gerçekleşmektedir. Ancak yapılan bazı çalışmalarda erken dönemlerde yanlış negatiflik oranlarının RT-PCR testlerinde yüksek çıktığı, akciğere inen virüslerin bu test yönteminde tespit edilmesinin zor olduğu görülmüştür (Kucirka, Lauer, Laeyendecker, Boon ve Lessler, 2020). Bu yüzden test sonuçları negatif çıkan ve hastalık semptomlarını taşıyan hastalardan doktorların akciğer X-Ray görüntüsü istemesi sıklıkla karşılaşılan ve tavsiye edilen bir yöntemdir (Khan, Shah ve Bhat, 2020).

Gelişen teknoloji ile özellikle tıp alanında, X-Ray görüntüsü, bilgisayarlı tömografi ve retina görüntülerinden oluşan veri setlerinden derin öğrenme yöntemleri ile hastalık tespitlerinden başarılı sonuçlar elde edilmektedir (Apostolopoulos, Aznaouridis ve Tzani, 2020). Bu yöntemlerin kullanılarak COVID-19 hastalığının tespit edilmesi ve hastalığın büyük benzerlik gösterdiği viral pnömoni hastalığından ayırt edilmesi sağlık sistemi açısından önemlidir.

Bu çalışmanın amacı, derin öğrenme yöntemleri kullanılarak akciğer X-Ray görüntüleri üzerinden COVID-19 hastalığını hızlı ve en yüksek doğruluk oranı ile tespit etmektir. Bu kapsamda akciğer X-Ray görüntüleriyle oluşturulan veri seti ile 4 farklı transfer öğrenme modeli üzerinden (VGG-16, ResNet-50, DenseNet-121 ve Inception V3) deneysel çalışmalar gerçekleştirilmiştir. Çalışma ilgili literatürle karşılaştırıldığında; veri seti sayısının fazla olması, verilerin sınıflar arasındaki dağılımının yakın olması, popüler ve gelişmiş derin öğrenme modellerinin kullanılması, özellikle görüntüler üzerinde adaptif ön işlemlerin uygulanması ve COVID-19 tespiti için başarı oranlarının pek çok çalışmaya kıyasla yüksek çıkması, bu çalışmanın önemini ortaya koymaktadır. Doktorlara yardımcı bir karar destek sistemi oluşturarak yüksek doğruluk seviyesinde COVID-19 hastalığını bilgisayar destekli sistemler ile tespit etmek, bu çalışmanın motivasyonunu oluşturmaktadır.

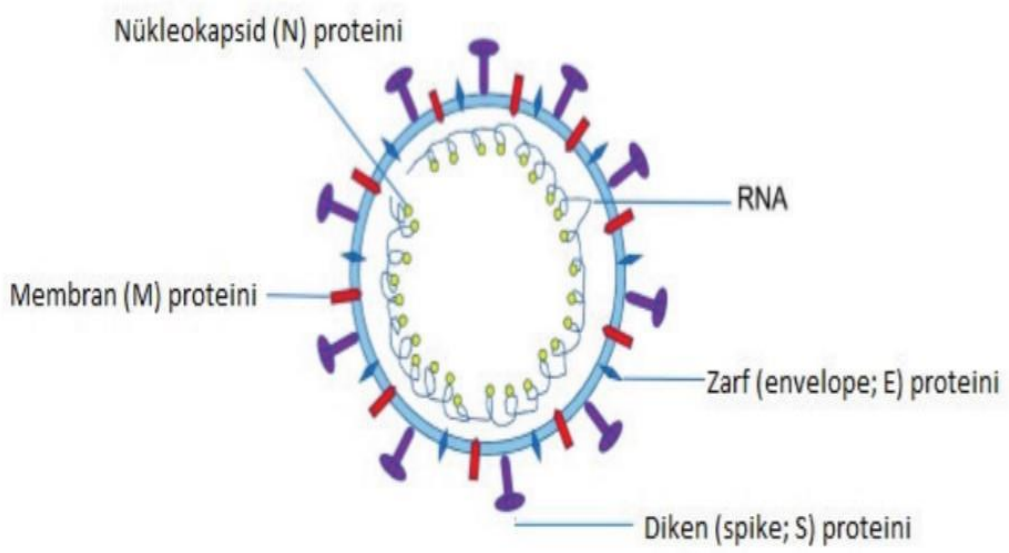
Bu çalışma, üç bölümden oluşmaktadır. İlk bölümde COVID-19 hastalığı, belirtileri ile bulaşma yolları, teşhis yöntemleri, görüntüleme teknikleri ve bu alanda yapılan çalışmalar incelenirken, ikinci bölümde materyal ve yöntem açıklanmıştır. Son bölümde ise yapılan deneysel çalışmalara ait bulgular belirtilmiştir.

BİRİNCİ BÖLÜM

COVID-19 ve TEŞHİSİ

1.1. COVID-19 Hastalığı

Koronavirüsler, tek zincirli, 65-210 nanometre (nm) boyutunda, pozitif polariteli, oval veya poligonal şekillerde olabilen zarflı ve bilinen en büyük pozitif polariteli RNA genomuna sahip virüslerdir (Zhou, Yang, Huang, Jiang ve Du, 2019). Virüsün mikroskobik görüntüdeki en belirgin özelliği, çevresinde çubuksu uzantılar gibi sivri çıkıntıların olmasıdır. Elektron mikroskobunda güneşin taç küresine benzemesinden dolayı koronavirüs adını almışlardır (Shah vd, 2020). Şekil 1.1'de koronavirüsün şematik yapısı belirtilmiştir.



Şekil 1.1. Koronavirüsün Şematik Yapısı (Zhu vd., 2019)

Koronavirüsler, coronavidea ailesi içerisindeki nidovirales virüs takımına aittir. Coronavidea alt ailesi alfa, beta, gama ve delta olmak üzere toplamda dört cins ile bunlarında altında farklı cinsleri barındırmaktadır. İnsanlarda hastalık oluşturabilen, yarasa veya kemirgen kökenli olan alfa ve beta koronavirüslerinde, dört adet yapısal protein bulunmaktadır (Chan vd., 2015). Alfa ve beta cinsine ait bilinen 7 tür koronavirüs insanlara bulaşabilmektedir. Tablo 1.1'de insanlara bulaşabilen koronavirüs türleri ile cins, semptom, konak ve bulunduğu yıllara ait bilgiler belirtilmiştir (Andersen, Rambaut, Lipkin, Holmes, ve Garry, 2020).

Tablo 1.1. İnsanlara Bulaşabilen Koronavirüs Türleri ve Özellikleri

Viral Tür	Viral Cins	Görülen Belirtiler	Viral Konak / Tespit Yılı
hCoV-OC43	β- CoV	HSYE*	İnek- Yarasa (1967)
hCoV-229E	α - CoV	ASYE**	Yarasa (1968)
SARS CoV	β - CoV	ASYE**	Misk Kedisi – Yarasa (2003)
hCoV-NL63	α - CoV	HSYE*	Misk Kedisi- Yarasa (2004)
HCoV-Hku1	β - CoV	Viral Pnömoni	Fare- Yarasa (2005)
MERS-CoV	β - CoV	ASYE**	Yarasa-Deve (2012)
SARS-CoV-2	β - CoV	ASYE**	Yarasa (2019)

Not: *HSYE: Hafif Solunum Yolu Enfeksiyonu, **ASYE: Ağır Solunum Yolu Enfeksiyonu

Koronavirüs türleri gibi insanlara bulaşan pek çok virüs türü, yüzyıllardır bulunmaktadır. Bu virüslerin insanlara bulaşmasından ve hızlı yayılım göstermelerinden dolayı insanlık tarihi boyunca pek çok salgın hastalık meydana gelmiştir. Bu hastalıkların bazıları kısa sürede kaybolurken, bazıları ise yıllarca devam ederek milyonlarca insanın ölümüne sebep olmuştur. Tarihte bilinen en büyük virüs salgını, 1918 yılında görülen grip salgınıdır. H1N1 virüsünden kaynaklanan bu salgın, 1918-1920 yılları arasında dünya genelinde hızlı bir şekilde yayılmış olup, yaklaşık 50 milyon insanın ölümüne sebep olmuştur (Horimoto ve Kawaoka, 2005). İlerleyen yıllarda bu virüsün mutasyona uğramış farklı türlerinden kaynaklanan grip salgınları da görülmüştür. İnsanlık sağlığını halen tehdit etmeye devam

eden HIV/AIDS virüs salgını ise 1981 yılında tespit edilmiştir. Halen kesin tedavisi bulunmayan bu virüsten ise yaklaşık 30 milyon insan hayatını kaybetmiştir (Horimoto ve Kawaoka, 2005). Tablo 1.2'de 20.yy ve sonrasında karşılaşılan büyük salgınlara ait genel bilgiler verilmiştir.

Tablo 1.2. 20.yy ve Sonrası Dünya Genelinde Görülen Salgın Hastalıklar

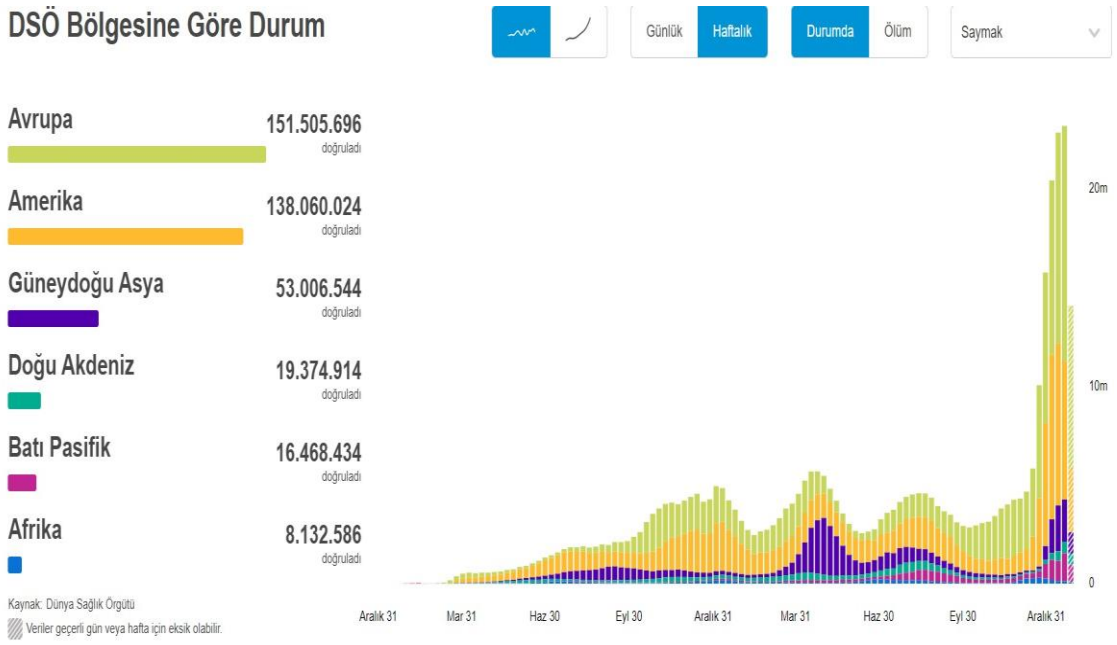
Salgın İsmi	Salgının Türü /Etkilediği Ülke	Saptanan Yaklaşık Ölüm sayıları (Milyon)	Görüldüğü Tarih
H1N1 (İspanyol Gribi)	Pandemi	50	1918-1920
H2N2 (Asya Gribi)	Pandemi	2	1957-1958
H3N2 (Hong Kong Gribi)	Pandemi	1	1968-1969
HIV/AIDS	Epidemi /Batı Afrika	30	1960 – Günümüz
SARS	Epidemi /Asya & Kanada	0.000775	2002 -2003
H1N1 (Domuz Gribi)	Epidemi /ABD & Meksika	0.2	2009 – 2010
MERS	Pandemi	0.00045	2012 – Günümüz
SARS-CoV-2	Pandemi	5.8*	2019 – Günümüz

* 04.02.2022 tarihinde elde edilen bilgidir.

Kaynak: Morens, Daszak, Markel, ve Taubenberger, 2020.

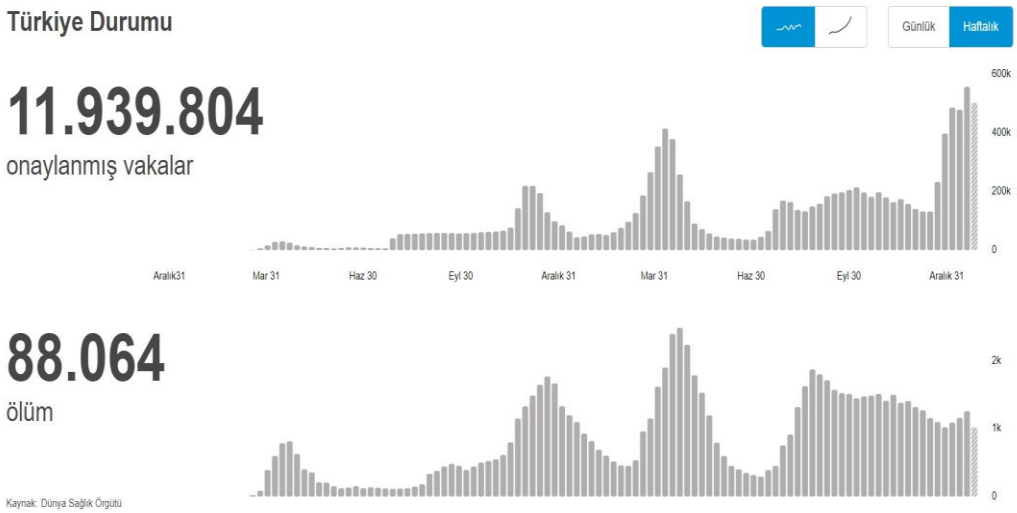
Tablo 1.2 incelendiğinde tarih boyunca ölümcül pek çok salgın hastalığın yaşandığı görülmektedir. Bu hastalıklardan dünya genelinde görülen ve günümüzde halen etkisi devam edeni ise COVID-19 salgınıdır. Koronavirüsün çeşitli türlerinin enfeksiyonu ile oluşan bu hastalık, Çin'in Hubei eyaletine bağlı Wuhan şehrinde ilk olarak Aralık 2019 yılında tespit edilmiştir. Hastalık belirtilerinin artması sebebiyle yapılan araştırmalar sonucunda kentin güneyinde bulunan Wuhan Güney Deniz Ürünleri Şehir Pazarı çalışanlarında kümelenme olduğu görülmüştür. Pazar çalışanlarının çoğunluğunda ateş, nefes darlığı ve pnömoni bulguları tespit edilmiştir (Shi vd., 2020). İnsanlarda daha önce tespit edilmeyen bir virüs olmasından dolayı 2019-nCoV şeklinde isimlendirilen yeni tip koronavirüs, mikroskobik bulguları 2003 yılında görülen SARS virüsüne benzediği için 7 Ocak 2020'de SARS-CoV-2 olarak isimlendirilmiştir. Bu tarihten itibaren virüsün insandan insana hızlı yayılım göstermesi ile birlikte, DSÖ bu hastalığı 30 Ocak 2020 tarihli bildirgesinde "Ulusal Boyutta Halk Sağlığı Acil Durumu" olarak nitelendirip, hastalığı COVID-19 olarak isimlendirmiştir. Hastalığın dünya geneline de yayılmasıyla birlikte 11 Mart 2020 tarihinde ise dünya genelinde görülen küresel salgın (pandemi) olarak tanımlanmıştır (T.C. Sağlık Bakanlığı, 2020a).

Salgınının başlamasından kısa bir süre sonra tüm dünya genelinde COVID-19 virüsü görülmeye başlanmıştır. Ülkemizde bu durumdan etkilenerek 11 Mart 2020 tarihinde ilk vaka görülmüştür. T.C. Sağlık Bakanlığı tarafından bilim kurulu oluşturularak, ülkemizde alınması gereken önlemler ile korunma yöntemleri belirlenmiştir. COVID-19 salgını tüm dünyada halen farklı varyantları ile devam etmektedir. DSÖ'nün 04.02.2022 tarihli bilgilerine göre, dünya genelinde 386.548.962 kişi COVID-19 hastalığına yakalanmış olup, toplamda 5.705.754 kişi hayatını kaybetmiştir. Şekil 1.2'de DSÖ tarafından paylaşılan dünya geneli vaka sayıları görülmektedir (DSÖ, 2022a).



Şekil 1.2. Dünya Geneli Onaylanmış Vaka Sayıları (DSÖ, 2022a)

Şekil 1.2 incelendiğinde, bir yıl içerisinde dünyanın tüm bölgelerinde vaka sayılarının çok hızlı artış gösterdiği görülmektedir. Dünyada en yüksek vaka sayıları Avrupa kıtasında olup, en az vaka sayısı Afrika kıtasında gerçekleşmiştir. Aynı veriler ışığında ülkemizde 4 Şubat 2022 yılı itibariyle toplamda 11.939.804 kişi COVID-19 hastalığına yakalanmış olup, 88.064 kişi ise aynı hastalıktan hayatını kaybetmiştir. Şekil 1.3'te DSÖ tarafından Türkiye COVID-19 bilgileri belirtilmiştir (DSÖ, 2022b).



Şekil 1.3. Türkiye Geneli Onaylanmış Vaka ve Ölüm Sayısı (DSÖ, 2022b)

Şekil 1.3'te görüldüğü gibi ülkemizde de vaka sayıları son bir yıl içerisinde hızlı bir artış göstermeye devam etmektedir. Salgının başladığı tarihten itibaren en yüksek vaka sayılarının karşılaşıldığı 2021 yılının Mart ayından sonra vakalarda düşüş meydana gelmiş olsa da, hastalığın mutasyona uğrayarak yeni varyantlarının ortaya çıkması ile birlikte vaka sayılarında artış meydana gelmiştir.

Karşılaşıldığı günden itibaren halk sağlığını tehdit eden COVID-19 hastalığının sebep olduğu virüsteki meydana gelen değişimler sonucu ortaya çıkan yeni varyantlar, DSÖ tarafından gözlemleme ve müdahale konusunda sınıflandırmayı zorunlu kılmıştır (DSÖ, 2022c). DSÖ tarafından bu zamana kadar 5 tip varyant tanımlanmıştır. Bunlar; Alpha, Beta, Gamma, Delta ve Omicron varyantlarıdır. Dünya Sağlık Örgütü Delta ve Omicron varyantlarını endişe verici varyantlar olarak sınıflandırmıştır (DSÖ, 2022c). Tablo 1.3'te varyantların tanımlanma tarihleri sırasıyla belirtilmiştir.

Tablo 1.3. COVID-19 Varyantları

Varyant Adı	Tanımlanma Tarihi
Alpha	18 Aralık 2020
Beta	18 Aralık 2020
Gamma	11 Ocak 2021
Delta	11 Mayıs 2021
Omicron	26 Kasım 2021

1.1.1. Belirtileri ve Bulaşma Yolları

COVID-19'un, yoğun olarak hastalık sahibi kişilerin dış ortama bıraktıkları damlacıklar vasıtasıyla bulaştığı bilinmektedir. Bunun yanı sıra hastaların hapşırma ve öksürme yoluyla oluşturdukları damlacıklara başka kişiler tarafından temas edilerek, kişilerin ağız, burun ve gözlerine bu salgıyı götürmesi yoluyla da bulaşmaktadır (Van Doremalen vd., 2020). COVID-19'un tahmini bulaştırıcılık süresi ise, semptomların görüldüğü dönemden 1-2 gün öncesi başlayıp, semptomların ortadan kalkmasıyla sonlanmaktadır. Ayrıca hastalık semptomu göstermeyen kişilerin salgılarında da virüs olduğu için, bu kişiler hastalığın taşıyıcısı olabilmektedir (T.C. Sağlık Bakanlığı, 2020b).

COVID-19 salgının ilk başladığı zamanlarda DSÖ tarafından yayınlanan raporda inkübasyon süresinin yaklaşık 4-14 gün aralığında olabileceği belirtilmiştir (DSÖ, 2021). İlerleyen süreçte yapılan çalışmalarda, hastalığın hafif seyrettiği kişilerin yaklaşık % 85'inde semptomların görülmesinden 7-10 gün sonrasında yapılan sürüntülerde viral RNA kalıntılarına rastlanılmadığı ortaya konulmuştur (Singh, Pandey ve Babu, 2021). Bu kapsamda da ülkemizde hafif semptomları gösteren kişilere yapılan RT-PCR testlerinin pozitif çıkması durumunda 7 günlük karantina uygulanmaktadır (T.C. Sağlık Bakanlığı, 2022).

Koronavirüslerin, ortamdaki nem, sıcaklık, temas ettiği yüzeyin dokusu ve dışarı saçılan organik maddenin miktarı gibi çeşitli etmenlere bağlı olarak dış ortamlara dayanıklılık süreleri değişmektedir. Virüs yapısı gereği yüksek sterilizasyon önlemlerine gerek olmadan alkol, sabun ve deterjan gibi ürünlerle temas anında yapısı bozulmaktadır (Carsetti, Quinti ve Locatelli, 2021). İnsanlarda COVID-19 hastalığının şiddeti hafif solunum yolu enfeksiyonlarından, ağır akut solunum enfeksiyonlarına kadar değişebilmektedir. Asemptomatik hastalarda ise, hiçbir belirti görülmeden bulaştırıcılık özellikleri görülebilmektedir. Salgının en önemli kesimini de asemptomatik kişiler oluşturmaktadır. Çünkü bu kişiler semptomlar görülene kadar toplum ve sağlık çalışanları tarafından tespit edilemedikleri için, virüsün topluma yayılmasına sebep olmaktadır. Yapılan araştırmalarda COVID-19 hastalığına yakalanmış 5 kişiden birinin semptom göstermediği ve bu kişilerin yayılım hızını arttırdığı belirtilmiştir (Nogrady, 2020).

Hastalığın başlangıcında sıklıkla görülen en belirgin belirtiler; yorgunluk, ateş, kas ağrısı, öksürük ve baş ağrısıdır. Yoğun olmamakla birlikte kusma, ishal ve burun tıkanıklığı gibi durumlarda ortaya çıkmaktadır. Pnömoni ise hastalığın en sık görülen belirtilerinin başında

gelmektedir (Stokes vd., 2020). Tablo 1.4'te COVID-19 hastalarında en sık görülen belirtileri listelenmiştir.

Tablo 1.4. COVID-19 Hastalarında En Sık Görülen Belirtiler

COVID-19 Belirti Türleri	
Ateş	Miyalji
Öksürük	Baş Ağrısı
İshal	Titreme
Burun Tıkanıklığı	Nefes Darlığı
Mide Bulantısı ve Kusma	Balgam
Boğaz Ağrısı	Yorgunluk

Kaynak: Stokes vd., 2020

COVID-19 hastalığı klinikte "hafif, orta, şiddetli ve kritik" olmak üzere 4 farklı şekilde sınıflandırılmaktadır (Liang, 2020). Bunlar:

- *Hafif Olgular:* Görüntülemede herhangi bir olguya rastlanılmayan, hafif semptomların görüldüğü olgulardır.
- *Orta Olgular:* Solunum yolu ve ateş enfeksiyonu semptomları görülmekle birlikte, tıbbi görüntülemelerde pnömoni bulgusu gözlemlenmektedir.
- *Şiddetli Olgular:* Oksijen satürasyonunun 90'dan küçük olduğu ve solunum sayısının dakikada 30'dan büyük olduğu durumlarda belirtilen olgulardır. Bu durumda tıbbi görüntülemelerde virüs lezyonları yarıdan fazla ilerlemektedir.
- *Kritik Olgular:* Hastalarda şok bulgularının gözlemlenmesi, ventilasyon gerektiren solunum yetmezliği ve yoğun bakım gerektiren organ yetmezliklerinin meydana geldiği durumlardır.

Belirlenen bulgu türleri kişilerin hastalık geçmişi, bağışıklık sisteminin güçlülüğü, yaş gibi etmenlere bağlı olarak değişiklik göstermektedir. Çocuklarda ve ergen bireylerde hastalık semptomları nadir olarak görülürken, orta yaş ve üzeri yetişkinlerde semptom düzeylerinin arttığı görülmektedir. Genellikle yaşlı ve kronik rahatsızlığı olan bireylerde hastalık daha ciddi sonuçlar doğurmaktadır (Chen vd., 2020).

1.1.2. Teşhis Yöntemleri

COVID-19 hastalığının hızlı yayılım göstermesi ve ciddi sonuçlara yol açmasından dolayı hızlı bir şekilde tespit edilmesi ve izolasyon süreçlerine başlanılması hayati önem taşımaktadır. Bu sebeple hastalık hızlı tanı yöntemleri ile tespit edilmektedir. Bu kapsamda dünya genelinde onaylanmış iki hızlı tanı yöntemi yoğun olarak kullanılmaktadır. Bunlar (Kucirka vd., 2020):

- *Antijen Testleri:* Yanal akış yöntemi ile yapılan antijen testleri, virüsün protein fragmentlerinin burun veya boğazdan alınan sürüntü örneklerinde tespit edilmesi işlemidir. Yapılan araştırmalar sonucunda enfeksiyonun aktif süreçlerinde negatif çıkma durumunun yükseldiği tespit edildiği için, Amerika Gıda ve İlaç Dairesi (U.S. Food and Drug Administration/FDA) tarafından hangi süreçlerde antijen testlerinin yapılması gerektiğine dair bir rapor yayınlanmıştır. Rapora göre enfekte olmuş bireylerde negatif yanlışlık seviyesinin yüksek olduğu ve bu yüzden enfeksiyon geçiren kişilerde bu test yönteminin uygulanmaması önerilmektedir (FDA, 2020).
- *RT-PCR Testi:* Virüsün genetik materyalinin tespitinin yapılması amacıyla hastalık belirtisi gösteren kişilerden boğaz ve burun sürüntü örneği alınarak uygulanan bir testtir. Bu test türünün kişilerden doğru yöntemler çerçevesinde alınması ve laboratuvarlara uygun şekilde hazırlanması testin pozitif doğruluğu açısından önemlidir (Tang, Schmitz, Persing ve Stratton, 2020). Uygulanan RT-PCR testleri laboratuvarların kapasitesine değişmekle birlikte birkaç saat veya birkaç gün içerisinde sonuç vermektedir.

RT-PCR testleri ile virüs genom materyali tespiti yapıldığı için virüs mutasyon durumlarında test sonuçlarında hata meydana gelebilmektedir. Kucirka ve ark. (2020) tarafından yapılan bir çalışmada; semptomların görülmesinden 5 gün sonrasında yapılan RT-PCR testlerinin sonuçları analiz edildiğinde, tıbbi görüntüleme ve doktor tanılarından pozitif görülen hastaların % 17'si negatif olarak saptanmıştır (Kucirka vd., 2020). Antikor testleri ile de geçirilmiş enfeksiyon hastalıkları belirlenebilmektedir. Yalnız antikor varlığının pozitif olduğu durumda, bu durumun ne kadar koruyucu olduğuna dair kesin bilgi bulunmamaktadır (Tang vd., 2020). Ayrıca klinik belirtileri kuvvetli olan kişilerde nazal sürüntünün negatif çıktığı durumlarda, hasta dışkısında viral saçılma meydana geldiği ve rektal sürüntü ile testlerin yapılmasının faydalı olacağı belirtilmektedir (Alsharif ve Qurashi, 2021).

Amerika Enfeksiyon Hastalıkları Derneği (Infectious Diseases Society of America/IDSA), belirlenen semptomları taşıyan olası vakalar ile enfeksiyon şüphesi olan tüm hastaların test edilmesini önermektedir. Bu grupların haricinde öncelikli olarak sağlık çalışanları, kalabalık iş yerlerinin çalışanları ile ciddi kronik rahatsızlıkları olan hastalara test önceliğinin verilmesi gerektiği belirtilmektedir (Ward, Lindsley, Courter ve Assa'ad, 2020).

Ülkemizde COVID-19 tanı ve tespit yöntemleri, Sağlık Bakanlığı tarafından belirli kurallar çerçevesinde yapılmaktadır. Semptomların görüldüğü vakalarda diğer ülkelere benzer yönde ülkemizde de RT-PCT testleri kullanılmaktadır. Sağlık Bakanlığı tarafından hazırlanan vaka tespit kılavuzuna göre kimlere RT-PCT testlerinin uygulanacağı belirlenmiştir. Sağlık Bakanlığı tarafından hazırlanan kılavuza göre (T.C. Sağlık Bakanlığı, 2022);

- COVID-19 pozitif bireylerle yakın temas içerisinde olanlara,
- Ciddi hastalık riskinin olduğu toplu yaşam merkezlerinde düzenli olarak,
- Cerrahi prosedürlerden hemen önce,
- Hafif ve orta olgularda bulunan hastaların tümünde,
- İmmünsüpresif tedavisi almadan hemen önce,
- Tıbbi görüntülemelerde COVID-19 bulgusuna rastlanıldığı durumlarda RT-PCR testi önerilmektedir.

DSÖ, COVID-19 hastalığının tespiti için RT-PCR testleri ile antijen testlerini önermemekle birlikte, hastalığın sürveyansını belirlemede kullanılabileceğini belirtmektedir (Yüce, Filiztekin ve Özkaya, 2021). Toplam antikor, RT-PCR ve antijen testleri arasından duyarlılık ağırlıkları zamansal farklılıklar göstermektedir. Tablo 1.5'te COVID-19 tespiti için kullanılan testlerin duyarlılıkları belirtilmiştir (Altındiş ve Toptan, 2020).

Tablo 1.5. COVID-19 Hastalığı Tanı Testlerinin Duyarlılıkları

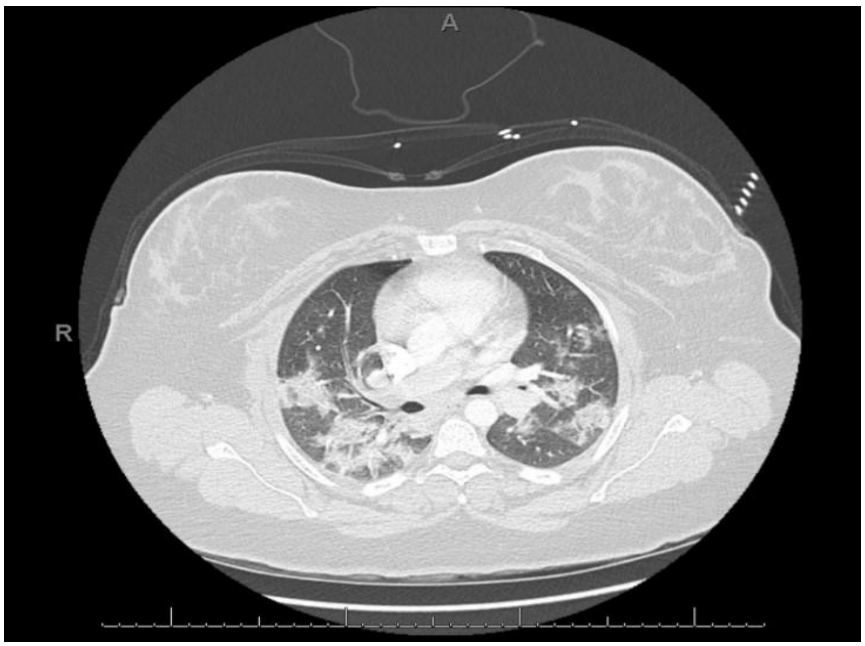
Semptomlardan Sonraki Gün Sayıları			
SARS-CoV2 Test	1-7 gün	8-14 Gün	15-39 Gün
RT-PCR	% 67	% 54	% 45
Toplam Antikor	% 38	% 90	% 100
Antijen Testleri	% 19	% 54	% 80

1.2. COVID-19 Teşhisi İçin Kullanılan Görüntüleme Teknikleri

COVID-19 hastalığının önüne geçilmesi amacıyla farklı ilaç ve aşı yöntemleri uygulanmakta olup, hastalığın hızlı yayılım göstermesinin önüne geçilebilmesi için tespitlerin hızlı yapılması önem arz etmektedir. Dünya genelinde hızlı tespit yöntemi olarak kullanılan RT-PCR test sonuçlarının, yanlış negatiflik ihtimalinin olması ve sonuçların yoğunluk durumuna bağlı olarak geç çıkmasından dolayı radyolojik görüntülemeler tercih edilmektedir (Khan vd., 2021). Bu durumlara bağlı olarak doktorlar tarafından semptom gösteren ve klinik bulguları yoğunlaşan bireylerden, COVID-19 hastalığını tespit etmek amacıyla bilgisayarlı tomografi (BT) veya akciğer X-Ray görüntüleme tercih edilmektedir.

1.2.1. Bilgisayarlı Tomografi

BT görüntüleri, organların, kan damarları ile kemiklerin ayrıntılı görüntülerini üreterek, hekimlerin enfeksiyon boyutları ile yoğunluk dokularını görmelerini sağlamaktadır (Pereira vd., 2020). Z-ray ışınları ile insan vücudunu tarama sistemi üzerine kurulu olan BT cihazı, dilim görüntüleme yöntemleri ile katmansal görüntülerin elde edilmesini sağlamaktadır (Savaş, 2014). Şekil 1.4'te COVID-19 hastalığı tespit edilen akciğer BT görüntüsü verilmiştir (Chams vd, 2020).



Şekil 1.4. COVID-19 Hastası Akciğer BT Görüntüsü (Chams vd, 2020)

COVID-19 hastalarında BT görüntüleri sonucunda yoğun olarak viral pnömoni ile buzlu cam görüntüleri görülmektedir. BT görüntüleri incelendiğinde COVID-19 hastalarında yoğun olarak görülen bulgular şu şekildedir (Ojha, Mani, Pandey, Sharma ve Kumar, 2020):

- Plevral alanda kalınlaşma
- Septal kalınlaşma
- Hava bronkogramları
- Buzlu cam opasiteleri

Tüm görüntü türlerinde olduğu gibi semptomların başlangıcında BT görüntüleri normal olarak görülebilir yalnız hastalık seyrinin ciddileştiği durumlarda bulguların gelişme ve değişme durumları ortaya çıkabilmektedir. BT görüntülerinden elde edilen bilgilerden COVID-19 hastalığını tespit etmek ve kliniksel raporlamalar için T.C. Sağlık Bakanlığı tarafından yayınlanan rapor örneği Tablo 1.6'da belirtilmiştir (T.C. Sağlık Bakanlığı, 2020b).

Tablo 1.6. Sağlık Bakanlığı BT Görüntüleri Bulguları Raporlama Yöntemi

Sınıflandırma Türü	Gerekçeler	BT Bulguları
Tipik	COVID-19 için bildirilen görüntüleme bulguları	Organize pnömoninin bulguları
Belirsiz	Spesifik olmayan görüntü bulguları	Periferik olmayan buzlu cam opasiteleri
Atipik	COVID-19 için bildirilmiş nadir bulgular	Ayrık küçük nodüller
Negatif	Pnömoni bulguları yok	Pnömoniyi düşündüren bulgular yok

Sağlık Bakanlığının belirtilen raporuna göre, COVID-19 hastalığının hızlı ve erken tespit edilmesinin yanı sıra, hastalık belirtileri artmakta olan ve klinik bulguları ağırlaşan hastalar içinde BT önerilmektedir. Genellikle hastalık seyrinin kötüleşmesinde enfeksiyon, emboli ve koronavirüsün kardiyak tutulumu bulunmaktadır. Hastaların genel durumunda enfeksiyon azalması veya ciddileşme durumları varsa bilgisayarlı tomografi önerilmemektedir (T.C. Sağlık Bakanlığı, 2020b).

1.2.2. X-Ray Görüntüleme

COVID-19 hastalığının tespit edilmesi için en sık kullanılan görüntüleme yöntemlerinden biri de X-Ray görüntüleme yöntemidir. X-Ray görüntüleme ilk kez Wilhem Conrad Röntgen'in x-ışınını bulması ile 1985 yılında kullanılmaya başlanmıştır (Sen ve Honavar, 2021). X-Ray ile akciğer görüntüleme yöntemi, akciğerin genel yapı durumunun analiz edilmesi açısından en sık kullanılan ve erişilebilir yöntemlerden biridir. Yapılan çalışmalar, COVID-19 hastalığının akciğerde meydana getirdiği etkilerin gözlenmesinde, X-Ray ile görüntülemenin başarılı sonuçlar verdiğini ortaya koymuştur (Ismael ve Şengür, 2021).

COVID-19 tıbbi görüntüleri ile bu hastalığa benzer yapılarda bulunan grip, pnömoni ve diğer akciğer hastalıklarının birbirinden ayrılması açısından X-Ray görüntüleme önemli bir yere sahiptir. Ayrıca hastane kaynaklarının verimli kullanımı için COVID-19 hastalarını tıbbi olarak sınıflandıracak en verimli yöntem X-Ray ile görüntüleme yöntemidir (Sümer, Engin, Ağıldere ve Oğul, 2020). X-Ray ile görüntüleme ile elde edilen sonuçlar radyologlar tarafından analiz edilebilmektedir. Şekil 1.5'te COVID-19 hastalığı tespit edilen bir X-Ray görüntüsü belirtilmiştir (Chams vd, 2020).



Şekil 1.5. COVID-19 Hastası X-Ray Görüntüsü (Chams vd, 2020)

1.3. COVID-19 Röntgen Desen Analizleri

X-Ray görüntüleri ile COVID-19 hastalığının tespit edilmesinde, akciğer röntgen görüntülerinin radyologlar tarafından tanı değeri %30 ile %80 arasında değişmektedir (Ye, Zhang, Wang, Huang, ve Song, 2020). Düşük doz radyasyona maruz kalınması, X-Ray cihazlarının kolay temizlenebilmesi ve hasta başı uygulanabilirliğinin kolay olması amacıyla, COVID-19 hastalığının takibinde akciğer grafisinin çekilmesi daha uygundur. Çocuk ve genç hastalarda bilgisayarlı tomografiden önce, X-Ray görüntüleme tercih edilmektedir (Kanne, Little, Chung, Elicker ve Ketai, 2020).

COVID-19 hastalığı, X-Ray görüntülerinde akciğer orta ve alt alanları tutan ve genellikle düzensiz sınırlı opasite[1] artışları şeklinde gözlenmektedir. Tablo 1.7'de COVID-19 hastalığının X-Ray görüntüleri üzerinde enfeksiyon bulgularına yer verilmiştir (Lauer vd., 2020). Her bir bulgunun görünümü, EK 1'de gösterilmiştir.

Tablo 1.7. X-Ray Görüntülerinde COVID-19 Hastalığı İçin Elde Edilen Bulgular

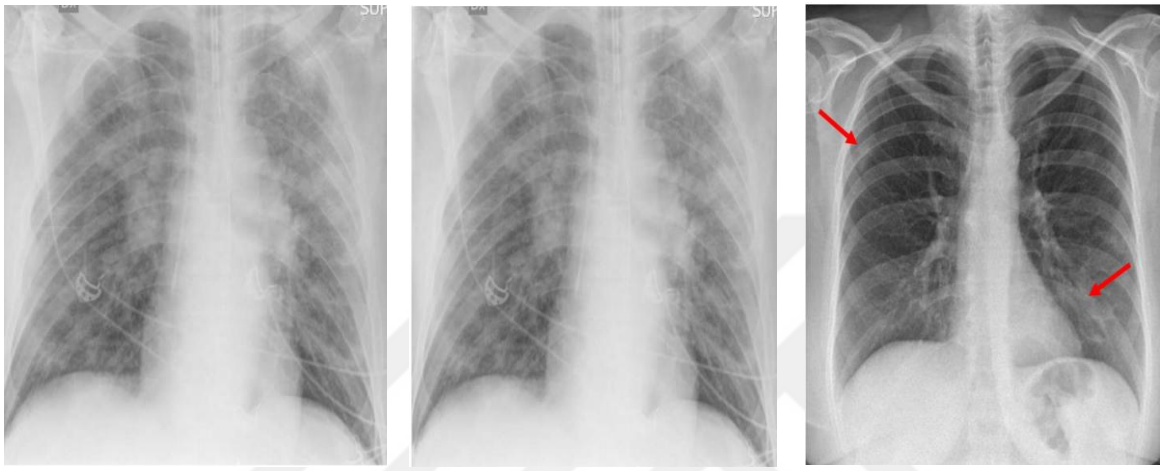
Tipik Bulgular	Atipik Bulgular
Retiküler Görünüm	Kavitasyon
Nodül Kısımları	Perikardiyal Sıvı
Hava Bronkogramı	Plevral Sıvı
Kaldırım Taşı	Lenfadonapati
Konsolidasyon	
Buzlu Cam Opasitesi	

X-Ray görüntülerinden COVID-19 hastalığının erken evrelerinde tespiti % 30-35 yalancı negatiflik payına sahiptir. Hastalığın ilk beş gününde bu değer % 37 gibiyken, altıncı günden itibaren bu değer % 60 oranına yaklaşmaktadır. Bunun en büyük sebebi, bulguların 6-11. günler arasında tepe noktaya ulaşmasından kaynaklanmaktadır.

[1] Opasite: Alveolların içerisine sıvı dolmasından dolayı alveol duvarlarının kalınlaşması sonucu meydana gelen hacimdeki doku yoğunluğudur.

Hastalığın toplumda görülme sıklığının yüksek olduğu ortamlarda X-Ray ile akciğer grafisinin özgüllük değeri ise, % 90'a yaklaşmaktadır (Ippolito vd., 2020).

Eşi COVID-19 hastalığı geçirmekte olup, belirtileri kendisinde görülen bir hastaya ait X-Ray görüntüleri Şekil 1.6'da belirtilmiştir. Şekil 1.6'da hastanın (a) İlk Başvuru (b) 2.gün (c) 10 gün sonra şeklinde ayrı ayrı X-ray görüntülerine yer verilmiştir (Yoon vd., 2020). Hasta 60 yaşında ve erkektir. Ateş, öksürük ve dispne[2] belirtilerini göstermektedir.



a) İlk Başvuru (b) 2.Gün (c) 10. Gün

Şekil 1.6. COVID-19 Belirtileri Gösteren Bir Hastaya Ait X-Ray Görüntüleri

Şekil 1.6'da belirtilen X-Ray görüntüleri incelendiğinde; hastanın ilk başvuru röntgen görüntüleri ile 2. gün röntgen görüntülerinde bir bulguya rastlanılmadığı görülmektedir. Hastalığın 10. gününde semptomların devam etmesi üzerine yapılan X-ray görüntüleme ile elde edilen sonuçlar incelendiğinde ise bilateral orta alt zonlara daha çok tutunum gösteren düşük dansiteli COVID-19 pnömonisi tespit edilmiştir (Yoon vd., 2020).

COVID-19 hastalığı ile viral pnömoni enfeksiyonları arasında bulunan büyük benzerlikler ve orta özellikler vakalara uzman radyologların tanı koymalarını zorlaştırmaktadır. X-ray görüntülerinden güvenilir bir yöntem ile COVID-19 hastalığının tespit edilmesi ve diğer benzer hastalıklardan ayırıcı özellik taşıması, vakaların hızlı tespiti ve klinik tedavisi için önem taşımaktadır.

[2]Dispne: Kişinin nefes almakta zorlandığı, akciğerlerde oksijen oranının düştüğü durumdur. Bu durumda kişilerde nefes alıp vermekte zorlanma meydana gelmektedir.

1.4. COVID-19 Teşhisi Üzerine Yapılmış Çalışmalar

Hastalıkların tespiti için yapılan çalışmalarda derin öğrenme algoritmalarının kullanımı giderek artmaktadır (Kumar Shukla vd., 2020). COVID-19 hastalığının günümüzde halen devam ediyor olması araştırmacıları, hastalığın tespitinde derin öğrenme çalışmaları uygulamaya yöneltmektedir. COVID-19 hastalığının derin öğrenme yöntemleri ile tespit edilmesi amacıyla farklı araştırmacılar tarafından çeşitli çalışmalar gerçekleştirilmiştir. Bu araştırmaların bazıları Tablo 1.8'de belirtilmiştir.

Minaee ve ark. (2020), halka açık veri setini kullanarak 71 adet COVID-19 olmak üzere toplamda 5000 akciğer X-Ray görüntüsüne ait bir veri seti ile çalışmıştır. Araştırmalarında, COVID-19'un tespiti için; ResNet-50, DenseNet-121, SqueezeNet ve ResNet-18 derin öğrenme modellerini kullanmışlardır. Çalışmada hastalıklı olan bireylerin akciğer bölgelerinde COVID-19 izlerini ısı haritasına dönüştürmüşlerdir. Oluşturulan ağların sonucunda başarı oranı % 90 olarak tespit edilmiştir. Toğaçar ve ark. (2020) ise, destek vektör makinesi kullanarak üç farklı sınıflandırma yaptıkları çalışma için 295 adet COVID-19, 65 adet normal ve 98 adet viral pnömoni akciğer X-Ray görüntülerinden oluşan bir veri seti kullanmışlardır. COVID-19 hastalığını tespit etmek için geliştirdikleri katmansal yapı üzerinden derin özellikleri çıkarmak için MobileNetV2 ve SqueezeNet derin öğrenme modellerini karşılaştırmışlardır. Yapılan deneysel çalışmalar sonucunda araştırmacılar, MobileNetV2 modeli ile veri setinde yer alan 295 adet COVID-19 görüntüsünden 293 tanesini doğru olarak sınıflandırarak %99.27 doğruluk oranı elde etmişlerdir.

Zheng ve ark. (2020), 630 adet 3 boyutlu bilgisayarlı tomografi görüntüleri ile bir veri seti oluşturmuşlardır. Çalışmada 3 boyutlu derin evrişimli sinir ağı tipli (DeCoVNet) bir model önerilmiştir. 2 farklı sınıflandırmanın yapıldığı (COVID Pozitif – COVID Negatif) çalışma sonucunda, % 90,1 doğruluk ve % 91,1 özgüllük değeri elde edilmiştir. Ayrıca geliştirilen uygulama ile, özel GPU kullanımı sayesinde bir BT görüntüsü üzerinden COVID-19 tespitinin 1.93 saniyede yapılabilmesini sağlamışlardır. Narin ve ark. (2020) ise, akciğer X-Ray görüntülerinden oluşan dört farklı sınıflandırma kapsamında (COVID-19, viral pnömoni, bakteriyel pnomoni ve sağlıklı birey) üç farklı veri seti ile toplamda 7406 görüntüden oluşan bir veri seti oluşturmuşlardır. Oluşturdukları veri seti üzerinden COVID-19 tespit etmek amacıyla ResNet-50, Inception V3, ResNet-101, ResNet 152 ve Inception-ResNet V2 modelleri üzerinde deneysel çalışmalar gerçekleştirmişlerdir. 5 kat çapraz doğrulama gerçekleştirilen çalışma sonucunda her veri setinde ayrı ayrı olmak üzere

ortalama % 98 doğruluk elde etmişlerdir.

Maghdid ve ark. (2020), halka açık veri setlerinden 170 X-Ray görüntüsü ile 361 bilgisayarlı tomografi görüntüsünden oluşan iki farklı veri seti oluşturmuşlardır. Çalışmaları boyunca COVID-19 ve normal olmak üzere iki farklı sınıflandırma üzerinde yoğunlaşan araştırmacılar, önceden eğitime tabi tutulmuş AlexNet modeli ile katmansal değişimler gerçekleştirdikleri konvolüsyonel sinir ağını (Convolutional Neural Network/CNN) karşılaştırmışlardır. Çalışma sonucunda AlexNet modeli ile X-Ray görüntüleri üzerinde % 98, BT görüntüleri üzerinde ise % 82 doğruluk oranı elde etmişlerdir. Aynı çalışma kapsamında geliştirilen CNN modeli ile yapılan deneyler sonucunda X-Ray görüntüleri üzerinde % 94, BT görüntüleri üzerinde ise % 94.1 doğruluk oranı elde etmişlerdir. Hemdan ve ark. (2020) tarafından yapılan bir başka çalışmada ise, 25 adet COVID-19 ve 50 adet sağlıklı akciğer X-Ray görüntüsünden oluşan veri seti üzerinde yapılan deneyler sonucunda, COVIDX-Net isimli bir model önerilmiştir. Derin öğrenme sınıflandırıcı altyapısını kullanan model kapsamında araştırmacılar, VGG-19 ve DenseNet-201 gibi yedi farklı derin konvolüsyonel sinir ağı (Deep Convolutional Neural Network/DCNN) modelini uygulamışlardır. Uygulama sonucunda VGG-19 modelinde en yüksek % 91 oranı başarı elde etmişlerdir.

Ucar ve Korkmaz (2020) üçlü sınıflandırma için halka açık veri setlerinin birleştirilmesi ile 45 adet COVID-19, 1203 adet normal ve 1591 adet viral pnömoni akciğer X-Ray görüntülerinden oluşan bir veri seti oluşturmuşlardır. COVID-19 hastalığını tespit etmek için sıralı bir tasarım stratejisi önerilmiş olup, SqueezeNet modelini Bayes modeli ile geliştirmişlerdir. Araştırmacılar tarafından Bayes-SqueezeNet temelli bir COVIDdiagnosis-Net modeli önerilmiştir. Yapılan deneysel çalışmalarla geliştirilen model ile, DenseNet ve ResNet-50 modellerinin karşılaştırılması sonucunda COVIDdiagnosis-Net modeli ile % 98.26 doğruluk oranı elde edilmiştir.

Apostolopoulos ve Mpesiana (2020) yapmış oldukları çalışmada, önceden tasarlanmış ve hazırlanmış derin öğrenme modelini kullanmışlardır. Çalışmada veri seti olarak 224 adet COVID-19, 504 adet sağlıklı ve 700 adet pnömoni görüntüsü kullanan araştırmacılar, VGG-19, MobileNet V2, Xception ve Inception modellerini karşılaştırmışlardır. Yapılan çalışma sonucunda en yüksek % 96.78 doğruluk oranını MobileNet V2 modeli ile elde etmişlerdir. Öztürk ve ark. (2020) ise, halka açık veri setlerinden elde ettikleri 127 adet COVID-19, 500 adet normal ve 500 adet viral pnömoni akciğer X-Ray görüntülerinden oluşan bir veri seti

oluşturmuşlardır. Araştırmacılar çalışmalarında ikili (COVID-19-Normal) ve üçlü (COVID-19-Normal-Viral Pnömoni) sınıflandırma çalışmaları gerçekleştirmişlerdir. Araştırmacılar tarafından gerçek zamanlı nesne algılama için, her katman seviyesinde farklı filtreleme ile 17 evrişim katmanından oluşan YOLO modeli tabanlı DarkCOVID-Net modeli geliştirilmiştir. Geliştirilen model ile ResNet, UNEt, ResNet-50 modelleri karşılaştırılarak DarkCOVID-Net modelinde ikili sınıflandırma için %98.08, üçlü sınıflandırma için ise %87.02 doğruluk elde etmişlerdir.

Khan ve ark. (2021) tarafından yapılan bir çalışmada; 3224 COVID-19 ve 3224 sağlıklı akciğer X-Ray görüntülerinden oluşturdukları veri seti ile güçlendirilmiş hibrit derin öğrenme (Deep Boosted Hybrid Learning/DBHL) adında bir model önermişlerdir. Önerilen model kapsamında akciğer görüntülerinin COVID-19 alanlarının kenar ve alan bazlı bağımsız sinir ağlarının eğitimi gerçekleştirilmiştir. Eğitim sonunda sondan bir önceki katmanda transfer öğrenme işlemi gerçekleştirilerek birleştirme yapılmıştır. Araştırmacılar önerdikleri model ile 9 farklı modeli kıyasladıklarında, % 98.53 doğruluk oranı ile DBHL modelinin daha başarılı olduğunu gözlemişlerdir. Albahli ve ark. (2021) ise, 6057 pnömoni, 590 COVID-19 ve 8851 sağlıklı akciğer X-Ray görüntüsünden oluşan bir veri seti oluşturmuşlardır. Araştırmacılar Google tarafından geliştirilen Büyük Transfer (Big Transfer /BiT) modelinde R152 x4, R101x3 ve R101x1 modelleri ile DenseNet modelini kıyaslamışlardır. Yapılan deneysel çalışmalar sonucunda DenseNet modeli ile %92 doğruluk oranı elde etmişlerdir.

Saha ve ark. (2021) halka açık, farklı kaynaklardan elde ettikleri görüntüleri birleştirerek 2300 adet COVID-19 ile 2300 adet normal akciğer X-ray görüntüsü ile birlikte toplamda 4600 görüntülük bir veri seti oluşturmuşlardır. COVID-19 hastalığının tespiti için evrişimsel sinir ağı tabanlı EMCNet isimli bir model öneren araştırmacılar, VGG-16 modelinin mimarisini basitleştirerek transfer öğrenme gerçekleştirmişlerdir. Çalışma kapsamında makine öğrenme sınıflandırıcılarından rastgele orman, karar ağacı, AdaBoost ve destek vektör makinesi kullanılmıştır. Yapılan deneysel çalışmalar sonucunda araştırmacılar tarafından önerilen EMCNet modeli ile COVID-19 sınıfı için en yüksek % 96.52 doğruluk oranı elde edilmiştir. Okolo ve ark. (2021) ise, 248 COVID-19, 1341 sağlıklı ve 1345 viral pnömoni akciğer X-Ray görüntüsünden oluşan bir veri seti oluşturmuşlardır. Üç farklı sınıflandırma için yapılan çalışma kapsamında, 11 farklı derin sinir ağı mimarisinin karşılaştırılması sonucunda, en yüksek %92.22 doğruluk oranını VGG-16 modelinde elde etmişlerdir. Çalışma sonucunda oluşturulan karşıtlık matrisi incelendiğinde, 234 görüntü

COVID-19 olarak doğru tespit edilmiştir.

Singh ve ark. (2021) halka açık veri kaynaklarından elde edilen 6041 adet viral pnömoni, 573 adet COVID-19 ve 8851 adet sağlıklı akciğer X-Ray görüntüsünden oluşan bir veri seti hazırlamışlardır. Çalışmada, görüntülere histogram eşitleme ile Gauss bulanıklığı ön işlemleri uygulanmıştır. Üç farklı sınıflandırma için, DenseNet-169, DenseNet-121, ResNet-50 ve VGG-19 modelleri karşılaştırılmıştır. Yapılan karşılaştırma sonucunda, segmentasyon ve ön işlemler uygulanmış görüntülerden VGG-19 modelinden en yüksek % 94.67 başarı oranını elde etmişlerdir. Gupta ve ark. (2021) ise, 1341 adet sağlıklı, 1345 adet viral pnömoni ve 361 adet COVID-19 akciğer X-Ray görüntüsünden oluşan bir veri seti oluşturmuşlardır. Çalışma kapsamında COVID-19 hastalarını tespit etmek için ResNet-101, MobileNet, NASNet, Xception ve Inception V3 modellerini kullanarak InstaCovNet-19 isimli bir model önermişlerdir. Model ile yapılan deneysel çalışmalar sonucunda üçlü sınıflandırma için % 99.08 doğruluk oranı elde etmişlerdir.

Song ve ark. (2021) 88 adet COVID-19, 101 viral pnömoni ve 86 sağlıklı akciğer bilgisayar tömografi görüntülerinden oluşan bir veri seti oluşturmuşlardır. Hastalığı tespit etmek amacıyla ResNet, DenseNet, VGG-16 ve DRE-Net modellerini kıyaslamışlardır. Yapılan çalışmalar sonucunda araştırmacılar, DRE-Net modeli ile en yüksek % 95 oranında doğruluk elde etmişlerdir. Bozkurt ve Yağanoğlu (2021) ise, halka açık veri setlerinden oluşan 1200 adet COVID-19, 1345 adet Viral Pnömoni ve 1341 adet normal görüntüden oluşan bir veri seti oluşturmuşlardır. Elde edilen veri setinin %70'i eğitim, % 10'u doğrulama ve % 20'si ise eğitim için ayrılmıştır. Derin evrişimli sinir ağları (Derin ESA) modelinin önerildiği çalışmanın deneysel çalışmalarında önerilen model, VGG-19, ResNet-50 ve InceptionV3 modelleri ile kıyaslanmıştır. Deneysel çalışmalar sonucunda önerilen Derin ESA modeli ile en yüksek % 96 doğruluk oranı elde edilmiştir.

Ismael ve Şengür (2021) tarafından yapılan bir çalışmada; 2 sınıflandırma için 80 adet COVID-19 ve 200 adet sağlıklı akciğer X-Ray görüntüsünden bir veri seti oluşturmuşlardır. Önceden eğitilmiş evrişimsel sinir ağı modellerinden VGG-16, ResNet-18, VGG-19, ResNet-101 ve ResNet-50 modellerini kullanan araştırmacılar, destek vektör makinesinin bazı çekirdek fonksiyonlarını özellik çıkarmada kullanmışlardır. Yapılan deneysel çalışmalar sonucunda, ResNet-50 modeli ile en yüksek % 94.7 doğruluk oranı elde etmişlerdir. Bhattacharyya ve ark. (2022) ise, iki farklı veri setinden 342 COVID-19, 1583 normal ve 4273 viral pnömoni akciğer X-Ray görüntülerinden bir veri seti oluşturmuşlardır.

Araştırmacılar Koşullu Çekişmeli Üretici Ağlar (Conditional Generative Adversarial Networks/cGAN) tabanlı oluşturdukları model ile akciğerlerin maskelenmesini sağlamışlardır. Yapılan ön işlemlerin ardından VGG-16, VGG-19, sCNN, DenseNet-169 ve DenseNet-201 modelleri üzerinde eğitimler gerçekleştirilerek, model sonuçlarını kıyaslamışlardır. Modellerin sonuçları karşılaştırıldığında % 96.6 oranı ile VGG-19 modelinde en yüksek başarı oranını elde etmişlerdir.

Loey ve ark. (2022) halka açık, farklı veri setlerinin birleştirilmesi ile oluşturdukları 3616 adet COVID-19, 3616 adet viral pnömoni ve 3616 adet sağlıklı akciğer X-Ray görüntülerinden oluşan bir veri setini kullanmışlardır. Model özniteliklerini çıkarmak ve sınıflandırmak için CNN kullanan araştırmacılar, model küçültme için Bayes makine öğrenme sınıflandırıcısını kullanmışlardır. Çalışmaları kapsamında üç farklı senaryo üzerinde çalışan araştırmacılar, Bayes optimizasyonuna dayalı evrişimli sinir ağı modeli ile en yüksek % 96 başarı oranı elde etmişlerdir.

COVID-19 hastalığının tespit edilmesi amacıyla yapılan çalışmalar incelendiğinde bazı çalışmalarda kullanılan veri setlerinde COVID-19 görüntü sayılarının az olduğu ve sınıf sayılarındaki dağılımının birbirine yakın olmadığı görülmektedir. Sınırlı sayıda verinin olması veya sınıflandırmalar arasında veri sayılarındaki uyumsuzluklar derin öğrenme çalışmalarında performansın düşmesine ve başarı oranının gerçeklikten uzaklaşmasına sebep olmaktadır (Islam, Karray, Alhajj ve Zeng, 2021). Ayrıca yapılan çalışmalar incelendiğinde veri setindeki görüntülerde görüntü düzleştirme ve segmentasyon işlemlerinin yapılmadığı görülmektedir. Görüntü üzerinde var olan gürültülerin giderilmesi sonucunda görüntünün eğitim değerleri yüksek görülse de, doğruluk değerinde düşmeler meydana gelmektedir. Bu durum görüntülerdeki etiketleme durumunun hatalı olması sonucunu vermektedir (Saravanan, Heshma, Shanofer ve Vanithamani, 2020). Görüntü üzerinde oluşan gürültülerin giderilmesi için toplam görüntü yoğunluk seviyesi yerine, görüntünün bölgesel pikselleri üzerinde belirlenmiş bir yoğunluk seviyesine göre ayarlamak gerekmektedir. Görüntü üzerinde parazit ve gürültüleri yok etmek yoğunluk seviye artışını sınırlandırdığı için sınıflandırma üzerinde daha doğru sonuçlar elde edilmektedir (Alwazzan, Ismael, ve Ahmed, 2021).

Tablo 1.8. COVID-19 Teşhisi Üzerine Yapılmış Bazı Çalışmalar

Yazar/lar - Yıl	Veri Seti	Sınıf Sayısı	Uygulanan / Önerilen Model	Başarı Oranı (En Yüksek)	Başarı Oranı En Yüksek Model
Minaee, Kafieh, Sonka, Yazdani ve Soufi (2020)	5000 X-Ray görüntüsü 71 COVID-19 görüntüsü	2	ResNet-50, DenseNet-121, SqueezeNet ResNet-18	% 90	SqueezeNet
Toğaçar, Ergen ve Cömert (2020)	295 adet COVID-19, 65 adet normal ve 98 adet viral pnömoni X-Ray görüntüsü	3	SqueezeNet MobileNetV2	% 99.27	MobileNetV2
Zheng vd. (2020)	630 Bilgisayarlı tomografi görüntüsü	2	DeCoVNet	% 90.1	DeCoVNet
Narin, Kaya ve Pamuk (2020)	2772 bakteriyel pnömoni, 341 COVID-19, 2800 sağlıklı ve 1493 viral pnömoni X-Ray görüntüsü	4	ResNet-50, ResNet-101, Inception V3, ResNet 152 Inception-ResNet V2	% 98	ResNet-50
Maghdid vd. (2020)	170 X-Ray görüntüsü 361 bilgisayarlı tomografi	2	AlexNet	X-Ray : % 98 BT : % 82	AlexNet
			CNN	X-Ray : % 94 BT : % 94	CNN
Hemdan, Shouman ve Karar (2020)	25 COVID-19 ve 50 sağlıklı akciğer X-Ray görüntüsü	2	VGG19 DenseNet201 ResNetV2 InceptionV3 InceptionResNetV2 Xception MobileNetV2	% 91	VGG-19
Ucar ve Korkmaz (2020)	45 adet COVID-19, 1203 adet normal ve 1591 adet viral pnömoni akciğer X-Ray görüntüsü	3	COVIDdiagnosis-Net DenseNet ResNet-50	% 98.26	COVIDdiagnosis-Net
Apostolopoulos ve Mpesiana (2020)	224 COVID-19, 504 sağlıklı ve 700 pnömoni görüntüsü	3	VGG-19, MobileNet V2 Xception Inception	% 96.78	MobileNet V2

Tablo 1.8. (Devamı) COVID-19 Teşhisi Üzerine Yapılmış Bazı Çalışmalar

Yazar/lar - Yıl	Veri Seti	Sınıf Sayısı	Uygulanan / Önerilen Model	Başarı Oranı (En Yüksek)	Başarı Oranı En Yüksek Model
Öztürk vd. (2020)	127 adet COVID-19, 500 adet normal ve 500 adet viral pnömoni akciğer X-Ray görüntüsü	3	DarkCOVID-Net ResNet UNEt ResNet-50	% 87.02	DarkCOVID-Net
Khan vd. (2021)	3224 COVID-19 ve 3224 sağlıklı akciğer X-Ray görüntüsü	2	DBHL (Güçlendirilmiş Hibrit Derin Öğrenme Modeli)	% 98.53	DBHL
Albahli , Ayub ve Shiraz (2021)	6057 pnömoni, 590 COVID-19 ve 8851 sağlıklı akciğer X-Ray görüntüsü	3	R152 x4 R101x3 R101x1 DenseNet	% 92	DenseNet
Saha, Sadi ve Islam (2021)	2300 COVID-19 ile 2300 normal akciğer X-ray görüntüsü	2	EMCNet	% 96.52	EMCNet
Okolo, Katsigiannis, Althobaiti, ve Ramzan (2021)	248 COVID-19, 1341 sağlıklı ve 1345 viral pnömoni akciğer X-Ray görüntüsü	3	VGG-16	% 92.22	VGG-16
Singh, Rohan, ve Rishie (2021)	6041 viral pnömoni, 573 COVID-19 ve 8851 sağlıklı akciğer X-Ray görüntüsü	3	DenseNet-169 DenseNet-121 ResNet-50 VGG-19	% 94.67	VGG-19
Gupta, Gupta, ve Katarya (2021)	1341 sağlıklı, 1345 viral pnömoni ve 361 COVID-19 akciğer X-Ray görüntüsü	3	InstaCovNet-19	% 99.08	InstaCovNet-19
Song vd. (2021)	88 COVID-19, 101 viral pnömoni ve 86 sağlıklı akciğer bilgisayar tömografi görüntüsü	3	ResNet DenseNet VGG-16 DRE-Net	% 95	DRE-Net

Tablo 1.8. (Devamı) COVID-19 Teşhisi Üzerine Yapılmış Bazı Çalışmalar

Yazar/lar - Yıl	Veri Seti	Sınıf Sayısı	Uygulanan / Önerilen Model	Başarı Oranı (En Yüksek)	Başarı Oranı En Yüksek Model
Bozkurt ve Yağanoğlu (2021)	1200 adet COVID-19, 1345 adet Viral Pnömoni ve 1341 adet akciğer X-Ray görüntüsü	3	Derin ESA VGG-19, ResNet-50 InceptionV3	% 96	Derin ESA
Ismael ve Şengür (2021)	80 COVID-19 ve 200 sağlıklı akciğer X-Ray görüntüsü	2	ResNet-18 ResNet-50 ResNet-101 VGG-16 VGG-19	% 94.7	ResNet-50
Bhattacharyya (2022)	342 COVID-19, 1583 normal ve 4273 viral pnömoni akciğer X-Ray görüntüsü	3	VGG-16 VGG-19 sCNN DenseNet-169 DenseNet-201	% 96.6	VGG-19
Loey , Sappagh ve Mirjalili (2022)	3616 COVID-19, 3616 viral pnömoni ve 3616 sağlıklı akciğer X-Ray görüntüsü	3	Bayes + CNN	% 96	Bayes + CNN

İKİNCİ BÖLÜM

MATERYAL VE YÖNTEM

Bu bölümde COVID-19 hastalığının tespiti için kullanılan veri seti, derin öğrenme ve derin öğrenme parametreleri ile, sınıflandırma işleminin daha başarılı olabilmesi amacıyla X-Ray görüntüleri üzerinde uygulanan ön işlem basamakları ve kullanılan derin öğrenme kütüphaneleri açıklanmıştır.

2.1. Veri Seti

Bu çalışmada popüler ve halka açık veritabanı olan Kaggle'ın COVID-19 radyografi veri alanından elde edilen X-Ray görüntüleri kullanılmıştır (Chowdhury vd., 2020). Veri setinde yer alan COVID-19 görüntüleri, Katar Üniversitesi, Dakka Üniversitesi ve Bangladeş'ten katılan bir grup araştırmacı ile Pakistan ve Malezya'da görev yapan bazı radyoloji doktorları tarafından yayınlanmıştır. Veri setinde COVID-19, Viral Pnömoni ve sağlıklı insanlara ait üç sınıfa ayrılmış akciğer X-Ray görüntüleri bulunmaktadır. Veri setinin yayıncılar tarafından sürekli olarak güncellenmesi, bu veri setinin araştırmacılar tarafından tercih edilmesine neden olmaktadır.

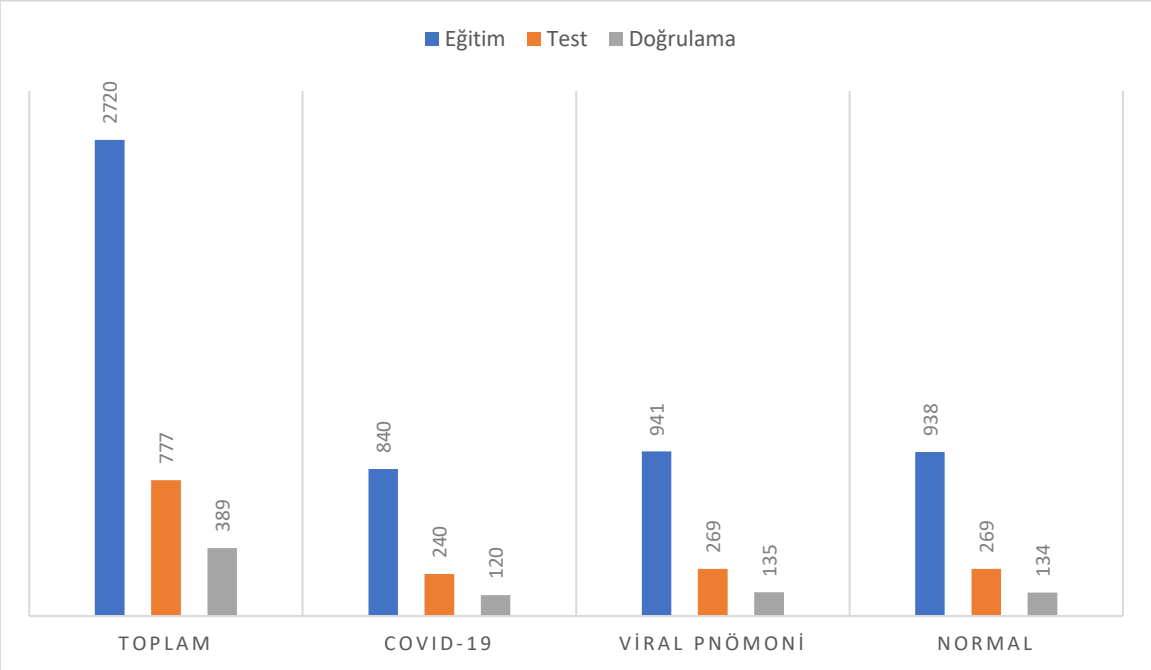
Veri setinde 1200 adet COVID-19, 1341 adet Normal (Sağlıklı) ve 1345 adet Viral Pnömoni sınıflandırmalarına ait toplam 3886 X-Ray görüntüsü yer almaktadır. Elde edilen veri setinden COVID-19, Viral Pnömoni ile Normal sınıfta yer alan görüntü sınıflandırma örnekleri Şekil 2.1'de gösterilmektedir.



COVID-19 Viral Pnömoni Normal

Şekil 2.1. Veri Setinde Yer Alan Sınıflandırılmış X-Ray Görüntülerine Ait Örnekler

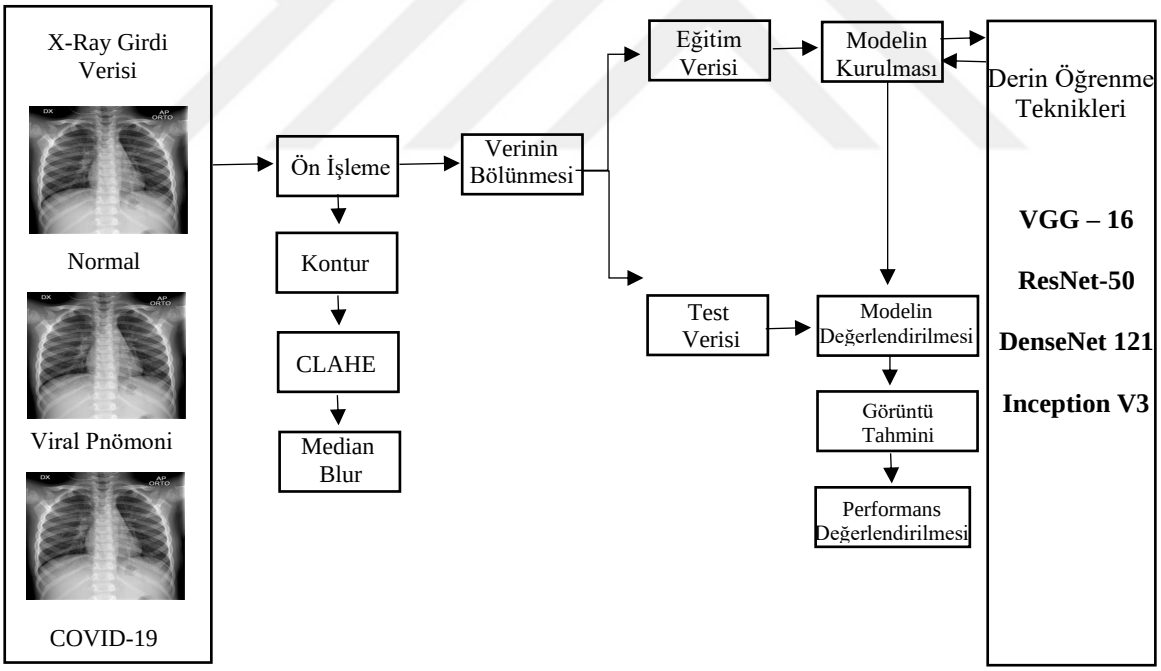
Bu çalışmaya ait X-Ray veri setinin %70'i (2720 Görüntü) eğitim, %20'si (777 Görüntü) test ve %10'u (389 Görüntü) ise doğrulama için kullanılmıştır. Veri seti üzerinde yapılan sınıflandırmaya dair grafik Şekil 2.2'de gösterilmiştir.



Şekil 2.2. Çalışmaya Ait X-Ray Veri Setinin Sınıfsal Dağılımı

2.2. Yöntem

Bu çalışmada derin öğrenme yöntemleri kullanılarak COVID-19 hastalığının tespit edilmesine yönelik sınıflandırma doğruluğunu arttırıcı yöntemler önerilmiştir. Önerilen yöntem bağlamında veri setinde yer alan X-Ray görüntüleri üzerinde akciğer sağ ve sol lobları threshold yöntemi ile tümleşik olarak görüntüden arındırılmıştır. Kırpılan görüntüler veri setinin orijinal 299x299 piksel boyutuna yeniden ölçeklendirilmiştir. Kesilen görüntüler üzerinde gürültülerin giderilmesi amacıyla segmentasyon işlemleri uygulanmıştır. Son olarak görüntüler üzerinde piksel yoğunluk seviyesini ayarlamak için Kontrast Limitli Adaptif Histogram Eşitleme (Contrast Limited Adaptive Histogram Equazation/CLAHE) yöntemi kullanılarak sınıflandırma işlemine hazır hale getirilmiştir. Sınıflandırma işlemi için transfer öğrenme yaklaşımı ile popüler CNN mimarileri kullanılarak veri seti yeniden eğitilmiştir. COVID-19 hastalığının tespiti için farklı derin öğrenme modellerinin karşılaştırılmasına yönelik kurulan mimari Şekil 2.3'te belirtilmiştir.



Şekil 2.3. COVID-19 Tespitinde Farklı Modellerin Karşılaştırılmasına Yönelik Kurulan Mimari

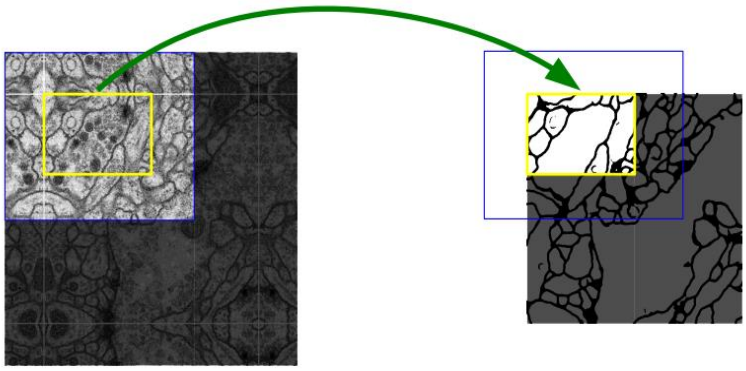
2.2.1. Ön İşlemler

Görüntüler üzerinde yapılacak olan farklı ön işleme yöntemleri, giriş görüntüleri üzerinde kalitenin artmasını sağlayarak, eğitim sürecinin optimizasyonunu sağlamaktadır. Bu çalışmada giriş veri seti üzerinde yapılan ön işlemler detaylı bir şekilde incelenmiştir.

2.2.1.1. Segmentasyon

Görüntü içerisinde bulunan uygun bölümlerin tümden çıkarılma işlemine segmentasyon denir (Salido ve Ruiz, 2018). Görüntü bölütleme adıyla da bilinen segmentasyon işlemi, derin öğrenme ve sınıflandırma işlemlerinde önemli bir yere sahiptir. Sınıflandırma işleminin başarı olabilmesi için giriş görüntüleri üzerinde yer alan gürültülü kısımların temizlenmesi gerekmektedir. Görüntü üzerinde gürültü işlemlerini gidermek için genellikle Gauss, Median ve Mean filtreleme yöntemleri aktif olarak kullanılmaktadır (Saravanan vd., 2020). Uyarlamalı eşikleme için birçok algoritma bulunmaktadır. Çalışmada segmentasyon işlemlerinde, görüntüyü bir hücre ızgarasına bölerek ayrı bir görüntü gibi işlem yaparak hücreye basit bir eşikleme yöntemi kullanan otsu eşikleme yöntemi tercih edilmiştir.

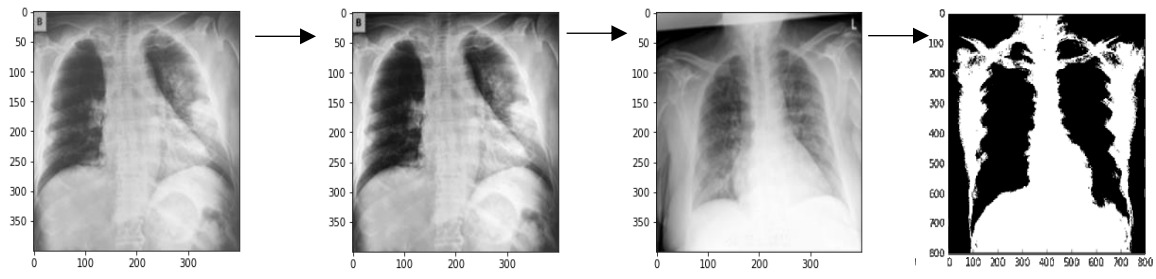
Otsu Eşikleme Yöntemi; görüntüler üzerinde otomatik eşikleme yapılmasını sağlamaktadır. Sınıflar arası varyans değerinin maksimum seviyede olabilmesi için sınıf içi varyans değerinin minimum seviyede olması gerekmektedir. Arka plan ve piksel sınıfları için sınıflar arası varyansın hesaplanmasında maksimum değerlerin ortaya çıkarılması gerekmektedir (Elen, 2020). Bu çalışmada görüntüde var olan eşik değerinin tespiti için bölge ile arka plan arasındaki maksimum sınıf varyansı kullanılmıştır. Gri seviyesindeki görüntülere OpenCV kütüphanesinde bulunan GaussianBlur fonksiyonu ile gürültü giderme işlemi uygulanmıştır. Gaussian Blur fonksiyonunda büyük şablonun tek bir taramada etkisi olması amacıyla 7x7 filtre tercih edilmiştir. Bu işlemlerin ardından otsu eşikleme yöntemi ile girdi görüntülerinin maskeleri çıkarılmıştır. Şekil 2.4'te görüntü üzerinde yapılan segmentasyon işlemi belirtilmiştir.



Şekil 2.4. Görüntü Üzerinde Uygulanan Segmentasyon İşlemi

2.2.1.2. Görüntü Kırpma

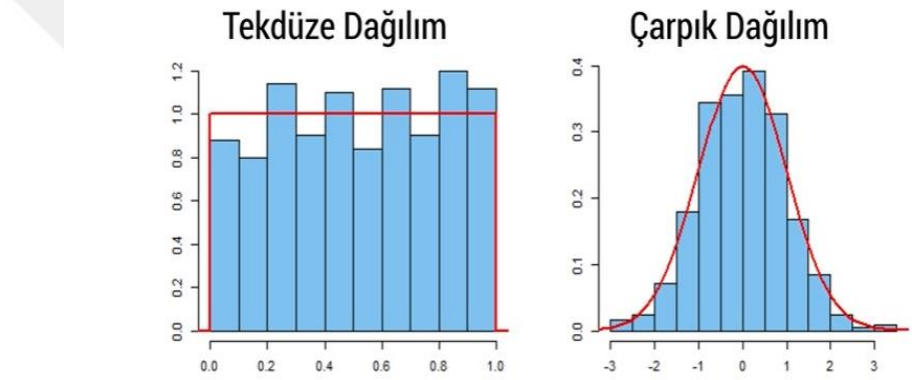
Çalışmada, veri setinde yer alan görüntüler üzerinde segmentasyon işleminden elde edilen görüntüler kullanılarak, ilgili bölümün kırpma işlemi gerçekleştirilmiştir. Bu işlem sınıflandırma modelinin X-Ray görüntüsünde bulunan ayırıcı özelliklerin elde edilmesini zorlaştıran görüntülerin atılmasını sağlamaktadır. Görüntü kırpma (Threshold) işlemi için segmentasyon maskeleri üzerinde görüntülerin kontur noktaları bulunmuştur. Bu noktalar ile görüntünün maske görünümünden hastalığın tespit edileceği akciğer sağ ve sol loblarını temsil eden x-y koordinatlarını veren matris elde edilmiştir. Elde edilen ikili dizi şeklindeki matrislerden maksimum x ve y koordinatlarını veren noktalar tespit edilerek asıl görüntüden çıkarılmıştır. Kırpılan görüntüler 299x299 boyutuna yeniden ölçeklendirilmiştir. Veri seti üzerinde uygulanan segmentasyon ve kırpma işlemi adımları Şekil 2.5'te belirtilmiştir.



Şekil 2.5. Segmentasyon ve Kırpma İşlemi

2.2.1.3. Kontrast Limitli Adaptif Histogram Eşitleme

Histogram eşitleme işlemi, görüntünün yoğunluğunu ayarlamak için kullanılan bir görüntü işleme tekniğidir. Histogram eşitleme tekniği ile, görüntü üzerinde kontrast iyileştirmesi yapılabilmektedir. Veri setinde Viral Pnömoni ve COVID-19 tespitlerinde akciğer üzerinde buzlu görüntülerin olduğu bölümlerde kontrast seviyesinin artması sınıflandırma açısından önem taşımaktadır. Bu yüzden histogram eşitleme tekniği çalışmanın sonuçları için önemlidir. Görüntüler üzerindeki pikseller düzgün dağılım göstermediği zaman, yani belirli bir değer aralığında tepe yapmış ise histogram eşitleme, görüntüyü iyileştirmesinin aksine bozmaktadır. Histogram eşitlemeye yönelik dağılım Şekil 2.6'da belirtilmiştir.



Şekil 2.6. Tekdüze ve Çarpık Dağılım Grafiği

Histogram eşitlemede, bir noktada piksellerin yoğunluğundan dolayı görüntünün bozulma ihtimalinin önüne geçmek için görüntüyü küçük parçalara ayırarak yapılan adaptif histogram eşitleme tekniği kullanılmaktadır. Adaptif histogram eşitleme yönteminde ise, görüntünün bazı bölgelerinde kontrast aşırıya kaçacağı için görüntüde kumlanma meydana gelmektedir (Jafar ve Ying, 2007). Kumlanma problemi, modelin başarısını düşürecektir. Şekil 2.7'de adaptif histogram eşitleme yönteminde oluşan kumlanma problemine bir örnek verilmiştir (Zhang, Tang, Fang, Shang ve Liu, 2009).



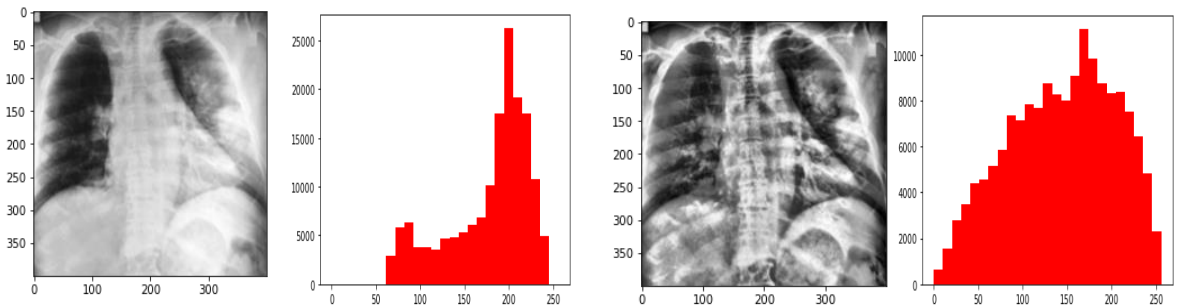
Kumlu Görüntü Normal Görüntü

Şekil 2.7. Aşırı Kontrast Sonucu Oluşan Kumlanma

Adaptif histogram eşitlemede oluşan kumlanma problemini kontrast seviyesine limit getirerek önlemek mümkündür. Bu yüzden çalışmada kontrast limitli adaptif histogram eşitleme (CLAHE) kullanılmıştır. Piksel yoğunluğunu yeniden düzenleme ve gürültü azaltma amaçlı CLAHE tekniği tıbbi görüntülerde sıkça kullanılmaktadır (Li, Wang ve Yu, 1994).

Bu çalışmada giriş görüntüleri üzerinde uygulanan histogram eşitlemenin adaptif bölümü için, piksellerin etrafındaki piksel derecelerine orantılı bir şekilde yoğunlaşma sağlamak amacıyla 8x8 filtre kullanılmıştır. Yapılan deneyler sonucunda uygulanan CLAHE adımında kontrast limiti olarak 7 tercih edilerek OpenCV kütüphanesinde gerekli düzenleme yapılmıştır.

clahe = cv2.createCLAHE(clipLimit=7.0,tileGridSize=((8,8)))



(a) (b) (c) (d)

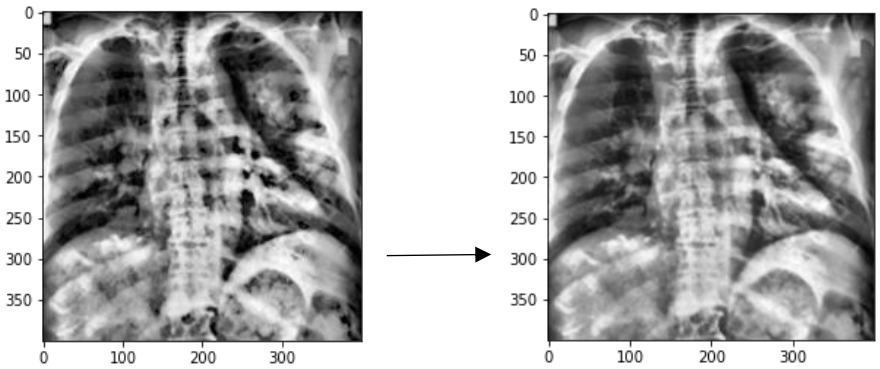
Şekil 2.8. CLAHE Uygulanmış Görüntü ve Kontrast Seviyesi

Şekil 2.8’de görüldüğü üzere ((a) CLAHE Uygulanmamış COVID-19 görüntüsü, (b) CLAHE uygulanmadan histogram grafiği, (c) CLAHE uygulanan COVID-19 görüntüsü, (d) CLAHE uygulanan histogram grafiği) giriş ham görüntüsü üzerinde histogram grafiği incelendiğinde görüntünün değerleri, yoğun olarak 150-250 arasında yoğunlaşmış durumdadır (b). 90’dan sonraki kontrast değerlerinde fark çok yoğun olduğu için bu görüntüye CLAHE tercih edilmiştir (d). Giriş görüntüsü üzerinde CLAHE uygulanmasının sonucunda kontrast seviyelerinin düzgün bir şekilde dağılım gösterdiği görülmüştür.

2.2.1.4. Medyan Filtresi

Görüntüler üzerinde gürültü oranlarının 0.2’den az olduğu durumlarda çok etkili olan bir görüntü filtresidir. Genellikle CLAHE uygulamaları sonrasında ortaya çıkan 0.01-0.12 gürültü oranlarının azaltılması için bu uygulamada tercih edilmiştir. Ayrıca medyan filtreleme tekniği görüntüdeki gürültü oranlarını azaltırken görüntüde var olan detayların kaybolmamasını sağlar (Xie ve Lam, 2005).

Medyan filtresi (Median Blur) 3*3 ’lük filtre parametreleri ile görüntü üzerinde tarama yaparken görüntü üzerindeki piksellerin medyan değerini alıp, bu değeri filtredeki merkez noktaya eşitlemektedir. Bu şekilde piksel değerlerin ortak değerine ulaştırması ile görüntüdeki ince kumlanma değerleri temizlenmiş olmaktadır. Şekil 2.9’da CLAHE uygulanan COVID-19 görüntüsüne gerçekleştirilen medyan filtreleme işlemi belirtilmiştir.



CLAHE Uygulanan X-Ray Görüntüsü

Medyan Filtresi Uygulanan X-Ray Görüntüsü

Şekil 2.9. Medyan Filtresi Uygulanarak Görüntüde İyileştirme

2.3. Makine Öğrenmesi

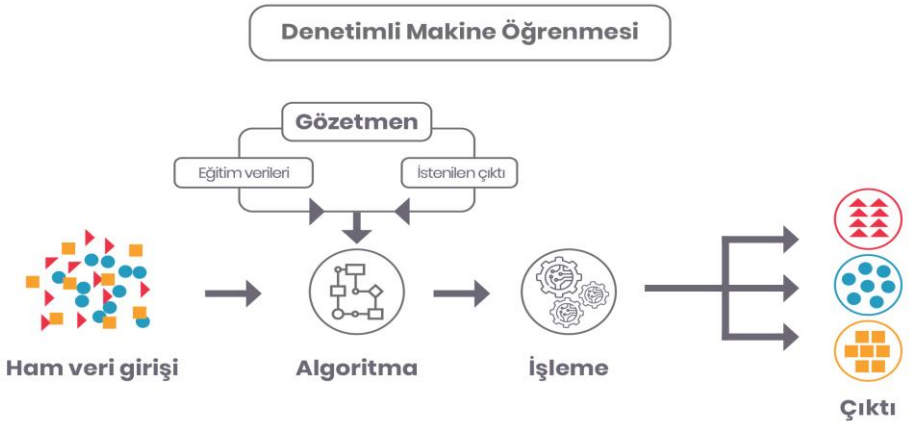
Belirli bir problemin, bu probleme özgü veri ile modellenmesini sağlayan algoritmaların oluşturulmasının genel adına makine öğrenmesi denir. Hazırlanan veri seti ve uygun algoritmayla tasarlanan model, doğruluk oranı en yüksek olacak şekilde kurgulanmaktadır (Atalay ve Çelik, 2017).

Veri girdilerinin eğitime tabi tutularak bir model oluşturulması, oluşturulan model üzerinde analiz ve çıkarımlar yaparak, yeni verilerin sonuçlarının tahmin edilmesi makine öğrenmesinin temel taşını oluşturmaktadır. Öngörülebilir örüntü veya anlamlı verileri ortaya çıkarabilmek için eldeki tüm verilerin analiz edilmesi gerekmektedir. Bundan sonrasında istatistiksel analiz kullanılarak geçmiş verilere göre çıkarım yapma yeteneğine sahip yeni verilere karşı tahminler yapmak için bir model oluşturulur (Yaraş, 2020). Oluşturulan model kapsamı, çeşitli parametreler ile test edilerek başarı ve hata oranları tespit edilip, modele eklenen her yeni veri ile başarı oranının yükseltilmesi hedeflenir. Öğrenme türlerine göre makine öğrenmesi üçe ayrılır (Varghese ve Sharma, 2018). Bunlar:

- Denetimli öğrenme
- Denetimsiz öğrenme
- Pekiştirerek öğrenme

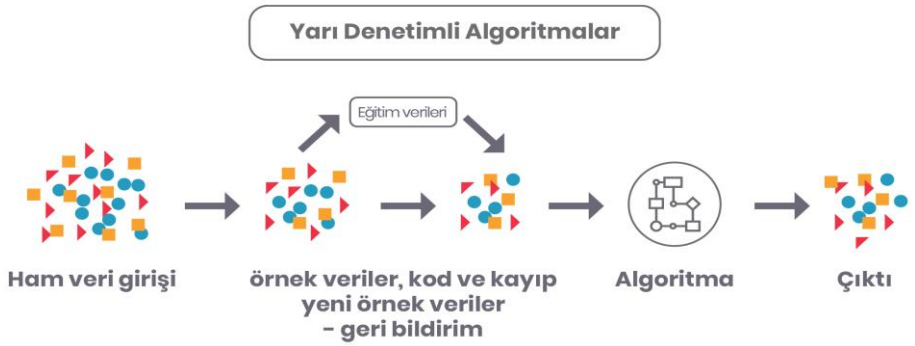
2.3.1. Denetimli Öğrenme

Gözetimli öğrenme adıyla da bilinen denetimli öğrenme, bilinen ve etiket sahibi verilerin girdi ve çıktı fonksiyonlarının birbirine eşlenmesine denir. Öğrenme için uygun model oluşturulduktan sonra, eğitim verilerinden model eğitime tabi tutulur. Girdi ve çıktı verileri arasında mantıklı bir ilişki kurularak, değişkenler üzerinde bir tahminde bulunulması istenir. Şekil 2.10'da öğrenme süreçleri verilen denetimli öğrenme, sıklıkla kullanılan bir makine öğrenmesi türüdür ve problemlerin çıktısına bağlı olarak regresyon (regression) ve sınıflandırma (classification) problemleri şeklinde gruplandırılır (Phelan vd., 2020).



Şekil 2.10. Denetimli Öğrenme Süreci

Yarı denetimli öğrenme türü ise denetimli ve denetimsiz öğrenme özelliklerinin birleştirildiği makine öğrenmesi türüdür. Eğitimde etiketlenmemiş verilerin kullanımını sağlayan denetlenen öğrenme şeklidir. Bu öğrenme türünde genelde etiketlenmemiş veri sayısı, etiketli veriden çok daha fazladır. Etiketlenmemiş verilerin, küçük miktarda etiketlenmiş veriler ile birlikte kullanıldığında öğrenme doğruluğunda önemli ölçüde iyileşme sağlayabildiği gözlemlenmiştir (Kaelbling, Littman ve Moore, 1996). Şekil 2.11' de belirtildiği üzere, küçük bir veri setinde eğitilen sınıflandırıcı, etiketleme işlemi yapılmamış bir veri setinde sınıflandırmaya tabi tutularak eğitim setine eklenmektedir. Bu işlem ile birlikte eğitim sürecine devam edilir.

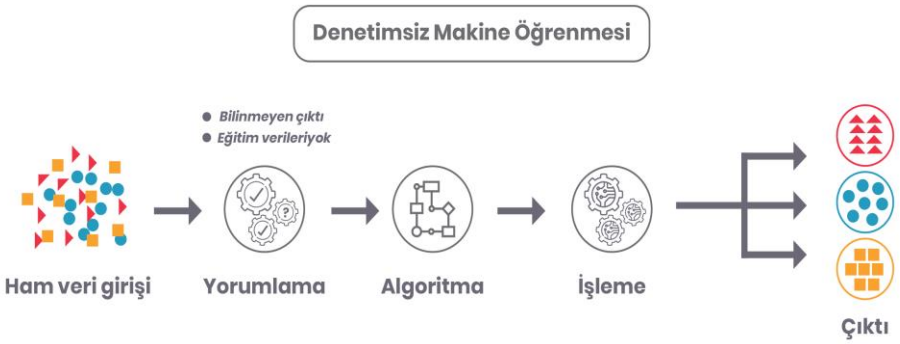


Şekil 2.11. Yarı Denetimli Öğrenme Süreci

2.3.2. Denetimsiz Öğrenme

Gözetimsiz öğrenme adıyla da bilinen denetimsiz öğrenmede, sadece girdi verileri kullanılmaktadır. Geliştirilen modelin, girdi verilerine göre öğrenme işlemini yapması,

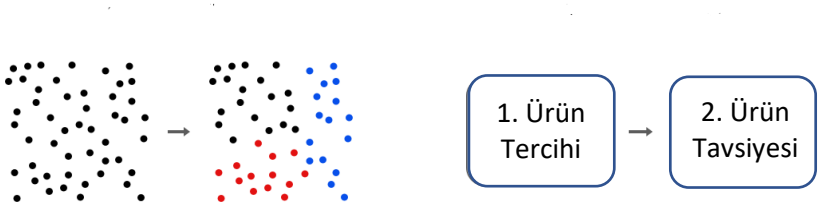
algoritmanın çıktı verilerini keşfetmesi hedeflenir. Şekil 2.12' de öğrenme süreci belirtilen denetimsiz öğrenme türünde temel amaç, girdi verileri hakkında bilgi edinip, temel yapıya ait verilerin doğru dağılımını sağlamaktır (Goodfellow, Bengio ve Courville, 2017).



Şekil 2.12. Denetimsiz Öğrenme Süreci

Denetimsiz öğrenme, veriler hakkında bolca bilgi toplayıp, bu verileri modellemekte oldukça başarılı bir makine öğrenmesi türüdür. Denetimsiz öğrenme iki gruba ayrılmaktadır (Şekil 2.13). Bunlar (Goodfellow vd., 2017):

- Kümeleme: Girdiler arasında mantıksal gruplamayı yapabilen algoritma türlerinden oluşmaktadır. Verilerin dağılımları göz önünde bulundurularak gruplamalarının yapılabildiği denetimsiz öğrenme modelidir. Bu çalışmada yer alan COVID-19 X-Ray görüntülerindeki buzlu cam görünümleri kümeleme yöntemi ile ayrıştırılmıştır.
- Birliktelik Kuralı: Bir ürünü tercih eden kişilerin, aynı özelliklere yakın veya ilişkili başka bir ürünü de tercih edebilecekleri gibi ilişkisel mantık kurabilen algoritma türüdür. Pazarlama yöntemlerinde sıkça kullanılmaktadır.

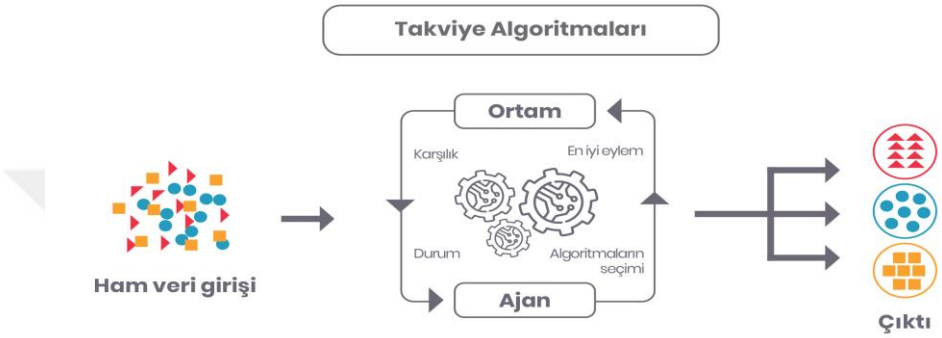


Kümeleme Birliktelik Kuralı

Şekil 2.13. Denetimsiz Öğrenme Gruplama Yöntemleri

2.3.3. Pekiştirmeli Öğrenme

Giriş yaptığı ortamı algılayan pekiştirmeli öğrenme, bulunduğu ortamda kendi başına kararlar alabilen bir sistemin, amacını gerçekleştirmek için doğru kararlar alabilmeyi nasıl öğreneceğini gösterir (Hacıbeyoğlu, 2006). Kuralları belirleyerek, olasılıkları deneme-yanılma yöntemi ile ortaya çıkarmaya çalışan algoritma türüdür. Şekil 2.14'te pekiştirmeli öğrenme süreci belirtilmiştir.



Şekil 2.14. Pekiştirmeli Öğrenme Süreci

Uygulandıkları veriye ait özellik seçimine bağlı olan makine öğrenmesi yönteminde çabanın büyük bir bölümü algoritmaları tasarlama konusundaki verilerin ön işleme tabi tutulmuş bir gösterimini hazırlamak için harcanır. Makine öğrenmesinin kapsamını ve işlevselliğini arttırmak için, öğrenme algoritmalarını özellik ayırımına bağımlı hale getirmemek gerekmektedir. Derin öğrenme algoritması, verilerin daha soyut yönlerini temsil eden daha üst düzey özellikler ile yani özellik çıkarımı olmadan, birden çok temsil düzeyini keşfeden belirli bir temsil öğrenme prosedürüdür (Zhao, Zheng, Xu ve Wu, 2019). Veri setinin genişlemesi ile birlikte klasik makine öğrenmesi yöntemlerindeki başarı oranı gittikçe azaldığı için, büyük verilerin derin öğrenme modelleri ile çalışılması başarı oranını arttırmaktadır (Talbi, 2020).

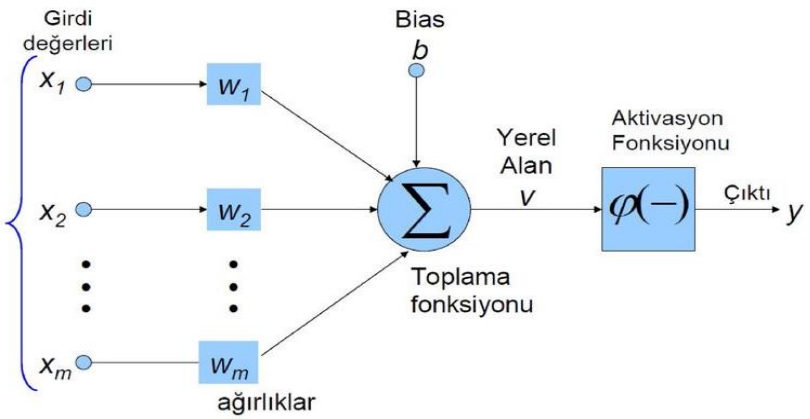
2.4. Derin Öğrenme

Verinin temsil şeklini öğrenmek amacıyla çoklu soyutlama yapısını bir araya getirilmesiyle çoklu işleme katmanlarından oluşan yapıya derin öğrenme adı verilir (LeCun, Bengio ve Hinton, 2015). Derin öğrenme, özellik çıkarma, algılama ve yeni öğrenimler üzerine

geliştirilen makine öğrenmesi alt alanıdır. Ardışık birden fazla katmanın kullanıldığı derin öğrenme tekniğinde, her katman bir önceki katmanda oluşturulan çıktıyı girdi olarak almaktadır (Gibson ve Patterson, 2017).

Çoklu soyutlama seviyelerinde yer alan verilerin öğrenilmesi için işleme katmanından oluşan modellere derin öğrenme izin vermektedir. Derin öğrenme, geri yayılım algoritmalarını kullanarak, karmaşık veri yapısını keşfetmek için dahili parametrelerin nasıl kullanılması gerektiğini göstermektedir (Ngiam vd., 2011). Geliştirilen derin öğrenme algoritmaları sayesinde, görüntü içerisinde yer alan nesnelerin tespit edilmesinin yanı sıra, tespit edilen nesneler arasındaki ilişkilerde analiz edilebilmektedir. Görüntülerden otomatik özellik çıkarma ve sınıflandırma işlemi üzerinde çalışan makine öğrenmesinin bir kombinasyonu olan derin öğrenme, geniş bir uygulama alanı ile nesne algılama veya tıbbi görüntü sınıflandırmada son yıllarda popüler olarak tercih edilmektedir (Goodfellow vd., 2017).

Görüntü sınıflandırma, dil öğrenme, video analizi ve konuşma tanısı süreçlerinde derin öğrenme çalışmaları kapsamında Grafik İşlemci Ünitesi (Graphics Processing Unit/GPU) kullanılmaktadır. Büyük miktarda etiketlenmiş veri setlerinden özellik saptama yapabilen sistemleri kurmak için kullanılan GPU teknolojisi sayesinde daha fazla veri ve daha az güç ile derin öğrenme alt yapıları desteklenmektedir. Temel olarak derin öğrenme, çok katmanlı algılayıcı bir modelden oluşmaktadır (Feldman ve Anderson, 2012).



Şekil 2.15. Çok Katmanlı Yapay Sinir Ağı

2.4.1. Derin Öğrenme Mimarileri

Bu bölümde derin öğrenme mimarilerinde en sık kullanılan 6 farklı mimari yapıdan bahsedilmiş olup, tez çalışmasında kullanılan Evrişimsel-Konvolüsyonel Sinir Ağları ayrı bir başlık altında ve kapsamlı olarak incelenmiştir.

- Tekrarlayan Sinir Ağları (Recurrent Neural Network/RNN): Alanlar arasında verilerin yönlendirilmiş bir döngü kurduğu yapay sinir ağıdır. Görüntü tanımlayıcı ve nesne tespitlerinde diğer mimari yapılar ile birlikte kullanılmaktadır.
- Uzun-Kısa Vadeli Hafıza Ağları (Long/Short Term Memory/LSTM): Genellikle konuşma ve metin işleme özelliklerinde yoğun olarak kullanılan bu ağ türü, değerleri rastgele aralık birimlerince hatırlayan ve tekrarlayan bir RNN mimarisidir.
- Sınırlı Boltzman Makineleri (Restricted Boltzman Machines/RBM): Görünür ve gizli katman olmak üzere olasılık dağılımlarını öğrenebilen bir yapay sinir ağıdır.
- Derin İnanç Ağları (Deep Belief Network/DBN): RBM yığıntıları ve kodlayıcılarla birleşim olarak işlev görür. Görüntü tanıma uygulamalarında yoğun kullanılmaktadır.
- Derin Oto Kodlayıcılar (Denoising Autoencoders/DAE): Girdi katmanı verilerini, çıktı katmanına aktaran bir yapay sinir ağıdır.

2.4.1.1. Konvolüsyonel Sinir Ağları

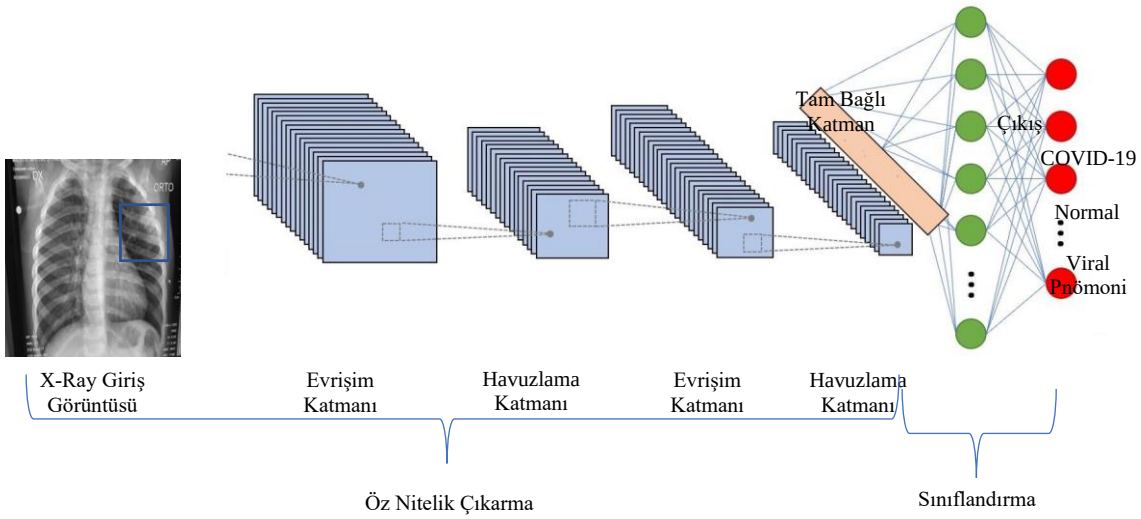
İlk defa 1988 yılında Yann LeCun tarafından oluşturulan konvolüsyonel sinir ağları, derin öğrenme modellerini oluşturan bir mimari yapıdır. Bu yapı içerisinde ilk geliştirilen LeNet mimarisi 1998'lere kadar sürekli güncellenmiştir (LeCun vd., 1989). Görüntüleri girdi olarak tasarlanan yapılar olan CNN mimarileri, bilgisayarlı görme tekniklerinde etkin olarak kullanıldığı görülmektedir. CNN mimari yapısı bir veya daha çok konvolüsyonel katman ile tamamen bağlı katmanlardan oluşmaktadır (LeCun vd., 2015).

Görüntü sınıflandırıcılarında en başarılı mimarilerden olan CNN, girdi imajını işledikten sonra belirli kategori altında sınıflandırmaktadır. Bilgisayarlar bir giriş görüntüsünü piksel dizisi olarak görür ve imaj çözünürlüğüne dayanır. İmaj çözünürlüğü (h) yükseklik x (w) genişlik x (d) boyut matris dizisinden oluşur. Görüntü boyut değeri 3 olduğunda, RGB (Red-Green-Blue/Kırmızı-Yeşil-Mavi), boyut değeri 1 olduğunda ise Grayscale (Gri Ton) olarak tek kanallı görüntüyü ifade eder. Bu tez çalışmasında da X-Ray görüntüleri üzerinde noktasal

tespitlerin yapılabilmesi ve renk yoğunluğunun dağıtılabilmesi amacıyla boyut dönüşümü uygulanmıştır.

CNN mimarisi ön işleme özelliği konusunda diğer mimarilere göre daha pratiktir. Görüntü tanıma, doğal dil işleme ve sınıflandırma gibi alanlarda uygulamaları mevcuttur (Qian, Liu, Liu, Wu ve San Wong, 2018). CNN mimarisi adını oluşturmuş olduğu gizli katman türünden almaktadır. Bir CNN mimarisinin gizli katmanları, tipik olarak evrişimsel/konvolüsyonel (convolutional), havuzlama (pooling), tamamen bağlı (fully-connected) ve normalizasyon (normalization) katmanlarından oluşmaktadır (LeCun vd., 2015). Şekil 2.16'da bu çalışmada kullanılan temel CNN mimarisi verilmiştir.

Bu çalışmada, akciğer X-ray görüntülerinden COVID-19 hastalığını tespit etmek amacıyla konvolüsyonel sinir ağı modeli kullanılmıştır. Mimari yapı içerisinde yer alan evrişim ve havuzlama katmanlarından model öznitelikleri tespit edilerek, görüntülerin sınıflandırılması gerçekleştirilmiştir.

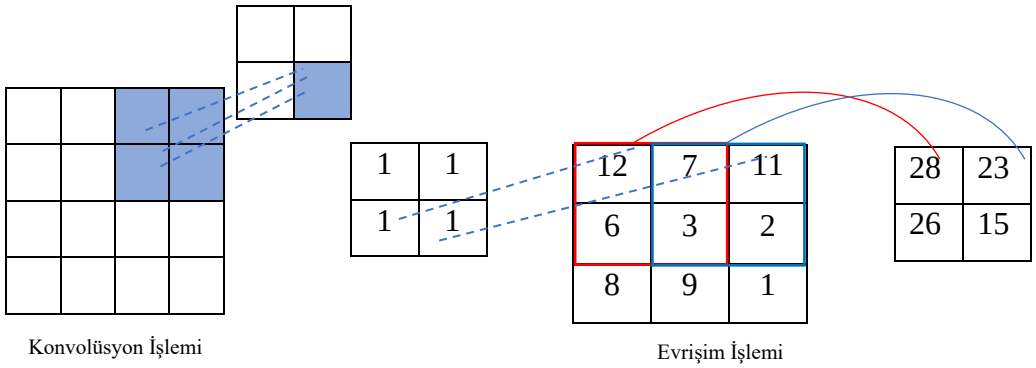


Şekil 2.16. Konvolüsyonel Sinir Ağının Temel Mimarisi

- *Evrişim Katmanı*

CNN mimarisinin en temel katmanı olan evrişim katmanı, dönüşüm işleminin gerçekleştirildiği katmandır. Bu dönüşüm işlemi, görüntü verisinin belirli filtre süzgeçlerinden kaydırılmasıyla meydana gelmektedir. Özellik haritası üreten evrişim katmanı, giriş görüntüsüne ve eldeki özelliklere konvolüsyon işleri gerçekleştirmektedir. Filtre aralıkları, görsel boyunca kaydırılmakta ve kaydırma sırasında görsele karşılık gelen

değer ile filtre değerlerinin çarpımı elde edilmektedir. Bu işlem, görselin tüm yapısına uygulandığında yeni bir görsel değeri elde edilmektedir. Şekil 2.17'de konvolüsyon ve evrişim filtreleme işlemi belirtilmiştir (Aggarwal, 2018).

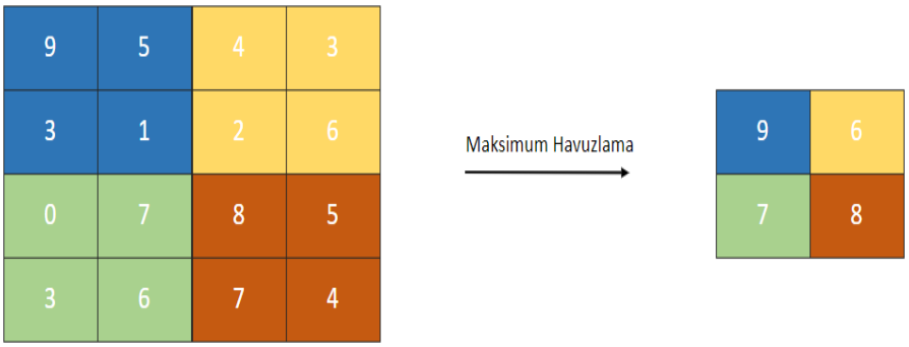


Şekil 2.17. Konvolüsyon ve Evrişim İşleminin Temel Mimarisi

Filtreler veya çekirdekler olarak da bilinen paylaşılan ağırlıklar, eğitim aşamasında öğrenilir. Evrişimsel katmanlar, genellikle havuzlama katmanları ile birleştirilir ve çıktıları tamamen bağlı katmanları besler (Afshar vd., 2020).

- *Havuzlama Katmanı*

Evrişim katmanında işlemi yapılan görüntü havuzlama katmanına aktarılmaktadır. Bu katmanda parametre sayılarının azaltılması hedeflenmiştir. Parametreler azaldıkça, ağda var olan uyumsuzluk kontrolü de artmaktadır. Konvolüsyonel katmandan elde edilen matrisin yükseklik ve genişliği azaltılarak karmaşıklığın önüne geçmek için havuzlama (pooling) katmanı kullanılmaktadır (Hinton, Srıvastava, Krızhevsky, Sutskever ve Salakhutdınov, 2012). Çalışmada maksimum havuzlama kullanılarak havuzlama boyutunun en yüksek değere sahip pikseller alınmıştır. Şekil 2.18'de maksimum havuzlama katmanının örneklenmesine yer verilmiştir.



Şekil 2.18. Maksimum Havuzlama Katmanı Temel Mimarisi

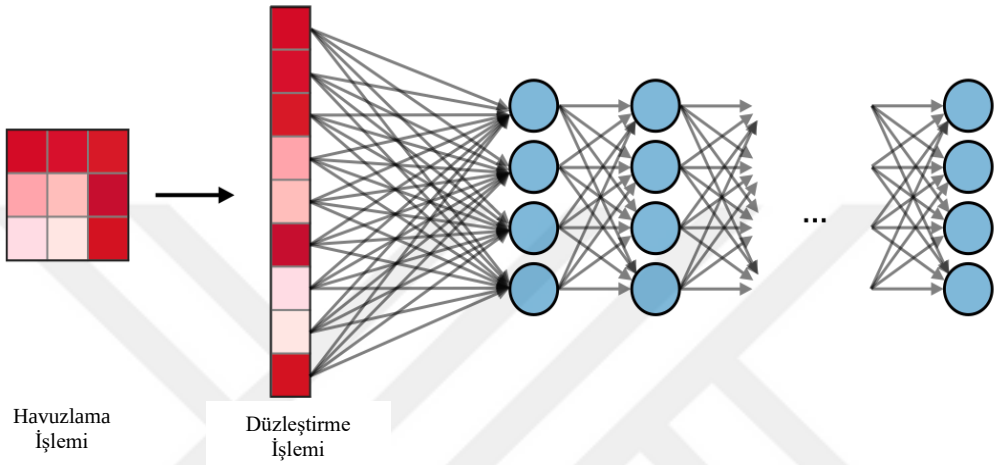
Hesaplama yükünü azaltmak için, ağ içerisindeki parametreleri azaltan bu katman, filtre alanları arasında kalan piksel değerlerinin yüksek olanı ile maksimum havuzlamayı oluşturur. Katman seviyesinde yer alan ortalama havuzlama ile ise, filtre alanları arasında kalan piksel değerlerinin ortalaması çıktı alanında tek bir değer olarak tutulmaktadır. Görüntünün en boy oranında küçülme işlemi, havuzlama işleminin en sonunda gerçekleşmektedir. Havuzlama işleminin sonunda, piksel değerlerinde belirli bir miktar kayıplar oluşmakta, bu kayıplar ile daha sonraki katman seviyelerinde hesaplama yükü azalmaktadır. Havuzlama katmanı, doğrusal olmayan etkinleştirme işlevi tarafından etkinleştirilen evrişimsel katmanı izleyen bir katmandır. Bu katman özellik haritalarında yalnızca en önemli değerleri belirterek önceki evrişim katmanından üretilen özellik haritalarındaki değerlerin sayısını en aza indirmekten sorumludur (Suarez ve Segura, 2018).

Havuzlama katmanında, sonraki katmana geçen değerlerin en büyükleri, en küçükleri ya da ortalamaları alınarak bir alt örnekleme işlemi yapılmaktadır (Havaei vd, 2017). Nöronlara ait piksel değerlerinin filtreleme işlemlerinin tüm nöronlara dağılabilmesi amacıyla bu çalışmada evrişim katmanı ve havuzlama katmanından sonra aynı işlem tekrar uygulanarak hesaplama yükü en aza indirgenmiştir.

- *Tam Bağlı Katman*

Bu katman türünde, kendisinden önce gelmekte olan nöronlar derin öğrenme parametresi olan flatten bölümünde birbirlerine bağlanır. Konvolüsyon ve havuzlama katmanından gelen matrisin kullanılabilmesi için, düzleştirme işlemine tabi tutulması gerekmektedir. Bu işlemden sonra giriş verileri hazırlanmış olur. Gizli katmandan alınan katsayılar üzerinde

işlem gerçekleştirilir. Nöronların kendinden önce yer alan katmandaki aktivasyonlara bağlanma yeri tam bağlı katmandır. Havuzlama katmanına bağlı olan nesnelerin sınıflandırılması bu katmanda yapılmaktadır (Doğan ve Türkoğlu, 2018). Şekil 2.19'da tam bağlı katmana ait düzleştirme işlemi yer almaktadır. Bir sınıfa bağlantı kurabilmek için yüksek seviyeli özellik sahibi olan değerlere bakılarak hangi sınıfa ait olduğu tam bağlantılı katmanda tespit edilmektedir (Lin, Chen ve Yan, 2013).



Şekil 2.19. Tam Bağlantılı Katmanı Temel Mimarisi

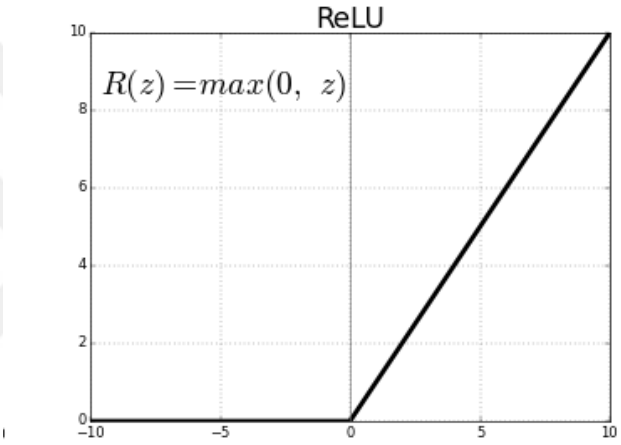
2.4.1.2 Aktivasyon Fonksiyonu Katmanları

Bir sinir ağının çıktılarına karar veren matematiksel denklemlere aktivasyon fonksiyonları denilmektedir. Her bir nöronun girdilerinin, modelin öngörüsüne göre uygun olup olmadığına bağlı kalarak, modelin etkin hale getirilip getirilmeyeceğine karar verilen katmanlardır. Nöronlarda yer alan girdiler, nöronlardaki ağırlıklarla çarpılıp, birleştirilmektedir. Bu işlemin sonucu, nöronun özet aktivasyonu olarak adlandırılır ve daha sonra nöronun çıktılarına karar veren aktivasyon fonksiyonu kullanılarak dönüştürülür (Jang, Cho, Kim, Lee ve Yang, 2020). Aktivasyon fonksiyonları iki farklı form metodundan oluşmaktadır. Bunlar (Kaynar, Aydın ve Görmez, 2017):

- Lineer aktivasyon fonksiyonları: Nöronların çıktılarında herhangi bir dönüşüme yol açmazlar.
- Lineer olmayan aktivasyon fonksiyonları: Veri setinde nöronlara ait karmaşık bilgileri algılamasına izin verildiği için en sık tercih edilen aktivasyon fonksiyonudur. Bu tez çalışmasında nöronlara ait bilgi değişikliği yapılmasından

dolayı lineer olmayan aktivasyon fonksiyonlarından Rectified Linear Unit (ReLU) kullanılmıştır.

Konvolüsyonel katmandan sonra kullanılan aktivasyon fonksiyonlarının başında gelen ReLU, konvolüsyonel katman içerisinde elde edilen matrislerde yer alan negatif değerli piksellerin sıfır değerine getirilmesini, yani hesaplamaya alınmamasını sağlamaktadır. ReLU, konvolüsyonel katman ile havuzlama katmanı arasında işlem görmektedir. ReLU fonksiyonundan sonra elde edilen matris havuzlama katmanına iletilir. Şekil 2.20'de Rectified Linear Aktivasyon Fonksiyonu gösterilmiştir.



Şekil 2.20. Rectified Linear Aktivasyon Fonksiyonu (ReLU)

2.5. Çalışmada Kullanılan Hiperparametreler

Hazırlanan derin öğrenme mimarisine göre araştırmacı tarafından modellenen, veri setlerine göre değişiklik gösteren ve model üzerinde yüksek başarı elde etmek için tasarlanan parametrelere hiperparametre denir. Model eğitimin başarısının büyük bir bölümünü oluşturan hiperparametreler, derin öğrenme çalışmalarında önem arz etmektedir (Huang, Hao ve Chang, 2016). COVID-19 hastalığının tespiti için bu çalışmada uygulanan hiperparametreler:

- *Optimizasyon algoritması:* Öğrenme işlemlerinde en temel problemi oluşturan optimizasyon algoritmaları, doğrusal olmayan problemlerin çözümünde optimum değere ulaşmak için optimizasyon yöntemlerini kullanmaktadır. Bu yöntemlerden katmansal sıralama yapabildiği ve derecesel momentlerin uyarlanabilir tahminine dayandığı için Adam optimizasyon yöntemi çalışmada kullanılmıştır.

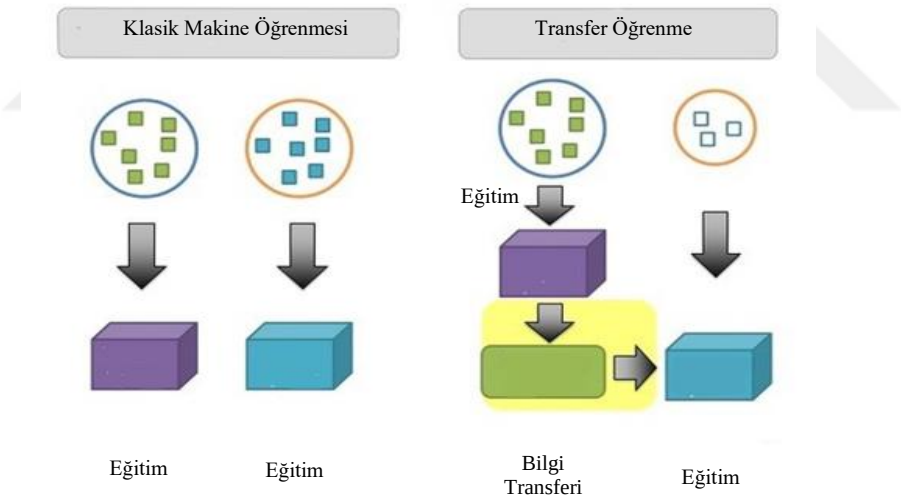
- *Eğitim tur (Epoch) sayısı:* İterasyon sayısına ya da tekrarlayan işlem sayısına epoch denilmektedir. İterasyon sayısı ne kadar fazla olursa model başarısıda gözle görünür düzeyde artar. Modelin eğitimi sırasında veri kümesine aşırı uyum gösterilmemesi için bu çalışmada epoch sayısı için 30 kullanılmıştır.
- *Batch boyutu :* Birden fazla girdiden oluşan yapının parçalara bölünerek işlenmesi olarak tanımlanabilir. Model üzerinde ayarlanan batch hiperparametresi, modelin kaç veriyi beraber işleyeceğini göstermektedir. Batch boyutunun küçük olmasının iyileştirme etkisi yarattığı ve verinin modele büyük gruplar halinde verildiğinde ezberleme durumlarının ortaya çıkmasından dolayı, bu çalışmada kayıp işlemini en aza indirmek için batch boyutu 32 olarak ayarlanmıştır.
- *Momentum katsayısı:* Öğrenme hızı adıyla da anılan momentum katsayısı varsayılan değer olarak 0.01 belirlenmiştir. Bu katsayısı, iterasyonlardan sonra 0.001'e düşürülerek aşırı öğrenmenin önüne geçilmesi hedeflenmiştir.
- *Ağırlık değeri:* Her ağırlık değeri boyunca yineleme sayısı artarak eğitim süresi azalmaktadır. Bu çalışmada standart sapmaya sahip olacak şekilde ağırlık değeri 0.5 ayarlanmıştır.
- *Aktivasyon fonksiyonu:* Çalışmada konvolüsyon ve havuzlama katmanlarını ReLU aktivasyon fonksiyonu izlemektedir. Doğrusal olmayan aktivasyon fonksiyonları içerisinde en etkin olan ReLU giriş değerini 0 'dan az ise değeri 0'a döndürmektedir (2.1).

$$\sigma(x) = \begin{cases} max(0, x) & , x >= 0 \\ 0 & , x < 0 \end{cases} \quad (2.1)$$

- *Seyreltme değeri:* Aşırı öğrenmeyi en aza indirmek için kullanılan seyreltme tekniği, sinir ağı mimarisi için kullanılmaktadır. Tipik olarak 0.1 ile 0.9 değerleri arasında değerler almaktadır. Çalışmada kıvrımlı katman formuyla kullanabilmek için 0.5 değeri kullanılmıştır.

2.6. Transfer Öğrenme

Derin öğrenme yöntemlerinde büyük veri setlerinin kullanılması doğruluk ve özgünlük açısından önem taşımaktadır. Öğrenme olayının başarılı olabilmesi ve tekrarlayan öğrenmelerden uzaklaşmak için büyük veri setleri tercih edilmektedir. Veri setlerinin genişlemesiyle eğitim için ihtiyaç duyulan donanımsal özelliklerde artmaktadır. Yapay sinir ağında kullanılan gizli katman sayıları arttıkça, daha büyük bellek ihtiyaçları ortaya çıkmaktadır. Çalışmada kullanılan veri setinde toplamda 3886 görüntünün yer alması, bu görüntüler üzerinde yapılacak eğitimler için büyük bir bellek, donanımsal araç ve her bir parametrenin doğruluk payının deneme ile belirlenmesi nedeniyle daha fazla zamana ihtiyaç duyulmaktadır. Transfer öğrenme (transfer learning) ile önceden eğitilmiş derin öğrenme modelleri ile elde edilen ağırlık değerlerini, farklı veri setlerinin ağına aktararak donanım ve zaman tasarrufu elde edilebilmektedir. Örneğin kedi-köpek sınıflandırmasını yapan bir model eğitirken, kazanılan bilgi ağı insan-hayvan sınıflandırması içinde kullanılabilir. Şekil 2.21'de transfer öğrenme mimarisi gösterilmiştir (Samtaş ve Gülesin, 2011).



Şekil 2.21. Transfer Öğrenme Mimarisi

Transfer öğrenmede temel adımlardan sonra, ilk katmanda aktarım yapılması gerekmektedir. Aksi taktirde negatif transfer ortaya çıkabilmektedir. Bu işlemler içinde farklı yöntemler kullanılmaktadır. Önceden eğitilmiş model türlerinde ağırlıklar içlerinde birçok bilgiyi barındırmaktadır. Yeni modelin daha hızlı eğitime tutulabilmesi amacıyla ince ayar yöntemi kullanmak daha pratik sonuçlar vermektedir (Abdulghani, Fadhil ve Gültekin, 2020). Bu çalışmada transfer öğrenme yöntemlerinden biri olan ince ayar yöntemi kullanılarak önceden

eğitilen derin öğrenme modellerinden eşikleyici (softmax) katmandaki sınıf sayısı ile veri setindeki sınıf sayısı değiştirilip eğitime tabi tutulmuş olup, sonuçta başarı oranları belirlenmiştir. Ayrıca çalışmada farklı derin öğrenme modellerinde öğrenim aktarımı yapılarak, az sayıda bulunan veri setinden elde edilen ağırlıkların öğrenme aktarımı ile büyük veri setine aktarımı sağlanarak modeller arası karşılaştırma yapılmıştır.

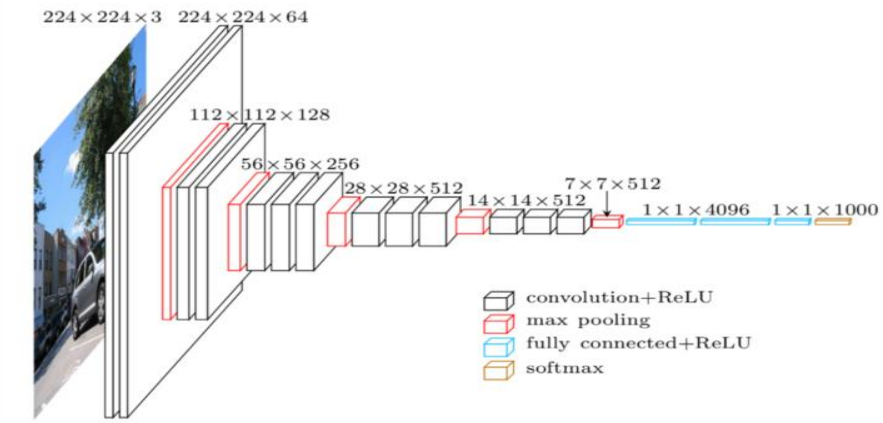
Çalışmada son katmansal hedeflerinde elde edilen sınıflandırma ve özellik değerleriyle başarı gösteren transfer öğrenme modellerinden sırasıyla VGG-16, ResNet-50, DenseNet-121 ve Inception V3 modellerinde eğitim ve test işlemleri yapılarak, başarı oranları karşılaştırılmıştır (Khan vd., 2020).

2.6.1. Transfer Öğrenmesi Modelleri

Transfer öğrenmesinde yer alan modellerden son yıllarda oldukça başarılı fonksiyonların yer aldığı modeller çalışma kapsamında tercih edilmiştir.

2.6.1.1. VGG-16 Mimarisi

İlk olarak 2015 yılında Simonyan ve Zisserman tarafından yayınlanmıştır. Oxford Üniversitesi tarafından ILSVRC2014 yarışmasında 13 konvolüsyon 3 tam bağlı katmanı ile daha başarılı sonuçları hedef alan bir ağ mimarisidir. Mimaride toplamda 41 katman bulunmaktadır. Maxpool, Fullconnected, Relu, Dropout ve Softmax katmanlarına bağlı olan bu katmanlarda, 3*3 evrişim katmanı ve filtreleme bulunmaktadır. VGG-16 mimarisinde 13 evrişimsel katman, 5 havuzlama katmanı ve 3 tam bağlantılı katman bulunmaktadır. Diğer farklı mimarilerden VGG-16 ’yı ayıran en önemli özellik, ikili veya üçlü konvolüsyon katmanlarını ortaklama katmanının izlemesi oluşturmaktadır. Ağ mimarisinin son yapısında 4096 nörondan oluşan, yoğun katman bulunmaktadır. VGG-16 mimarisinin en sonunda ise 1000 nörondan oluşan ortaklama katmanı görev almaktadır. Şekil 2.22’de VGG-16 mimarisinin yapısı belirtilmiştir (Wahab, Khan ve Lee, 2019).



Şekil 2.22. VGG-16 Mimarisi

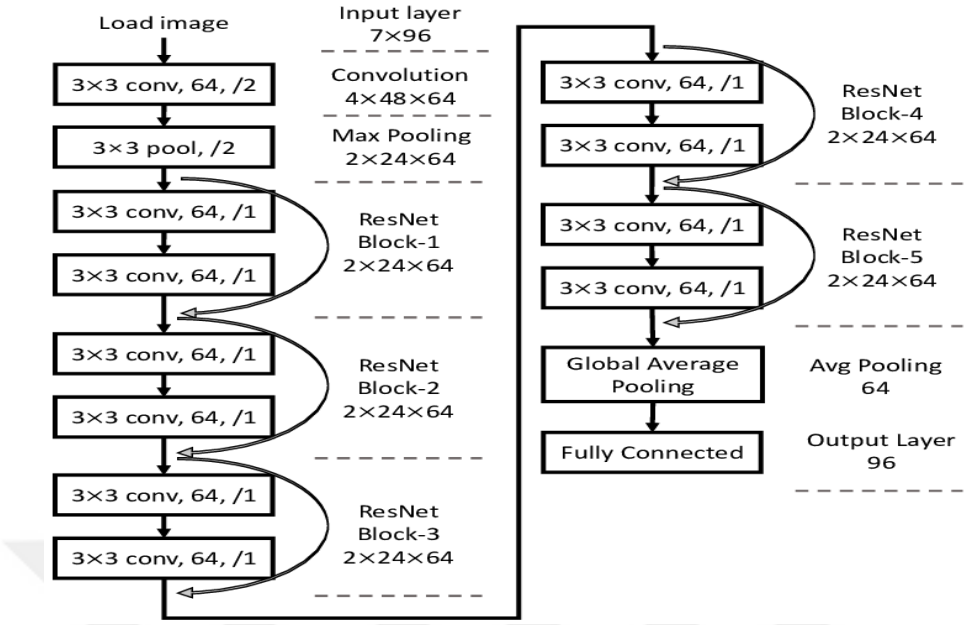
VGG-16 mimarisi oldukça büyük bir ağı temsil etmektedir. ReLU aktivasyon kullanılmıştır ve yaklaşık olarak 138 milyon parametre değerine sahiptir.

2.6.1.2. ResNet-50 Mimarisi

2015 yılında Microsoft Research Asia önderliğinde, He Kaiming ve Sun Jian tarafından önerilen ResNet-50 mimarisi, derin ağ yapıların dar boğaz yapısını oluşturmaktadır. ResNet-50 mimarisi parametre sayılarını azaltmaya yönelik olarak, hesaplama yükünü hafifletmek ve modeli genişletmeyi hedeflemektedir. Bu işlemler sonucunda hata oranlarında büyük miktarda azalma göstermektedir (Kavuncu, 2018).

ResNet-50 mimariside, VGG-16 gibi ImageNet veri seti üzerinde eğitilmiş olup, mimari yapısı ile diğer modellerden ayrılmaktadır. ResNet-50 mimari yapısında bazı katmanlardaki değişimler pas geçilerek alt katmana geçişe izin verilmektedir. Bu durum başarı oranını arttırmaktadır. 177 katmanın yer aldığı ağ mimarisinde, bağlantılar arası iletişim kurulmaktadır (Doğan ve Türkoğlu, 2018).

ResNet-50 mimari ağında, 1*1’ lik boyutsallık azaltıcı evrişim alanın ardından 3*3 ’lük evrişim işlemi uygulanır. Bu işlemlerin ardından ve tekrar 1*1’ lik boyutsallık uygulanır. Şekil 2.23’te ResNet-50 mimari yapısı belirtilmiştir (Kavuncu, 2018).

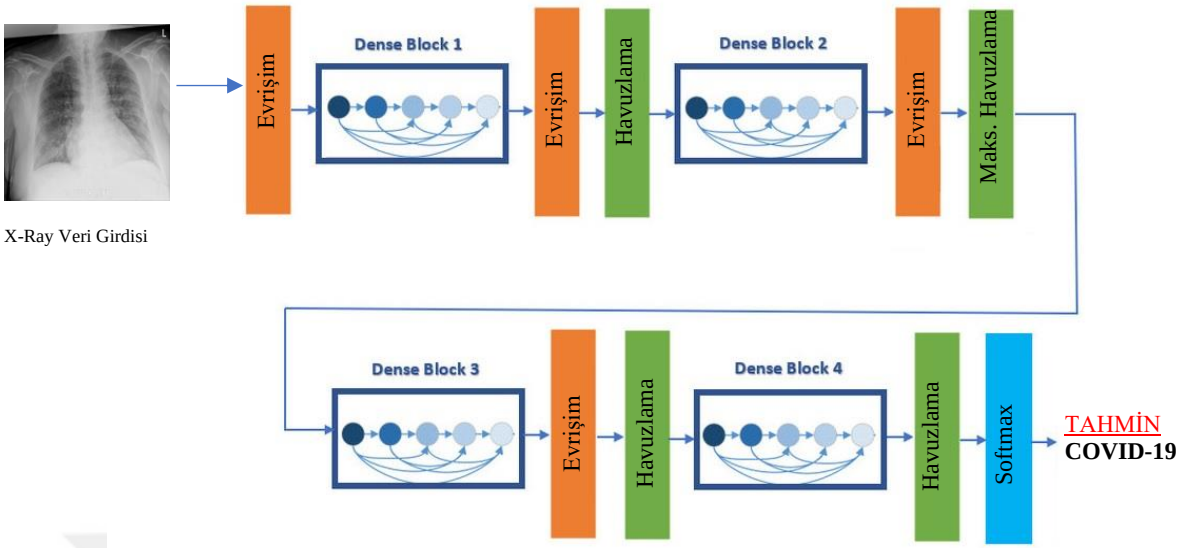


Şekil 2.23. ResNet-50 Mimarisi

Çalışmada ResNet-50 mimari yapılarının seçilmesinin başında, konvolüsyonel sinir ağındaki performans düşümü problemini ortadan kaldırmak gelmektedir. Derin ağların yakınsamasına doğru bozulmalar oluşur. ResNet-50 mimari yapısı katmanlara kısa yollar ekleyerek, bu problemi çözmeye çalışır (Fulton, Dolezel, Harrop, Yan ve Fulton, 2019).

2.6.1.3. DenseNet-121 Mimarisi

DenseNet-121 modeli, kaybolmakta olan gradyan piksel problemlerini hafifleterek, özniteliğin ön plana çıkmasını ve parametrelerde azaltma işlemi yaparak modelin eğitimini yönetebilmeyi sağlamaktadır (Huang, Liu, Van Der Maaten ve Weinberger, 2017). DenseNet-121 mimarisinin temel taşını dense blokları (DenseBlock) oluşturmaktadır. Bu dense blokları evrişim katmanlarında yer aldığı için bilgisayarlı görme problemlerinde oldukça başarı sonuçlar üretmektedir. Hiyerarşik yapıya sahip olan klasik CNN modellerinde, öznitelik haritaları katmana girdi olarak verilirken; DenseNet-121 modelinde, öznitelik haritalarının her biri birleştirilir. Sonradan gelen katmanlar için kendi öznitelik haritalarını kullanan DenseNet-121 modeli bilgi akışını iyileştirerek, gradyan problemini hafifletir. Şekil 2.24'de COVID-19 hastalığının tespiti için geliştirilen DenseNet-121 mimari yapısı belirtilmiştir (Huang vd., 2017).

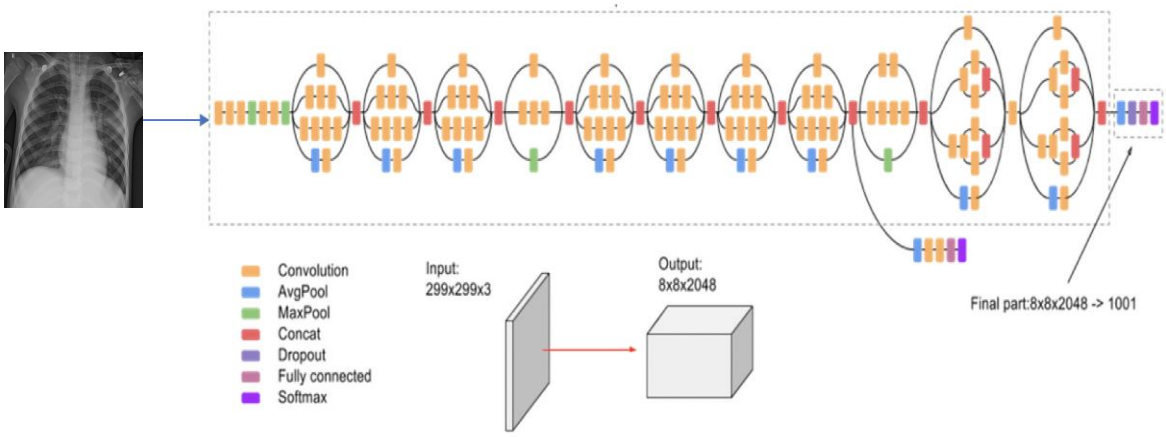


Şekil 2.24. COVID-19 Tespiti İçin Geliştirilen DenseNet-121 Mimarisi

Bu çalışmada DenseNet-121 mimarisinin seçilmesinin en önemli nedeni, sık bağlantı noktalarının düzenleştirme özelliğine sahip olması ve çok büyük olmayan verilerde aşırı öğrenmenin (overfitting) önüne geçmektir. Her dense bloğu bir evrişim katmanından oluşurken, her geçiş katmanı sırasında bir etkileşim, bir havuzlama katmanı devreye girer. Çalışmada doğrusal olmamayı en yüksek seviyeye çıkarmak için ReLU aktivasyon fonksiyonu tercih edilmiştir. Veri seti üç sınıflı (COVID-19, Viral Pnomöni, Normal) bir yapıdan oluştuğu için, sınıflandırmada tam bağlı katman kullanılmıştır. Son bölümde softmax aktivasyonu ile tam bağlı katmanın çıktısı normalleştirilmiştir.

2.6.1.4. Inception V3 Mimarisi

Inception V3 derin öğrenme modeli, Google tarafından geliştirilmiş olup, ImageNet veri kümesini kullanmaktadır (Szegedy, Vanhoucke, Loffe, Shlens ve Wojna, 2016). 299*299*3 boyutlarında girdi işlemi yapılabilen Inception V3 mimarisinde 48 katman bulunmaktadır. Şekil 2.25'te bu çalışma için geliştirilen InceptionV3 mimarisinin yapısı belirtilmiştir (Szegedy vd., 2016).



Şekil 2.25. Inception V3 Mimarisi

Inception V1'de, 5*5 evrişim durumunun çok sayıda olması hesaplama açısından maliyeti arttırmaktadır. Çıktı boyutu, evrişim ve havuzlama katmanlarının birleşmesi ile büyümektedir. Bu yüzden Inception V2 mimarisinde 5*5' lik evrişim 3*3' lük evrişim ile yer değiştirmiştir. Bu işlemin sonucunda hesaplama süresi azaldığı için hesaplama hızı da artmaktadır. 48 katman derinliğine sahip olan Inception V3 modeli, 1*1, 3*3, 5*5 evrişim katmanlarını kullanan inception modüllerini kullanmaktadır. Çalışmada, parametre sayılarını azaltarak eğitim hızını arttırmak ve ağın derinlik ile genişliğini iyileştirerek en yüksek bilgi akışını sağlamak için Inception V3 modeli tercih edilmiştir.

2.7. Değerlendirme Kriterleri

Bu çalışmada COVID-19 hastalığını tespit etmek için geliştirilen modelin performansını değerlendirmek için "Doğruluk (Accuracy), Geri Çağırma (Recall), F1- Skor (F1-Score), Hassasiyet (Precision) ve Hata oranı (Error Rate)" metrikleri kullanılmıştır. Çalışma sonuçları karşıtlık matrisi tabanlı analizleri içermektedir. Karşıtlık Matrisi sınıflandırma tabanlı kurulan modeller hakkında bilginin yanı sıra hata oranları hakkında da bilgiler vermektedir (Goutte ve Gaussier, 2005).

Çalışmada kullanılmış olan modellerin elde edilen sonuçlarının yorumlanabilmesi ve tahmin edilen değerler üzerinde doğruluk ve hata oranlarını çaprazlama değerlendirmek için karşıtlık matrisi kullanılmaktadır. Tablo 2.1'de karşıtlık matrisin dayalı olduğu sistem belirtilmiştir.

Tablo 2.1. Karşıtlık Matrisi

	Tahmin Edilen Pozitif	Tahmin Edilen Negatif
Gerçek Pozitif	Gerçek Pozitif (TP)	Yanlış Negatif (FN)
Gerçek Negatif	Yanlış Pozitif (FP)	Gerçek Negatif (TN)

Çalışma kapsamında karşıtlık matrisleri aşağıdaki kriterler özelinde değerlendirilmiştir.

- Gerçek Pozitif (TP) : Giriş görüntüsünde COVID-19 tanısı olan verilerin çıktı sonucu COVID-19 olarak tahmin edilmesidir.
- Gerçek Negatif (TN) : Giriş görüntüsünde normal tanısı olan verilerin çıktı sonucu normal olarak tahmin edilmesidir.
- Yanlış Pozitif (FP) : Giriş görüntüsünde normal tanısı olan verilerin çıktı sonucu COVID-19 olarak tahmin edilmesidir.
- Yanlış Negatif (FN): Giriş görüntüsünde COVID-19 tanısı olan verilerin çıktı sonucu normal olarak tahmin edilmesidir.

Modelin performansını değerlendirmek için kullanılan metrikler (Goutte ve Gaussier, 2005):

- Doğruluk (Accuracy): Eğitim ve test olarak ayrılmış olan veri setinde, test verilerinin eğitime tabi tutulması sonucunda ulaşılan doğru tahminler ile oranlanmasına doğruluk denir. Değerlendirme kriterleri açısından en önemli metrik olan doğruluk, sınıf bazında yetersiz kalabilmesi için karşıtlık matrislerinin hesaplanması gerekmektedir. Sınıf bazında doğruluk hesabı, denklem (2.2) 'de belirtilmiştir.

$$Doğruluk = \frac{\mathrm{TP} + \mathrm{TN}}{\mathrm{TP} + \mathrm{TN} + \mathrm{FP} + \mathrm{FN}} \quad (2.2)$$

- Hassasiyet/Kesinlik (Precision) : Pozitif tahmin edici olarak bilinen hassasiyet veri setinin tüm sınıflarında ne kadar doğru tahmin ettiğimizi bildirmektedir. Bu değerin yüksek olması doğru tahminlerin ne kadar yüksek olduğuyla ilgilidir. %100 değerine yakın olması doğru sınıflandırma açısından önemlidir. Hassasiyet denklemi, denklem (2.3) 'te belirtilmiştir.

$$\text{Hassasiyet} = \frac{TP}{TP+FP} \quad (2.3)$$

- Geri Çağırma (Recall): Algoritma sonucunda elde edilen tüm pozitif sınıfların ne kadar doğru tahmin edildiğinin bilgisidir. Sınıflandırma sonucunda yüksek oranlar hedeflenmektedir. Geri çağırma denklemi, denklem (2.4) 'te belirtilmiştir.

$$\text{Geri Çağırma} = \frac{TP}{TP+FN} \quad (2.4)$$

- F1-Skoru (F1-Score): Sınıflandırma sonucunda elde edilen hassasiyet ve geri çağırma değerlerinin harmonik ortalamasıdır. Bu yüzden hassasiyet ile geri çağırma arasında dengeyi oluşturmak için F1 skoru hesaplanır. F1 skoru denklemi, denklem (2.5) 'te belirtilmiştir.

$$\text{F1-Skoru} = \frac{2*(\text{Hassasiyet}*\text{Geri Çağırma})}{\text{Hassasiyet}+\text{Geri Çağırma}} \quad (2.5)$$

- Hata Oranı (Error Rate): Ortalama doğruluk sonuçlarının %100 başarı oranlarından düşülmesi ile elde edilen sonuçlardır. Hatanın değişimini görmek açısından önem taşımaktadır. Hata oranı denklemi, denklem (2.6) 'de belirtilmiştir.

$$\text{Hata Oranı} = 1 - \text{Doğruluk} \quad (2.6)$$

ÜÇÜNCÜ BÖLÜM

BULGULAR VE TARTIŞMA

3.1. Deneysel Çalışma Ortamı

Kurulan derin öğrenme mimarileri ve modelleri üzerinden veri setinde yer alan büyük boyuttaki görüntüleri eğitime tabi tutmak için güçlü donanımsal makinelere ihtiyaç duyulmaktadır. Bu çalışma Intel Core i7 8700U CPU @ 3.00 GHz işlemcili, 16 GB NVIDIA GeForce GTX 1050 Ti ekran kartlı ve 16 GB birincil belleğe sahip dizüstü bilgisayar üzerinden, Google Colab isimli platformda gerçekleştirilmiştir. Google hesabı ile giriş yapılabilen Google Colab platformu 12 saate kadar çalışma imkanı vermektedir. GPU desteği sağlayan ve arka uç alanlarında araştırmacılara ücretsiz alan sağlayan colab platformu ile büyük veri setlerinin eğitim süreleri kısalmaktadır. Platformda NVIDIA Tesla-K80 GPU hızlandırıcı kullanılmıştır. Ayrıca çalışma alanında arka uç olarak 12 GB rastgele erişilebilir GPU kullanılmıştır.

Python 3.7 ve sınıflandırma için python kütüphaneleri kullanılmıştır. Çalışmada kullanılan kütüphaneler aşağıda açıklanmıştır.

- OpenCV Kütüphanesi: Görüntü işleme konusunda en başarılı kütüphanelerden bir tanesidir (Shubair, 2014). Bu çalışmada görüntüler üzerinde uygulanan ön işlemler OpenCV kütüphanesinde gerçekleştirilmiştir. Derin öğrenme mimarilerinde görüntüler üzerinde renk uzayı dönüşümleri ve filtre uygulamaları çok önemli olduğu için OpenCV kütüphanesi çalışmada kullanılmıştır.
- TensorFlow Kütüphanesi: Google tarafından geliştirilen açık kaynak kodlu bir derin öğrenme kütüphanesi olan TensorFlow, numerik hesaplamalar için kullanılmaktadır. Araştırma ve geliştirme alanları ile üretim sistemlerinde aktif olarak kullanılan TensorFlow yüzlerce düğümden oluşan büyük sistemlerde

çalışabilmektedir (Nguyen vd. 2019). Çalışmada TensorFlow kütüphanesi graflar arasındaki düğümleri matematiksel olarak çözmek için kullanılmıştır. Derin öğrenme mimarisi olarak kurulan transfer öğrenme yaklaşımında TensorFlow kütüphanesi kişisel sınıfları tanıyan model olarak çalıştırılmıştır.

- Keras Kütüphanesi: Keras, derin öğrenme araçları olan birçok kütüphane ile bağlantı sağlayan bir API kütüphanesidir. Her algoritmik kod alanında bir ağ katmanı oluşturduğu için okunması kolay bir kütüphanedir. 2017 yılında Google TensorFlow ekibi tarafından Keras kütüphanesi üst düzey paket olarak benimsenmiştir (Narin vd., 2021). Çalışmada keras kütüphanesi içerisinde aktivasyon (activation) katmanı, düzleştirme (flatten) katmanı, seyreltme (dropout) katmanı ve yeniden boyutlandırma (reshape) katmanları kullanılmıştır. Aktivasyon katmanında ReLU ve sigmoid fonksiyonları kullanılmıştır. Seyreltme katmanı ile eğitim aşamasında aşırı öğrenmenin önüne geçilmesi hedeflenmiştir. Matris verisini düzleştirmek için düzleştirme katmanı seçilirken, girdi boyutlarında değişim için yeniden boyutlandırma katmanı kullanılmıştır.

3.2. Model Tasarımları

Bu çalışmada COVID-19 hastalığı tespiti amacıyla akciğer bölgesi X-ray görüntülerinden 4 farklı derin öğrenme modeli performans başarısı açısından incelenmiştir. Veri setinde 1200 adet COVID-19, 1345 adet viral pnömoni ve 1341 adet normal (sağlıklı) olmak üzere toplam 3886 adet X-Ray görüntüsü bulunmaktadır (Chowdhury vd., 2020). Çalışmada kullanılan X-Ray veri setinin %70'i (2720 Görüntü) eğitim, %20'si (777 Görüntü) test ve %10'u (389 Görüntü) ise doğrulama için kullanılmıştır. 3 farklı sınıfta yer alan veri setinde giriş etiketleri Tablo 3.1 'de belirtilmiştir. Çalışmada derin öğrenme mimarilerinden transfer öğrenme modelleri olan VGG-16, ResNet-50, DenseNet-121 ve Inception V3 modellerinin başarı oranları karşılaştırılmıştır. Eğitim tur sayısı (epoch) arttıkça modelin doğruluk oranları gözle görülür oranda artmaktadır. Doğruluk oranı belli bir eğitim tur sayısından sonra çok küçük birimlerde artış göstereceği için bu noktalarda eğitimin sonlandırılması aşırı öğrenmenin önüne geçmektedir (Nguyen vd. 2019). Bu yüzden bu çalışmada tüm modellerin eğitim durumlarında eğitim tur sayısı (epoch) 30 olarak belirlenmiştir.

Tablo 3.1. Sınıf Düzeylerinde Giriş Etiketleri

Sınıf Adı	Giriş Etiketi
COVID-19	0
Viral Pnömoni	1
Normal	2

Veri setinde yer alan görüntülerin farklı boyutlarda bulunmasından dolayı tüm görüntüler 299x299x3 büyüklüğüne yeniden boyutlandırılmış ve görüntülerin piksel değerleri 255'e bölünerek 0-1 aralığına normalize edilmiştir. Bu çalışmada görüntüler üzerinde uygulanan ön işlemlerin modelin başarısına etkisi gözlemlenerek, karşılaştırma işlemi yapılmıştır. Görüntüler üzerinde daralmanın önüne geçmek amacıyla tek kanallı olan görüntülere kanal eklenerek kanal sayısının 3 olması sağlanmıştır.

3.2.1. VGG-16 Modeli Sonuçları

13 evrişim katmanı ile 2 tamamen bağlı katmandan oluşan VGG-16 modeli tasarlandıktan sonra, ağırlık başlatma işlemi uygulanmıştır. Kurulan modelde 5 maksimum ve 1 ortalama havuzlama katmanı kullanılmıştır. Tasarlanan VGG-16 modelinde optimizasyon fonksiyonu olarak Adam (Adaptive Moment Estimation/Adaptif Moment Tahmini) tercih edilmiştir. Modelin erken durdurma değeri olarak 5 tercih edilirken, öğrenme oranı olarak 0.001 belirlenmiştir. Modelde eğitim tur sayısı 30 olarak belirlenmiştir. Kurulan modele ait parametre değerleri Tablo 3.2'de belirtilmiştir.

Tablo 3.2. VGG-16 Modeli Kullanılan Parametre Değerleri

Parametreler	Değerler
Evrişim Katmanı	13
Maksimum Havuzlama Katmanı	5
Seyreltme Katmanı	--
Ortalama Havuzlama Katmanı	1
Yığın Normalleştirme	--
Tam Bağlı Katman	2
Optimizasyon Modeli	ADAM
Öğrenme Oranı	0.001
Aktivasyon Fonksiyonu	Relu - Softmax

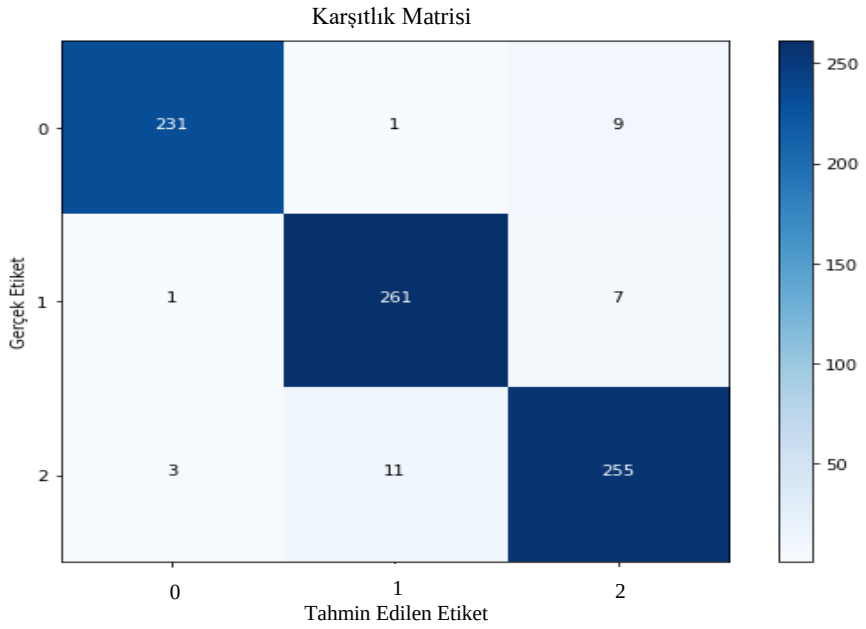
Erken Durdurma Değeri	5
Yığın Boyutu (Batch Size)	32
Tekrar Sayısı	30

Çalışma kapsamında kurulan VGG-16 modeline ait model özeti ise Tablo 3.3'te belirtilmiştir.

Tablo 3.3. VGG-16 Model Özeti

Model Parametreleri	**Parametre Sayıları**
Toplam Parametre Sayısı	16.815.426
Eğitilebilir Parametre Sayısı	2.100.738
Eğitime Girmeyen Parametre Sayısı	14.714.688

Oluşturulan VGG-16 modeline ait tahmin edilen değerler ile gerçek değerlerin karşılaştırılması amacıyla oluşturulan karşıtlık matrisi Şekil 3.1'de belirtilmiştir.



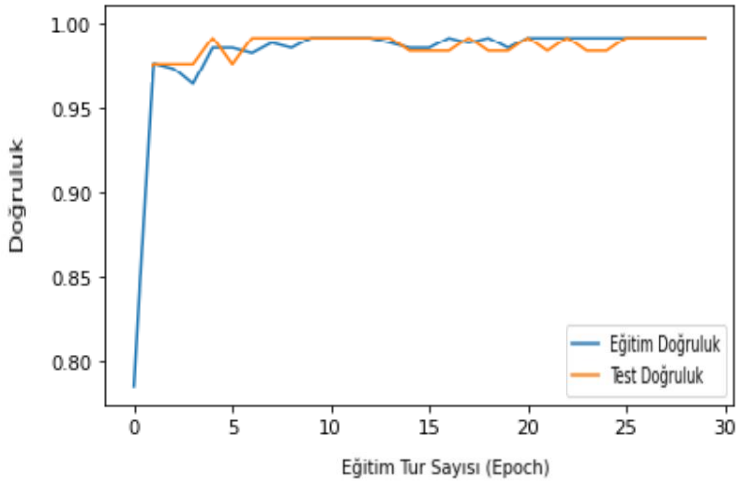
Şekil 3.1. VGG-16 Modeli Karşıtlık Matrisi

Modele ait karşıtlık matrisi incelendiğinde test veri setinde yer alan 269 adet normal sınıflandırmadaki görüntüden 255 tanesi doğru olarak tespit edilirken, 241 adet COVID-19 sınıflandırmadaki görüntüden 231 adet COVID-19 görüntüsünün doğru olarak tespit edildiği görülmektedir. Ayrıca test veri setinde yer alan 269 adet viral pnömoni sınıflandırmasındaki görüntüden 261 tanesi doğru olarak tespit edilmiştir. Eğitime tabi tutulan modelin, ölçüm parametreleri ile değer sonuçları Tablo 3.4' te belirtilmiştir.

Tablo 3.4. VGG-16 Modeli Ölçüm Parametre Sonuçları

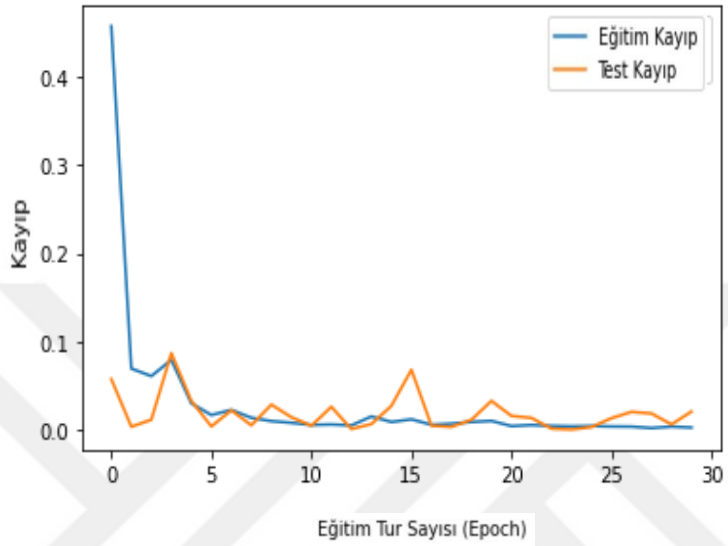
Ölçüm Parametreleri	**Sonuçlar**
Kesinlik	% 97.1
Duyarlılık	% 96.2
F-1 Skoru	% 94.3
Doğruluk	% 96.7
Eğitim Süresi	4 Saat 24 Dakika

VGG-16 modeli ile yapılan 4 saat 24 dakika süren eğitimler sonucunda en yüksek % 96.7 doğruluk oranı elde edilirken, % 96.2 duyarlılık oranı ile doğruluk oranına çok yakın olduğu ve modelin hassasiyet değerinin yüksek olduğu tespit edilmiştir. Aynı model üzerinde % 97.1 kesinlik değeri ile, % 94.3 F-1 skoru elde edilmiştir. Bir modelin doğru değerlendirilebilmesi için doğruluk (Acc) ve kayıp (Loss) değerlerini incelemek gerekmektedir. Çalışmada eğitim tekrarına bağlı olarak oluşan Acc ve Loss grafikleri Şekil 3.2 ve Şekil 3.3'te belirtilmiştir.



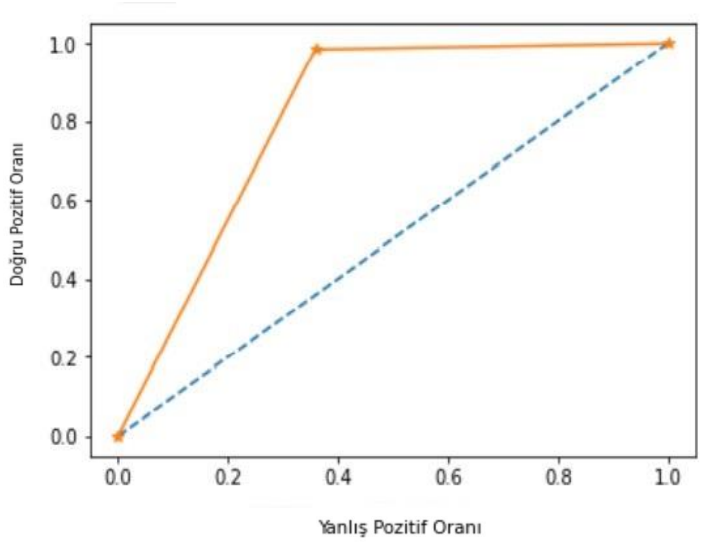
Şekil 3.2. VGG-16 Modeli Eğitim-Test Doğruluk Grafiği

Modelin eğitimi sırasında eğitim doğruluk grafiği, 3. eğitim turunda % 95.89 değerine ulaşmış olup, 9. eğitim turunda en yüksek doğruluk oranı olan % 96.7 değeri elde edilmiştir. İlerleyen eğitim tur sayılarında başarı oranında küçük düşmeler meydana gelmiş olsa da, 20. eğitim turundan itibaren doğruluk oranı yatay seyirde ilerlemiştir.



Şekil 3.3. VGG-16 Modeli Eğitim-Test Kayıp Grafiği

Şekil 3.3 incelendiğinde ise, eğitim doğruluk grafiğine paralel olarak kayıpların doğruluk seviyesinde azaldığı ve 10. eğitim tur sayısından itibaren yatay bir seyir gösterdiği görülmektedir. Modelin en yüksek eğitim kayıp değeri 3. eğitim turunda 0.07 olarak ölçülmüştür. VGG-16 modeli uygulandıktan sonra en yüksek Acc değeri yaklaşık 0.97, Roc-Auc değeri ise 0.88 olarak tespit edilmiştir. Modele ait Roc-Auc değeri Şekil 3.4'te belirtilmiştir. Roc eğrisinin altında bulunan bölüm AUC değerini belirlemektedir. Auc, ayrılabilirliğin ölçüsünü yani sınıflar arasındaki ayrım başarısını temsil etmektedir.



Şekil 3.4. VGG-16 Modeli Roc-Auc Değişimi

Bir modelin doğruluğunun 1'e yakın olması, o modelin eğitim başarısını gösterdiği gibi, kayıp oranlarının 0'a yakın olması da eğitimin doğruluğunu desteklemektedir. Uygulanan VGG-16 modeli için uygulanan deneysel çalışma 30 eğitim tur sayısı için toplamda 4 saat 24 dakika sürmüştür. Modelin filtre görüntüleri ayrıntılı olarak incelendiğinde bazı ileri katmanlarda kompleks çıktılar verdiği görülmektedir. Bu modelde 1. Katmanda 64 filtresi olarak 1x224*224*64 gözlemlenmektedir. Katman ilerledikçe filtrenin X-Ray görüntüsü üzerinde aradığı özellikler artmaktadır.

3.2.2. ResNet-50 Modeli Sonuçları

34 katmanın yer aldığı ağdaki her 2 katmanlı bloğu darboğaz yoluyla değiştirerek 3 katmanlı hale getiren ResNet-50 modeli, ImageNet veri seti ile önceden eğitilmiş model ağırlığına sahiptir. ResNet-50, 50 katman derinliğinde kıvrımlı bir sinir ağından oluşmaktadır. Tasarlanan ResNet-50 modelinde optimizasyon fonksiyonu olarak Adam tercih edilmiştir. Modelin erken durdurma değeri olarak 5 tercih edilirken, öğrenme oranı olarak 0.001 belirlenmiştir. Modelde eğitim tur sayısı 30 olarak belirlenmiştir. Kurulan modele ait parametre değerleri Tablo 3.5'te belirtilmiştir.

Tablo 3.5. ResNet-50 Modeli Kullanılan Parametre Değerleri

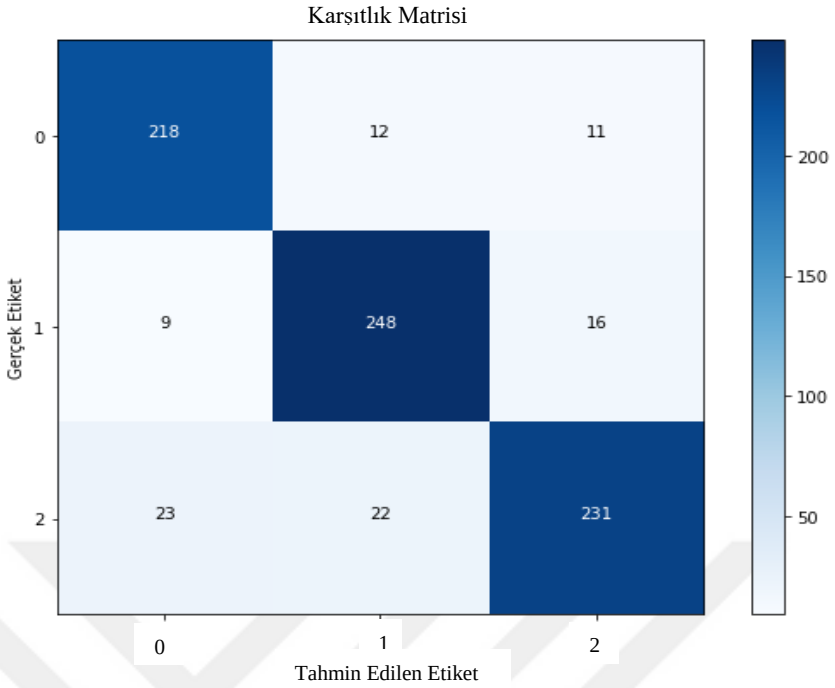
Parametreler	**Değerler**
Evrişim Katmanı	42
Maksimum Havuzlama Katmanı	7
Seyreltme Katmanı	--
Ortalama Havuzlama Katmanı	10
Yığın Normalleştirme	42
Tam Bağlı Katman	3
Optimizasyon Modeli	ADAM
Öğrenme Oranı	0.001
Aktivasyon Fonksiyonu	Relu - Softmax
Erken Durdurma Değeri	5
Yığın Boyutu (Batch Size)	32
Tekrar Sayısı	30

Çalışma kapsamında kurulan ResNet-50 modeline ait model özeti ise Tablo 3.6'da belirtilmiştir.

Tablo 3.6. ResNet-50 Model Özeti

Model Parametreleri	**Parametre Sayıları**
Toplam Parametre Sayısı	28.282.562
Eğitilebilir Parametre Sayısı	12.702.566
Eğitime Girmeyen Parametre Sayısı	15.579.996

Oluşturulan ResNet-50 modeline ait tahmin edilen değerler ile gerçek değerlerin karşılaştırılması amacıyla oluşturulan karşıtlık matrisi Şekil 3.5'te belirtilmiştir.



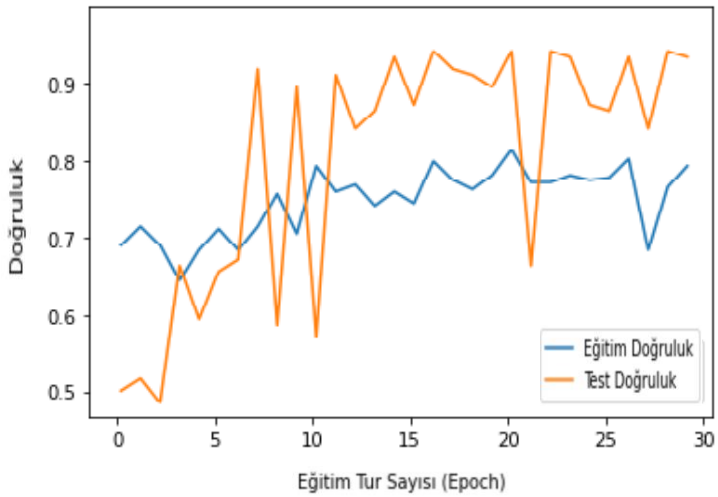
Şekil 3.5. ResNet-50 Modeli Karşıtlık Matrisi

Modele ait karşıtlık matrisi incelendiğinde test veri setinde yer alan 269 adet normal sınıflandırmadaki görüntüden 231 adeti doğru olarak tespit edilirken, 241 adet COVID-19 sınıflandırmadaki görüntüden 218 adet COVID-19 görüntüsünün doğru olarak tespit edildiği görülmektedir. Ayrıca test veri setinde yer alan 269 adet viral pnömoni sınıflandırmasındaki görüntüden 248 tanesi doğru olarak tespit edilmiştir. Model sonucunda, 16 adet COVID-19 görüntüsünün viral pnomöni olarak tespit edildiği görülmektedir. 23 adet viral pnomöni hastası ise normal hasta olarak yanlış sınıflandırılmıştır. Eğitime tabi tutulan modelin ölçüm parametreleri ile değer sonuçları Tablo 3.7'de belirtilmiştir.

Tablo 3.7. ResNet-50 Modeli Ölçüm Parametre Sonuçları

Ölçüm Parametreleri	**Sonuçlar**
Kesinlik	% 90.8
Duyarlılık	% 93.1
F-1 Skoru	% 89.8
Doğruluk	% 92.7
Eğitim Süresi	6 Saat 17 Dakika

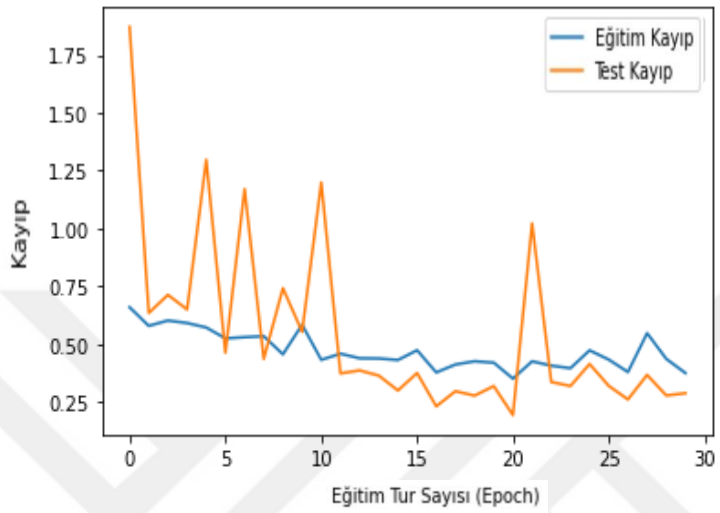
ResNet-50 modeli ile yapılan 6 saat 17 dakika süren eğitimler sonucunda en yüksek % 92.7 doğruluk oranı elde edilirken, % 93.1 duyarlılık oranı tespit edilmiştir. Aynı model üzerinde % 90.8 kesinlik değeri ile, % 89.8 F-1 skoru elde edilmiştir. Bir modelin doğru değerlendirilebilmesi için Acc ve Loss değerlerini incelemek gerekmektedir. Eğitim tekrarına bağlı olarak oluşan Acc ve Loss grafikleri Şekil 3.6'da ve Şekil 3.7'de belirtilmiştir.



Şekil 3.6. ResNet-50 Modeli Eğitim-Test Doğruluk Grafiği

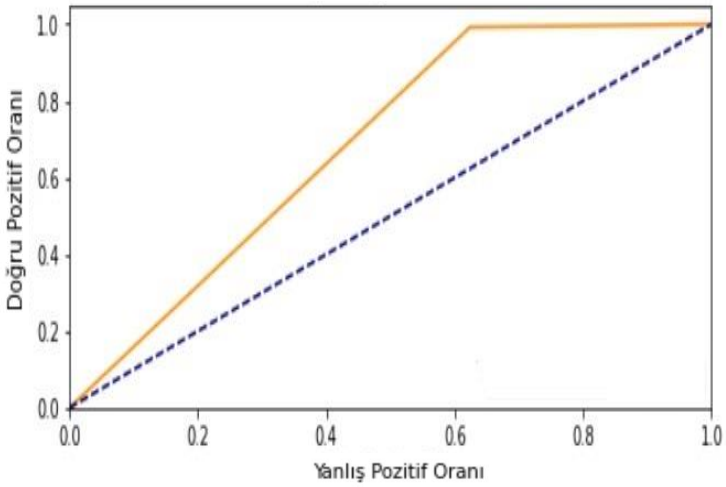
Modelin eğitimi sırasında test doğruluğu grafiği 8. eğitim turunda % 92.1 değerine ulaşmış olup, 22. eğitim turunda en yüksek doğruluk oranı olan % 92.7 değeri elde edilmiştir. Modelin test doğruluğu eğitim doğruluğunun üst değerlerinde doğru sonuçlar verirken,

modelin bazı eğitim turlarında kayıpların arttığı görülmüştür. Şekil 3.7'de belirtilen eğitim-test kayıp grafiği incelendiğinde ise, modelin eğitim kaybının 0.72 değerinden alt seviyelere gerilediği görülmüştür. Doğruluk grafiğine paralel olarak modelin eğitimi sırasında bazı eğitim tur sayılarında test kayıplarının yüksek değerlere ulaştığı tespit edilmiştir.



Şekil 3.7. ResNet-50 Modeli Eğitim-Test Kayıp Grafiği

ResNet-50 modeli uygulandıktan sonra en yüksek Acc değeri, yaklaşık 0.93, Roc-Auc değeri ise 0.69 olarak tespit edilmiştir. Modele ait Roc-Auc değeri Şekil 3.8'de belirtilmiştir. Roc eğrisinin altında bulunan bölüm AUC değerini belirlemektedir. Auc, ayrılabilirliğin ölçüsünü yani sınıflar arasındaki ayrım başarısını temsil etmektedir. Oluşturulan ResNet-50 modelinin birinci katman boyutları 1x229x229x64 şeklinde olup, birinci katmanda 64 filtre bulunmaktadır. Birinci katmanda yer alan görüntüler incelendiğinde ResNet-50 modelinin kenar çıktılarından ziyade akciğer geneline odaklandığı görülmektedir. Dokuzuncu katmanda yer alan 256 filtre boyutunda etiket kenarlarına odaklandığı görülmüştür.



Şekil 3.8. ResNet-50 Modeli Roc-Auc Değişimi

3.2.3. DenseNet-121 Modeli Sonuçları

İlk evrişim katmanında 7x7 filtre kullanılan DenseNet-121 mimarisinin maksimum havuzlama katmanında 3x3'lük filtreler kullanılmaktadır. Adım sayısı olarak 2 tercih edilmiştir. Yoğun işlem bloklarında adım sayısı olarak 1 kullanılırken, aynı bloklarda 1x1 ve 3x3'lük filtreler kullanılmıştır. Ortalama havuzlama katmanında filtre boyutu olarak 2x2 filtre kullanılarak, adım sayısı 2 tercih edilmiştir. Kurulan modele ait parametre değerleri Tablo 3.8'de belirtilmiştir.

Tablo 3.8. DenseNet-121 Modeli Kullanılan Parametre Değerleri

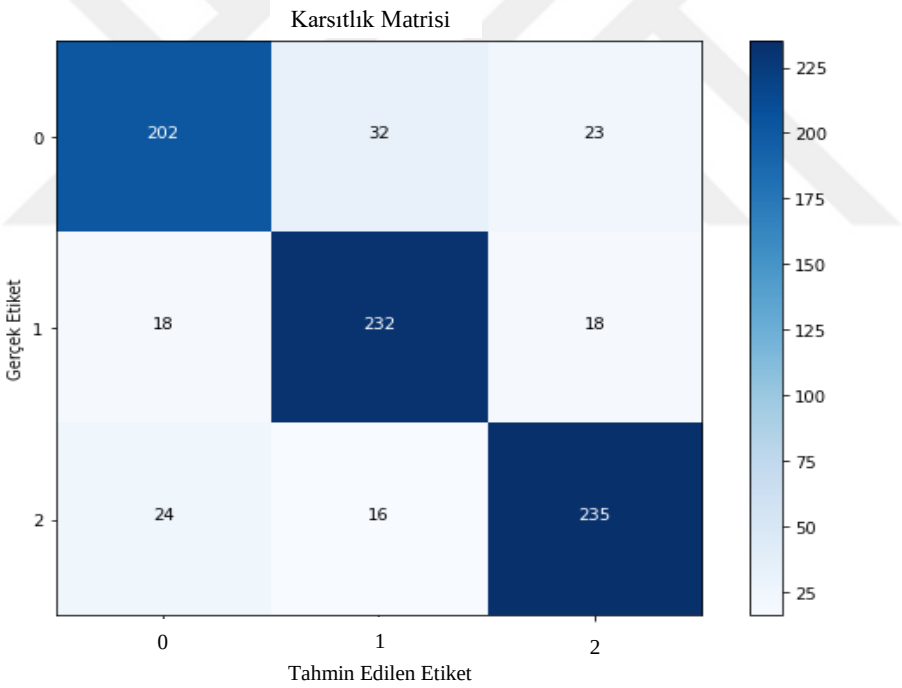
Parametreler	**Değerler**
Evrişim Katmanı	18
Maksimum Havuzlama Katmanı	10
Seyreltme Katmanı	--
Ortalama Havuzlama Katmanı	8
Yığın Normalleştirme	18
Tam Bağlı Katman	4
Optimizasyon Modeli	ADAM
Öğrenme Oranı	0.001
Aktivasyon Fonksiyonu	Relu - Softmax
Erken Durdurma Değeri	5
Yığın Boyutu (Batch Size)	32
Tekrar Sayısı	30

Çalışma kapsamında kurulan DenseNet-121 modeline ait model özeti ise Tablo 3.9'da belirtilmiştir.

Tablo 3.9. DenseNet-121 Model Özeti

Model Parametreleri	**Parametre Sayıları**
Toplam Parametre Sayısı	34.123.687
Eğitilebilir Parametre Sayısı	23.152.456
Eğitime Girmeyen Parametre Sayısı	10.971.231

Oluşturulan DenseNet-121 modeline ait tahmin edilen değerler ile gerçek değerlerin karşılaştırılması amacıyla oluşturulan karşıtlık matrisi Şekil 3.9'da belirtilmiştir.



Şekil 3.9. DenseNet-121 Modeli Karşıtlık Matrisi

Modele ait karşıtlık matrisi incelendiğinde test veri setinde yer alan 269 adet normal sınıflandırmadaki görüntüden 235 tanesi doğru olarak tespit edilirken, 241 adet COVID-19 sınıflandırmadaki görüntüden 202 adet COVID-19 görüntüsünün doğru olarak tespit edildiği görülmektedir. Ayrıca test veri setinde yer alan 269 adet viral pnömoni sınıflandırmasındaki görüntüden 232 tanesi doğru olarak tespit edilmiştir. Modelde sonucunda, 18 adet COVID-

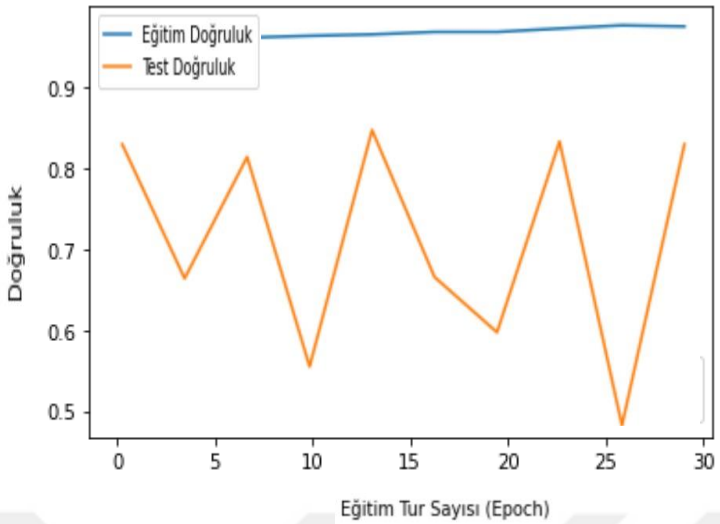
19 görüntüsünün viral pnomöni olarak tespit edildiği görülürken, 16 adet viral pnomöni hastası ise COVID-19 hastası olarak yanlış sınıflandırılmıştır.

Tasarlanan DenseNet-121 modelinde erken durdurma değeri 5 tercih edilirken, model yeniden eğitime tabi tutulmayıp, transfer öğrenme yaklaşımı kullanılmıştır. Mimarilerin eğitimi ImageNet ağırlığı ile başlatılmıştır. Modelde eğitim tur sayısı 30 olarak belirlenmiştir. Eğitime tabi tutulan modelin ölçüm parametreleri ile değer sonuçları Tablo 3.10'da belirtilmiştir.

Tablo 3.10. DenseNet-121 Modeli Ölçüm Parametre Sonuçları

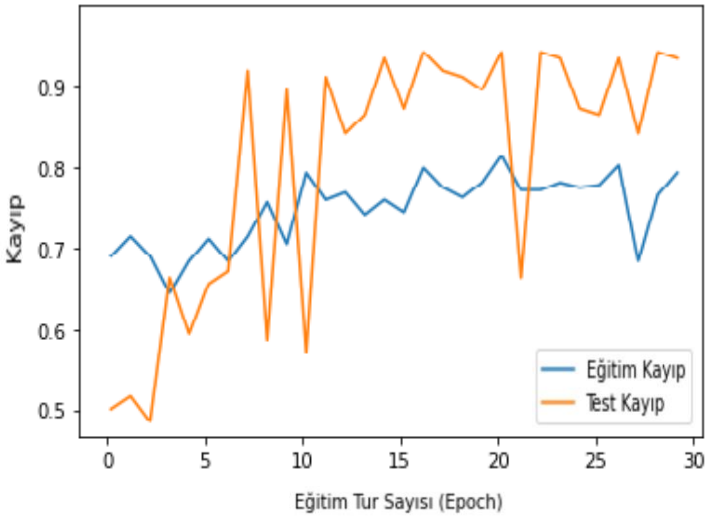
Ölçüm Parametreleri	**Sonuçlar**
Kesinlik	% 89.7
Duyarlılık	% 88.4
F-1 Skoru	% 90.2
Doğruluk	% 91.6
Eğitim Süresi	3 Saat 42 Dakika

DenseNet-121 modeli ile yapılan 3 saat 42 dakika süren eğitimler sonucunda en yüksek % 91.6 doğruluk oranı elde edilirken, % 88.4 duyarlılık oranı tespit edilmiştir. Aynı model üzerinde % 89.7 kesinlik değeri ile, % 90.2 F-1 skoru elde edilmiştir. Bir modelin doğru değerlendirilebilmesi için Acc ve Loss değerlerini incelemek gerekmektedir. Eğitim tekrarına bağlı olarak oluşan Acc ve Loss grafikleri Şekil 3.10'da ve Şekil 3.11'de belirtilmiştir.



Şekil 3.10. DenseNet-121 Modeli Eğitim-Test Doğruluk Grafiği

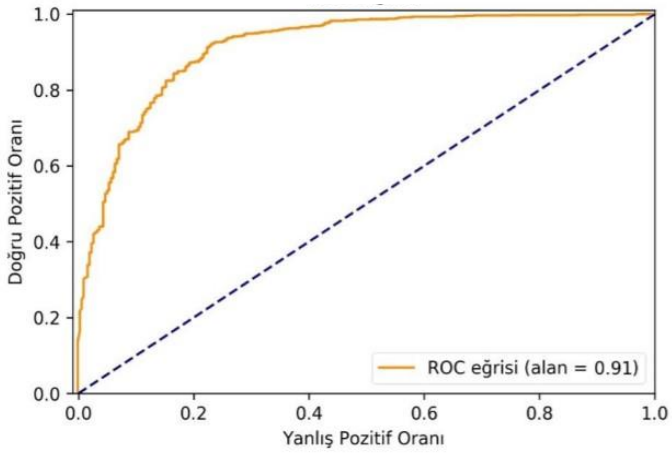
Modelin eğitimi sırasında eğitim doğruluğu ile test doğruluğu grafiğinin ayrıştığı görülmektedir. Bu durum modelde gerçekleşen duyarlılık oranlarının düşmesinden meydana gelmektedir. Modelin parametre değerlerinden kaynaklanan bu durum ile modelin kayıplarının belirli aralıklarla yükseldiği görülmüştür. Modelin eğitim doğruluğu 27. eğitim tur sayısında en yüksek %91.6 olarak tespit edilmiştir.



Şekil 3.11. DenseNet-121 Modeli Eğitim-Test Kayıp Grafiği

Şekil 3.11'de belirtilen eğitim-test kayıp grafiği incelendiğinde ise, modelin test kaybının eğitim kayıplarından daha yüksek olduğu görülmektedir. Bu durum duyarlılık oranlarındaki

düşmeyi meydana getirmektedir. Model eğitiminin 19. eğitim tur sayısında en yüksek 0.77 kayıp oranı elde edilmiştir. DenseNet-121 modeli uygulandıktan sonra en yüksek Acc değeri yaklaşık 0.91, Roc-Auc değeri ise 0.91 olarak tespit edilmiştir. Modele ait Roc-Auc değeri Şekil 3.12'de belirtilmiştir. Roc eğrisinin altında bulunan bölüm AUC değerini belirlemektedir. Auc, ayrılabilirliğin ölçüsünü yani sınıflar arasındaki ayrım başarısını temsil etmektedir. Oluşturulan DenseNet-121 modelinin birinci katman boyutları 1x229x229x64 şeklinde olup, birinci katmanda 64 filtre bulunmaktadır. Uygulanan modelin toplam parametre sayısı 34.123.687'dir.



Şekil 3.12. DenseNet-121 Modeli Roc-Auc Değişimi

3.2.4. Inception V3 Modeli Sonuçları

94 evrişim, toplu normalleştirme ve 2 tam bağlı katmandan oluşan Inception V3 modelinde havuzlama katmanı olarak 4 maksimum katman kullanılmıştır. Model tasarımı kurulduktan sonra ağırlık başlatma işlemi yapılmıştır. ImageNet ağırlığı ile başlatılan modelde optimizasyon olarak Adam kullanılmıştır. Önceki modellerde de olduğu gibi öğrenme oranı olarak 0.001, erken durdurma olarak 5 belirlenmiştir. Kurulan modele ait parametre değerleri Tablo 3.11'de belirtilmiştir.

Tablo 3.11. Inception V3 Modeli Kullanılan Parametre Değerleri

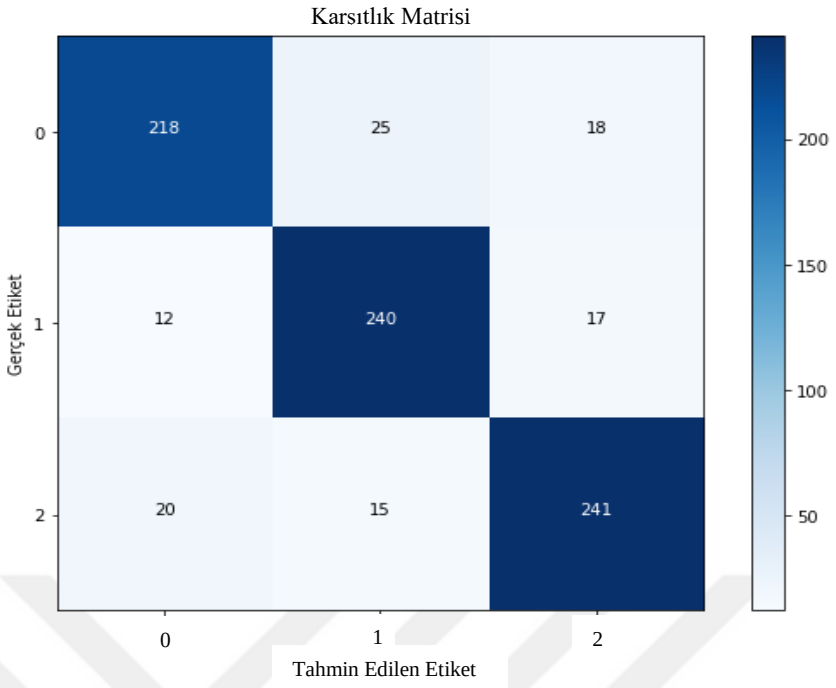
Parametreler	**Değerler**
Evrişim Katmanı	94
Maksimum Havuzlama Katmanı	4
Seyreltme Katmanı	1
Ortalama Havuzlama Katmanı	10
Yığın Normalleştirme	94
Tam Bağlı Katman	2
Optimizasyon Modeli	ADAM
Öğrenme Oranı	0.001
Aktivasyon Fonksiyonu	Relu - Softmax
Erken Durdurma Değeri	5
Yığın Boyutu (Batch Size)	32
Tekrar Sayısı	30

Çalışma kapsamında kurulan Inception V3 modeline ait model özeti ise Tablo 3.12'de belirtilmiştir.

Tablo 3.12. Inception V3 Model Özeti

Model Parametreleri	**Parametre Sayıları**
Toplam Parametre Sayısı	25.476.386
Eğitilebilir Parametre Sayısı	3.673.602
Eğitime Girmeyen Parametre Sayısı	21.802.784

Oluşturulan Inception V3 modeline ait tahmin edilen değerler ile gerçek değerlerin karşılaştırılması amacıyla oluşturulan karşıtlık matrisi Şekil 3.13'te belirtilmiştir.



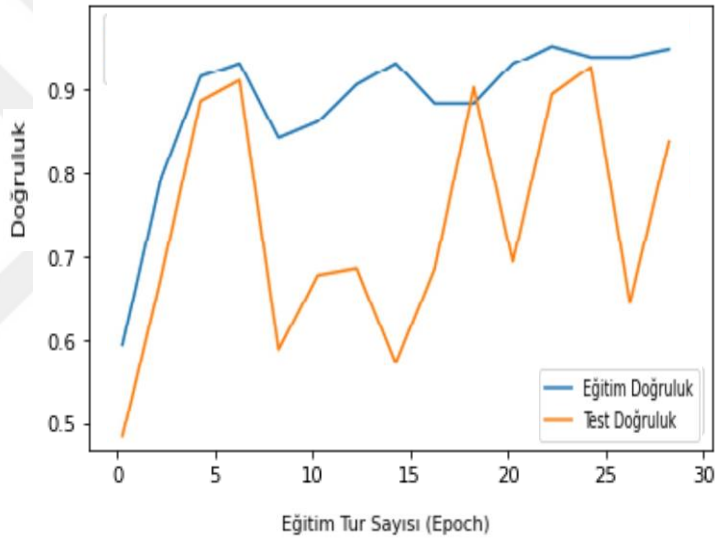
Şekil 3.13. Inception V3 Modeli Karşıtlık Matrisi

Modele ait karşıtlık matrisi incelendiğinde test veri setinde yer alan 269 adet normal sınıflandırmadaki görüntüden 241 tanesi doğru olarak tespit edilirken, 240 adet COVID-19 sınıflandırmadaki görüntüden 218 adet COVID-19 görüntüsünün doğru olarak tespit edildiği görülmektedir. Ayrıca test veri setinde yer alan 269 adet viral pnömoni sınıflandırmasındaki görüntüden 241 tanesi doğru olarak tespit edilmiştir. Eğitime tabi tutulan modelin ölçüm parametreleri ile değer sonuçları ise Tablo 3.13'te belirtilmiştir.

Tablo 3.13. Inception V3 Modeli Ölçüm Parametre Sonuçları

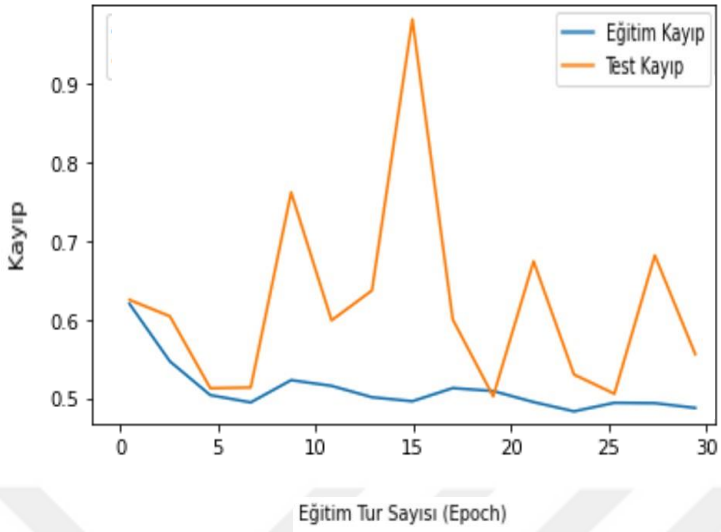
Ölçüm Parametreleri	**Sonuçlar**
Kesinlik	% 92.1
Duyarlılık	% 91.7
F-1 Skoru	% 90.7
Doğruluk	% 90.9
Eğitim Süresi	2 Saat 23 Dakika

Inception V3 modeli ile yapılan 2 saat 23 dakika süren eğitimler sonucunda en yüksek % 90.7 doğruluk oranı elde edilirken, % 91.7 duyarlılık oranı tespit edilmiştir. Aynı model üzerinde % 92.1 kesinlik değeri ile, % 90.7 F-1 skoru elde edilmiştir. Sonuçlar incelendiğinde VGG-16 modeline göre tüm parametrelerin sonuçlarında düşüş olduğu görülmektedir. Uygulanan diğer modellere göre duyarlılık parametresinde düzelme meydana gelmiş olsa da bu değer yeterince yüksek değildir. Şekil 3.13'te verilen karşıtlık matrisi incelendiğinde de bir önceki modellere göre COVID-19 tespitinin daha az olduğu ve hata kayıplarının meydana geldiği görülmektedir. Bir modelin doğru değerlendirilebilmesi için Acc ve Loss değerlerini de incelemek gerekmektedir. Eğitim tekrarına bağlı olarak oluşan Acc ve Loss grafikleri Şekil 3.14'de ve Şekil 3.15'de belirtilmiştir.



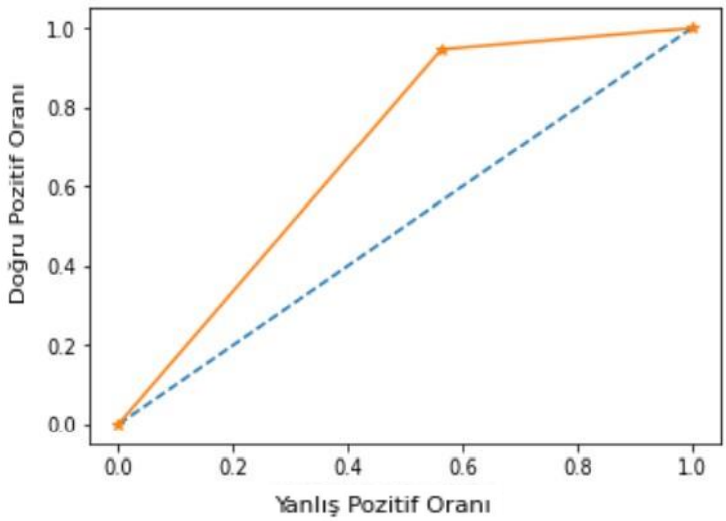
Şekil 3.14. Inception V3 Modeli Eğitim-Test Doğruluk Grafiği

Modelin duyarlılığının başarı sonuçlar vermesi sonucunda eğitim doğruluk grafiği test doğruluk grafiğinin üzerinde görülmektedir. Modelin eğitimi sırasında en yüksek doğruluk değeri 23. eğitim tur sayısında % 90.9 olarak tespit edilmiştir. Modelin katman geçişlerinde eğitim kayıplarının yükseldiği ve bu kayıpların F-1 skorunu doğrudan etkilediği tespit edilmiştir. Modelin 15. eğitim turunda en yüksek 0.98 kayıp değeri gözlemlenmiştir (Şekil 3.15).



Şekil 3.15. Inception V3 Modeli Eğitim-Test Kayıp Grafiği

Inception V3 modeli uygulandıktan sonra en yüksek Acc değeri yaklaşık 0.92, Roc-Auc değeri ise 0.90 olarak tespit edilmiştir. Modele ait Roc-Auc değeri Şekil 3.16'da belirtilmiştir. Roc eğrisinin altında bulunan bölüm AUC değerini belirlemektedir. Auc, ayrılabilirliğin ölçüsünü yani sınıflar arasındaki ayrım başarısını temsil etmektedir. Inception V3 modelinin birinci katmanında 1x111x111x32 şeklinde 32 filtresi uygulanmaktadır. Aynı modelin dokuzuncu katmanında ise 64 filtresi bulunmaktadır. Her iki filtrenin farklı katman boyutlarında farklı noktalara odaklandığı görülmektedir.



Şekil 3.16. Inception V3 Modeli Roc-Auc Değişimi

3.2.5. Modellerin Ölçüm Sonuçlarının Karşılaştırılması

COVID-19 tespiti amacıyla akciğer X-ray görüntülerinden 4 farklı derin öğrenme modelinin deneysel modellemelerinin yapıldığı bu çalışmada sırasıyla VGG-16, ResNet-50, DenseNet-121 ve Inception V3 mimarilerinde veri seti eğitime tabi tutulmuştur. Tüm modellerde eğitim tekrar sayısı 30 olarak uygulanmıştır. Modeller uygulamaya konulmadan önce veri setindeki tüm görüntülerin renk katmanları ön işleme tabi tutulmuştur. Uygulanan dört model için deney sonuçları Tablo 3.14'te belirtilmiştir.

Tablo 3.14. Uygulanan Modellerin Ölçüm Sonuçlarının Karşılaştırılması

Model Adı	**Kesinlik**	**Duyarlılık**	**F-1 Skoru**	**Doğruluk**
VGG-16	% 97.1	% 96.2	% 94.3	**% 96.7**
ResNet-50	% 90.8	% 93.1	% 89.8	% 92.7
DenseNet-121	% 89.7	% 88.4	% 90.2	% 91.6
Inception V3	% 92.1	% 91.7	% 90.7	% 90.9

Deneysel çalışmada kullanılan tüm modeller rastgele bölünmüş veri kümesindeki yöntem ile çalışılmış olup, Inception modelinin filtre boyutu özelliğinden dolayı kesinlik değerinin ResNet-50 ve DenseNet-121 modelinden yüksek çıktığı görülmüştür. Katman sayısındaki artış ile ResNet-50 modelinin duyarlılık parametresinde ciddi bir artış meydana gelirken, modelin güvenirliği hakkında yol gösteren Auc değerinde ciddi bir artış meydana gelmemiştir. Veri setinde yer alan görüntülerin fazla olması sebebiyle eğitim süreleri uzun sürmüştür. Uygulanan modeller arasında en fazla eğitim süresi ResNet-50 ile elde edilirken, en kısa eğitim süresi Inception V3 modelinde elde edilmiştir.

SONUÇ VE ÖNERİLER

2019 yılının son aylarında Çin'de başlayıp tüm dünyaya yayılarak halen etkisini gösteren COVID-19 pandemisi farklı varyantları ile insan hayatını tehdit etmeye devam etmektedir. Dünya genelinde günde yüzbinlerce insan hastalığa yakalanmakta olup, pek çok insan hayatını kaybetmektedir. COVID-19 hastalığı günlük hayatı da olumsuz etkileyerek çoğu insanın hayatını değiştirmiştir. İnsandan insana yayılım gösteren bu hastalığın hızlı bir şekilde tespit edilmesi insanların sağlığı ve sağlık sistemi açısından önem taşımaktadır.

Akciğer X-Ray görüntüleri COVID-19 hastalığının tespiti için önemli tanı araçları arasında yer almaktadır. Ancak COVID-19, X-Ray görüntüleri ile viral pnömoni X-Ray görüntüleri arasında benzerlik ve ortak özellikler bulunmaktadır. Bu durum radyologların teşhis koymasında işlerini zorlaştırmakta ve yanlış tanı sonuçlarına yol açmaktadır. Bu çalışmada, derin öğrenme yöntemleri ile halka açık veri seti üzerinde deneysel çalışmalar yapılmıştır. COVID-19, viral pnömoni ve normal olmak üzere toplam 3886 adet görüntünün yer aldığı veri seti test, eğitim ve doğrulama için ayrılmıştır. Veri seti üzerinde VGG-16, ResNet-50, DenseNet-121 ve Inception V3 gibi son teknoloji transfer öğrenme modellerinde deneysel çalışmalar gerçekleştirilmiştir.

COVID-19 hastalığını tespit etmek amacıyla geliştirilen çalışmanın sonucunda en yüksek doğruluk oranı % 96.7 ve en yüksek kesinlik değeri % 97.1 ile VGG-16 modelinde tespit edilmiştir. Çalışma kapsamında veri seti görüntüleri üzerinde güncel segmentasyon işlemleri uygulanması ile görüntülerin daha adaptif hale getirilmesi bu çalışmanın ayırt edici özelliklerinden birisidir. Ayrıca veri seti sayısının literatürdeki pek çok çalışmaya göre yüksek olması ve bunun sonucunda elde edilen başarı oranı bu çalışmanın önemini vurgulamaktadır.

COVID-19 hastalarının X-Ray görüntüleri ile sınıflandırma işlemlerinde yüksek doğruluk sonuçlarının edildiği bu çalışma, COVID-19 hastalarına erken teşhis koymak, benzer akciğer

hastalıkları ile ayırt edici özellikleri belirlemek, hastaların hızlı bir şekilde izolasyonlarını sağlamak, radyologların ve sağlık çalışanlarının iş yükünü hafifletmek ve salgını kontrol altına almak açısından önemlidir. Bu çalışma ile elde edilen sonuçların, COVID-19 hastalığını tespit etmek için kullanılan RT-PCR testlerine oranla daha yüksek doğruluk oranına sahip olması bu çalışmanın potansiyelini ortaya koymaktadır.

Çalışmalarda kullanılan modellerin performansı veri seti sayısı ile doğrudan bağlantılıdır. Veri setindeki görüntülerin daha fazla olması derin öğrenme modellerinden elde edilen performansın doğruluğunu ortaya koymaktadır. Bu çalışmada kullanılan veri setinin halka açık bir veri seti olması ve veri setindeki görüntülerin sınırlı olması bu çalışmanın sınırlılıkları arasında yer almaktadır. Gelecekte yapılacak olan çalışmalarda, daha geniş ve özgün veri setleri ile derin öğrenme modelleri incelenebilir. Ayrıca bu çalışmada dört adet derin öğrenme modelinin sonuçları kıyaslanmış olup, gelecekte yapılacak olan çalışmalarda farklı derin öğrenme modelleri ile deneyler gerçekleştirilerek karşılaştırma yapılabilir.

KAYNAKÇA

Abdulghani, S., Fadhil, A. ve Gültekin, S. S. (2020). Transfer learning using alexnet with support vector machine for breast cancer detection. *Avrupa Bilim ve Teknoloji Dergisi*, *141*(23), 423-430.

Afshar, P., Heidarian, S., Naderkhani, F., Oikonomou, A., Plataniotis, K. N. ve Mohammadi, A. (2020). COVID-CAPS: A capsule network-based framework for identification of COVID-19 cases from X-ray images. *Pattern Recognition Letters*, *138*(4), 638–643.

Aggarwal, C. C. (2018). *Neural networks and deep learning*. USA: Springer.

Albahli, S., Ayub, N., ve Shiraz, M. (2021). Coronavirus disease (COVID-19) detection using X-ray images and enhanced DenseNet. *Applied Soft Computing*, *110*(7), 107645.

Alsharif, W. ve Qurashi, A. (2021). Effectiveness of COVID-19 diagnosis and management tools: A review. *Radiography (London, England: 1995)*, *27*(2), 682–687.

Altındiş, M., ve Toptan, H. (2020). SARS CoV-2 laboratuvar tanısı. *Journal of Biotechnology and Strategic Health Research, 4*(32), *76-84.*

Alwazzan, M. J., Ismael, M. A., ve Ahmed, A. N. (2021). A hybrid algorithm to enhance colour retinal fundus images using a wiener filter and CLAHE. *Journal of Digital Imaging*, *34*(3), 750–759.

Amerika Gıda ve İlaç Dairesi (FDA), (2020). Coronavirus (COVID-19) update: FDA authorizes antigen test as first over-the-counter fully at-home diagnostic test for COVID-19. 04.02.2022 tarihinde https://www.fda.gov/news-events/press- 50 announcements/coronavirus-covid-19-update-fda-authorizes-antigen-test-first-over-counter-fully-home sayfasından erişilmiştir.

Andersen, K. G., Rambaut, A., Lipkin, W. I., Holmes, E. C. ve Garry, R. F. (2020). The proximal origin of SARS-CoV-2. *Nature Medicine*, *26*(4), 450–452.

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*, *43*(2), 635-640.

Apostolopoulos, I. D., Aznaouridis, S. I. ve Tzani, M. A. (2020). Extracting possibly representative COVID-19 biomarkers from X-ray images with deep learning approach and image data related to pulmonary diseases. *Journal of Medical& Biological Engineering*, 1–8.

Atalay, M. ve Çelik, E. (2017). Büyük veri analizinde yapay zekâ ve makine öğrenmesi uygulamalari. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, *9*(22), 155-172.

Bhattacharyya, A., Bhaik, D., Kumar, S., Thakur, P., Sharma, R., Pachori, R.B. (2022). A deep learning based approach for automatic detection of COVID-19 cases using chest X-ray images. *Biomedical Signal Processing&Control*, 71, 103182.

Bozkurt, F., ve Yağanoğlu, M. (2021). Derin evrişimli sinir ağları kullanarak akciğer X-Ray görüntülerinden COVID-19 tespiti. *Veri Bilimi*, *4*(2), 1-8.

Carsetti, R., Quinti, I. ve Locatelli, F. (2021). COVID-19-pathogenesis and immunological findings across the clinical manifestation spectrum. *Current Opinion in Pulmonary Medicine*, *27*(3), 193–198.

Chams, N., Chams, S., Badran, R., Shams, A., Araji, A., Raad, M., Mukhopadhyay, S., Stroberg, E., Duval, E. J., Barton, L. M., ve Hajj Hussein, I. (2020). COVID-19: A multidisciplinary review. *Frontiers in Public Health*, *8*(43), 383.

Chan, J. F., Lau, S. K., To, K. K., Cheng, V. C., Woo, P. C. ve Yuen, K. Y. (2015). Middle East respiratory syndrome coronavirus: Another zoonotic betacoronavirus causing SARS-like disease. *Clinical Microbiology Reviews*, *28*(2), 465–522.

Chen, N., Zhou, M., Dong, X., Qu, J., Gong, F., Han, Y., Qiu, Y., Wang, J., Liu, Y., Wei, Y., Xia, J., Yu, T., Zhang, X. ve Zhang, L. (2020). Epidemiological and clinical characteristics of 99 cases of 2019 novel coronavirus pneumonia in Wuhan, China: A descriptive study. *Lancet (London, England)*, *395*(10223), 507–513.

Chowdhury, M. E., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B. ve Islam, M. T. (2020). Can AI help in screening viral and COVID-19 pneumonia?. *IEEE Access, 8*, 132665-132676.

Doğan, F. ve Türkoğlu, İ. (2018). Derin öğrenme algoritmalarının yaprak sınıflandırma başarımlarının karşılaştırılması. *Sakarya University Journal of Computer and Information Sciences*, *1*(1), 10-21.

Dünya Sağlık Örgütü (DSÖ), (2020). Coronavirus disease (COVID-19) situation reports, 04.02.2022 tarihinde https://www.who.int/emergencies/diseases/novel-coronavirus 2019/situation-reports / sayfasından erişilmiştir.

Dünya Sağlık Örgütü (DSÖ), (2021). General's opening remarks at the media briefing on COVID19. 22.12.2021 tarihinde https://www.who.int/directorgeneral/speeches/detail/who-director-general-sopening-remarks-at-themedia-briefing-on-covid-19 sayfasından erişilmiştir.

Dünya Sağlık Örgütü (DSÖ), (2022a). COVID-19 Dünya geneli onaylanmış vaka ve ölüm sayıları. 04.02.2022 tarihinde https://covid19.who.int/sayfasından erişilmiştir.

Dünya Sağlık Örgütü (DSÖ), (2022b). COVID-19 Türkiye geneli onaylanmış vaka ve ölüm sayıları. 04.02.2022 tarihinde https://covid19.who.int/region/euro/country/tr / sayfasından erişilmiştir.

Dünya Sağlık Örgütü (DSÖ), (2022c). SARS-CoV-2 Varyantları. 04.02.2022 tarihinde https://www.who.int/en/activities/tracking-SARS-CoV-2-variants sayfasından erişilmiştir.

Elen, A. (2020). Görüntü ikileştirme için global eşikleme yöntemleri üzerine bir inceleme. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, *2*(2), 38-49.

Feldman, C. ve Anderson, R. (2012). Antibiotic resistance of pathogens causing community-acquired pneumonia. *Seminars in Respiratory & Critical Care Medicine*, *33*(3), 232–243.

Fulton, L. V., Dolezel, D., Harrop, J., Yan, Y., ve Fulton, C. P. (2019). Classification of alzheimer's disease with and without imagery using gradient boosted machines and ResNet-50. *Brain Sciences*, *9*(9), 212.

Gibson, A. , Patterson, J. (2017). Deep learning a practitioner's approach. *Controlling Epochs and Mini-Batch Size*, 6(2), 273-275.

Goodfellow, I., Bengio, Y. ve Courville, A. (2017). *Deep Learning*. MIT Press, 173-175

Gorbalenya, A. E., Baker, S. C., Baric, R. S., De Groot, R. J., Drosten, C., Gulyaeva, A. A ve Ziebuhr, J. (2020). The species severe acute respiratory syndrome-related coronavirus: Classifying 2019-nCoV and naming it SARS-CoV-2. Nat Microbiol; 5, 536–44.

Goutte, C. ve Gaussier, E. (2005, Mart). *A probabilistic interpretation of precision, recall and F-score, with implication for evaluation.* In European Conference On İnformation Retrieval Kongresi'nde sunulmuş bildiri, Santiago de Compostela, Spain.

Gupta, A., Gupta, S. ve Katarya, R., (2021). InstaCovNet-19: A deep learning classification model for the detection of COVID-19 patients using Chest X-ray. *Applied Soft Computing*, 99, 106859.

Hacıbeyoğlu, M. (2006). *Çoklu Etmen Mimarisi ve Takviyeli Öğrenme*. Yüksek Lisans Tezi, Selçuk Üniversitesi, Konya.

Havaei, M., Davy, A., Warde-Farley, D., Biard, A., Courville, A., Bengio, Y., Pal, C., Jodoin, P. M. ve Larochelle, H. (2017). Brain tumor segmentation with deep neural networks. *Medical Image Analysis*, *35*(23), 18–31.

Hemdan, E. E. D., Shouman, M. A., ve Karar, M. E. (2020). Covidx-net: A framework of deep learning classifiers to diagnose covid-19 in x-ray images. *ArXiv Preprint ArXiv:2003.11055*.

Hinton, G. E., Srivastava, N., Krizhevsky, A., Sutskever, I. ve Salakhutdinov, R. R. (2012). Improving neural networks by preventing co-adaptation of feature detectors. *ArXiv Preprint ArXiv:1207.0580*.

Horimoto, T. ve Kawaoka, Y. (2005). Influenza: Lessons from past pandemics, warnings from current incidents. *Nature Reviews. Microbiology*, *3*(8), 591–600.

Huang, G., Liu, Z., Van Der Maaten, L. ve Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4700-4708.

Huang, Q., Hao, B. ve Chang, S. (2016). Adaptive digital ridgelet transform and its application in image denoising. *Digital Signal Processing*, *52*(24), 45-54.

Ippolito, D., Pecorelli, A., Maino, C., Capodaglio, C., Mariani, I., Giandola, T., Gandola, D., Bianco, I., Ragusi, M., Talei Franzesi, C., Corso, R. ve Sironi, S. (2020). Diagnostic impact of bedside chest X-ray features of 2019 novel coronavirus in the routine admission at the emergency department: Case series from Lombardy region. *European Journal of Radiology*, *129*(67), 109092.

Islam, M. M., Karray, F., Alhajj, R., & Zeng, J. (2021). A review on deep learning techniques for the diagnosis of novel coronavirus (COVID-19). *IEEE access :Practical innovations, open solutions*, *9*, 30551–30572.

Ismael, A. M. ve Şengür, A. (2021). Deep learning approaches for COVID-19 detection based on chest X-ray images. *Expert Systems with Applications*, *164*(21), 114054.

Jafar, I. ve Ying, H. (2007). A new method for image contrast enhancement based on automatic specification of local histograms. *International Journal of Computer Science&Network Security*, *7*(7), 1-10.

Jang, J., Cho, H., Kim, J., Lee, J. ve Yang, S. (2020). Deep neural networks with a set of node-wise varying activation functions. *Neural Networks: The Official Journal of The International Neural Network Society*, *126*(93), 118–131.

Kaelbling, L. P., Littman, M. L. ve Moore, A. W. (1996). Reinforcement learning: A survey. *Journal of Artificial Intelligence Research*, *4*(9), 237-285.

Kanne, J. P., Little, B. P., Chung, J. H., Elicker, B. M. ve Ketai, L. H. (2020). Essentials for radiologists on COVID-19: An update-radiology scientific expert panel. *Radiology*, *296*(2), E113–E114.

Kavuncu, S. K. (2018). *Makine öğrenmesi ve derin öğrenme: Nesne tanıma uygulaması*. Yüksek Lisans Tezi, Kırıkkale Üniversitesi, Kırıkkale.

Kaynar, O., Aydın, Z. ve Görmez, Y. (2017). Sentiment analizinde öznitelik düşürme yöntemlerinin oto kodlayıcılı derin öğrenme makinaları ile karşılaştırılması. *Bilişim Teknolojileri Dergisi*, *10*(3), 319-326.

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 & Programs in Biomedicine*, *196*(26), 105581.

Khan, S. H., Sohail, A., Khan, A., Hassan, M., Lee, Y. S., Alam, J., Basit, A. ve Zubair, S. (2021). COVID-19 detection in chest X-ray images using deep boosted hybrid learning. *Computers in Biology & Medicine*, *137*, 104816.

Kucirka, L. M., Lauer, S. A., Laeyendecker, O., Boon, D. ve Lessler, J. (2020). Variation in false-negative rate of reverse transcriptase polymerase chain reaction-based SARS-CoV-2 tests by time Since exposure. *Annals of Internal Medicine*, *173*(4), 262–267.

Kumar Shukla, P., Kumar Shukla, P., Sharma, P., Rawat, P., Samar, J., Moriwal, R., ve Kaur, M. (2020). Efficient prediction of drug-drug interaction using deep learning models. *IET Systems Biology*, 14(4), 211–216.

Lauer, S. A., Grantz, K. H., Bi, Q., Jones, F. K., Zheng, Q., Meredith, H. R., Azman, A. S., Reich, N. G. ve Lessler, J. (2020). The incubation period of coronavirus disease 2019 (COVID-19) from publicly reported confirmed cases: Estimation and application. *Annals of Internal Medicine*, *172*(9), 577–582.

LeCun, Y., Jackel, L. D., Boser, B., Denker, J. S., Graf, H. P., Guyon, I. ve Hubbard, W. (1989). Handwritten digit recognition: Applications of neural network chips and automatic learning. *IEEE Communications Magazine*, *27*(11), 41-46.

LeCun, Y., Bengio, Y. ve Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436-444.

Li, Y., Wang, W., ve Yu, D. (1994). Application of adaptive histogram equalization to x-ray chest images. *Second International Conference on Optoelectronic Science and Engineering'94* (Vol. 2321, pp. 513-514).

Liang, T. (2020). *Handbook of COVID-19 prevention and treatment*. China: University School of Medicine

Lin, M., Chen, Q. ve Yan, S. (2013). Network in network. *Arxiv Preprint Arxiv:1312.4400*.

Loey, M., El-Sappagh, S., ve Mirjalili, S. (2022). Bayesian-based optimized deep learning model to detect COVID-19 patients using chest X-ray image data. *Computers in Biology & Medicine*, *142*(20), 105213.

Maghdid, H. S., Asaad, A. T., Ghafoor, K. Z., Sadiq, A. S., Mirjalili, S., ve Khan, M. K. (2020). Diagnosing COVID-19 pneumonia from X-ray and CT images using deep learning and transfer learning algorithms. *Multimodal Image Exploitation & Learning*, 11734, 117340E.

Minaee, S., Kafieh, R., Sonka, M., Yazdani, S., ve Jamalipour Soufi, G. (2020). Deep-COVID: Predicting COVID-19 from chest X-ray images using deep transfer learning. *Medical Image Analysis*, *65*(31), 101794.

Morens, D. M., Daszak, P., Markel, H. ve Taubenberger, J. K. (2020). Pandemic COVID-19 joins history's pandemic legion. *mBio*, *11*(3), e00812-20.

Narin, A., Kaya, C., & Pamuk, Z. (2021). Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks. *Pattern Analysis&Applications:PAA*, 1–14.

Ngiam, J., Khosla, A., Kim, M., Nam, J., Lee, H. ve Ng, A. Y. (2011). Multimodal deep learning. Appearing in Proceedings of the 28 th International Conference on Machine Learning, Bellevue, USA.

Nguyen, G., Dlugolinsky, S., Bobák, M., Tran, V., Lopez Garcia, A., Heredia, I. ve Hluchý, L. (2019). Machine learning and deep learning frameworks and libraries for large-scale data mining: a survey. *Artificial Intelligence Review*, *52*(1), 77-124.

Nogrady B. (2020). What the data say about asymptomatic COVID infections. *Nature*, *587*(7835), 534–535.

Ojha, V., Mani, A., Pandey, N. N., Sharma, S., ve Kumar, S. (2020). CT in coronavirus disease 2019 (COVID-19): A systematic review of chest CT findings in 4410 adult patients. *European Radiology*, *30*(11), 6129-6138.

Okolo, G. I., Katsigiannis, S., Althobaiti, T., ve Ramzan, N. (2021). On the use of deep learning for imaging-based COVID-19 detection using chest X-rays. *Sensors*, *21*(17), 5702.

Öztürk, T., Talo, M., Yıldırım, E. A., Baloglu, U. B., Yıldırım, O., ve Rajendra Acharya, U. (2020). Automated detection of COVID-19 cases using deep neural networks with X-Ray images. *Computers in Biology&Medicine*, *121*(9), 103792.

Pereira, R. M., Bertolini, D., Teixeira, L. O., Silla, C. N. ve Costa, Y. (2020). COVID-19 identification in chest X-ray images on flat and hierarchical classification scenarios. *Computer Methods & Programs in Biomedicine*, *194*(14), 105532.

Phelan, A. L., Katz, R. ve Gostin, L. O. (2020). The novel coronavirus originating in Wuhan, China: Challenges for global health governance. *JAMA*, *323*(8), 709–710.

Qian, S., Liu, H., Liu, C., Wu, S. ve San Wong, H. (2018). Adaptive activation functions in convolutional neural networks. *Neurocomputing*, *272(*16), 204-212.

Saha, P., Sadi, M. S., ve Islam, M. M. (2021). EMCNet: Automated COVID-19 diagnosis from X-ray images using convolutional neural network and ensemble of machine learning classifiers. *Informatics in Medicine Unlocked*, *22*(4), 100505.

Salido, J. A. ve Ruiz JR, C. (2018). Hair artifact removal and skin lesion segmentation of dermoscopy images. *Asian Journal of Pharmaceutical&Clinical Research*, *11*(3).

Samtaş, G. ve Gülesin, M. (2011). Sayısal görüntü işleme ve farklı alanlardaki uygulamaları. *Electronic Journal of Vocational Colleges*, *2*(1), 85-97.

Saravanan, S., Heshma, B., Shanofer, A. A. ve Vanithamani, R. (2020). Skin cancer detection using dermoscope images. *Materials Today: Proceedings*, *33*, 4823-4827.

Savaş, R. (2014). Akciğer kanserinde PET/BT. Türk Radyoloji Semineri: 1 Eylül 2004-İzmir: Bildiriler (s. 326-329). İzmir: Türk Radyoloji Derneği

Sen, M. ve Honavar, S. G. (2021). Wilhelm conrad röntgen: Finding X. *Indian Journal of Ophthalmology*, *69*(10), 2570–2572.

Shah, N., Davariya, V., Gupta, S. K., Gajjar, P., Parmar, J. ve D'Cruz, L. (2020). Review: An insight into coronaviruses: Challenges, security and scope. *Reviews in Medical Virology*, *30*(6), 1–8.

Shi, Y., Wang, G., Cai, X. P., Deng, J. W., Zheng, L., Zhu, H. H., Zheng, M., Yang, B. ve Chen, Z. (2020). An overview of COVID-19. *Journal of Zhejiang University. Science B*, *21*(5), 343–360.

Shubair, A. H. (2014). *The usability of a visual, flow-based programming environment for non-programmers.* Yüksek Lisans Tezi, Ryerson University, Canada.

Simonyan, K. ve Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *ArXiv Preprint ArXiv:1409.1556*.

Singh, R. K., Pandey, R. ve Babu, R. N. (2021). COVID screen: Explainable deep learning framework for differential diagnosis of COVID-19 using chest X-rays. Neural Computing &Applications, 1–22.

Song, Y., Zheng, S., Li, L., Zhang, X., Zhang, X., Huang, Z., Chen, J., Wang, R., Zhao, H., Chong, Y., Shen, J., Zha, Y., ve Yang, Y. (2021). Deep learning enables accurate diagnosis of novel coronavirus (COVID-19) with CT images. *Transactions on Computational Biology &Bioinformatics*, *18*(6), 2775–2780.

Stokes, E. K., Zambrano, L. D., Anderson, K. N., Marder, E. P., Raz, K. M., El Burai Felix, S., Tie, Y. ve Fullerton, K. E. (2020). Coronavirus disease 2019 case surveillance. *Morbidity & Mortality Weekly Report (MMWR)*, *69*(24), 759–765.

Suárez V. ve Segura I. (2018). Evaluation of pooling operations in convolutional architectures for drug-drug interaction extraction. *BMC Bioinformatics*, *19* (Suppl 8), 209.

Sümer, E., Engin, M., Ağıldere, M. ve Oğul, H. (2020). Monitoring nodule progression in chest X-ray images. *Pamukkale University Journal of Engineering Sciences*, *24*(5), 934-941.

Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. ve Wojna, Z. (2016). Rethinking the inception architecture for computer vision. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2818-2826.

T.C. Sağlık Bakanlığı, (2020a). Sağlık Bakanlığı covid-19 rehberi, https://covid19.saglik.gov.tr/Eklenti/39551/0/covid5619rehberigenelbilgilerepidemiyolojivetanipdf.pdf adresinden 04.02.2022 tarihinde erişilmiştir.

T.C. Sağlık Bakanlığı, (2020b). COVID-19 genel bilgiler, epidemiyoloji ve tanı rehberi. 22.12.2021 tarihinde https://covid19.saglik.gov.tr/Eklenti/39551/0/covid19rehberigenelbilgilerepidemiyolojivetani.pdf sayfasından erişilmiştir.

T.C. Sağlık Bakanlığı, (2022). Vaka sorgulama kılavuzu. 04.02.2022 tarihinde https://covid19.saglik.gov.tr/Eklenti/37810/0/covid19-vaka-sorgulama-kilavuzu-a41pdf.pdf sayfasından erişilmiştir.

Talbi, E. G. (2020). Machine learning into metaheuristics: A survey and taxonomy of data-driven metaheuristics. *HAL-Inria*, Hal-02745295.

Tang, Y. W., Schmitz, J. E., Persing, D. H. ve Stratton, C. W. (2020). Laboratory diagnosis of COVID-19: Current issues and challenges. *Journal of Clinical Microbiology*, *58*(6), e00512-20.

Toğaçar, M., Ergen, B., ve Cömert, Z. (2020). COVID-19 detection using deep learning models to exploit social mimic optimization and structured chest X-Ray images using fuzzy color and stacking approaches. *Computers in Biology& Medicine*, *121*(23), 103805.

Ucar, F., ve Korkmaz, D. (2020). COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. *Medical Hypotheses*, *140*(2), 109761.

Van Doremalen, N., Bushmaker, T., Morris, D. H., Holbrook, M. G., Gamble, A., Williamson, B. N., Tamin, A., Harcourt, J. L., Thornburg, N. J., Gerber, S. I., Lloyd-Smith, J. O., de Wit, E. ve Munster, V. J. (2020). Aerosol and surface stability of HCoV-19 (SARS-CoV-2) compared to SARS-CoV-1. M*edRxiv : the preprint server for health sciences*, 09.20033217.

Varghese, R. ve Sharma, S. (2018, Haziran). *Affordable smart farming using IoT and machine learning*. In 2018 Second International Conference on Intelligent Computing&Control Systems (ICICCS) Kongresi'nde sunulmuş bildiri, Madurai, India.

Wahab, N., Khan, A. ve Lee, Y. S. (2019). Transfer learning based deep CNN for segmentation and detection of mitoses in breast cancer histopathological images. *Microscopy*, *68*(3), 216–233.

Wang, C., Horby, P. W., Hayden, F. G. ve Gao, G. F. (2020). A novel coronavirus outbreak of global health concern. *Lancet (London, England)*, *395*(10223), 470–473.

Ward, S., Lindsley, A., Courter, J., ve Assa'ad, A. (2020). Clinical testing for COVID-19. *The Journal of Allergy and Clinical Immunology*, *146*(1), 23–34.

Xie, X. ve Lam, K. M. (2005). Face recognition under varying illumination based on a 2D face shape model. *Pattern Recognition*, *38*(2), 221-230.

Yaraş, N. (2020). *Vehicle Type Classification with Deep Learning*. Yüksek Lisans Tezi, İzmir Yüksek Teknoloji Üniversitesi, İzmir.

Ye, Z., Zhang, Y., Wang, Y., Huang, Z. ve Song, B. (2020). Chest CT manifestations of new coronavirus disease 2019 (COVID-19): A pictorial review. *European Radiology*, *30*(8), 4381–4389.

Yoon, S. H., Lee, K. H., Kim, J. Y., Lee, Y. K., Ko, H., Kim, K. H., Park, C. M. ve Kim, Y. H. (2020). Chest radiographic and CT findings of the 2019 novel coronavirus disease (COVID-19): Analysis of nine patients treated in Korea. *Korean Journal of Radiology*, *21*(4), 494–500.

Yüce, M., Filiztekin, E., & Özkaya, K. G. (2021). COVID-19 diagnosis -A review of current methods. *Biosensors & Bioelectronics*, *172*(42), 112752.

Zhang, T., Tang, Y. Y., Fang, B., Shang, Z. ve Liu, X. (2009). Face recognition under varying illumination using gradient faces. *IEEE Transactions on Image Processing*, *18*(11), 2599-2606.

Zhao, Z. Q., Zheng, P., Xu, S. T. ve Wu, X. (2019). Object detection with deep learning: a review. *IEEE Transactions on Neural Networks & Learning Systems*, *30*(11), 3212–3232.

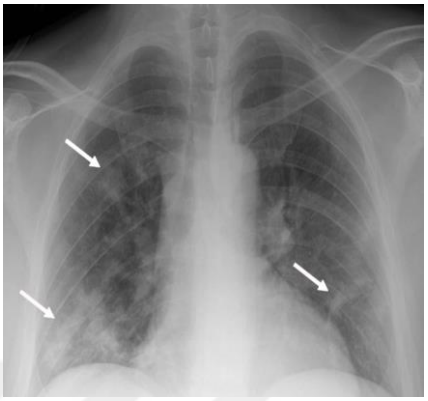
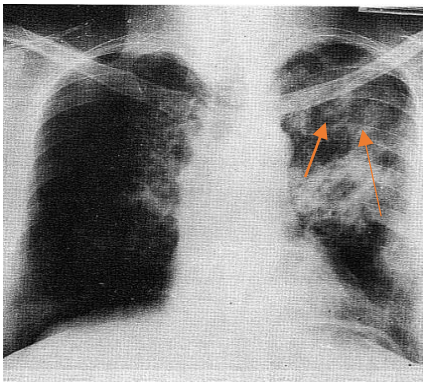
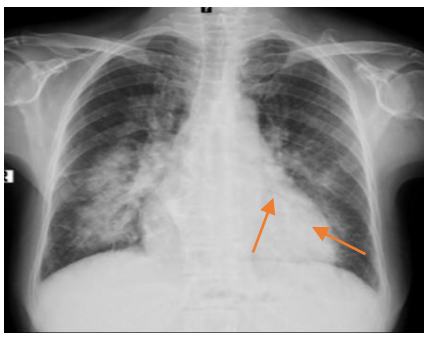
Zheng, C., Deng, X., Fu, Q., Zhou, Q., Feng, J., Ma, H., Liu, W., Wang, X. (2020). Deep learning-based detection for COVID-19 from chest CT using weak label. *IEEE Transactions on Medical Imaging*, 1–13.

Zhou, Y., Yang, Y., Huang, J., Jiang, S. ve Du, L. (2019). Advances in MERS-CoV vaccines and therapeutics based on the receptor-binding domain. *Viruses*, *11*(1), 60.

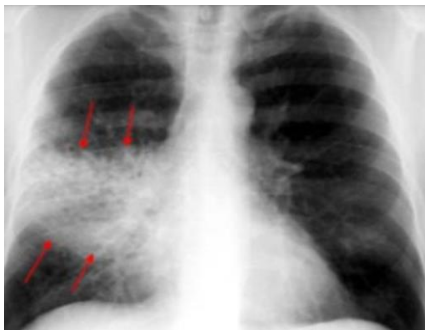
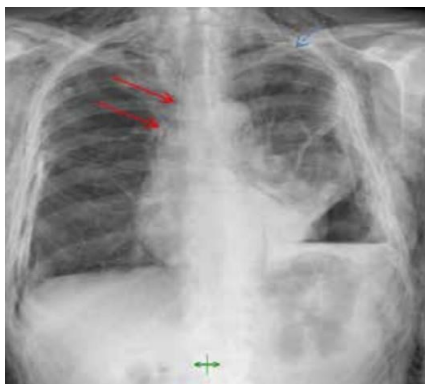
Zhu, N., Zhang, D., Wang, W., Li, X., Yang, B., Song, J. ve Tan, W. (2019). A novel coronavirus from patients with pneumonia in China. *New England Journal of Medicine. 382*(2), 727-733.

EKLER

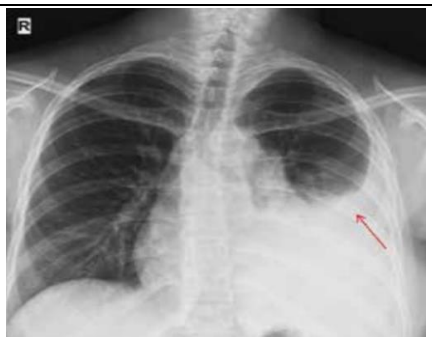
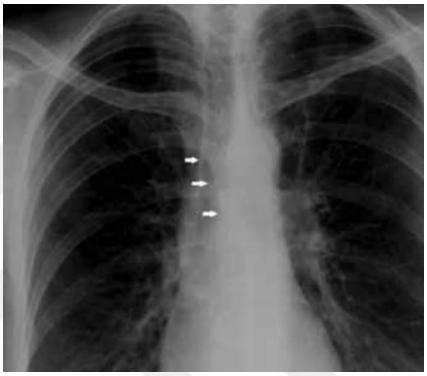
EK 1. X-Ray Görüntülerinde COVID-19 Hastalığı İçin Elde Edilen Bulgu Görüntüleri

TİPİK BULGULAR	
Retiküler Görünüm	
Nodül Kısımları	
Hava Bronkogramı	
Kaldırım Taşı	

EK 1. (Devamı)

TİPİK BULGULAR	
Konsolidasyon	
Buzlu Cam Opasitesi	
ATİPİK BULGULAR	
Kavitasyon	
Perikardiyal Sıvı	

EK 1. (Devamı)

ATİPİK BULGULAR	
Plevral Sıvı	
Lenfadenopati	

Aksaray Üniversitesi Tez Değerlendirme Formu		
Öğrencinin Adı Soyadı: Özgür FOTO		**EVET**
	Kapak	X
1	Tez Başlığı tutanaktaki başlıkla aynı mı?	X
2	Kapaktaki ay ve yıl savunmaya girilen tarihle tutarlı mı?	X
3	Kapak format kılavuzdaki kapak formatına uygun mu?	X
4	Kapakta yazılan tüm yazılar doğru olarak verilmiş mi?	X
	İçindekiler	
5	Sayfa numaraları tam verilmiş mi?	X
6	Şekil, Çizelge vb. listeleri verilmiş mi? Sıralaması doğru mu?	X
7	Özet, Abstract, Giriş, Sonuçlar vb. bölümler var mı?	X
8	Yazım hataları kontrolü yapıldı mı?	X
	Giriş	
9	Hazırlanan tezin önemini anlatıyor mu?	X
10	İkinci ve Üçüncü dereceden başlık içermemeli kuralına uyuldu mu?	X
	Özet/Abstract	
11	Kılavuza uygun mu?	X
12	Ay ve yıl savunmaya girilen tarihle tutarlı mı?	X
13	Özet; tek sayfa, tek aralık, tek paragraf kuralına uygun olarak yazıldı mı?	X
14	Bilim kodu, sayfa adedi, anahtar kelimeler ve tez danışmanı yazıldı mı?	X
	Kaynakça	
15	Kaynakların tamamına metin içinde atıf yapıldı mı?	X
16	Kaynak formatı Kılavuzdaki kaynak formatına uygun olarak hazırlanmış mı?	X
17	Atıf formatı kılavuzdaki atıf formatına uygun mu?	X
	Atıf Yöntemi APA 6 X CMS ☐ İSNAD ☐	
	Genel Değerlendirme	
18	Etik Beyan açıklaması okundu, uyuldu ve imzalandı mı?	X
19	Kabul/Onay sayfası kılavuzdaki formata uygun olarak düzenlenmiş mi?	X
20	Kabul /Onay sayfasında belirtilen oy birliği/oy çokluğu seçeneklerinden uygun olanı savunmayla tutarlı olacak şekilde belirlenmiş mi?	X
21	Sayfa kenar boşluklar ve sayfa numaraları kılavuzdaki formatına uygun mu?	X
22	Paragraf boşlukları ve metin satır aralığı kılavuza uygun olacak şekilde düzenlenmiş mi?	X
23	Başlık yazımları kılavuzdaki başlık formatlarına uygun mu?	X
24	Yazı tipi ve boyutu kılavuzdaki yazı tipi ve boyutu formatına uygun mu?	X
25	Şekil, Çizelge vb. açıklama ve numaralandırmaları kılavuzdaki formata uygun olarak yazılmış mı?	X

Bu tezin tarafımdan "Tez yazım kuralları" okunarak dikkatlice hazırlanmış olduğunu ve doğabilecek her türlü olumsuzluktan sorumlu olacağımı kabul ederim.

Öğrencinin imzası