

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI
BİYOMEDİKAL MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

RADYOLOJİ GÖRÜNTÜLERİNDEN COVID19 ZATÜRRESİ ANALİZİ

HAZIRLAYAN

MUHAMMED MEHDİ MENTEŞ

YÜKSEK LİSANS TEZİ

ANKARA - 2022

**BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI
BİYOMEDİKAL MÜHENDİSLİĞİ TEZLİ YÜKSEK LİSANS
PROGRAMI**

RADYOLOJİ GÖRÜNTÜLERİNDEN COVID19 ZATÜRRESİ ANALİZİ

HAZIRLAYAN

MUHAMMED MEHDİ MENTEŞ

YÜKSEK LİSANS TEZİ

TEZ DANIŞMANI

DR. ÖĞR. ÜYESİ ORHAN ERDEM HABERAL

TEZ EŞ DANIŞMANI

DR. ÖĞR. ÜYESİ MEHMET YÜKSEKKAYA

ANKARA- 2022

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

Biyomedikal Mühendisliği Anabilim Dalı Biyomedikal Mühendisliği Tezli Yüksek Lisans Programı çerçevesinde Muhammed Mehdi Menteş tarafından hazırlanan bu çalışma, aşağıdaki jüri tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Tez Savunma Tarihi: 02 / 02 / 2022

Tez Adı: RADYOLOJİ GÖRÜNTÜLERİNDEN COVID19 ZATÜRRESİ ANALİZİ

Tez Jüri Üyeleri (Unvanı, Adı - Soyadı, Kurumu)

İmza

Prof. Dr. Hilal GÖKTAŞ – Ankara Üniversitesi (Başkan)

.....

Dr. Öğr. Üyesi Orhan Erdem HABERAL – Başkent Üniversitesi (Danışman)

Dr. Öğr. Üyesi Hüseyin KURTULDU – Başkent Üniversitesi (Üye)

.....

ONAY

Prof. Dr. Ömer Faruk ELALDI

Fen Bilimleri Enstitüsü Müdürü

Tarih : ... / ... /

BAŞKENT ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ
YÜKSEK LİSANS TEZ ÇALIŞMASI ORJİNALLİK RAPORU

Tarih: ... / 02 / 2022

Öğrencinin Adı, Soyadı : Muhammed Mehdi MENTEŞ

Öğrencinin Numarası : 22010373

Anabilim Dalı : Biyomedikal Mühendisliği Anabilim Dalı

Programı : Biyomedikal Mühendisliği Tezli Yüksek Lisans Programı

Danışmanın Unvanı/Adı, Soyadı : Dr. Öğr. Üyesi Orhan Erdem HABERAL

Tez Eş Danışmanının Unvanı/Adı, Soyadı : Dr. Öğr. Üyesi Mehmet YÜKSEKKAYA

Tez Başlığı : RADYOLOJİ GÖRÜNTÜLERİNDEN COVID19 ZATÜRRESİ ANALİZİ

Yukarıda başlığı belirtilen Yüksek Lisans tez çalışmamın; Giriş, Ana Bölümler ve Sonuç Bölümünden oluşan, toplam 67 sayfalık kısmına ilişkin 03 / 02 / 2022 tarihinde tez danışmanım tarafından Turnitin adlı intihal tespit programından aşağıda belirtilen filtrelemeler uygulanarak alınmış olan orijinallik raporuna göre, tezimin benzerlik oranı % 3 'tür. Uygulanan filtrelemeler:

1. Kaynakça hariç
2. Alıntılar hariç
3. Beş (5) kelimeden daha az örtüşme içeren metin kısımları hariç

“Başkent Üniversitesi Enstitüleri Tez Çalışması Orijinallik Raporu Alınması ve Kullanılması Usul ve Esaslarını” inceledim ve bu uygulama esaslarında belirtilen azami benzerlik oranlarına tez çalışmamın herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve yukarıda vermiş olduğum bilgilerin doğru olduğunu beyan ederim.

Öğrenci İmzası:

ONAY

Tarih: / 02 / 2022

Öğrenci Danışmanı Unvan, Adı, Soyadı, İmza:

Dr. Öğr. Orhan Erdem HABERAL

TEŞEKKÜR

Lisans hayatımdan bu yana önümde yolundan gidebileceğim bir önder, yanımda bir dost olan ve arkamda her koşulda desteğini hissettiğim ve bunu benden hiçbir zaman esirgemeyen çok değerli hocam Dr. Öğr. Üyesi Mehmet YÜKSEKKAYA'ya, kıymetli görüşlerinden istifade ettiğim çok değerli hocam Dr. Öğr. Üyesi Orhan Erdem HABERAL'a, maddi manevi desteğini eksik etmeyen beni her zaman daha iyisi için motive eden bu dünyadaki en büyük varlıklarım annem Fatma ve babam Nevzat'a, canımdan çok sevdiğim ve dünyada eşi benzeri olmayan kardeşim Metehan'a teşekkürü borç bilirim.



ÖZET

Muhammed Mehdi MENTEŞ

RADYOLOJİ GÖRÜNTÜLERİNDEN COVID19 ZATÜRRESİ ANALİZİ

Başkent Üniversitesi Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

2022

COVID19, ilk olarak 2019 yılı sonunda Aralık ayında ortaya çıkmıştır ve ilk vaka Çin'in Wuhan kentinde görülmüştür. Birkaç ay içerisinde tüm dünyayı saran bir pandemi haline gelen hastalığa dönüşmüştür. Hastalığa sebep olan virüs, SARS virüs ailesine ait olan SARS-CoV-2'dir. Hastalığın başlıca belirtileri, yüksek ateş, halsizlik, öksürük ve nefes darlığıdır. Hastalığın ilerleyen safhalarında çeşitli sindirim sistemi rahatsızlıkları, kalp rahatsızlıkları ve zatürre gibi mortaliteyi artıran sonuçlar görülebilir. Radyolojik görüntüler COVID19 pandemisi döneminde, hastalığın zatürre oluşturup oluşturmadığını incelemek ve eğer akciğerlerde zatürre oluştuysa bunun durumunun takibi için kullanılmaktadır. Radyolojik görüntüler birkaç başlık altında açıklanabilmektedir; röntgen görüntüleri, manyetik rezonans görüntüleri, pozitron emisyon tomografisi görüntüleri ve bilgisayarlı tomografi görüntülerinden oluşmaktadır. Bilgisayarlı tomografi genellikle kemik dokusu, damar dokuları, kalp dokusu ve akciğer dokuları gibi çeşitli bölgelerin incelenmesi amacıyla kullanılabilir. COVID19 pandemisi döneminde de, zatürre tespiti için en çok kullanılan yöntemlerden birisi olmuştur. Bunun başlıca sebepleri, yüksek çözünürlüklü görüntüler sunması, kısa sürede sonuç alınabilmesi, çok katmanlı görüntüler sunduğu için detaylı bilgiler sunması şeklinde sayılabilir. Bilgisayarlı tomografi görüntüleri lezyonların tespitinin yanı sıra hastalığın akciğerler üzerinde seyrinin takip edilmesi için de kullanılabilir. Bu çalışmada VGG16, ResNet50, ResNet50v2 ve katman eklenmiş ResNet50v2 mimarileri ile 12967 görüntü, oluşturulan sistem tarafından eğitilmiş ve test edilmiştir. Eğitilen katman eklenmiş ResNet50v2 modeli ile sınıf aktivasyonu görüntüler üzerinde görselleştirilmiştir. Yapılan testlerin sonuçlarına göre katman eklenmiş ResNet50v2 modeli %97.83 hassasiyet, %99.47 özgüllük ve %99.53 test kesinliği vermiştir.

ANAHTAR KELİMELER : COVID19, Zatürre, Derin Öğrenme

ABSTRACT

Muhammed Mehdi MENTEŞ

COVID 19 PNEUMONIA ANALYSIS FROM RADIOLOGY IMAGES

Başkent University Institute of Sciences

Biomedical Engineering Major Science

2022

COVID19 is a disease that appeared in China, Wuhan in end of the 2019, December. It became a pandemic within a few months. The virus that causes the disease is SARS-CoV-2, which belongs to the SARS virus family. The main symptoms of the disease are high fever, weakness, shortness of breath and cough. In the later stages of the disease, results that increase mortality such as various digestive system disorders, heart diseases and pneumonia can be seen. Radiological images are used during the COVID19 pandemic period to examine whether the disease causes pneumonia and to monitor the situation if pneumonia has occurred in the lungs. Radiological images can be explained under several headings; computed tomography images, magnetic resonance images, X-ray images and positron emission tomography images. Computed tomography can generally be used to examine various regions such as bone tissue, vascular tissues, heart tissue and lung tissues. During the COVID19 pandemic, it is one of the most used methods for detecting pneumonia. The main reasons for this can be counted as offering high-resolution images, getting results in a short time, and providing detailed information because it offers multi-layered images. Computerized tomography images can be used to detect lesions as well as to follow the course of the disease on the lungs. In this study, 12967 images were trained and tested by VGG16, ResNet50, ResNet50v2 and ResNet50v2 architectures with added layers. Class activation was visualized on images with the ResNet50v2 model with the trained layer added. According to the results of the tests, the ResNet50v2 model with the added layer gave 97.83% sensitivity, 99.47% specificity and 99.53% test accuracy.

KEYWORDS : COVID19, Pneumonia, Deep Learning

İÇİNDEKİLER

TEŞEKKÜR.....	i
ÖZET	ii
ABSTRACT	iii
İÇİNDEKİLER.....	iv
TABLolar LİSTESİ	vii
ŞEKİLLER LİSTESİ	viii
SİMGELER VE KISALTMALAR LİSTESİ	xi
1.GİRİŞ.....	1
1.1.Tezin Amacı, Motivasyonu ve Genel Özeti	1
1.2.COVID-19 ve Zatürre	1
1.3.COVID-19 Teşhis Yöntemleri	3
1.3.1.Viral Test Yöntemleri.....	4
1.3.2.Görüntüleme Yöntemleri	5
1.4.Görüntüleme Yöntemleri ile Covid 19 Teşhisi.....	5
1.4.1.Bilgisayarlı Tomografi	5
1.4.2.Akciğer Röntgeni	8
1.4.3.Manyetik Rezonans Görüntüleme	9
1.4.4.Pozitron Emisyon Tomografisi.....	9
1.5.Derin Öğrenme	10
1.5.1.Yapay Sinir Ağları.....	11
1.5.2.Derin Öğrenme Uygulama Alanları.....	15
1.6.Tıbbi Görüntülerde Derin Öğrenme.....	17
1.7.COVID-19 Zatürre Lezyonlarının Tespiti	18
2.MATERYAL METOT	20
2.1.Ver i Seti	20

2.1.1.DICOM Görüntü Tipi.....	23
2.1.2.TIFF Görüntü Tipi.....	24
2.2.Programlama Ortamı.....	26
2.2.1.Tensorflow ve Keras.....	26
2.2.1.Jupyter Notebook ve Google Colab	26
2.2.3.Grafik İşlem Birimi	28
2.3.Derin Öğrenme Modeli	28
2.3.1.VGG.....	29
2.3.2.ResNet.....	30
2.3.3.ResNetV2.....	32
2.3.4.Katman Eklenmiş ResNetV2	33
2.4.Katmanlar	34
2.4.1.Conv2D	34
2.4.2.MaxPooling	35
2.4.3.ZeroPadding.....	35
2.4.4.BatchNormalization	37
2.4.5.Activation-ReLU.....	37
2.5.GradCAM Algoritması	37
3.DENEYLER.....	38
3.1.VGG16 Mimarisi	38
3.2.ResNet50 Mimarisi	41
3.3.ResNet50v2 Mimarisi	44
3.3.1.ResNet50v2 Mimarisi	44
3.3.2.ResNet50v2 Mimarisine Katman Eklenmiş Mimari	47
3.4.Modelin Görüntü Üzerine Uygulanması ve Görselleştirilmesi	52
3.5.Lezyonların Hacim Hesaplaması	55
4.SONUÇ VE TARTIŞMA	59

KAYNAKLAR.....	62
-----------------------	-----------



TABLÖLAR LİSTESİ

	Sayfa
Tablo 3.1. VGG16 İçin Ortalama Kesinlik ve Kayıp Değerleri.....	38
Tablo 3.2. VGG16 İçin İstatiksel Veriler	39
Tablo 3.3. ResNet50 İçin Ortalama Kesinlik ve Kayıp Değerleri.....	42
Tablo 3.4. ResNet50 İçin İstatiksel Değerler	42
Tablo 3.5. ResNet50v2 İçin Ortalama Kesinlik ve Kayıp Değerleri.....	45
Tablo 3.6. ResNet50v2 İçin İstatiksel Değerler	45
Tablo 3.7. Katman Eklenmiş ResNet50v2 İçin Kesinlik ve Kayıp Değerleri.....	48
Tablo 3.8. Katman Eklenmiş ResNet50v2 İçin İstatiksel Değerler.....	48



ŞEKİLLER LİSTESİ

	Sayfa
Şekil 1.1. Koronavirüsün Elektron Mikroskobu Altındaki Görüntüsü [3].....	2
Şekil 1.2. Burun ve Ağızdan Alınan PCR Sürüntü Testi Örneği [25].....	5
Şekil 1.3. Zatürre Lezyonu Görülmeyen Bir BT Görüntüsü.....	7
Şekil 1.4. Buzlu Cam Opasiteleri (Akciğer İçerisinde Bulunan Gri Bulanık Görüntüler) Şeklinde Zatürre Lezyonu Görülen BT Görüntüsü.....	7
Şekil 1.5. Zatürre Lezyonu Görülmeyen (üstte) ve Zatürre Lezyonu Görülen (altta) Akciğer Röntgenleri [41].....	8
Şekil 1.6. Karşılaştırmalı Olarak Zatürre Lezyonu Görülen BT (solda) ve MR (sağda) Görüntüleri [46].....	9
Şekil 1.7. Zatürre Lezyonu Görülen PET-BT Görüntüsü [51].....	10
Şekil 1.8. Basit Anlamda Düz Bir Yapay Sinir Ağı Sistemi.....	12
Şekil 1.9. Konvolüsyonel Sinir Ağı Sistemini Bir Gösterimi.....	13
Şekil 1.10. Kalıntısız Sinir Ağının Kalıntıları Toplama Yöntemi.....	14
Şekil 1.11. Derin Öğrenme İçin Girdi Oluşturan Çeşitli Tıbbi Görüntüler [92].....	16
Şekil 2.1. Veri Setinde Yer Alan Zatürre Lezyonu Görülen BT Görüntüleri.....	21
Şekil 2.2. Veri Setinde Yer Alan Zatürre Lezyonu Görülmeyen BT Görüntüleri.....	21
Şekil 2.3. Veri Setinde Bulunan BT Görüntülerin İlk (üstte), Orta ve Son (altta) Sekansları.....	22
Şekil 2.4. Veri Setinde Bulunan Açık Gözüken Akciğer BT Görüntüleri.....	22
Şekil 2.5. Veri Setinde Buluna Kapalı Gözüken Akciğer BT Görüntüleri.....	23
Şekil 2.6. Veri Setinde Bulunan BT Görüntülerinin Gerçek Görünümü.....	25
Şekil 2.7. Veri Setinde Bulunan BT Görüntülerinin Görünebilir Hale Dönüştürülmüş Görünümü.....	25
Şekil 2.8. Jupyter Notebook'un Arayüzü.....	27
Şekil 2.9. Google Colab'ın Arayüzü.....	27

Şekil 2.10.	Katman Sayısına Karşılık Hata Oranları.....	29
Şekil 2.11.	VGG16 Mimarisinin Katmanları.....	30
Şekil 2.12.	ResNet'in Kalıntı Toplama Yapısı.....	31
Şekil 2.13.	34 Katmanlı (solda) ve 50 Katmanlı (sağda) ResNet Modelinin Artık Toplama Yöntemi.....	32
Şekil 2.14.	ResNet50'nin Katmanları.....	32
Şekil 2.15.	ResNet50 (üstte) ve ResNet50v2'nin (altta) Katman Sıralamaları.....	33
Şekil 2.16.	Girdi Matrisi (solda), Filtre veya Kernel Matrisi (ortada), Çıktı Matrisi (sağda).....	34
Şekil 2.17.	Filtrenin Girdi Matrisi Üzerinde Gezinimi.....	34
Şekil 2.18.	MaxPooling İşlemi Gösterimi.....	35
Şekil 2.19.	Piksel Eklenmiş Girdi Matrisi (solda), Filtre Matrisi (ortada), Çıktı Matrisi (sağda).....	36
Şekil 2.20.	Filtrenin Piksel Eklenmiş Girdi Matrisi Üzerinde Gezinimi.....	36
Şekil 3.1.	VGG16 İçin Eğitim Kaybı.....	39
Şekil 3.2.	VGG16 İçin Eğitim Kesinliği.....	40
Şekil 3.3.	VGG16 İçin Geçerleme Kaybı.....	40
Şekil 3.4.	VGG16 İçin Geçerleme Kesinliği.....	41
Şekil 3.5.	ResNet50 İçin Eğitim Kaybı.....	42
Şekil 3.6.	ResNet50 İçin Eğitim Kesinliği.....	43
Şekil 3.7.	ResNet50 İçin Geçerleme Kaybı.....	43
Şekil 3.8.	ResNet50 İçin Geçerleme Kesinliği.....	44
Şekil 3.9.	ResNet50v2 İçin Eğitim Kaybı.....	45
Şekil 3.10.	ResNet50v2 İçin Eğitim Kesinliği.....	46
Şekil 3.11.	ResNet50v2 İçin Geçerlem Kaybı.....	46
Şekil 3.12.	ResNet50v2 İçin Geçerleme Kesinliği.....	47

Şekil 3.13.	Katman Eklenmiş ResNet50v2 İçin Eğitim Kaybı.....	48
Şekil 3.14.	Katman Eklenmiş ResNet50v2 İçin Eğitim Kesinliği.....	49
Şekil 3.15.	Katman Eklenmiş ResNet50v2 İçin Geçerleme Kaybı.....	49
Şekil 3.16.	Katman Eklenmiş ResNet50v2 İçin Geçerleme Kesinliği.....	50
Şekil 3.17.	Modellerin Eğitim Kaybı Karşılaştırması.....	50
Şekil 3.18.	Modellerin Eğitim Kesinliği Karşılaştırması.....	51
Şekil 3.19.	Modellerin Geçerleme Kaybı Karşılaştırması.....	51
Şekil 3.20.	Modellerin Geçerleme Kesinliği Karşılaştırması.....	52
Şekil 3.21.	Orijinal Görüntü ve Modelin Çıktı Görüntü.....	53
Şekil 3.22.	Modelin Orijinal Görüntü Üzerine Eklenmiş Görüntüsü ve Isı Haritası.....	53
Şekil 3.23.	Farklı Katmanlardaki Lezyonların Görüntüleri.....	54
Şekil 3.24.	Zatürre Lezyonu Görülmeyen Görüntü Çıktısı.....	55
Şekil 3.25.	47 Numaralı Sekans ve Lezyonun Eşiklenmiş Görüntüsü.....	56
Şekil 3.26.	48 Numaralı Sekans ve Lezyonun Eşiklenmiş Görüntüsü.....	56
Şekil 3.27.	49 Numaralı Sekans ve Lezyonun Eşiklenmiş Görüntüsü.....	57
Şekil 3.28.	50 Numaralı Sekans ve Lezyonun Eşiklenmiş Görüntüsü.....	57
Şekil 3.29.	51 Numaralı Sekans ve Lezyonun Eşiklenmiş Görüntüsü.....	57
Şekil 3.30.	Orijinal Görüntüler ve Eşiklenmiş Lezyon Görüntüleri.....	58
Şekil 4.1.	Modellerin Hassasiyet, Özgüllük ve Test Kesinliğine Göre Karşılaştırma Grafiği.....	60
Şekil 4.2.	Modellerin Eğitim Süresi, Boyut ve Çalışma Süresinde Göre Karşılaştırma Grafiği.....	60

SİMGELER VE KISALTMALAR LİSTESİ

BT	bilgisayarlı tomografi
MR	manyetik rezonans
MRG	manyetik rezonans görüntüleme
PET	pozitron emisyon tomografisi
YSA	yapay sinir ağı
KAY	kredi atama yolu



1.GİRİŞ

1.1.Tezin Amacı, Motivasyonu ve Genel Özeti

Bu çalışmanın amacı medikal görüntüleme yöntemlerinden biri olan bilgisayarlı tomografi ile alınan görüntüler üzerinden, COVID19 zatürresine sahip olan ve olmayan bireyleri teşhis eden ve görüntüleri yorumlamak amacıyla inceleyen, alanında uzman personele katkı sağlayabilecek ve iş gücünü azaltabilecek bir karar destek sistemi üretmektir.


2020 yılının başından bu yana dünya üzerinde artan COVID19 hafif, orta ve ağır semptomatik vakalar ile birlikte sağlık personellerinin iş gücü de, yadsınamayacak şekilde artmıştır. Ağır semptomatik vakalar için uygun tedavi yöntemlerinin zatürrenin ilk aşamalarında uygulanması önem arz etmektedir. Ayrıca zatürrenin seyrinin izlenebilmesi için en uygun ve en sağlıklı sonuç veren görüntüleme yöntemi de bilgisayarlı tomografidir. Tüm bunların neticesinde sağlık personeli bilgisayar ile desteklemek ve iş gücünü azaltmak tezin motivasyon kaynağını oluşturmuştur.

Bu çalışmada dört farklı derin öğrenme mimarisine girdi olarak İranlı bilim insanları tarafından hazırlanan veri seti kullanılmıştır. Oluşturulan modeller test verileriyle test edilmiştir. Ayrıca modeller görselleştirilerek maskeler oluşturulmuş ve bu maskeler ham görüntülerin üzerine eklenerek incelenmiştir.

1.2.COVID-19 ve Zatürre

Koronavirüs, hayvanları ve de bazı hayvanları enfekte eden, tek sarmallı büyük RNA virüslerindendir. Koronavirüs 1966 yılında ilk defa Tyrell ve Bynoe isimli bilim adamları tarafından, belirti olarak soğuk algınlığına benzer belirtisi bulunan vakalardan alınan virüsler tarafından tanımlanmıştır. Çekirdek kabuğu ve güneş koronasına benzeyen yüzey çıkıntıları olan küresel yapılarından dolayı, koronavirüsler olarak adlandırıldılar. Alfakoronavirüs, betakoronavirüs, gamagamakoronavirüs ve deltakoronavirüsler olmak üzere dört sınıfa ayrılmışlardır. Alfakoronavirüs ve betakoronavirüs genelde memelilerden, özellikle de yarasalardan kaynaklanırken, gamakoronavirüs ve deltakoronavirüs domuzgillerden ve çeşitli kuş türlerinden kaynaklanabilmektedir. İnsanlarda enfeksiyona sebep olan 7 koronavirüs alt tipi arasında betakoronavirüsler diğerlerine göre daha sert bir hastalığa ve hatta ölümlere neden olabiliyorken, alfa sınıfı koronavirüsler semptom göstermeyen veya hafif semptom gösteren enfeksiyonlara neden olur. Başlıca dört yapısal gen, nükleokapsid proteini (N), başak proteini (S), küçük bir zar proteini (SM) ve zar glikoproteininden (M)

meydana gelen ilave bir zar glikoproteini (HE) ile kodlanmıştır [1-3]. Aşağıda yer alan Şekil 1.1’ de koronavirüsün elektron mikroskobu altındaki görüntüsü gösterilmiştir.



Şekil 1.1. Koronavirüsün Elektron Mikroskobu Altındaki Görüntüsü [3]

Koronavirüs hastalığı 2019 ya da daha çok bilinen adıyla COVID-19’a sebep olan virüs, şiddetli akut solunum sendromu koronavirüs 2 kısa ismiyle SARS-CoV-2’dir. Aralık 2019’da Çin’in Wuhan kentinde ilk defa bir COVID-19 vakası tespit edilmiştir. Hastalık Aralık 2019’dan itibaren dünya çapında yayılmış ve milyonlarca insanın enfekte olduğu bir pandemiye yol açmıştır.

COVID-19’da ilk vakaların tespitinde klinik belirti olarak pnömoni yani zatürre olmuştur. Daha sonraları incelenen vakalarda, özellikle pediatrik hastalar arasında sindirim sistemi enfeksiyonlarının görüldüğü belirtilmiştir. Şimdiye kadar yapılan gözlemler, kuluçka süresinin ortalama üç gün ila beş gün arasında olduğunu göstermektedir. Enfeksiyon, şikayeti olan vakalarda bilgisayarlı tomografide incelenerek, hastaların büyük çoğunluğunda pnömoni görülmüştür. Bunu takiben gelen öksürük, nefes darlığı ve şiddetli göğüs semptomları ile birlikte hastalığın ilerleyebildiği gözlemlenmiştir. Zatürre, enfeksiyonun ilerleyen safhalarında, genellikle 2-3 haftada ortaya çıkmaktadır. Viral pnömoninin belirgin belirtileri arasında oksijen saturasyonunda azalma, kan gazı sapmaları, buzlu cam görüntüleri gibi, röntgen ve diğer görüntüleme teknikleriyle görülebilen değişiklikler, yer almaktadır [4-6].

COVID-19’un semptomları kişiden kişiye değişkenlik göstermektedir, yine de çoğu enfekte hastada sıklıkla ateş, öksürük, koku ve tat kaybı, baş ağrısı, yorgunluk, nefes alma

güçlükleri gibi semptomlar sayılabilmektedir. Belirtiler virüse maruz kaldıktan sonra 1-14 gün içerisinde ortaya çıkabilir. Enfeksiyona maruz kalan kişilerin yaklaşık üçte biri belirgin semptomlar geliştirmemektedir. Yalnızca %5'lik kısım kritik semptomlardan muzdariptir. Orta yaş üstünde, yani 65 yaş ve üzerinde şiddetli semptomlar geliştirme riski daha yüksektir. Bazı enfekte hastalarda, enfeksiyon sonrasında uzun süre çeşitli etkiler yaşamaya devam ettiği ve çeşitli organlarda enfeksiyona bağlı düzensizlikler olduğu gözlemlenmiştir. Hastalık yeni denilebilecek kadar kısa süre öncesinde ortaya çıktığı için, gelecekteki etkilerini daha detaylı olarak incelemek için uzun süreli çalışmalar yapılmaktadır [7].

COVID-19, insanlara, enfekte diğer insanların ekstrede ettiği solunum gazlarından veya öksürük yoluyla vücutlarında çıkan virüs içeren damlacıklar ile bulaşmaktadır. Bunları soluma riski, yakın temasta, kapalı ortamlarda en yüksektir. Virüs içeren sıvıların gözlere, buruna veya ağza sıçraması veya püskürtülmesi ile ve de nadiren yüzeyler yoluyla bulaşma meydana gelebilmektedir. İnsanlarda bulaşıcılık yaklaşık 21 güne kadar sürebilmektedir ve herhangi bir belirti göstermeseler bile virüsü yayabilmektedirler [8].

Hastalığı teşhis etmek için çeşitli test yöntemleri, halihazırda olan yöntemlerden uyarlanmıştır. Standartlaşmış ve en yaygın olan teşhis yolu, virüsün nükleik asidinin gerçek zamanlı ters transkripsiyon polimeraz zincir reaksiyonu (PCR) testleridir. Bu test yönteminde yalnızca pozitif veya negatif gibi sonuçlar verilmektedir [9-10].

2020 ve 2021 yılları içerisinde çeşitli COVID-19 aşılı onaylanmıştır. Onaylanan aşılar dünyanın birçok ülkesinde halka uygulanmaya devam etmektedir. Çeşitli ülkelerin sağlık kuruluşları tarafında halka yapılan duyurlarda genellikle önleyici tedbir olarak yakın temastan kaçınmak, karantina, kapalı alanların havalandırılması, öksürük ve hapsirıkların kapatılması, ellerin yıkanması ve yüzey temasından uzak kalınması sayılabilmektedir. Ayrıca bulaş ihtimalini azaltmak ve kişisel korunmayı sağlamak amacı ile kalabalık ortamlarda ağız ve burnu kapatacak maskeler veya koruyucu ekipmanların kullanılması tavsiye edilmiştir [11-14].

1.3.COVID-19 Teşhis Yöntemleri

COVID-19, yalnızca belirli bir sürede, belirtiler hala hastada bulunuyorken teşhis edilebilmektedir ve genellikle ters transkripsiyon polimeraz zincir reaksiyonu (PCR) testleri kullanılarak tespit edilmektedir. Laboratuvar testleri ile birlikte bilgisayarlı tomografi ve röntgen görüntüleri, hastalık şüphesi olan kişilerde COVID-19'u teşhis için kullanılmakta ve hastalığın ilerleyen düzeylerinde hekimlere hasta ve hastalık ile ilgili daha detaylı bilgiler

verebilmektedir. Enfeksiyona tepki olarak vücudun ürettiği antikor seviyesini ölçen bir takım testler ile daha önceden geçirilmiş hastalığın tespiti de mümkündür [15-16].

1.3.1.Viral Test Yöntemleri

Viral test yöntemleri, SARS-CoV-2'nin halihazırdaki ve önceki varlığını değerlendirmek için örneklerin laboratuvarda incelenmesini içeren bir yöntemdir. Günümüzde uygulanan ana yöntemlerde virüsün varlığını ya da virüse yanıt olarak vücut tarafından üretilen antikorları tespit edilmektedir. Virüs mevcudiyetini tespit için moleküler testler, bireysel hastaları ve toplumu etkileyen salgınları takip etmek gibi sebeplerden kullanılmaktadır. Bunun yerine antikor testleri (serolojik immünolojik testler) birisinin bir zamanlar hastalığa sahip olup olmadığını göstermektedir. Antikor testleri mevcut enfeksiyonların teşhisinde daha az faydalıdır çünkü enfeksiyondan sonra haftalarca antikor gelişmediği gözlemlenmiştir [17-19].

Test analizi genellikle tıbbi laboratuvarlarda çalışan bilim insanları tarafından otomatikleştirilmiş, yüksek verimli tıbbi laboratuvarlarda gerçekleştirilmektedir. Alternatif olarak, muayenahanelerde ve otoparklarda, işyerlerinde, kurumsal ortamlarda veya toplu taşıma merkezlerinde bu testler yapılabilmektedir. Virüsün tespiti genellikle ya virüsün iç RNA'sı ya da virüsün dışındaki protein parçaları aranarak yapılmaktadır. Viral antijenleri (virüsün parçaları) arayan testlere antijen testleri denmektedir.

Virüsün RNA'sının varlığını tespit ederek virüsü arayan çok sayıda test türü kullanılmaktadır. 2021 itibariyle moleküler testler arasında en yaygın kullanılan yöntem ters transkripsiyon polimeraz zincir reaksiyonu yani PCR testidir [20-24]. Aşağıda yer alan Şekil 1.2'de PCR testi için örnek alma aşamaları gösterilmiştir.



Şekil 1.2. Burun ve Ağızdan Alınan PCR Sürüntü Testi Örneği [25]

1.3.2. Görüntüleme Yöntemleri

Göğüs BT görüntüler, hastalık şüphesi olan kişilerde COVID-19'u teşhis etmede kullanılmaktadır, ancak hekim tarafından gerekli görülmedikçe yüksek X-ışını dozlarından dolayı önerilmemektedir. Her iki akciğer lobunda da buzlu cam opasiteleri erken enfeksiyonda yaygın olarak görülmektedir. Göğüs radyografilerinde ve semptomatik olan kişilerin bilgisayarlı tomografilerinde (BT) karakteristik olarak asimetrik ve her iki lobda da bulunabilen buzlu cam opasiteleri bulunmaktadır.

Doğrulanmış vakalar için görüntüleme bulgularının uluslararası bir çevrimiçi veritabanını derleyen birçok grup, görüntüleri içeren COVID-19 veri kümeleri oluşturmuştur. Yapılan büyük bir çalışmada, BT sonuçlarını ile PCR sonuçları karşılaştırılmış ve BT'nin hastalık için daha az özgül olmasına rağmen daha seri ve daha hassas sonuçlar verdiği gösterilmiştir [26-29].

1.4. Görüntüleme Yöntemleri ile Covid 19 Teşhisi

1.4.1. Bilgisayarlı Tomografi


Göğüs BT'si, satın alınabilirliği, bulunabilirliği ve ayrıntılı anatomik çözünürlüğü nedeniyle pandeminin başlangıcından bu yana COVID19'un sebep olduğu zatürre lezyonlarının görüntülenmesinde sıklıkla kullanılmaktadır. Bilateral akciğer tutulumu en sık olarak, genellikle periferik, subplevral ve posterior dağılımda baskın olarak gözlemlenmektedir. Altta yatan vasküler ve bronş mimarisinin korunduğu puslu opasiteler olarak tanımlanan buzlu cam opasiteleri en yaygın olan gözlemlerdir ve oluşma oranları %50 ile %80 arasındadır [30-32].

Yayınlanmış literatürde bildirilen vaka oranlarındaki büyük farklılıkların muhtemelen hastalığın ilerlemesi, hasta özellikleri ve hastalığın genel ciddiyeti faktörlerinden kaynaklanması mümkündür. Örneğin, kritik hastalarda lineer opasiteler, konsolidasyon, bronşiyal duvar kalınlaşması modeli oluşum oranlarının hepsinin çok daha yüksek olduğu gözlemlenmiştir. Benzer şekilde, konsolidasyon gelişiminin, fibromiksoid eksüdaların alveoler birikimi ile çakışan hastalık ilerlemesi ile ilişkili olabileceği de öne sürülmüştür. Bu nedenle, bu lezyonlar hastalığın ilerleyen safhalarında ve 65 yaşın üzerindeki hastalarda daha belirgin olmaktadır. Ayrıca, başlangıç lezyonları genellikle akciğer çevresini işgal edebilirken, lezyon sayısında artış merkezci yayılma ile de hastalık ilerlemesi ile ilişkilendirilmektedir. Görüntüleme yöntemleri ile elde edilen sonuçlara göre hastalık yaklaşık 10 günde zirve yapma eğilimindedir [33-35].

Özellikle pediatrik popülasyonlara odaklanan çalışmalar, çocukların yetişkinlere kıyasla daha hafif hastalık yaşayabileceğini öne sürmüştür. Buna karşılık, gebe hastalar başlangıçta göğüs BT'sinde genel yetişkin popülasyonu ile benzer bulgularla başvurabilirken, güncel literatürde veriler bu popülasyonun aslında plevral efüzyonlarla daha sık ortaya çıkabileceğini ve ilerlemeye daha yatkın olabileceğini düşündürmektedir. Bununla birlikte, COVID-19 pnömonisinin görüntüleme bulgularının oldukça spesifik olmadığı ve hem SARS-CoV-1 hem MERS-CoV ile hem de diğer viral pnömonilerle çok sayıda örtüşen özelliği paylaştığı konusunda çeşitli çalışmalar bulunmaktadır. Özellikle, herpes simpleks virüsü, adenovirüs ve sitomegalovirüs pnömonilerinin hepsinin benzer görüntüler oluşturduğu incelenilmektedir. COVID-19 pnömonisinde göğüs BT bulgularının influenza virüsü pnömonisine karşı karşılaştırmalı bir çalışmada, konsolidasyon, opasiteler, interlobüler septal kalınlaşma, bronşiyal duvar kalınlaşması, sentrilobüler nodüller, mozaik zayıflama, hava bronkogramları ve yanallık varlığında hiçbir fark bulunamamıştır [36-38]. Aşağıda bulunan Şekil 1.3 ve Şekil 1.4'te zatürre lezyonu bulunan ve bulunmaya BT görüntüleri gösterilmiştir.




Şekil 1.3. Zatürre Lezyonu Görülmeyen Bir BT Görüntüsü



Şekil 1.4. Buzlu Cam Opasiteleri (Akciğer İçerisinde Bulunan Gri Bulanık Görüntüler)
Şeklinde Zatürre Lezyonu Görülen BT Görüntüsü

1.4.2.Akciğer Röntgeni

COVID-19 zatürre lezyonunu tespit etmek için göğüs röntgeni kullanılan diğer bir metottur ancak tek bir yönden bakış açısı sağlaması sebebiyle net bir görüş sağlamak nispeten daha zordur. Ancak röntgen görüntüleri, geleneksel tanı testlerine göre çok daha yaygın ve uygundur. Dijital X-ışını görüntülerinin alımı ile aktarımı arasında oldukça kısa bir süre mevcuttur. Bu nedenle teşhis sürecini son derece hızlı hale getirir. BT taramalarından farklı olarak, portatif X-ışını makineleri ayrıca bir izole ortam içinde çekim yapılmasını sağlar, bu nedenle ek kişisel koruyucu ekipman gereksinimine gerek duyulmaz. Ayrıca hastalar için BT de alınan yüksek dozlu radyasyon riskini de azaltır [39-41]. Şekil 1.5'te zatürre lezyonu görülen ve görülmeyen akciğer röntgeni gösterilmiştir.




Şekil 1.5. Zatürre Lezyonu Görülmeyen (üstte) ve Zatürre Lezyonu Görülen (altta) Akciğer Röntgenleri [41]

1.4.3. Manyetik Rezonans Görüntüleme

Giderek artan sayıdaki vakalar, diğer klinik endikasyonlar için baş ve boyun veya göğüs MR görüntülemesi yapılan kişilerde COVID-19 pnömonisi ile ilgili tesadüfi bulguların görselleştirilmesini doğrulamıştır. Sekiz hastadan oluşan bir ön vaka serisinde opasitelerin görselleştirilmesi, konsolidasyon, retikülasyon görülmüştür. Benzer şekilde, diğer bir çalışmada opasitelerin veya konsolidatif lezyonların MR görüntüleme tespitinde geleneksel BT'ye göre anlamlı bir farklılık göstermemiştir. Ultrashort eko zamanlı MR (UTE-MRI) ile konvansiyonel BT'nin ileriye dönük karşılaştırmalı analizinde de lezyon tespitinde yüksek uyum göstermiştir. Şüpheli alt solunum yolu enfeksiyonlarını değerlendirmek için rutin olarak kabul edilmese de, pulmoner MR görüntüleme, hamile hastalar ve iyonlaştırıcı radyasyona maruziyetten kaçınılması gereken çocuklar gibi yüksek riskli hasta gruplarının görüntülenmesi için uygun bir alternatif sağlayabilmektedir [42-47].

Şekil 1.6'da zatürre lezyonu görülen BT ve MR görüntüleri gösterilmiştir.




Şekil 1.6. Karşılaştırmalı Olarak Zatürre Lezyonu Görülen BT (solda) ve MR (sağda) Görüntüleri [46]

1.4.4. Pozitron Emisyon Tomografisi

Pozitron emisyon tomografisi de COVID-19 zatürre lezyonlarının belirlenmesi için kullanılan yöntemlerden birisidir. Bu yöntemde kullanılan F etiketli florodeoksiglukoz (F-FDG), yaklaşık 110 dakikalık bir yarı ömre sahip bir glikoz analogu pozitron yayan radyoizleyicidir. En iyi malignitelerin fonksiyonel görüntülemesindeki uygulanabilirliği ile bilinmesine rağmen, enfeksiyöz ve inflamatuvar pulmoner durumların değerlendirilmesinde ve karakterizasyonunda F-FDG-PET kullanımının artan bir rolü vardır. Önceki çalışmalar, kronik obstrüktif akciğer hastalığı (KOAH) ve astım gibi hastalıklarda akciğer hücrelerinin davranışını incelemek için damardan enjekte edilen radyoaktif maddeler ile görüntülemesi

iin bir kullanılmıřtır. BT ile birleřtiėinde, PET/BT, hem fonksiyonel hem de anatomik srelerin ayrıntılı deėerlendirilmesini saėlamaktadır [48-52].

Ařaėıda yer alan řekil 1.7’de zatrre lezyonu grlen PET-BT grnts gsterilmiřtir.



řekil 1.7. Zatrre Lezyonu Grlen PET-BT Grnts [51]

1.5.Derin ėrenme

Derin ėrenme, yapay sinir aėlarına dayalı, sistemin sınıflandırma veya ėrenme grevinin kendi kendine geliřtirdiėi, makine ėrenimi yntemlerin parasıdır. ėrenme sistemi, denetimli, yarı denetimli veya denetimsiz olarak gerekleřebilir. Derin ėrenme, konuřma tanıma, bilgisayarla grme, makine evirisi, doėal dil iřleme, biyoinformatik, tıbbi grnt analizi, ila tasarımı gibi alanlara, derin sinir aėları, derin pekiřtirmeli ėrenme, derin inan aėları, evriřimli veya konvolsyonol sinir aėları, tekrarlayan sinir aėları gibi derin ėrenme mimarileri ile uygulanmıřtır [53-57].

Yapay sinir aėları, organizmalarda bulunan sistemlerdeki bilgi iřleme ve bu bilgiyi ileten dėmlerden ilham almaktadır. Ancak YSA'ların organizmalardan belirli bařlı ynlerden farklılıkları bulunmaktadır. zellikle, yapay sinir aėları dijital ve matematiksel olarak iřlerken, oėu canlı organizmanın beyni analog ve dinamiktir. Derin ėrenme ismi, aėda ok fazla yani derin seviyede katmanın kullanımını ifade etmektedir. Modern derin ėrenme sistemlerinin bir oėu yapay sinir aėları ile gerekleřtirilmektedir. Yapay sinir

ağları arasında da özellikle evrişimli veya konvolüsyonel sinir ağları (CNN) en çok kullanılan yöntemlerdir [58-60].

Derin öğrenmenin içerdiği her bir katman, somut girdi verilerini daha da soyut ve bileşik bir fonksiyonel modele dönüştürmeyi öğrenmektedir. Örneğin, bir hayvan ayırma ve tanımlama uygulamasında, giren veri bir görüntü olabilir; birinci katmanda pikseller soyutlanabilir ve kenarlar kodlanabilir; ikinci katmanda, kenarların düzenlemeleri oluşturulabilir ve kodlanabilir; üçüncü katmanda burnu, gözleri, kulakları ve tüy rengi kodlanabilir ve son katman görüntünün hangi hayvanı içerdiğini anlayabilir. Asıl önemli olan nokta, bir derin öğrenme uygulaması, hangi çıkarım işleminin hangi düzeyde daha uygun şekilde yerleştirileceğini kendi başına öğrenebilir. Ancak, kendi kendine öğrenmesi, insana olan ihtiyacı tamamı ile yok etmez, örnek olarak; katman özellikler ve katman boyutu vb. [61-62].

Denetimli öğrenme için, derin öğrenme yöntemleri, verileri ana bileşenlere benzer kompakt ara öğelere çevirerek ham verilerdeki gereksiz bölümleri yok eden katmanlı yapılar türetir. Derin öğrenme algoritmaları, herhangi bir denetim içermeyen yani verilerin ham olduğu öğrenme görevlerinde de uygulanabilir. Bu derin öğrenme için çok önemlidir çünkü etiketlenmemiş ham halde olan veriler etiketlenmiş verilerden çok daha fazladır [63-64].

1.5.1.Yapay Sinir Ağları

Yapay sinir ağları (YSA) veya bağlantı sistemleri, organizmaların bir bileşeni olan biyolojik sinir ağlarından ilham alan bilgi işleme mekanizmalarıdır. Bu tür sistemler, genellikle işe özel programlama olmadan, örnekler üzerinden işi yapmayı öğrenir ve kademeli olarak yeteneklerini geliştirir. Örneğin, görüntü tanıma yöntemleri için, el ile girilen "covid" veya "normal" olarak önceden sınıflandırılmış örnek görüntüleri analiz ederek, test görüntülerindeki lezyonları bulmak için analiz sonuçlarını kullanarak zatürre lezyonu bulunan ve bulunmayan görüntüleri öğrenebilirler.

Bir yapay sinir ağı, biyolojik beyindeki biyolojik nöronlara benzeyen ve yapay nöronlar olarak adlandırılan birbirleri ile bağlantılı birimler kümesidir. Ağlar arasındaki her irtibat kuran bölüm, başka bir ağa bilgi iletebilir. Alıcı olan ağ, sinyali veya sinyalleri işleyebilir ve daha sonra ona bağlı olan akıştaki diğer ağlara sinyal gönderebilir. Ağlar, genellikle gerçek sayılarla temsil edilen, tipik olarak 0 ile 1 arasında bir değer alabilirler. Ağlar ve bağlantı yolları ayrıca, akış yönünde ilettiği veri veya sinyalin derecesini ve genliğini artırabilen veya azaltabilen yapılardır ve ağda ilerleme katedildikçe


gelişebilmektedirler. Yapay sinir ağları katmanlar halinde oluşturulur. Birbirinden farklı katmanlar, girdileri üzerinde farklı türde dönüşümler gerçekleştirebilir.

Sinir ağları, konuşma tanıma, görüntü tanıma, tıbbi teşhis, makine çevirisi, gibi çeşitli alanlarda kullanılmaktadır. Günümüzde sinir ağları genellikle binlerce hatta milyonlarca birime ve bağlantıya sahip olabilmektedirler. Bu sayı, bir insandaki nöron sayısından daha azdır ancak, bu ağlar, insanlarınkinden daha yüksek düzeyde birçok görevi gerçekleştirebilmektedir [65-68].

1.5.1.1.İleri Beslemeli Sinir Ağları

İleri beslemeli sinir ağlar, bağlantılar arasında bir döngü oluşturmaz ve bu özelliğiyle ön plana çıkan tek yönlü bir yapay sinir ağıdır. Bu özelliği ile, tekrarlayan sinir ağlarından ayrılmaktadır. Tasarlanan ilk ve en basit yapay sinir ağı türü ileri beslemeli sinir ağlarıdır. Bu ağda bilgi, girdi katmanından, gizli katmanlar aracılığıyla ve çıkış katmanına doğru tek bir yönde, ileriye doğru, hareket eder ve ağda döngü veya geri besleme yoktur. İleri belemeli sinir ağında girdiler doğrudan doğruya çıktılar ile beslenir [69].

Aşağıda bulunan Şekil 1.8’de düz bir yapay sinir ağı sistemi gösterilmiştir.




Şekil 1.8. Basit Anlamda Düz Bir Yapay Sinir Ağı Sistemi

Bu ağ çeşidi, ileri yönlü bir şekilde birbirilerine bağlı birçok hesaplama katmanından oluşmaktadır. Bir katmandaki her parametre, sonraki katmanın parametrelerine bağlantıları yönlendirilmiş ve önceki nöronların çıktıları kendilerinden sonra gelen nöronların girdileri olarak kullanılmıştır [70].

1.5.1.2.Konvolüsyonal Sinir Ağları

Derin öğrenmede, evrişimli veya konvolüsyonal sinir ağı (CNN), en çok görüntüleri analiz etmek için kullanılmakta olan yapay sinir ağı sınıfıdır. Görüntü ve videolardan obje tanıma,, görüntü sınıflandırma, çeşitli öneri sistemleri, görüntü bölümlendirme, tıbbi görüntü analizi, insan-bilgisayar arayüzleri gibi alanlarında uygulamaları bulunmaktadır [71].



Şekil 1.9. Konvolüsyonal Sinir Ağı Sistemini Bir Gösterimi


Konvolüsyonal sinir ağları, çok katmanlı derin öğrenme sistemlerinin derlenmiş modelleridir. Birden çok katmanı bulunan derin öğrenme sistemleri genellikle parametrelerin birbiriyle tamamen ilişkili olduğu ağlar anlamına gelmektedir, bu da bir katmandaki her parametrenin bir sonraki katmandaki tüm parametrelere bağlı olduğunu göstermektedir. Bu ağlar arasındaki bağlanabilirlik ilişkisi, onları daha fazla veriyle işlem yapabilir hale getirmektedir [72-73].

CNN'lerde, diğer görüntü ile ilgili algoritmalara nazaran daha az ön işleme kullanılmaktadır. Bu, ağın otomatikleştirilmiş öğrenme yoluyla filtreleri optimize etmeyi öğrenmektedir yani el ile belirlenen özelliklerde kullanılan filtrelere ihtiyaç duyulmamaktadır. Öznitelik çıkarmada ham verilerin kullanımı ve insan müdahalesinden bağımsızlık, sistem için büyük bir avantajdır [74-75].

1.5.1.3. Kalıntısıl Sinir Ağları

. Artık sinir ağları, atlama bağlantılarını veya bazı katmanların üzerinden atlamak için ağda bulunan kısayolları kullanarak atlama işlemini yapmaktadır. ResNet modelleri, doğrusal olmayanlar ve arada toplu normalleştirme içeren çift veya üç katmanlı atlamalarla uygulanmaktadır. Artık sinir ağları bağlamında, artık olmayan bir ağ, düz bir ağ olarak tanımlanabilmektedir [76].

Aşağıdaki Şekil 1.10'da kalıntısıl sinir ağının, kalıntıları toplama yöntemi gösterilmiştir.



Şekil 1.10. Kalıntısıl Sinir Ağının Kalıntıları Toplama Yöntemi

Atlama bağlantıları eklemenin iki ana nedeni vardır: kaybolan gradyanlar sorununu önlemek veya doğruluk doygunluğu sorununu azaltmak; uygun şekilde derin bir modele daha fazla katman eklemek, daha yüksek eğitim hatasına yol açmaktadır [77].

Atlama, eğitimin başlarında daha az katman kullanarak eğitimi ya da ağı etkili bir şekilde basitleştirir. Bu, kullanımda daha az katman olduğundan, kaybolan gradyanların etkisini azaltarak öğrenmeyi hızlandırmaktadır. Ardından ağ, özellik alanını öğrenirken atlanan katmanları kademeli olarak geri yükler. Artık parçaları olmayan bir sinir ağı, özellik alanının daha fazlasını keşfeder [78-80].

1.5.2.Derin Öğrenme Uygulama Alanları

Derin öğrenme, görüntü tanıma, doğal dil işleme,görsel sanat işleme, ilaç keşfi ve toksikoloji, öneri sistemleri, müşteri ilişkileri yönetimi, mobil reklamcılık, kısmi diferansiyel denklemler, görüntü restorasyonu, tıbbi görüntü analizi ve biyoinformatik gibi çeşitli alanlarda kullanılmaktadır [81-98].

1.5.2.1.Görüntü Tanıma

Görüntü sınıflandırmasında birçok ortak veri seti günümüzde oluşturulmuştur. Bazı veri tabanı setleri yüzbinlerce veri ile milyarlarca veri ile eğitilmiştir. Bu setler görüntü veya obje tanıma amaçlı olarak kullanılmaktadır.

Derin öğrenme tabanlı görüntü tanıma sistemleri, gün geçtikçe insanlara göre daha iyi sonuçlar üreten ve daha kararlı çalışabilen bir hale gelmeye başlamıştır. Bu, ilk olarak 2011'de trafik işaretlerinin ve 2014'te de insan yüzlerinin tanınmasıyla gerçekleşmiştir. Derin öğrenmeyle eğitilmiş araçlar artık 360° kamera görüntülerini yorumlayabilmektedir [81].

1.5.2.3.Görüntü Restorasyonu

Derin öğrenme, gürültü giderme, çözünürlük artırma, görüntü renklendirme ve film renklendirme gibi genel problemlere başarıyla uygulanmıştır [89].


1.5.2.4.Tıbbi Görüntü Analizi

Tıpta ilk uygulamalardan biri, hastalar için farklı antibiyotik tedavi rejimleri öneren Shortliffe tarafından geliştirilen sistem olmuştur. Bu gelişmelerle birlikte, yapay zeka algoritmaları buluşsal tabanlı tekniklerden, manuel özellik çıkarma tekniklerine ve ardından denetimli ve denetimsiz öğrenme tekniklerine geçiş yapmıştır. Denetimsiz makine öğrenme yöntemleri de günümüzde kullanılmaktadır, ancak yayınlanan literatürde halen daha kullanılan algoritmaların çoğu denetimli öğrenme yöntemlerini, diğer bir deyişle evrişimli ağırlarını kullanmıştır. Günümüzde etiketli veri setlerinin sayısının artması, grafik işleme birimlerindeki donanım gelişmeleri, CNN performansındaki gelişmelerle birlikte, bunların tıbbi görüntü analizinde yaygın olarak kullanımına yol açmıştır [92-93].

Derin bir sinir ağının avantajı, önemli ve belirgin özellikleri örneğin, çizgiler veya kenarlar gibi, otomatik olarak öğrenme ve bunları sonraki katmanlarda daha da geliştirerek yüksek seviyeli özelliklerle birleştirme yeteneğidir. Memeli ve insan görsel kortekslerinin

görsel bilgiyi işlemesi ve nesneleri bu şekilde tanıdığı düşünülmektedir. Derin öğrenme tıbbi görüntü analizinde son dönemlerde popüler bir metot haline gelmiştir [94-96].

Şekil 1.11’de derin öğrenme için girdi olarak kullanılabilen çeşitli tıbbi görüntüler gösterilmiştir.



Şekil 1.11. Derin Öğrenme İçin Girdi Oluşturan Çeşitli Tıbbi Görüntüler [92]

İncelenen bir organın hem 2 boyutlu hem de 3 boyutlu yapıları, neyin normale karşı anormal olduğunu belirlemek için çok önemlidir. Bu yerel uzamsal ilişkileri sürdürerek, CNN'ler görüntü tanıma görevlerini gerçekleştirmek için çok uygun sistemlerdir. CNN'ler, görüntü tanıma, sınıflandırma, algılama, segmentasyon ve kayıt dahil olmak üzere birçok yönde kullanılmaktadır. CNN'ler, boyutsallık azaltırken, yerel görüntü ilişkilerini de korumaktadır. Bu özelliği nedeniyle görüntü tanıma ve görsel öğrenme görevlerinde en popüler makine öğrenme algoritmasıdır. Bu, bir görüntüdeki önemli özellik ilişkilerini yakalar örneğin, bir kenardaki piksellerin bir çizgi oluşturmak için nasıl birleştiği gibi ve algoritmanın hesaplaması gereken parametre sayısını azaltarak hesaplama verimliliğini artırır. CNN'ler hem 2 boyutlu görüntüleri hem de küçük değişikliklerle 3 boyutlu görüntüleri girdi olarak alabilir ve işleyebilir. Tıbbi görüntü analizinde kullanılmak üzere denetimsiz öğrenme algoritmaları da kullanılmaktadır. Bunlara otomatik kodlayıcılar, kısıtlı Boltzmann makineleri, derin inanç ağları ve üretken düşman ağları dahildir. Derin öğrenme,

lezyon tespiti, kanser hücresi sınıflandırması, görüntü iyileştirme ve organ segmentasyonu gibi tıbbi uygulamalarda yüksek başarımlar ürettiği gösterilmiştir [97-98].

1.6. Tıbbi Görüntülerde Derin Öğrenme

Son birkaç on yılda, bilgisayarlı tomografi, manyetik rezonans görüntüleme, mamografi, ultrason, pozitron emisyon tomografisi ve röntgen gibi tıbbi görüntüleme teknikleri erken teşhis ve hastalıkların tedavisi için kullanılmıştır. Klinikte tıbbi görüntü yorumlaması çoğunlukla radyologlar ve hekimler gibi uzmanlar tarafından yapılmıştır. Bunlar göz önüne alınarak, hastalıklardaki geniş çeşitlilik ve uzmanların iş yükünden, geniş mesai sürelerinde doğabilecek yorgunluk göz önüne alındığında, bu personeller bilgisayar destekli müdahalelerden yararlanmaya başlamışlardır. Otomatize edilmiş tıbbi görüntü analizindeki ilerleme hızı tıbbi görüntüleme teknolojilerindeki kadar hızlı olmasa da, makine öğrenmesi tekniklerinin devreye girmesiyle durum paralel bir hal almaya başlamıştır.

Makine öğrenimini uygularken, verilerin doğasında bulunan düzenlilikleri veya kalıpları iyi tanımlayan bilgilendirici özelliklerin bulunması veya öğrenilmesi, tıbbi görüntü analizindeki çeşitli görevlerde çok önemli bir rol oynamaktadır. Günümüz derin öğrenme metotlarında, özellikleri manuel olarak çıkarmak yerine, derin öğrenme, gerekirse küçük ön işleme ile yalnızca bir dizi veri gerektirmektedir. Ardından bilgilendirici temsilleri, sistem, kendi kendine öğretir ve keşfeder. Bu nedenle, görüntü özellikleri ile ilgili uzmanlık bir gereksinim olmaktan çıkıp, bilgisayarlarla birlikte makine öğreniminde uzman olmayan kişilerin derin öğrenmeyi kendi araştırmaları ve/veya uygulamaları için, özellikle tıbbi görüntü analizinde etkin bir şekilde kullanmalarına olanak sağlamıştır [99-100].

Derin öğrenmenin yüksek başarısının kaynakları aşağıdaki gibi sıralanabilmektedir:

- Merkezi işlem birimleri (CPU'lar) ve grafik işleme birimlerindeki (GPU'lar) gelişmeler,
- Veri miktarındaki artış,
- Öğrenme algoritmalarındaki gelişmeler.

Teknik olarak derin öğrenme, çoklu (ikiden fazla) katmana sahip ağların oluşturulmasını sağlaması bakımından geleneksel yapay sinir ağlarına göre bir gelişme olarak kabul edilebilir. Derin sinir ağları, daha yüksek seviyeli özelliklerin daha düşük seviyeli özelliklerden türetilmesi için hiyerarşik özellik çıkarımı yapabilmektedir. Özellikle bilgisayarla görme alanındaki gelişmeler, görüntü segmentasyonu, görüntü kaydı, görüntü sınıflandırma, görüntü açıklama, bilgisayar destekli tanı ve lezyon/yer işareti tespiti ve

mikroskobik görüntü gibi tıbbi görüntü analizinde derin öğrenmenin kullanılmasını teşvik etmiştir.

Derin öğrenme yöntemleri, eğitim aşamasında mevcut örneklerin sayısı fazla olduğunda oldukça etkilidir, ancak doyum seviyesi aşıldığında sistemlerin yavaşlaması söz konusu olmaktadır. Örneğin, ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasında (ILSVRC), bir milyondan fazla açıklamalı görüntü sunmaktadır. Bunun yanı sıra, çoğu tıbbi uygulamada çok az kaynak görüntüsü vardır. Bu nedenle, derin öğrenmeyi tıbbi görüntülere uygulamadaki en büyük zorluk, veri yetersizliği yani fazla uyum sorunu yaşamadan derin modeller oluşturmak için mevcut sınırlı sayıdaki eğitim örneğidir. Bu zorluğun üstesinden gelmek için, araştırma grupları;

- Girdiyi azaltmak için tam boyutlu görüntüler yerine iki boyutlu (2B) veya üç boyutlu (3B) görüntü yamaları almak;
- Veri büyütme yoluyla yapay olarak örnekler üreterek veri kümesini genişletmek ve daha sonra artırılmış veri kümesiyle ağlarını sıfırdan eğitmek;
- Bilgisayarla görüde çok sayıda doğal görüntü üzerinde eğitilmiş derin modelleri "kullanıma hazır" özellik çıkarıcılar olarak kullanmak ve ardından hedef görev örnekleriyle son sınıflandırıcıyı veya çıktı katmanını eğitmek;
- Model parametrelerinin tıbbi olmayan veya doğal görüntülerden önceden eğitilmiş modellerinkilerle başlatılması, ardından görevle ilgili örneklerle ağ parametrelerinin ince ayarının yapılması;

Derin sinir ağları ile birlikte, oluşturulan modeller, günümüzde beyin hastalığı teşhisine, lezyon segmentasyonuna, hücre segmentasyonuna, görüntü ayrıştırmasına ve doku sınıflandırmasına başarıyla uygulanmıştır [101-103].

1.7.COVID-19 Zatürre Lezyonlarının Tespiti

Harmon ve arkadaşlarının yaptığı çalışmada, parietal plevra/akciğer parankimini lokalize etmek için 1280 hastadan oluşan çok uluslu bir veri seti ile eğitilmiş ve ardından COVID-19 zatürresi sınıflandırmasının takip ettiği bir dizi derin öğrenme algoritmasının %90.8 kesinlik, %84 hassasiyet ve %93 özgüllük sonuçları elde edilmiştir. Normal kontroller onkoloji, acil durum ve zatürre ile ilgili endikasyonlardan elde edilen göğüs BT'lerini içermektedir. Laboratuvar tarafından doğrulanmış diğer zatürre tiplerine sahip olan 140 hastada yanlış pozitiflik oranı %10 olarak elde edilmiştir [104].

Gozes ve arkadaşlarının yaptığı çalışmada çalışmada radyologları desteklemek için sınırlı ek açıklamalar ile göğüs BT taramalarından COVID-19 hastalığının ciddiyetini tespit edebilen, lokalize edebilen ve ölçebilen zayıf denetimli bir derin öğrenme sistemi geliştirilmiştir. Sistem, veri kümelerinin kullanılabilirliğinin sınırlı olduğu bir pandeminin, ilk patlak verdiği dönemde hızla bir çözüm sağlamak üzere tasarlanmıştır. Sistem akciğer segmentasyonu, 2 boyutlu dilim sınıflandırması ve lokalizasyon içeren bir dizi görüntü işleme algoritmasından oluşmuştur. Ek olarak, hastalığın şiddet derecesine karşılık gelen Coronascore biyo belirteçleri sunulmuştur [105].

Kassania ve arkadaşlarının yaptığı çalışmada, otomatik COVID-19 sınıflandırması için popüler derin öğrenme tabanlı özellik çıkarma sistemleri karşılaştırılmıştır. Çalışmada en doğru özelliği elde etmek için, derin evrişimli sinir ağlarından oluşan bir havuz arasından DenseNet, MobileNet, Xception, InceptionV3, ResNet, InceptionResNetV2, NASNet, VGGNet seçilmiştir. Çıkarılan özellikler daha sonra konuları bir COVID-19 vakası veya bir kontrol olarak sınıflandırmak için birkaç makine öğrenimi sınıflandırıcısına aktarılmıştır. Önerilen yöntemin performansı, göğüs röntgeni ve BT görüntülerinden oluşan halka açık bir COVID-19 veri seti ile denenmiştir. DenseNet121 öznitelik çıkarıcı, %99 sınıflandırma doğruluğu ile en iyi performansı elde etmiştir ve ikinci en iyi öğrenici, LightGBM tarafından %98 doğrulukla eğitilmiş bir ResNet50 özellik çıkarıcı olmuştur [106].

2.MATERYAL METOT


2.1.Verİ Setİ

5 Mart - 23 Nisan 2020 tarihleri arasında İran'da Sari'de bulunan Negin radyolojisinden alınan açık kaynak veriler kullanılmıştır. Bu tıp merkezi 512x512 piksel çözünürlüğe sahip 16 bit gri tonlamalı DICOM görüntüler sunan, SOMATOM Scope modeli BT ve syngo CT VC30- easyIQ yazılımını kullanmaktadır. Dışa aktarılan radyoloji görüntülerinin formatı, formatındadır. Hastanın bilgilerine DICOM dosyaları aracılığıyla erişilebildiğinden ve bu bilgiler dosyada görüntü haricinde de yer kapladığından, bu görüntüler yine 16 bit olacak şekilde gri tonlamalı verileri tutan ancak hastaların özel bilgilerini depolamayan TIFF formatına dönüştürülmüştür. Ayrıca, TIFF formatının DICOM formatına göre önemli bir özelliği de, standart programlama kitaplıklarıyla kullanımı daha kolaydır. Veri setinin avantajlarından birisi sınıflandırma sonuçlarını iyileştirmeye yardımcı olan ancak daha dar bir aralıkta değerleri olan 8 bit veri yerine 16 bit veri formatında depolanmasıdır. DICOM dosyalarının 8 bit veriye dönüştürülmesi, özellikle görüntüde klinik uzmanların bile tespit etmesi zor olan birkaç enfeksiyon varsa, bazı verilerin kaybolmasına neden olabilmektedir. Orijinal 16 bit BT görüntüleri insan gözünün ayırt edemediği ancak bilgisayarların işlenirken fark ettiği çeşitli bilgiler içerebilmektedir. Veri setindeki verilerin piksel değerleri 0 ile 5000 arasında değişmektedir.

Şekil 2.1 ve Şekil 2.2’de veri setinde bulunan zatürre lezyonu görülen ve görülmeyen BT görüntülerinden örnekler gösterilmiştir.




Şekil 2.1. Veri Setinde Yer Alan Zatürre Lezyonu Görülen BT Görüntüleri




Şekil 2.2. Veri Setinde Yer Alan Zatürre Lezyonu Görülmeyen BT Görüntüleri

Veri seti, COVID-19 ile enfekte 95 hastaya ait 15.589 görüntü ve 282 normal insana ait 48.260 görüntüden oluşmaktadır. Her hastanın, farklı sekans sayıları ile alınan BT taramalarını içeren üç ayrı klasörü vardır [107].


Şekil 2.3., Şekil 2.4. ve Şekil 2.5.'te veri setinden çeşitli görüntüler gösterilmiştir.



Şekil 2.3. Veri Setinde Bulunan BT Görüntülerin İlk (üstte), Orta ve Son (altta) Sekansları



Şekil 2.4. Veri Setinde Bulunan Açık Gözüken Akciğer BT Görüntüleri



Şekil 2.5. Veri Setinde Buluna Kapalı Gözüken Akciğer BT Görüntüleri

2.1.1.DICOM Görüntü Tipi

Tıpta dijital görüntüleme ve iletişim kelimelerinin İngilizce karşılığının kısaltılmış hali olan DICOM, tıbbi görüntüleme bilgilerinin ve ilgili verilerin iletişimi ve yönetimi için standartlaşmış bir sistematik görüntü biçimidir. DICOM günümüzde sağlık kuruluşlarında alınan, farklı üreticilerin farklı görüntüleme sistemlerinden alınan verileri, resim arşivleme ve iletişim amacıyla, depolamak ve iletmek için kullanılan dosya sistemleridir. Hastaneler ve birçok sağlık kuruluşu tarafından geniş çapta kullanılmaktadır.

DICOM dosyaları, farklı marka ve modelde DICOM formatında görüntü ve hasta verilerini alabilen iki cihaz arasında değiş tokuş edilebilir. Farklı cihazlar, hangi DICOM sınıflarını desteklediklerini belirten DICOM uygunluk bildirimleri ile birlikte gelir.

DICOM, tıbbi görüntüleri depolamak, değiştirmek ve iletmek için dünya çapında kullanılmaktadır. DICOM, modern radyolojik görüntülemenin geliştirilmesinde merkezi olmuştur. Radyografi, ultrasonografi, bilgisayarlı tomografi, manyetik rezonans görüntüleme ve radyasyon tedavisi gibi görüntüleme modülleri için standartları bünyesinde barındırmaktadır. DICOM, görüntü alışverişi, görüntü sıkıştırma, 3 boyutlu görselleştirme, görüntü sunumu ve sonuç raporlama için çeşitli protokoller içermektedir [108].

DICOM dosyaları, bilgileri kümeler halinde gruplandırır ve birden fazla veri içerir. Örneğin, bir akciğer röntgeni görüntüsünün DICOM dosyası, içerisinde hasta kimliğini içerebilir, böylece görüntü ile görüntünün kime ait olduğu bilgisi hiçbir zaman yanlışlıkla birbirinden ayrılamaz.

Tek bir DICOM dosyası, birden çok veriyi barındırabildiği gibi yalnızca piksel verilerini içeren bir yapıya da sahip olabilir. Birçok görüntüleme sistemi için bu, tek bir görüntüye karşılık gelir. Piksel verileri, JPEG, kayıpsız JPEG, JPEG 2000 ve çalışma uzunluğu kodlaması dahil olmak üzere çeşitli standartlar kullanılarak sıkıştırılabilir [108].

2.1.2.TIFF Görüntü Tipi


TIFF veya TIF olarak bilinen görüntü dosyası biçimi, grafik sanatçılar, yüksek detay gerektiren endüstriler, yayıncılık ile uğraşanlar ve fotoğrafçılar arasında popülerdir ve grafiksel görüntüleri depolamak için kullanılan bir görüntü dosyası biçimidir.

Başlangıçta, TIFF yalnızca bir ikili görüntü formatıydı yani her piksel için yalnızca iki olası değer olan 1 ve 0'ı içeriyordu, çünkü masaüstü ekranlar günümüzdeki kadar gelişmemiş olması nedeniyle içerebileceği maksimum değerler bunlardı. Görüntü izleme teknolojisi geliştikçe ve disk alanları daha da büyüdükçe, TIFF gri tonlamalı görüntüler yanı sıra renkli görüntüleri de barındıracak şekilde geliştirilmiştir. Günümüzde, TIFF, JPEG ve PNG ile birlikte, gri tonlamalı ve çok katmanlı renkli görüntüler için kullanılan popüler formatlar arasındadır [109].

Şekil 2.6. ve Şekil 2.7.'de veri setinde bulunan 16 bit ve 8 bit'lik görüntüler gösterilmiştir.



Şekil 2.6. Veri Setinde Bulunan BT Görüntülerinin Gerçek Görünümü



Şekil 2.7. Veri Setinde Bulunan BT Görüntülerinin Görünebilir Hale Dönüştürülmüş Görünümü

2.2.Programlama Ortamı

2.2.1.Tensorflow ve Keras


TensorFlow, makine öğrenimi ve yapay zekâ için kullanılan açık kaynaklı bir yazılım ortamıdır. Birçok amaçla kullanılabilir, ancak derin öğrenme uygulamaları ve bunların modellenmesi amacıyla özel olarak geliştirilmiştir. TensorFlow, Google Brain ekibi tarafından araştırma ve üretimde Google'ın dahili kullanımı için geliştirilmiştir. İlk sürüm, 2015 yılında Apache Lisansı 2.0 adı altında yayınlandı. Google, Eylül 2019'da TensorFlow 2.0 adlı güncellenmiş TensorFlow sürümünü yayınlamıştır [110-113].

TensorFlow, Javascript, C++ ve Java'nın yanı sıra Python başta olmak üzere çok çeşitli programlama dillerinde kullanılabilir. Bu esneklik sayesinde, kendisini birçok farklı sektörde görmek mümkündür.

Keras, YSA için bir kullanılan açık kaynaklı bir yazılım kütüphanesidir. Keras, TensorFlow kitaplığı için bir arayüz görevi görür. Derin sinir ağlarıyla çok daha hızlı deneyler yapmak amacıyla tasarlanmış olup, kullanıcı dostu, modüler ve genişletilebilir özelliklere sahiptir. Keras, kullanıcıların derin modelleri akıllı telefonlarda, web sitelerinde veya çeşitli sanal makinelerde üretmelerine olanak tanır [114].

2.2.1.Jupyter Notebook ve Google Colab

Jupyter Notebook eski adıyla IPython Notebooks, not defteri belgeleri oluşturmak için web tabanlı etkileşimli bir hesaplama ortamıdır. Jupyter Notebook belgesi, kod, metin, matematik, grafikler ve zengin medya içerebilen sıralı bir giriş/çıkış hücreleri listesi içeren tarayıcı tabanlı bir derleyicidir. Arayüzün altında, bir not defteri, sürümlü bir şemayı izleyen ve genellikle ".ipynb" uzantısıyla biten bir not belgesidir. Şekil 2.8'de Jupyter Notebook'un arayüzü gösterilmiştir.



Şekil 2.8. Jupyter Notebook'un Arayüzü

Jupyter Notebook, farklı dillerde programlamaya izin vermek için birçok çekirdeğe bağlanabilir. Jupyter çekirdeği, çeşitli türdeki istekleri, örneğin kod yürütme, kod tamamlama, inceleme gibi, işlemekten ve yanıt sağlamaktan sorumlu bir programdır.

Google Araştırma Ekibinin geliştirmiş olduğu Google Colab ya da Colaboratory, programlama ortamını ve Jupyter Notebook derleyicisinin kullanılabildiği, ayrıca sanal makine, grafik ve tensör işlem birimi sunan sınırlı ücretsiz bir veri bilimi, makine öğrenmesi ve derin öğrenme ortamıdır. Bu çalışmada kullanılan veriler, yine Google'ın bulut sistemi olan Google Drive'da saklanmaktadır ve Google Colab ile kullanıldığında veriler bilgisayar ortamından değil, bulut ortamından alınıp ve yine bulut ortamına kaydedilmektedir [115].

Şekil 2.9.'da Google Colab'ın arayüzü gösterilmiştir.



Şekil 2.9. Google Colab'ın Arayüzü

2.2.3.Grafik İşlem Birimi

Bir grafik işleme birimi ya da GPU, bir bilgisayarın veya benzer bir görüntü çıkışı olan cihazlar için tasarlanan bir arabellekte görüntü ve grafik işleyebilen ve yüksek işlem kapasitesine sahip olan özel olarak tasarlanmış bir elektronik devredir. Grafik işleme birimleri cep telefonlarında, gömülü sistemlerde, kişisel bilgisayarlarda, oyun konsollarında, iş istasyonlarında kullanılmaktadır. Günümüzde grafik işleme birimleri, bilgisayar grafiklerini ve görüntü işlemeyi uygulamada CPU'lara göre çok daha verimlidir [116].

Derin öğrenmenin ortaya çıkmasıyla birlikte grafik işlem birimlerinin önemi artmıştır. Yapılan araştırmalarda, derin öğrenme eğitimlerinde GPU'ların CPU'lardan 250 kat daha hızlı olduğu bulunmuştur. Bu alanda, en belirgin olarak Google tarafından yapılan Tensör İşleme Birimi (TPU) ile bir miktar rekabet olmuştur. Ancak, TPU'lar mevcut kodda değişiklik gerektirir ve GPU'lar halen daha popülerliğini korumaktadır [117].

Yeni gelişen teknoloji sayesinde Nvidia Quadro gibi iş istasyonu kartları ve tensör ile derin öğrenme uygulamaları için ayrılmış işlem çekirdeklerine sahiptir. Nvidia'nın mevcut GPU serisinde bu çekirdeklere Tensör Çekirdekleri denir. Google Colab grafik işlem birimi olarak Nvidia markasının Tesla K80, T4 ve P100 modellerinin kullanımına izin vermektedir.

2.3.Derin Öğrenme Modeli

CNN, bilgisayarla görü için bir derin ileri beslemeli yapay sinir ağı sınıfı olarak tanımlanabilmektedir. Bu, basitçe ifade etmek gerekirse, “başlangıçta bir görüntü girişinin tüm katmanlar boyunca tek yönlü bir sırayla, istenen çıktının elde edildiği bir noktaya kadar dikkatlice rafine edilmesini sağlayacak şekilde yığılmış katmanlara sahip bir algoritmadır.”

CNN mimarilerinin her biri aşağıda gösterilen katmanları farklı şekilde kullanır;


- Evrişim katmanları; bir görüntüdeki özelliklerin uzamsal yönelimini korumak için kullanılır.
- Havuzlama katmanları; bir görüntüyü aşağı örneklemek için kullanılır (küçültülür)
- Tam bağlantılı katmanlar; evrişim/havuzlama katmanlarından gelen çıktıyı tek bir sütun matrisine yığmak ve daha küçük ancak makul bir çıktı elde etmek için sürekli olarak sıkıştırmak
- Yumuşak maksimum çıkış; tam bağlı katmanlar tarafından üretilen çıktıyı sunmak.

Derin evrişimli sinir ağıları, görüntü sınıflandırması için bir dizi atılımı yol açmıştır. Derin ağlar doğal olarak düşük/orta/yüksek seviye özellikleri ve sınıflandırıcıları uçtan uca

çok katmanlı bir tarzda entegre eder ve özelliklerin “seviyeleri” yığılanmış katmanların sayısı ile zenginleştirilebilir. Son çalışmalar ağ derinliğinin çok önemli olduğunu ve zorlu ImageNet veri kümesindeki önde gelen sonuçların tümünün "çok derin" modellerden yararlandığını ortaya koymaktadır. Derinliğin öneminden hareketle bir soru ortaya çıkıyor: Daha iyi ağ oluşturmak sadece katman sayısını artırmakla gerçekleştirilebilir mi?

Daha derin ağlar yakınsamaya başlayabildiğinde, bir bozulma sorunu ortaya çıkar: ağ derinliği arttıkça doğruluk doygun hale gelir (ki bu şaşırtıcı olmayabilir) ve ardından hızla düşer. Beklenmedik bir şekilde, bu tür bozulmaya fazla uydurma neden olmaz ve uygun şekilde derin bir modele daha fazla katman eklemek daha yüksek eğitim hatasına yol açar.

Şekil 2.10.’da katman sayısına karşılık hata oranları gösterilmiştir.



Şekil 2.10. Katman Sayısına Karşılık Hata Oranları

Katman sayısının artması hem eğitim, hem test aşamalarında hata oranını artırmaktadır, teorik olarak derinlik arttığında ağda eğitim hatasının azalmasını beklenir fakat gerçekte doğruluk doyar ve ardından hızla düşerek eğitim hatası artar.

2.3.1.VGG

VGG16 ve VGG19, Oxford Üniversitesi'nden Simonyan ve Zisserman tarafından geliştirilen evrişimli bir sinir ağı modelidir. Model, ImageNet'in yarışmasında 1000 sınıfa ait yaklaşık 15 milyon görüntüden oluşan veri setinde %92,7'lik test doğruluğuna ulaşmıştır. Büyük çekirdek boyutlu filtreleri birden fazla 3×3 çekirdek boyutunda filtreyle değiştirir.

Günümüzde ImageNet, yaklaşık 22.000 kategoriye ait 20 milyona yakın etiketlenmiş yüksek çözünürlüklü görüntüden oluşan bir veri kümesidir. Görüntüler internetten üzerinden toplanmış ve Amazon'un Mechanical Turk kitle kaynak aracını kullanan insanlar

tarafından etiketlenmiştir. 2010'dan itibaren, Pascal Görsel Nesne Yarışmasının bir parçası olarak, ImageNet Büyük Ölçekli Görsel Tanıma Yarışması (ILSVRC) adlı yıllık bir yarışma düzenlenmeye başlamıştır. ILSVRC, 1000 kategorinin her birinde yaklaşık 1000 görüntü içeren bir ImageNet alt kümesini kullanmaktadır [118].

Aşağıdaki Şekil 2.11.'de VGG16'nın katmanları gösterilmiştir.



Şekil 2.11. VGG16 Mimarisinin Katmanları

2.3.2.ResNet

ResNet, “Residual Network” yani artık ağ için kısa bir isimdir. Derin ağlar, düşük, orta ve yüksek seviyeli özellikleri ve sınıflandırıcıları uçtan uca çok katmanlı bir şekilde çıkarır ve yığılmış katmanların sayısı, özelliklerin "seviyelerini" zenginleştirebilir.


Daha derindeki ağ yakınsamaya başladığında, bir bozulma sorunu ortaya çıkar, yani ağ derinliği arttıkça doğruluk doygun hale gelir ve hata oranının da artmasıyla beraber doğruluk hızla düşmektedir. Eğitim doğruluğunun bozulması, tüm sistemlerin optimize edilmesinin kolay olmadığını göstermektedir. Katman atlama işlemi aşağıdaki formül ile ifade edilebilir.

$$y = F(x)$$

$$y' = y + x$$

$$y' = F(x) + x$$

Burada x , girdi iken y çıktıyı ifade etmektedir. Girdi ile çıktının toplanmasıyla birlikte yeni bir çıktı değeri oluşmaktadır.



Şekil 2.12. ResNet'in Kalıntı Toplama Yapısı

Bu sorunun üstesinden gelmek için Microsoft, derin bir kalıcı öğrenme çerçevesi sunmuştur. Her birkaç yığılmış katmanın doğrudan istenen temel işlemeye uymasını ummak yerine, bu katmanların artık bir işlemeye uymasına açıkça izin verirler. Konvolüsyon çıktısının konvolüsyonun girdisi ile toplamının formülasyonu, kestirme bağlantılara sahip ileri beslemeli sinir ağları ile gerçekleştirilebilir. Kısayol bağlantıları, Şekil 2.12.'de gösterilen bir veya daha fazla katmanı atlayabilmektedir. Kısayol bağlantıları kimlik eşleme yapar ve çıktıları yığın katmanların çıktılarına eklenir.

ResNet'leri optimize etmek kolaydır, ancak "düz" ağlar, derinlik arttığında daha yüksek eğitim hatası gösterir. ResNet'ler, önceki ağlardan daha iyi sonuçlar üreterek, büyük ölçüde artırılmış derinlikten kolayca doğruluk elde edebilir.

Düz ağlar, esas olarak VGG ağlarının felsefesinden esinlenmiştir. Evrişim katmanları çoğunlukla 3×3 filtreye sahiptir ve iki basit kuralı takip eder:


- Aynı çıktı özellik haritası için, katmanlar aynı sayıda filtreye sahiptir;
- Özellik haritasının boyutu yarıya indirilirse, her katmanın zaman karmaşıklığını korumak için filtre sayısı iki katına çıkar.

ResNet modelinin VGG ağlarından daha az filtreye ve daha düşük karmaşıklığa sahiptir. Artık ağ, düz ağa dayalı olarak, ağı karşılık gelen artık sürümüne dönüştüren bir kısayol bağlantısı eklenir. Seçeneklerden herhangi biri için, kısayollar iki boyutlu özellik haritalarında geçiyorsa, 2 adımda gerçekleştirilir.

Her ResNet bloğu ya iki katman derinliğindedir, ResNet 18, 34 gibi küçük ağlarda kullanılır ya da 3 katman derinliğindedir ResNet 50, 101, 152 bunlara örnek olarak

gösterilebilir. 50 katmanlı ResNet için, her 2 katmanlı blok, 34 katmanlı ağda bu 3 katmanlı darboğaz bloğuyla değiştirilir ve 50 katmanlı ResNet ile sonuçlanır. Boyutları artırmak için 2. seçeneği kullanırlar [78].

Şekil 2.13.'te 34 katmanlı ve 50 katmanlı ResNet için iki farklı artık toplama yöntemi gösterilmiştir. Şekil 2.14.'te ise ResNet50'nin katmanları gösterilmiştir.



Şekil 2.13. 34 Katmanlı (solda) ve 50 Katmanlı (sağda) ResNet Modelinin Artık Toplama Yöntemi



Şekil 2.14. ResNet50'nin Katmanları

2.3.3.ResNetV2

ResNetV2'nin tamamen ağırlık katmanlarının aktivasyon sonrası yerine ön aktivasyonunu kullanmakla ilgilidir. ResNetV1 ve ResNetV2 arasındaki büyük farklar aşağıdaki gibidir:

- ResNetV1, konvolüsyon girişi ve konvolüsyon çıkışı arasında toplama işlemi gerçekleştirildikten sonra ikinci doğrusal olmayanlığı ekler. ResNet V2, son doğrusal

olmayanlığı ortadan kaldırmış, bu nedenle girişten çıkışa giden yolu kimlik bağlantısı biçiminde temizlemiştir.

- ResNetV2, ağırlık matrisi ile çarpmadan yani konvolüsyon işleminden önce girdiye toplu normalleştirme ve ReLU aktivasyonu uygular. ResNet V1 ise, evrişim ardından toplu normalleştirme ve ReLU aktivasyonunu gerçekleştirir.

ResNetV2 temel olarak ikinci doğrusal olmayanlığı bir kimlik eşlemesi olarak yapmaya odaklanır, yani kimlik eşleme ile artık eşleme arasındaki ekleme işleminin çıktısı, sonraki işlemler için bir sonraki bloğa olduğu gibi geçirilmelidir. Ancak ResNet V1'deki ekleme işleminin çıkışı ReLU aktivasyonundan geçer ve daha sonra giriş olarak bir sonraki bloğa aktarılır.

Aşağıdaki Şekil 2.15.'te, ResNet sürümlerinin etkinleştirme sonrası (orijinal sürüm 1) ve ön etkinleştirme (sürüm 2) temel mimarisini göstermektedir [119].



Şekil 2.15. ResNet50 (üstte) ve ResNet50v2'nin (altta) Katman Sıralamaları

2.3.4.Katman Eklenmiş ResNetV2


ResNetV2, VGG ve ResNet yöntemlerinden sonra her ne kadar yeterli gibi görünse de konvolüsyon ve düzleştirme katmanları eklenerek daha iyi sistemler elde edilmeye çalışılmıştır. Ayrıca ResNet50V2'nin çıkış katmanından sonra iki adet konvolüsyon katmanı ile birlikte yoğunlaştırma katmanları da sisteme eklenerek sistemin oluşturduğu özellik çıkarımı geliştirilmek istenmiştir.

2.4.Katmanlar

2.4.1.Conv2D


Öğrenmenin asıl olarak gerçekleştiği ve öğrenme parametrelerinin olduğu katmandır. İki boyutlu veriye uygulanacak olan kernel veya filtrenin farklı eksenlerde simetrisi alınır ve verideki tüm değerler kernel ile hücre hücre çarpılır ve sonuçta elde edilen toplam değeri çıkış matrisinin ilgili elemanına olarak yazılır. Gri skala görüntüler tek bir katmandan oluşurken, renkli görüntüler, üç katmandan oluşmaktadır. Bu sebeple de konvolüsyon işlemi üç katman için ayrı ayrı yapılmaktadır.

Aşağıdaki Şekil 2.16’da Conv2D katmanının için girdi filtre ve çıktı örnek olarak gösterilmiştir.



Şekil 2.16. Girdi Matrisi (solda), Filtre veya Kernel Matrisi (ortada), Çıktı Matrisi (sağda)

Aşağıdaki Şekil 2.17’de filtrenin girdi matrisi üzerinde gezinimi ve çıktı matrisini oluşturan matris hücreleri gösterilmiştir.



Şekil 2.17. Filtrenin Girdi Matrisi Üzerinde Gezinimi

Conv2D katmanında eğer herhangi bir özellik eklenmez ise girdi matrisinin bazı özellikleri kaybolmaktadır. Bu konvolüsyon işleminde, giriş görüntüsü de, filtre de aslında sürekli ağırlık matrisleridir. Aşağıdaki örnekte bir girdi matrisi, bir filtre ve bir de çıktı matrisinin işlemleri gösterilmiştir.

$$\begin{bmatrix} 1 & -2 & 1 \\ 2 & -1 & 0 \\ 1 & 0 & 3 \end{bmatrix} \times \begin{bmatrix} 1 & -1 \\ 0 & 1 \end{bmatrix} = \begin{bmatrix} n_{11} & n_{12} \\ n_{21} & n_{22} \end{bmatrix}$$

$$n_{11} = (1 \times 1) + (-1 \times -2) + (0 \times 2) + (1 \times -1) = 2$$


$$n_{12} = (1 \times -2) + (-1 \times 1) + (0 \times -1) + (1 \times 0) = -3$$

$$n_{21} = (1 \times 2) + (-1 \times -1) + (0 \times 1) + (1 \times 0) = 3$$

$$n_{22} = (1 \times -1) + (-1 \times 0) + (0 \times 0) + (1 \times 3) = 2$$

2.4.2.MaxPooling

Bu katmanda en büyük alma yöntemi kullanılır. Ağın bu katmanında herhangi bir öğrenme parametresi yoktur. Giriş matrisinin kanal sayısını sabit tutarak görüntünün boyutunu azaltır. Hesaplama işlemlerini azaltmak için kullanılır, ancak verideki önemli bazı bilgilerin de kaybolmasına sebep olur ve bu da başarıyı düşürmektedir.



Şekil 2.18. MaxPooling İşlemi Gösterimi

Lokasyon bilgisinin önemli olduğu problemlerde kullanımı veri kaybından dolayı önerilmemektedir. Seçilen boyuta göre girdi piksellerinin en büyüğünü çıkışa aktarır.


2.4.3.ZeroPadding

Konvolüsyon işleminden sonra girdi ile çıktı arasındaki boyut farkını engellemek amacıyla kullanılan bir yöntemdir. Bu işlem girdiye eklenen ek pikseller ile sağlanır. Bu eklenen pikseller 0 değerli oldukları için bu katmanın ismi ZeroPadding'tir. Giriş matrisi $a \times a$, filtre matrisi $b \times b$ olduğu durumda çıkış matrisinde, girişe kıyasla kayıp olmaması isteniyorsa aşağıdaki formül uygulanır.


$$(a + 2p - b + 1) \times (a + 2p - b + 1)$$

Buradaki 'p' piksel değeridir ve çıkış matrisinin giriş ile aynı boyda olması için gereken sayıyı ifade eder. Bu ifadeyi belirlemek için $p = (b - 1)/2$ denklemi kullanılır.

Aşağıdaki Şekil 2.29 ve Şekil 2.30'da 4×4 girdi görüntüsü ve 3×3 filtre için eklenen pikseller ve filtrenin ZeroPadding sonrası yeni oluşan matris üzerinde gezinimi gösterilmiştir.



Şekil 2.19. Piksel Eklenmiş Girdi Matrisi (solda), Filtre Matrisi (ortada), Çıktı Matrisi (sağda)



Şekil 2.20. Filtrenin Piksel Eklenmiş Girdi Matrisi Üzerinde Gezinimi

2.4.4.BatchNormalization

BatchNormalization katmanı sayesinde ağıdaki diğer katmanlar, kendinden önce gelen katmanın öğrenmesini beklemek zorunda kalmadan öğrenme işlemin eş zamanlı olarak başlamayabilir bu sayede eğitimin hızlanmasını sağlar. Ayrıca BatchNormalization, ağı daha kararlı ve düzenli hale gelmesini sağlar.

2.4.5.Activation-ReLU

Conv2D katmanından çıkarılan özellik haritaları, doğrusal olmayan aktivasyon katmanlarına beslenir. Bu şekilde, neredeyse tüm sinir ağı doğrusal olmayan bir fonksiyona yaklaşabilir. Aktivasyon işlevleri genellikle basit doğrultulmuş doğrusal birimler veya ReLU'lar olarak bilinir. Eğer çıktı pozitifse, ReLU girişi doğrudan üretecektir, negatif olduğu takdirde çıkış sıfır olacaktır.

Girdiler x_i , filtreler f_j ve çıktılar y_{ij} iken, eğer, $conv(x_a, f_n) \approx conv(x_b, f_n)$ ise yani, $y_{ij} \approx y_{ij}$ ise çıktı bire yaklaştırılır veya doğrusallaştırılır.

2.5.GradCAM Algoritması

GradCAM algoritması eğitilen yapay zekâ modellerinin, sınıf aktivasyonunun görselleştirilmesi amacıyla kullanılan bir yöntemdir. Bu yöntem sayesinde eğitilen görsel girdileri olan modellerin çıktıları, girdiler üzerinde gösterilebilmektedir. Girdi sistemde test edilen bir görüntü iken, çıktı görüntünün üzerine uygulanabilecek bir maskedir. Maske ısı haritası şeklinde olabileceği gibi çeşitli haritalama sistemleri ile de şekillendirilebilmektedir.

3.DENEYLER

Sistemde girdi için kullanılan toplam 12967 zatürre vakası görülen ve görülmeyen görüntü, “covid” ve “normal” adı altında iki sınıfa ayrılmıştır. Görüntüler %75 eğitim, %18 test ve %7 geçerleme için ayrıştırılmıştır. Ayrıca bu görüntüler üzerindeki denemeler ham verilerin bulunduğu veri seti üzerinden yapılmıştır. Birinci veri seti ham görüntüleri içerirken, ikinci veri seti eşiklenmiş verileri içermektedir. Sistem ham veri seti için VGG16, ResNet50, ResNet50v2 ve ResNet50v2’ye katman eklenmiş ağ modelleri ile eğitilmiştir. Hassasiyet ($DP/(DP + YN)$), özgüllük ($DN/(DN + YP)$) ve kesinlik ($((DP + DN)/(DP + DN + YP + YN))$) değerleri, gerekli formüller ile hesaplanmıştır.

3.1.VGG16 Mimarisi

VGG16 mimarisi toplamda 16 katmandan ve eğitilebilir 15 milyon yapay nöral ağdan oluşmaktadır. Modelin eğitim girdileri, yatay ayna görüntüsü, dikey ayna görüntüsü, %5 yakınlaştırma ve uzaklaştırma aralığı, 360 derece dönme aralığı, ende ve boyda %5 kayma aralığı ve %5 kırpma aralığı gibi ön işleme aşamalarına girerek tekrar tekrar denenmiştir. Model eğitilirken ham görüntülerin yanı sıra buradaki parametrelerle elde edilen görüntüler de eğitime dahil edilmiştir.

Zatürre lezyonlu görüntüler ve lezyonsuz görüntüler arasındaki benzerlik oranı yüksek olduğundan, eğitim grup boyutu (batch size) 14 olarak tercih edilmiştir. Geçerleme ve test için ise grup boyutu 10 olarak seçilmiştir.

Model toplam 10 devir (epoch), ve her devirde 692 basamak olacak şekilde eğitilmiştir.


VGG16 mimarisi ve ham görüntüler ile oluşturulan model için alınan doğruluk, kayıp değerlerinin ortalaması, hassasiyet, özgüllük, doğru pozitif, yanlış pozitif, doğru negatif, yanlış negatif değerleri aşağıda yer alan Tablo 4.1’de ve Tablo 4.2’de gösterilmiştir. Şekil 3.1., Şekil 3.2., Şekil 3.3. ve Şekil 3.4.’te ise kesinlik ve kayıp grafikleri gösterilmiştir.

Tablo 3.1. VGG16 İçin Ortalama Kesinlik ve Kayıp Değerleri


VGG16	Kesinlik	Kayıp
Eğitim	0.91026	0.23542
Geçerleme	0.84808	0.34441

Tablo 3.2. VGG16 İin İstatiksel Veriler


VGG16	Pozitif	Negatif
Doğru	420	1898
Yanlış	18	41
Hassasiyet	0,9111	
Özgüllük	0,9907	
Test Kesinliğı	0,9627	




Şekil 3.1. VGG16 İin Eğitim Kaybı



Şekil 3.2. VGG16 İçin Eğitim Kesinliği



Şekil 3.3. VGG16 İçin Geçerleme Kaybı



Şekil 3.4. VGG16 İçin Geçerleme Kesinliği

3.2. ResNet50 Mimarisi

ResNet50 mimarisi 50 katmandan oluşur ve artık toplamalı bir sistemdir. 24 milyon yapay nöral ağdan oluşmuştur. Modelin eğitim girdileri, yatay ayna görüntüsü, dikey ayna görüntüsü, %5 yakınlaştırma ve uzaklaştırma aralığı, 360 derece dönme aralığı, ende ve boyda %5 kayma aralığı ve %5 kırpmaya aralığı gibi ön işleme aşamalarına girerek tekrar tekrar denenmiştir. Model eğitilirken ham görüntülerin yanı sıra buradaki parametrelerle elde edilen görüntüler de eğitime dahil edilmiştir.

Zatürre lezyonlu görüntüler ve lezyonsuz görüntüler arasındaki benzerlik oranı yüksek olduğundan, eğitim grup boyutu (batch size) 14 olarak tercih edilmiştir. Geçerleme ve test için ise grup boyutu 10 olarak seçilmiştir.

Model toplam 10 devir (epoch), ve her devirde 692 basamak olacak şekilde eğitilmiştir.


ResNet50 mimarisi ve ham görüntüler ile oluşturulan model için alınan doğruluk, kayıp değerlerinin ortalaması, hassasiyet, özgüllük, doğru pozitif, yanlış pozitif, doğru negatif, yanlış negatif değerleri aşağıda yer alan Tablo 3.3'te ve Tablo 3.4'te gösterilmiştir. Şekil 3.5., Şekil 3.6., Şekil 3.7. ve Şekil 3.8.'de ise kesinlik ve kayıp grafikleri gösterilmiştir.

Tablo 3.3. ResNet50 İçin Ortalama Kesinlik ve Kayıp Değerleri


ResNet50	Kesinlik	Kayıp
Eğitim	0.9524	0.23466
Geçerleme	0.93303	0.28872

Tablo 3.4. ResNet50 İçin İstatiksel Değerler


ResNet50	Pozitif	Negatif
Doğru	439	1900
Yanlış	16	22
Hassasiyet	0.9523	
Özgüllük	0.9916	
Test Kesinliği	0.9840	




Şekil 3.5. ResNet50 İçin Eğitim Kaybı



Şekil 3.6. ResNet50 İçin Eğitim Kesinliği



Şekil 3.7. ResNet50 İçin Geçerleme Kaybı



Şekil 3.8. ResNet50 İçin Geçerleme Kesinliği

3.3. ResNet50v2 Mimarisi

ResNet50v2 mimarisi, ResNet50'den farklı olarak katmanlardaki, aktivasyon, ağırlık gibi katmanların yerleri değiştirilmiştir.

3.3.1. ResNet50v2 Mimarisi

Modelin eğitim girdileri, yatay ayna görüntüsü, dikey ayna görüntüsü, %5 yakınlaştırma ve uzaklaştırma aralığı, 360 derece dönme aralığı, ende ve boyda %5 kayma aralığı ve %5 kırpma aralığı gibi ön işleme aşamalarına girerek tekrar tekrar denenmiştir. Model eğitilirken ham görüntülerin yanı sıra buradaki parametrelerle elde edilen görüntüler de eğitime dahil edilmiştir.

Zatürre lezyonlu görüntüler ve lezyonsuz görüntüler arasındaki benzerlik oranı yüksek olduğundan, eğitim grup boyutu (batch size) 14 olarak tercih edilmiştir. Geçerleme ve test için ise grup boyutu 10 olarak seçilmiştir.

Model toplam 10 devir (epoch), ve her devirde 692 basamak olacak şekilde eğitilmiştir.

ResNet50v2 mimarisi ve ham görüntüler ile oluşturulan model için alınan doğruluk, kayıp değerlerinin ortalaması, hassasiyet, özgüllük, doğru pozitif, yanlış pozitif, doğru negatif, yanlış negatif değerleri aşağıda yer alan Tablo 3.5'te ve Tablo 3.6'da gösterilmiştir.


Şekil 3.9., Şekil 3.10., Şekil 3.11. ve Şekil 3.12.'de ise kesinlik ve kayıp grafikleri gösterilmiştir.

Tablo 3.5. ResNet50v2 İçin Ortalama Kesinlik ve Kayıp Değerleri


ResNet50v2	Kesinlik	Kayıp
Eğitim	0.9631	0.11792
Geçerleme	0.92679	0.26894

Tablo 3.6. ResNet50v2 İçin İstatiksel Değerler


ResNet50v2	Pozitif	Negatif
Doğru	447	1890
Yanlış	26	14
Hassasiyet	0.9696	
Özgüllük	0.9864	
Test Kesinliği	0.9832	




Şekil 3.9. ResNet50v2 İçin Eğitim Kaybı



Şekil 3.10. ResNet50v2 İçin Eğitim Kesinliği



Şekil 3.11. ResNet50v2 İçin Geçerleme Kaybı



Şekil 3.12. ResNet50v2 İçin Geçerleme Kesinliği

3.3.2. ResNet50v2 Mimarisine Katman Eklenmiş Mimari

Modelin eğitim girdileri, yatay ayna görüntüsü, dikey ayna görüntüsü, %5 yakınlaştırma ve uzaklaştırma aralığı, 360 derece dönme aralığı, ende ve boyda %5 kayma aralığı ve %5 kırpma aralığı gibi ön işleme aşamalarına girerek tekrar tekrar denenmiştir. Model eğitilirken ham görüntülerin yanı sıra buradaki parametrelerle elde edilen görüntüler de eğitime dahil edilmiştir.

Zatürre lezyonlu görüntüler ve lezyonsuz görüntüler arasındaki benzerlik oranı yüksek olduğundan, eğitim grup boyutu (batch size) 14 olarak tercih edilmiştir. Geçerleme ve test için ise grup boyutu 10 olarak seçilmiştir.

Model toplam 10 devir (epoch), ve her devirde 692 basamak olacak şekilde eğitilmiştir. Test ise 50 basamakta gerçekleştirilmiştir.

ResNet50v2 mimarisine katman eklenmiş mimari ve ham görüntüler ile oluşturulan model için alınan doğruluk, kayıp değerlerinin ortalaması, hassasiyet, özgüllük, doğru pozitif, yanlış pozitif, doğru negatif, yanlış negatif değerleri aşağıda yer alan Tablo 3.7’de ve Tablo 3.8’de gösterilmiştir. Şekil 3.13., Şekil 3.14., Şekil 3.15. ve Şekil 3.16.’de ise kesinlik ve kayıp grafikleri gösterilmiştir.

Tablo 3.7. Katman Eklenmiş ResNet50v2 İçin Kesinlik ve Kayıp Değerleri


ResNet50v2 (Katman Eklenmiş)	Kesinlik	Kayıp
Eğitim	0.97307	0.08315
Geçerleme	0.95056	0.16159
Test	0.98201	0.05123

Tablo 3.8. Katman Eklenmiş ResNet50v2 İçin İstatiksel Değerler


ResNet50v2 (Katman Eklenmiş)	Pozitif	Negatif
Doğru	451	1907
Yanlış	9	10
Hassasiyet	0.9783	
Özgüllük	0.9947	
Test Kesinliği	0.9953	




Şekil 3.13. Katman Eklenmiş ResNet50v2 İçin Eğitim Kaybı



Şekil 3.14. Katman Eklenmiş ResNet50v2 İçin Eğitim Kesinliği




Şekil 3.15. Katman Eklenmiş ResNet50v2 İçin Geçerleme Kaybı




Şekil 3.16. Katman Eklenmiş ResNet50v2 İçin Geçerleme Kesinliği


Şekil 3.17., Şekil 3.18., Şekil 3.19. ve Şekil 3.20.'de ise modellerin kesinlik ve kayıp verileri karşılaştırılmıştır.




Şekil 3.17. Modellerin Eğitim Kaybı Karşılaştırması



Şekil 3.18. Modellerin Eğitim Kesinliği Karşılaştırması



Şekil 3.19. Modellerin Geçerleme Kaybı Karşılaştırması




Şekil 3.20. Modellerin Geçerleme Kesinliği Karşılaştırması


Bu sonuçlara göre katman eklenmiş ResNet50v2 diğer modellere göre daha üstün bir başarı göstermiştir. Model en yüksek geçerleme sonucu veren döngüden kaydedilmiştir ve sistemin görselleştirilmesi için bu seçilen model kullanılmıştır.

3.4. Modelin Görüntü Üzerine Uygulanması ve Görselleştirilmesi

Modelin görüntüye uygulanması, sınıf aktivasyonun hangi bölgede olduğunun görselleştirilmesini sağlayan, GradCAM isimli algoritma ile oluşturulmuştur. GradCAM eğitilen modelin ham görüntüleri girdi olarak kullanıldığı ve çıktı olarak bir maske üretilen algoritmadır. Aşağıdaki Şekil 4.21. ve Şekil 4.22.'de girdi görüntüsü, oluşturulan maske, maske ile üst üste bindirilmiş orijinal görüntü gösterilmiştir.




Şekil 3.21. Orijinal Görüntü ve Modelin Çıktı Görüntü




Şekil 3.22. Modelin Orijinal Görüntü Üzerine Eklenmiş Görüntüsü ve Isı Haritası

Aşağıdaki Şekil 4.23'te ise, farklı katmanlardan alınmış girdilerin ve çıktıların alındığı görseller gösterilmiştir.



Şekil 3.23. Farklı Katmanlardaki Lezyonların Görüntüleri

Zatürre görülmeyen vakalarda ise görüntülerin maskeli hali aşağıdaki Şekil 4.24.’teki gibi görülmektedir.




Şekil 3.24. Zatürre Lezyonu Görülmeyen Görüntü Çıktısı

3.5. Lezyonların Hacim Hesaplaması


Lezyonların GradCAM algoritması ile görselleştirilmesinin ardından elde edilen gri skala görüntüler uygun bir eşik değeri ile siyah beyaz görüntülere dönüştürülmüştür. Dönüştürülen görüntüler arasından zatürre lezyonu içeren görüntüler el ile seçilerek seçilen görüntülerin yaklaşık voksel değerleri elde edilebilmektedir. Seçilen görüntüler arka arkaya gelen sekansların birleşiminden oluşmalıdır. Örneğin, her bir sekans a_i iken, b_i ilgili sekanstaki lezyonun piksel sayısı, $b_{i-2}, b_{i-1}, b_i, b_{i+1}, b_{i+2}$ seçilen sekanslardaki 0’dan büyük piksel sayıları, sekanslar arasında boşluk milimetre cinsinden y , her pikselin milimetre kare cinsinden ifade ettiği alan da A ve lezyon hacmi de V olsun. Bu değerlere göre,

$$V = \sum_{n=i-2}^{i+1} A \times \frac{b_n + b_{n+1}}{2} \times y$$


formülasyonu ile ortalama hacim bulunabilir. Aşağıdaki Şekil 3.25, 3.26, 3.27, 3.28 ve 3.29 da farklı sekanslardaki lezyonların eşiklenmiş görüntüleri gösterilmiştir.




Şekil 3.25. 47 Numaralı Sekans ve Lezyonun Eşiklenmiş Görüntüsü




Şekil 3.26. 48 Numaralı Sekans ve Lezyonun Eşiklenmiş Görüntüsü



Şekil 3.27. 49 Numaralı Sekans ve Lezyonun Eşiklenmiş Görüntüsü




Şekil 3.28. 50 Numaralı Sekans ve Lezyonun Eşiklenmiş Görüntüsü



Şekil 3.29. 51 Numaralı Sekans ve Lezyonun Eşiklenmiş Görüntüsü

Aşağıda yer alan Şekil 3.30’da ise eşiklenmiş lezyon görüntülerin üst üste dizilimi ile birlikte orijinal görüntüler gösterilmiştir.



Şekil 3.30. Orijinal Görüntüler ve Eşiklenmiş Lezyon Görüntüleri

Veri setinde yer alan görüntülerden 192 sekans içeren hastanın görüntüleri kullanılmıştır. Bu görüntülerde sekanslar arası boşluk 2.4 mm ’dir. Tüm sekanslardaki piksel sayıları sırasıyla 3738, 3761, 6058, 4648 ve 4985’tir. Ancak şekillerden görüldüğü üzere görüntülerde iki farklı lezyon bulunmaktadır. Bu lezyonlardan bir tanesi 47, 48, ve 49.sekanslarda iken, diğeri, 49, 50 ve 51.sekanslarda yer almaktadır. Ortak olan 49.sekans sebebiyle görüntü tam ortadan ikiye bölünerek hesaplama işlemleri tekrar yapıldığında, 49.sekansın sol akciğer lobunda 3228 ve sağ akciğer lobunda 2830 piksel bulunmuştur. Siemens SOMATOM Scope modeli için bu sekanslarda piksel başına düşen alan değeri 0.95 mm^2 ‘dir. Bu değerlere göre,

$$V = \sum_{n=47}^{48} 0.95\text{mm}^2 \times \frac{b_n + b_{n+1}}{2} \times 2.4\text{mm} + \sum_{n=49}^{50} 0.95\text{mm}^2 \times \frac{b_n + b_{n+1}}{2} \times 2.4\text{mm}$$

$$V = 0.95\text{mm}^2 \times 2.4\text{mm}$$

$$\times \left[\left(\frac{3738 + 3761 + 3761 + 2830}{2} \right) + \left(\frac{3228 + 4648 + 4648 + 4985}{2} \right) \right]$$


$$V = 36022.86\text{mm}^3 = 36,02286\text{cm}^3$$

olarak bulunur.


4.SONUÇ VE TARTIŞMA

Çalışmada dört farklı derin öğrenme modeli, açık kaynak olarak sunulan bir veri setindeki COVID-19 enfeksiyonu sonucu oluşan zatürre lezyonları görülen ve görülmeyen görüntüler ile eğitilmiştir. Eğitim süreleri, Tesla P100 GPU ve her basamak (epoch) için VGG16'da 326 ile 3880 saniye, ResNet50'de 371 ile 4875 saniye, ResNet50v2'de 319 ile 2715 saniye ve katman eklenmiş ResNet50v2'de 302 ile 1720 saniye arasındadır. Oluşturulan modelleri boyutları, VGG16'da 171.5 megabyte, ResNet50'de 282.4 megabyte ResNet50v2'de 282.2 megabyte ve katman eklenmiş ResNet50v2'de 672.3 megabyte'tır. Oluşturulan modeller denendiğinde COVID-19 pozitif ya da negatif sonuç veren programın çalışma süresi tek bir görüntü için VGG16'da 1.1s, ResNet50'de 1.6s, ResNet50v2'de 1.5s ve katman eklenmiş ResNet50v2'de 2.3s'de sonuç vermektedir. GradCAM algoritması yalnızca katman eklenmiş ResNet50v2 ile denenmiştir. Algoritma ile görüntülerdeki lezyonların görselleştirilmesi için kullanılan programın çalışma süresi tek bir görüntü için katman eklenmiş ResNet50v2'de 2.6s'de sonuç vermektedir.

Çalışma neticesinde dört farklı model detaylı olarak karşılaştırılmış, hassasiyet özgüllük ve test kesinliğine göre en iyi sonuç veren model olan katman eklenmiş ResNet50v2 ile sınıf aktivasyonu GradCAM algoritması ile görselleştirilmiştir. Çıktıda oluşan maske görüntü üzerine eklenerek, ham görüntüdeki lezyonların olduğu kısımlar görülebilmektedir. Ayrıca elde edilen maske eşiklenerek lezyonların hacim hesaplaması ortalama olarak gerçekleştirilmiştir. Elde edilen model farklı veri setleri ile geliştirilerek klinik düzeyde kullanılabilir bir karar destek sistemine dönüştürülebilir. Oluşturulan modeller özet olarak karşılaştırılması aşağıda yer alan Şekil 4.1. ve Şekil 4.2.'de gösterilmiştir.



Şekil 4.1. Modellerin Hassasiyet, Özgüllük ve Test Kesinliğine Göre Karşılaştırma Grafiği



Şekil 4.2. Modellerin Eğitim Süresi, Boyut ve Çalışma Süresinde Göre Karşılaştırma Grafiği

Kurulan sistem her ne kadar COVID19 zatürresi görüntüleri için eğitilmiş olsa da, diğer viral zatürre ile bakteriyel zatürre arasında spesifik farklar bulunmadığı için, yalnız COVID19 zatürresi değil herhangi bir zatürre türü tespit edilmektedir. Bu nedenle daha

spesifik bir çalışma için sınıf sayısı artırılarak diğer viral zatürre görüntüleri ile birlikte, bakteriyel zatürre türleri de yeni sınıf olarak eklenebilir. Yapılan çalışmada yalnızca bir klinik merkezden alınan görüntüler kullanılmıştır. Bu sebeple diğer kliniklerden alınan görüntülere nasıl tepkiler vereceği ölçülmemiştir. GradCAM algoritması, görselleştirilme ve sınıf aktivasyonu için her ne kadar sık kullanılan bir yöntem olsa da lezyonların tamamı her zaman ayırt edilememektedir. Buna bağlı olarak hacimsel veri lezyon içeren bölgeyi GradCAM algoritmasının geniş bir biçimde almasından dolayı, olduğundan daha yüksek çıkmaktadır.

Eğitilen modeller arasında en doğru sonucu veren model olarak katman eklenmiş ResNet50v2 gösterilebilir. Ancak buna karşın bu modelin çeşitli dezavantajları da mevcuttur. Bu dezavantajlardan başlıca olanı modelin boyutunun büyüklüğüdür. Diğer modellere göre katman eklenmiş ResNet50v2 neredeyse 4 kat daha büyüktür. Bu büyüklüğe bağlı olarak modelin sonuç verme süresi de uzamaktadır. Tek bir görüntü için önemli sayılmayacak kadar küçük olan bu süre farkı veri sayısının artmasıyla birlikte yüksek süre farklarına dönüşebilmektedir. Eğitim süreleri, eğitim gerçekleştiği ortamdaki çalışan RAM, CPU, GPU çalışma kapasitesi ve ağ yoğunluğu gibi değişkenlere bağlı olduğundan, ayrıca eğitimler uzak sunucu üzerinde gerçekleştirildiğinden, bu konuda objektif bir kıyaslama mümkün değildir.

Çalışma esnasında, zatürre lezyonlarının genellikle akciğer çeperine yakın bölgelerde olduğu gözlemlenmiş ve test edilmiştir. Bu konuda lezyon lokasyonu takibi amaçlı bir çalışma yapılmış olup, farklı hastaların farklı vücut ve akciğer boyutlarından kaynaklanan zorluk nedeniyle başarısız olmuştur. Bahsi geçen zorluk akciğer boyutunun sabitlenmesi yani her hastada yaklaşık olarak aynı sayıda piksel boyutuna sahip olmasını amaçlamak ve bunun sonrasında her biri birbirinden farklı çözünürlükteki görüntüler üzerinden lokasyon takibi yapmaktır.

Çalışma sonrasında, eğitilebilecek model sayısı artırılarak daha farklı mimariler ile daha iyi sonuçlar elde etmeye çalışılabilir. Veri seti başka kliniklerden başka cihazlarla alınan görüntüler eklenerek zenginleştirilebilir ve modeller geliştirilebilir. Görselleştirme konusunda GradCAM algoritmasına ek algoritmalar eklenerek algoritma başarısı artırılıp bu algoritmanın çıktıları ile de hacim takibi, lokasyon takibi gibi klinik amacı olan çalışmalar yapılabilir.

KAYNAKLAR

- [1] Tyrrell, D. A. J., & Bynoe, M. L. (1966). Cultivation of viruses from a high proportion of patients with colds. *Lancet*, 76-7.
- [2] Velavan, T. P., & Meyer, C. G. (2020). The COVID-19 epidemic. *Tropical medicine & international health*, 25(3), 278.
- [3] Zhou, P., Yang, X. L., Wang, X. G., Hu, B., Zhang, L., Zhang, W., ... & Shi, Z. L. (2020). A pneumonia outbreak associated with a new coronavirus of probable bat origin. *nature*, 579(7798), 270-273.
- [4] Li, Q., Guan, X., Wu, P., Wang, X., Zhou, L., Tong, Y., ... & Feng, Z. (2020). Early transmission dynamics in Wuhan, China, of novel coronavirus-infected pneumonia. *New England journal of medicine*.
- [5] Guan, W. J., Ni, Z. Y., Hu, Y., Liang, W. H., Ou, C. Q., He, J. X., ... & Zhong, N. S. (2020). Clinical characteristics of 2019 novel coronavirus infection in China. *MedRxiv*.
- [6] Chan, J. F. W., Yuan, S., Kok, K. H., To, K. K. W., Chu, H., Yang, J., ... & Yuen, K. Y. (2020). A familial cluster of pneumonia associated with the 2019 novel coronavirus indicating person-to-person transmission: a study of a family cluster. *The lancet*, 395(10223), 514-523.
- [7] Islam, M. A., Kundu, S., Alam, S. S., Hossan, T., Kamal, M. A., & Hassan, R. (2021). Prevalence and characteristics of fever in adult and paediatric patients with coronavirus disease 2019 (COVID-19): A systematic review and meta-analysis of 17515 patients. *PloS one*, 16(4), e0249788.
- [8] Islam, M. A., Alam, S. S., Kundu, S., Hossan, T., Kamal, M. A., & Cavestro, C. (2020). Prevalence of headache in patients with coronavirus disease 2019 (COVID-19): a systematic review and meta-analysis of 14,275 patients. *Frontiers in neurology*, 11.
- [9] Saniasiaya, J., Islam, M. A., & Abdullah, B. (2021). Prevalence of Olfactory Dysfunction in Coronavirus Disease 2019 (COVID-19): A Meta-analysis of 27,492 Patients. *The Laryngoscope*, 131(4), 865-878.

- [10] Saniasiaya, J., Islam, M. A., & Abdullah, B. (2020). Prevalence and characteristics of taste disorders in cases of COVID-19: a meta-analysis of 29,349 patients. *Otolaryngology–Head and Neck Surgery*, 0194599820981018.
- [11] Agyeman, A. A., Chin, K. L., Landersdorfer, C. B., Liew, D., & Ofori-Asenso, R. (2020, August). Smell and taste dysfunction in patients with COVID-19: a systematic review and meta-analysis. In *Mayo Clinic Proceedings* (Vol. 95, No. 8, pp. 1621-1631). Elsevier.
- [12] Oran, D. P., & Topol, E. J. (2021). The proportion of SARS-CoV-2 infections that are asymptomatic: a systematic review. *Annals of internal medicine*, 174(5), 655-662.
- [13] Centers for Disease Control and Prevention. (2020). Interim clinical guidance for management of patients with confirmed coronavirus disease (COVID-19).
- [14] Pellino, S., Luciano, M., Luciano, R., Mancini, E., Conte, M. C., Volpe, G., & Zerella, T. (2021). Long-COVID-19 Symptoms after Infection in COVID Long-Haulers. *Open Journal of Epidemiology*, 11(4), 473-482.
- [15] Wastnedge, E. A., Reynolds, R. M., Van Boeckel, S. R., Stock, S. J., Denison, F. C., Maybin, J. A., & Critchley, H. O. (2021). Pregnancy and COVID-19. *Physiological reviews*, 101(1), 303-318.
- [16] Li, C., Zhao, C., Bao, J., Tang, B., Wang, Y., & Gu, B. (2020). Laboratory diagnosis of coronavirus disease-2019 (COVID-19). *Clinica Chimica Acta; International Journal of Clinical Chemistry*, 510, 35.
- [17] Kobokovich, A., West, R., & Gronvall, G. (2020). Global progress on COVID-19 serology-based testing. Johns Hopkins Center for Health Security.
- [18] Kubina, R., & Dziedzic, A. (2020). Molecular and serological tests for COVID-19. A comparative review of SARS-CoV-2 coronavirus laboratory and point-of-care diagnostics. *Diagnostics*, 10(6), 434.
- [19] Abbasi, J. (2020). The promise and peril of antibody testing for COVID-19. *Jama*, 323(19), 1881-1883.
- [20] Ward, D. (2020). Sampling Bias: Explaining Wide Variations in COVID-19 Case Fatality Rates. Preprint. WardEnvironment. Bern, Switzerland. [http://dx. doi. org/10.13140/RG, 2\(24953.62564\)](http://dx.doi.org/10.13140/RG.2(24953.62564)), 1.

- [21] Mina, M. J., Parker, R., & Larremore, D. B. (2020). Rethinking Covid-19 test sensitivity—a strategy for containment. *New England Journal of Medicine*, 383(22), e120.
- [22] Jones, R. T., Guest, C., Lindsay, S. W., Kleinschmidt, I., Bradley, J., Dewhirst, S., ... & Logan, J. G. (2020). Could bio-detection dogs be used to limit the spread of COVID-19 by travellers?. *Journal of travel medicine*, 27(8), taaa131.
- [23] Jendrny, P., Schulz, C., Twele, F., Meller, S., von Köckritz-Blickwede, M., Osterhaus, A. D. M. E., ... & Volk, H. A. (2020). Scent dog identification of samples from COVID-19 patients—a pilot study. *BMC infectious diseases*, 20(1), 1-7.
- [24] Jendrny, P., Twele, F., Meller, S., Schulz, C., von Köckritz-Blickwede, M., Osterhaus, A. D. M. E., ... & Volk, H. A. (2021). Scent dog identification of SARS-CoV-2 infections in different body fluids. *BMC infectious diseases*, 21(1), 1-14.
- [25] Spekking, R. Demonstration of a nasopharyngeal swab for COVID-19 testing (via Wikimedia Commons)
- [26] Jefferson, T., Spencer, E. A., Brassey, J., & Heneghan, C. (2021). Viral cultures for Coronavirus Disease 2019 infectivity assessment: A systematic review. *Clinical Infectious Diseases*, 73(11), e3884-e3899.
- [27] Pormohammad A, Ghorbani S, Khatami A, Razizadeh MH, Alborzi E, Zarei M, et al. (October 2020). "Comparison of influenza type A and B with COVID-19: A global systematic review and meta-analysis on clinical, laboratory and radiographic findings"
- [28] Lee, E. Y., Ng, M. Y., & Khong, P. L. (2020). COVID-19 pneumonia: what has CT taught us?. *The Lancet Infectious Diseases*, 20(4), 384-385.
- [29] Li, X., Zeng, X., Liu, B., & Yu, Y. (2020). COVID-19 infection presenting with CT halo sign. *Radiology: Cardiothoracic Imaging*, 2(1), e200026.
- [30] Kooraki, S., Hosseiny, M., Myers, L., & Gholamrezanezhad, A. (2020). Coronavirus (COVID-19) outbreak: what the department of radiology should know. *Journal of the American college of radiology*, 17(4), 447-451.
- [31] Bernheim, A., Mei, X., Huang, M., Yang, Y., Fayad, Z. A., Zhang, N., ... & Chung, M. (2020). Chest CT findings in coronavirus disease-19 (COVID-19): relationship to duration of infection. *Radiology*, 200463.

- [32] Carotti, M., Salaffi, F., Sarzi-Puttini, P., Agostini, A., Borgheresi, A., Minorati, D., ... & Giovagnoni, A. (2020). Chest CT features of coronavirus disease 2019 (COVID-19) pneumonia: key points for radiologists. *La radiologia medica*, 125, 636-646.
- [33] Zheng, Y., Wang, L., & Ben, S. (2021). Meta-analysis of chest CT features of patients with COVID-19 pneumonia. *Journal of Medical Virology*, 93(1), 241-249.
- [34] Zhao, W., Zhong, Z., Xie, X., Yu, Q., & Liu, J. (2020). Relation between chest CT findings and clinical conditions of coronavirus disease (COVID-19) pneumonia: a multicenter study. *American Journal of Roentgenology*, 214(5), 1072-1077.
- [35] Wu, J., Wu, X., Zeng, W., Guo, D., Fang, Z., Chen, L., ... & Li, C. (2020). Chest CT findings in patients with coronavirus disease 2019 and its relationship with clinical features. *Investigative radiology*, 55(5), 257.
- [36] Demirjian, N. L., Fields, B. K., & Gholamrezanezhad, A. (2020). Role of chest CT in resource-driven healthcare systems. *American Journal of Roentgenology*, 215(3), W36-W36.
- [37] Lim, Z. Y., Khoo, H. W., Hui, T. C. H., Kok, S. S. X., Kwan, K. E. L., Young, B. E., ... & Kaw, G. J. L. (2020). Variable computed tomography appearances of COVID-19. *Singapore medical journal*, 61(7), 387.
- [38] Ojha, V., Mani, A., Pandey, N. N., Sharma, S., & Kumar, S. (2020). CT in coronavirus disease 2019 (COVID-19): a systematic review of chest CT findings in 4410 adult patients. *European radiology*, 30, 6129-6138.
- [39] Rajpurkar, P., Irvin, J., Zhu, K., Yang, B., Mehta, H., Duan, T., ... & Ng, A. Y. (2017). Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning. *arXiv preprint arXiv:1711.05225*.
- [40] Ranjan, E., Paul, S., Kapoor, S., Kar, A., Sethuraman, R., & Sheet, D. (2018, December). Jointly learning convolutional representations to compress radiological images and classify thoracic diseases in the compressed domain. In *Proceedings of the 11th Indian Conference on computer vision, graphics and image processing* (pp. 1-8).
- [41] Mangal, A., Kalia, S., Rajgopal, H., Rangarajan, K., Namboodiri, V., Banerjee, S., & Arora, C. (2020). CovidAID: COVID-19 detection using chest X-ray. *arXiv preprint arXiv:2004.09803*.

- [42] Yang, S., Zhang, Y., Shen, J., Dai, Y., Ling, Y., Lu, H., ... & Shan, F. (2020). Clinical potential of UTE-MRI for assessing COVID-19: Patient-and lesion-based comparative analysis. *Journal of Magnetic Resonance Imaging*, 52(2), 397-406.
- [43] Liszewski, M. C., Gökem, S., Sodhi, K. S., & Lee, E. Y. (2017). Lung magnetic resonance imaging for pneumonia in children. *Pediatric radiology*, 47(11), 1420-1430.
- [44] Galougahi, M. K., Ghorbani, J., Bakhshayeshkaram, M., Naeini, A. S., & Haseli, S. (2020). Olfactory bulb magnetic resonance imaging in SARS-CoV-2-induced anosmia: the first report. *Academic radiology*, 27(6), 892-893.
- [45] Meier-Schroers, M., Kukuk, G., Homsy, R., Skowasch, D., Schild, H. H., & Thomas, D. (2016). MRI of the lung using the PROPELLER technique: Artifact reduction, better image quality and improved nodule detection. *European journal of radiology*, 85(4), 707-713.
- [46] Ates, O. F., Taydas, O., & Dheir, H. (2020). Thorax magnetic resonance imaging findings in patients with coronavirus disease (COVID-19). *Academic radiology*, 27(10), 1373-1378.
- [47] Ekinçi, A., Uçarkuş, T. Y., Okur, A., Öztürk, M., & Doğan, S. (2017). MRI of pneumonia in immunocompromised patients: comparison with CT. *Diagnostic and Interventional Radiology*, 23(1), 22.
- [48] Deng, Y., Lei, L., Chen, Y., & Zhang, W. (2020). The potential added value of FDG PET/CT for COVID-19 pneumonia. *European journal of nuclear medicine and molecular imaging*, 1.
- [49] Capitanio, S., Nordin, A. J., Noraini, A. R., & Rossetti, C. (2016). PET/CT in nononcological lung diseases: current applications and future perspectives. *European Respiratory Review*, 25(141), 247-258.
- [50] Katal, S., Amini, H., & Gholamrezanezhad, A. (2020). PET in the diagnostic management of infectious/inflammatory pulmonary pathologies: a revisit in the era of COVID-19. *Nuclear Medicine Communications*.
- [51] Rafiee, F., Keshavarz, P., Katal, S., Assadi, M., Nejati, S. F., Sadabad, F. E., & Gholamrezanezhad, A. (2021, March). Coronavirus disease 2019 (COVID-19) in molecular

imaging: a systematic review of incidental detection of SARS-CoV-2 pneumonia on PET studies. In *Seminars in nuclear medicine* (Vol. 51, No. 2, pp. 178-191). WB Saunders.

[52] Lütje, S., Marinova, M., Kütting, D., Attenberger, U., Essler, M., & Bundschuh, R. A. (2020). Nuclear medicine in SARS-CoV-2 pandemia: 18F-FDG-PET/CT to visualize COVID-19. *Nuklearmedizin*, 59(03), 276-280.

[53] Bengio, Y., Courville, A., & Vincent, P. (2013). Representation learning: A review and new perspectives. *IEEE transactions on pattern analysis and machine intelligence*, 35(8), 1798-1828.

[54] Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural networks*, 61, 85-117.

[55] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *nature*, 521(7553), 436-444.

[56] Hu, J., Niu, H., Carrasco, J., Lennox, B., & Arvin, F. (2020). Voronoi-based multi-robot autonomous exploration in unknown environments via deep reinforcement learning. *IEEE Transactions on Vehicular Technology*, 69(12), 14413-14423.

[57] Schmidhuber, J., Meier, U., & Ciresan, D. (2012, June). Multi-column deep neural networks for image classification. In *2012 IEEE Conference on Computer Vision and Pattern Recognition* (pp. 3642-3649). IEEE Computer Society.

[58] Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*, 25, 1097-1105.

[59] Marblestone, A. H., Wayne, G., & Kording, K. P. (2016). Toward an integration of deep learning and neuroscience. *Frontiers in computational neuroscience*, 10, 94.

[60] Bengio, Y. (2009). *Learning deep architectures for AI*. Now Publishers Inc.

[61] Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.

[62] Bengio, Y., Lamblin, P., Popovici, D., & Larochelle, H. (2007). Greedy layer-wise training of deep networks. In *Advances in neural information processing systems* (pp. 153-160).

[63] Schmidhuber, J. (2015). Deep learning. *Scholarpedia*, 10(11), 32832.

- [64] Hinton, G. E. (2009). Deep belief networks. *Scholarpedia*, 4(5), 5947.
- [65] McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- [66] Hasperué, W. (2015). The master algorithm: how the quest for the ultimate learning machine will remake our world. *Journal of Computer Science and Technology*, 15(02), 157-158.
- [67] Yegnanarayana, B. (2009). *Artificial neural networks*. PHI Learning Pvt. Ltd..
- [68] Graupe, D. (2013). *Principles of artificial neural networks (Vol. 7)*. World Scientific.
- [69] Zell, A. (1994). *Simulation neuronaler netze (Vol. 1, No. 5.3)*. Bonn: Addison-Wesley.
- [70] Gidon, A., Zolnik, T. A., Fidzinski, P., Bolduan, F., Papoutsis, A., Poirazi, P., ... & Larkum, M. E. (2020). Dendritic action potentials and computation in human layer 2/3 cortical neurons. *Science*, 367(6473), 83-87.
- [71] Valueva, M. V., Nagornov, N. N., Lyakhov, P. A., Valuev, G. V., & Chervyakov, N. I. (2020). Application of the residue number system to reduce hardware costs of the convolutional neural network implementation. *Mathematics and Computers in Simulation*, 177, 232-243.
- [72] Mouton, C., Myburgh, J. C., & Davel, M. H. (2021, February). Stride and translation invariance in CNNs. In *Southern African Conference for Artificial Intelligence Research* (pp. 267-281). Springer, Cham.
- [73] Wang, P. S., Liu, Y., Guo, Y. X., Sun, C. Y., & Tong, X. (2017). O-cnn: Octree-based convolutional neural networks for 3d shape analysis. *ACM Transactions On Graphics (TOG)*, 36(4), 1-11.
- [74] Girshick, R. (2015). Fast r-cnn. In *Proceedings of the IEEE international conference on computer vision* (pp. 1440-1448).
- [75] Gupta, H., Jin, K. H., Nguyen, H. Q., McCann, M. T., & Unser, M. (2018). CNN-based projected gradient descent for consistent CT image reconstruction. *IEEE transactions on medical imaging*, 37(6), 1440-1453.

- [76] Chen, H., Zhang, Y., Kalra, M. K., Lin, F., Chen, Y., Liao, P., ... & Wang, G. (2017). Low-dose CT with a residual encoder-decoder convolutional neural network. *IEEE transactions on medical imaging*, 36(12), 2524-2535.
- [77] Thorpe, M., & van Gennip, Y. (2018). Deep limits of residual neural networks. *arXiv preprint arXiv:1810.11741*.
- [78] He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [79] Srivastava, R. K., Greff, K., & Schmidhuber, J. (2015). Highway networks. *arXiv preprint arXiv:1505.00387*.
- [80] Huang, G., Liu, Z., Van Der Maaten, L., & Weinberger, K. Q. (2017). Densely connected convolutional networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 4700-4708).
- [81] Ciregan, D., Meier, U., & Schmidhuber, J. (2012, June). Multi-column deep neural networks for image classification. In *2012 IEEE conference on computer vision and pattern recognition* (pp. 3642-3649). IEEE.
- [82] Smith, G. W., & Leymarie, F. F. (2017, June). The machine as artist: An introduction. In *Arts* (Vol. 6, No. 2, p. 5). Multidisciplinary Digital Publishing Institute.
- [83] Gao, J., He, X., & Deng, L. (2015). Deep learning for web search and natural language processing.
- [84] Wallach, I., Dzamba, M., & Heifets, A. (2015). AtomNet: a deep convolutional neural network for bioactivity prediction in structure-based drug discovery. *arXiv preprint arXiv:1510.02855*.
- [85] Zhavoronkov, A., Ivanenkov, Y. A., Aliper, A., Veselov, M. S., Aladinskiy, V. A., Aladinskaya, A. V., ... & Aspuru-Guzik, A. (2019). Deep learning enables rapid identification of potent DDR1 kinase inhibitors. *Nature biotechnology*, 37(9), 1038-1040.
- [86] Tkachenko, Y. (2015). Autonomous CRM control via CLV approximation with deep reinforcement learning in discrete and continuous action space. *arXiv preprint arXiv:1504.01840*.

- [87] Elkahky, A. M., Song, Y., & He, X. (2015, May). A multi-view deep learning approach for cross domain user modeling in recommendation systems. In Proceedings of the 24th international conference on world wide web (pp. 278-288).
- [88] De, S., Maity, A., Goel, V., Shitole, S., & Bhattacharya, A. (2017, April). Predicting the popularity of instagram posts for a lifestyle magazine using deep learning. In 2017 2nd International Conference on Communication Systems, Computing and IT Applications (CSCITA) (pp. 174-177). IEEE.
- [89] Schmidt, U., & Roth, S. (2014). Shrinkage fields for effective image restoration. In Proceedings of the IEEE conference on computer vision and pattern recognition (pp. 2774-2781).
- [90] Raissi, M., Perdikaris, P., & Karniadakis, G. E. (2019). Physics-informed neural networks: A deep learning framework for solving forward and inverse problems involving nonlinear partial differential equations. *Journal of Computational Physics*, 378, 686-707.
- [91] Chicco, D., Sadowski, P., & Baldi, P. (2014, September). Deep autoencoder neural networks for gene ontology annotation predictions. In Proceedings of the 5th ACM conference on bioinformatics, computational biology, and health informatics (pp. 533-540).
- [92] Ker, J., Wang, L., Rao, J., & Lim, T. (2017). Deep learning applications in medical image analysis. *Ieee Access*, 6, 9375-9389.
- [93] Singha, A., Thakur, R. S., & Patel, T. (2021). Deep Learning Applications in Medical Image Analysis. *Biomedical Data Mining for Information Retrieval: Methodologies, Techniques and Applications*, 293-350.
- [94] Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Liang, J. (2016). Convolutional neural networks for medical image analysis: Full training or fine tuning?. *IEEE transactions on medical imaging*, 35(5), 1299-1312.
- [95] Ravishankar, H., Sudhakar, P., Venkataramani, R., Thiruvankadam, S., Annangi, P., Babu, N., & Vaidya, V. (2016). Understanding the mechanisms of
- [96] Chen, J., Yang, L., Zhang, Y., Alber, M., & Chen, D. Z. (2016). Combining fully convolutional and recurrent neural networks for 3d biomedical image segmentation. In *Advances in neural information processing systems* (pp. 3036-3044).

- [97] Clark, K., Vendt, B., Smith, K., Freymann, J., Kirby, J., Koppel, P., ... & Prior, F. (2013). The Cancer Imaging Archive (TCIA): maintaining and operating a public information repository. *Journal of digital imaging*, 26(6), 1045-1057.
- [98] Gibson, E., Li, W., Sudre, C., Fidon, L., Shakir, D. I., Wang, G., ... & Vercauteren, T. (2018). NiftyNet: a deep-learning platform for medical imaging. *Computer methods and programs in biomedicine*, 158, 113-122.
- [99] Shen, D., Wu, G., & Suk, H. I. (2017). Deep learning in medical image analysis. *Annual review of biomedical engineering*, 19, 221-248.
- [100] Brody, H. (2013). Medical imaging. *Nature*, 502(7473), S81-S81.
- [101] Wang, L., Chen, K. C., Gao, Y., Shi, F., Liao, S., Li, G., ... & Shen, D. (2014). Automated bone segmentation from dental CBCT images using patch-based sparse representation and convex optimization. *Medical physics*, 41(4), 043503.
- [102] Yap, P. T., Zhang, Y., & Shen, D. (2016). Multi-Tissue Decomposition of Diffusion MRI Signals via $\ell_{2,1}$ Sparse-Group Estimation. *IEEE Transactions on Image Processing*, 25(9), 4340-4353.
- [103] Chen, Y., Juttukonda, M., Su, Y., Benzinger, T., Rubin, B. G., Lee, Y. Z., ... & An, H. (2015). Probabilistic air segmentation and sparse regression estimated pseudo CT for PET/MR attenuation correction. *Radiology*, 275(2), 562-569.
- [104] Artificial Intelligence for The Detection of COVID-19 Pneumonia on Chest CT Using Multinational Datasets (Harmon, S. A., Sanford, T. H., Xu, S., Turkbey, E. B., Roth, H., Xu, Z., ... & Turkbey, B.)
- [105] A Weakly Supervised Deep Learning Framework for COVID-19 CT Detection and Analysis (Gozes, O., Frid-Adar, M., Sagie, N., Kabakovitch, A., Amran, D., Amer, R., & Greenspan, H.)
- [106] Automatic Detection of Coronavirus Disease (COVID-19) in X-ray and CT Images: A Machine Learning Based Approach (Kassania, S. H., Kassanib, P. H., Wesolowskic, M. J., Schneidera, K. A., & Detersa, R.)
- [107] Rahimzadeh, M., Attar, A., & Sakhaei, S. M. (2021). A fully automated deep learning-based network for detecting covid-19 from a new and large lung ct scan dataset. *Biomedical Signal Processing and Control*, 68, 102588.

- [108] Kahn, C. E., Carrino, J. A., Flynn, M. J., Peck, D. J., & Horii, S. C. (2007). DICOM and radiology: past, present, and future. *Journal of the American College of Radiology*, 4(9), 652-657.
- [109] Murray, J. D., & VanRyper, W. (1996). *Encyclopedia of graphics file formats*. Sebastopol: O'Reilly.
- [110] Van Rossum, G. (2007, June). Python Programming Language. In *USENIX annual technical conference* (Vol. 41, p. 36).
- [111] Bradski, G. (2000). The openCV library. *Dr. Dobb's Journal: Software Tools for the Professional Programmer*, 25(11), 120-123.
- [112] Dillon, J. V., Langmore, I., Tran, D., Brevdo, E., Vasudevan, S., Moore, D., ... & Saurous, R. A. (2017). Tensorflow distributions. *arXiv preprint arXiv:1711.10604*.
- [113] Zaccane, G. (2016). *Getting started with TensorFlow*. Birmingham: Packt Publishing.
- [114] Ketkar, N. (2017). Introduction to keras. In *Deep learning with Python* (pp. 97-111). Apress, Berkeley, CA.
- [115] Randles, B. M., Pasquetto, I. V., Golshan, M. S., & Borgman, C. L. (2017, June). Using the Jupyter notebook as a tool for open science: An empirical study. In *2017 ACM/IEEE Joint Conference on Digital Libraries (JCDL)* (pp. 1-2). IEEE.
- [116] Oh, K. S., & Jung, K. (2004). GPU implementation of neural networks. *Pattern Recognition*, 37(6), 1311-1314.
- [117] Wang, Y. E., Wei, G. Y., & Brooks, D. (2019). Benchmarking tpu, gpu, and cpu platforms for deep learning. *arXiv preprint arXiv:1907.10701*.
- [118] Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [119] He, K., Zhang, X., Ren, S., & Sun, J. (2016, October). Identity mappings in deep residual networks. In *European conference on computer vision* (pp. 630-645). Springer, Cham.