

**T.C.**  
**KASTAMONU ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**  
**ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI**



**GÖĞÜS RÖNTGEN GÖRÜNTÜLERİNİ KULLANARAK DERİN  
TRANSFER ÖĞRENME YÖNTEMLERİYLE COVID-19 TESPİTİ**

**AYŞE EMİNE DURU ÇOBAN**

**YÜKSEK LİSANS TEZİ**

**DR. ÖĞR. ÜYESİ YASEMİN GÜLTEPE**

**OCAK - 2023**  
**KASTAMONU**

## TEZ ONAYI

Ayşe Emine DURU ÇOBAN tarafından hazırlanan “GÖĞÜS RÖNTGEN GÖRÜNTÜLERİNİ KULLANARAK DERİN TRANSFER ÖĞRENME YÖNTEMLERİYLE COVID-19 TESPİTİ” adlı tez çalışmasının savunma sınavı 12.01.2023 tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Elektrik-Elektronik Mühendisliği Ana Bilim Dalı Yüksek Lisans Tezi** olarak kabul edilmiştir

<b>Danışman</b>	Dr. Öğr. Üyesi Yasemin GÜLTEPE Atatürk Üniversitesi	.....
<b>Jüri Üyesi</b>	Prof. Dr. İbrahim Taner OKUMUŞ Kahramanmaraş Sütçü İmam Üniversitesi	.....
<b>Jüri Üyesi</b>	Dr. Öğr. Üyesi Seçil KARATAY Kastamonu Üniversitesi	.....

Jüri üyeleri tarafından kabul edilmiş olan bu tez Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Enstitüsü Müdürü Doç. Dr. Osman ÇİÇEK .....

## TAAHHÜTNAME

*Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranıř ve akademik kurallar çerçevesinde elde edilerek sunulduđunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalıřmada bana ait olmayan her türlü ifade ve bilginin kaynađına eksiksiz atıf yapıldıđını, bilimsel etiđe uygun olarak kaynak gösterildiđini bildirir ve taahhüt ederim.*

Ayře Emine DURU ÇOBAN

## ÖZET

### YÜKSEK LİSANS TEZİ

#### GÖĞÜS RÖNTGEN GÖRÜNTÜLERİNİ KULLANARAK DERİN TRANSFER ÖĞRENME YÖNTEMLERİYLE COVID-19 TESPİTİ

AYŞE EMİNE DURU ÇOBAN

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ  
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI  
DANIŞMAN: DR. ÖĞR. ÜYESİ YASEMİN GÜLTEPE

Çin Wuhan kentinde 17 Kasım 2019 tarihinde ilk kez ortaya çıkan Koronavirüs (Covid-19) kısa sürede tüm dünyayı etkisi altına almıştır. Koronavirüsler, tarihte birçok varyantı olan virüslerdir. Bazı hastalarda hafif nezle gibi etkileri olurken bazı hastalara bulaşan varyasyonlarında ölümcül sonuçlara neden olmaktadır. Covid-19 virüsü fiziksel temas ve hava yoluyla çok hızlı bir şekilde enfekte olmaktadır. Covid-19 tanısında bilinen üç yöntem kullanılmaktadır. PZR (Polimeraz Zincir Reaksiyonu) testi, kan testi ve akciğer tomografisi tanı için kullanılan yöntemlerdir. PZR (Polimeraz Zincir Reaksiyonu) testi, ağız ve burundan test çubukları ile alınan sürüntü ile tespit edilmektedir. Bilgisayarlı tomografi görüntülerini anlamak ve sınıflandırmak, Covid-19 tanısı için son derece önemlidir. Birçok vaka sınıflandırma çalışması, özellikle dengesiz ve yetersiz veriler olmak üzere birçok sorunla karşı karşıyadır. Büyük verileri analiz etmek için etkili bir araç olarak ortaya çıkan Derin Öğrenme, bilgisayarları eğitmek için karmaşık algoritmalar ve yapay sinir ağları kullanır, böylece tıpkı bir insan beyninin yaptığı gibi deneyimlerden öğrenebilir, verileri/görüntüleri sınıflandırabilir ve tanıyabilirler. Derin Öğrenme içinde, Evrişimli Sinir Ağı (CNN), görüntü/nesne tanıma ve sınıflandırma için yaygın olarak kullanılan bir tür yapay sinir ağıdır. Derin Öğrenme böylece bir CNN kullanarak bir görüntüdeki nesnelere tanır. Bu çalışmada radyoloji göğüs görüntülerden oluşan bir veri seti üzerinde ResNet50, VGG16, VGG19 ve DenseNet derin öğrenme yöntemleri kullanılarak Covid-19 vakasını tespit etmek amaçlanmıştır. Önerilen bu modeller ile yapılan deneysel çalışmamız sonucunda ResNet50 modelinde maksimum %0,91 ile %0,99 doğruluk oranı elde edilmiştir. Sonuç olarak, Covid-19 hastalığını tespit etmek için röntgen görüntülerinin kullanımı sağlık çalışanlarının iş yükünü hafifleteceği gibi hasta ile temasta bulunmadan bilgisayarlı sistemlerle hastalık tespitinin daha kolay olacağı öngörülmektedir. Bu alanda çalışmalar desteklediği takdirde teorikte olduğu gibi pratikte de başarı elde edilecektir.

**ANAHTAR KELİMELER:**Covid-19, Pneumonia, Evrişimli Sinir Ağları, ResNet50, VGG16, VGG19, Derin Öğrenme

Ocak 2023, 53 Sayfa

## ABSTRACT

### MSC THESIS

#### COVID-19 DETECTION BY DEEP TRANSFER LEARNING METHODS USING CHEST X-RAY IMAGES

AYŞE EMİNE DURU ÇOBAN

KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE  
DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING  
SUPERVISOR: ASSIST. PROF. DR. YASEMİN GÜLTEPE

The Coronavirus (Covid-19), which appeared for the first time on November 17, 2019 in the city of Wuhan, China, has taken the whole world under its influence in a short time. Coronaviruses are viruses that have had many variants in history. While it has effects such as mild cold in some patients, it causes fatal consequences in its variations transmitted to some patients. Covid-19 virus infects very quickly through physical contact and air. Three known methods are used in the diagnosis of Covid-19. PCR(Polymerase Chain Reaction) test, blood test and lung tomography are the methods used for diagnosis. The PCR(Polymerase Chain Reaction) test is detected with a swab taken from the mouth and nose with test sticks. Understanding and classifying computed tomography images is extremely important for the diagnosis of Covid-19. Many case-classification studies face many problems, particularly unbalanced and insufficient data. Emerging as an effective tool for analyzing big data, Deep Learning uses complex algorithms and artificial neural networks to train computers so they can learn from experience, classify and recognize data/images just like a human brain does. Within Deep Learning, Convolutional Neural Network (CNN) is a type of artificial neural network widely used for image/object recognition and classification. Deep Learning thus recognizes objects in an image using a CNN. In this study, it is aimed to detect the Covid-19 case by using ResNet50, VGG16, VGG19 and DenseNet deep learning methods on a data set consisting of radiology chest images. As a result of our experimental work with these proposed models, a maximum accuracy rate of 0.91% and 0.99% was obtained in the ResNet50 model. As a result, it is predicted that the use of x-ray images in detecting the Covid-19 disease will ease the workload of health workers and it will be easier to detect the disease with computerized systems without contacting the patient. If studies in this field are supported, success will be achieved in practice as well as in theory.

**KEYWORDS:**Covid-19, Pneumonia, Convolutional Neural Networks, ResNet50, VGG16, VGG19, Deep Learning

January 2023, 53 Page.

## TEŞEKKÜR

Başta Mustafa Kemal Atatürk olmak üzere eğitim ve öğretim hayatımda emeği geçen tüm öğretmenlerime teşekkürü borç bilirim.

Hayatımın her alanında beni destekleyen varlığımın en büyük sebebi sevgili annem ve babama eğitim hayatım boyunca desteklerini hiç esirmediği için minnettarım. Lisans eğitimine başladığım günden itibaren her an destek olan, eğitim hayatımda yoluma ışık tutan değerli hocam Dr. Öğr. Üyesi Yasemin GÜLTEPE'ye sonsuz minnettarlığımı belirtmek isterim.

Görüş ve bilgileriyle beni yönlendiren değerli hocalarım Prof. Dr. İbrahim Taner OKUMUŞ ve Dr. Öğr. Üyesi Seçil KARATAY'a çok teşekkür ederim.

Çalışma hayatımda idolüm olan dil ve akademik eğitimimde bana destek olan Orhan ARİFİOĞLU, Fatih IŞIK ve Neslihan OKYAY ve ayrıca her an destek olan eşim Muhammed ÇOBAN'a teşekkürlerimi sunarım.

Ayşe Emine DURU ÇOBAN  
Kastamonu, 2023

# İÇİNDEKİLER

	<u>Sayfa</u>
<b>TEZ ONAYI</b> .....	<b>ii</b>
<b>TAAHHÜTNAME</b> .....	<b>iii</b>
<b>ÖZET</b> .....	<b>iv</b>
<b>ABSTRACT</b> .....	<b>v</b>
<b>TEŞEKKÜR</b> .....	<b>vi</b>
<b>İÇİNDEKİLER</b> .....	<b>vii</b>
<b>ŞEKİLLER DİZİNİ</b> .....	<b>viii</b>
<b>TABLolar DİZİNİ</b> .....	<b>ix</b>
<b>SİMGELER VE KISALTMALAR DİZİNİ</b> .....	<b>x</b>
<b>1. GİRİŞ</b> .....	<b>1</b>
<b>2. LİTERATÜR ARAŞTIRMASI</b> .....	<b>8</b>
<b>3. MATERYAL VE YÖNTEM</b> .....	<b>13</b>
3.1 Veri Seti .....	13
3.2 Görüntüleme Sistemleri .....	14
3.3 Kullanılan Materyal ve Yazılım Dili .....	16
3.4 Yapay Sinir Ağları.....	17
3.5 Derin Öğrenme (Derin Sinir Ağı).....	20
3.6 Evrişimli Sinir Ağı.....	21
3.6.1 Evrişim Katmanı.....	23
3.6.2 Gizli Katman .....	24
3.6.3 Dolgu İşlemi .....	25
3.6.4 Havuzlama Katmanı .....	25
3.6.5 Tam Bağlaşımli Katman .....	26
3.6.6 Çıkış Katmanı.....	26
3.6.7 Aktivasyon Fonksiyonu .....	27
3.6.8 Transfer Öğrenme.....	28
3.7 Başarım Ölçütleri ve İstatiksel Analiz .....	29
3.7.1 Alıcı İşlem Karakteristiği Eğrisi.....	31
3.8 ResNet Ağı.....	32
3.9 ResNet50.....	33
3.10 VGG16.....	34
3.11 VGG19.....	35
3.12 DenseNet.....	35
<b>4. BULGULAR</b> .....	<b>38</b>
4.1 Kullanılan Materyal .....	38
4.2 VGG16 Mimarisi Sonuçları .....	38
4.3 VGG19 Mimarisi Sonuçları .....	40
4.4 DenseNet Mimarisi Sonuçları .....	41
4.5 ResNet50 Mimarisi Sonuçları .....	43
4.5.1 Röntgen Görüntülerine Yönelik Sonuçlar.....	43
<b>5. SONUÇ VE ÖNERİLER</b> .....	<b>47</b>
<b>KAYNAKLAR</b> .....	<b>48</b>
<b>ÖZGEÇMİŞ</b> .....	<b>53</b>

## ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 1.1 Covid-19 vakası dünya haritası.....	3
Şekil 1.2 Koronavirüslü akciğer röntgen görüntüsü .....	4
Şekil 3.1 Veri kümesinden etiketli X-Ray örnekleri.....	13
Şekil 3.2 Göğüs röntgen verisi .....	15
Şekil 3.3 Göğüs tomografi verisi .....	15
Şekil 3.4 Biyolojik sinir hücresi .....	18
Şekil 3.5 Yapay sinir ağı modeli .....	19
Şekil 3.6 ESA katman yapısı .....	22
Şekil 3.7 Evrişim katmanı işlem şeması .....	24
Şekil 3.8 Biyolojik sinir hücresi .....	26
Şekil 3.9 Sinir hücresi matematiksel modeli .....	27
Şekil 3.10 Aktivasyon fonksiyonlarının eğrileri .....	28
Şekil 3.11 Karmaşıklık matrisi .....	29
Şekil 3.12 AİK eğrisinde EAA değerleri .....	31
Şekil 3.13 ResNET ağ mimarisi .....	33
Şekil 3.14 ResNet50 için darboğaz yapısı.....	34
Şekil 3.15 ResNet50 ağ mimarisi .....	34
Şekil 3.16 VGG16 ağ mimarisi .....	35
Şekil 3.17 VGG19 ağ mimarisi .....	35
Şekil 3.18 Standart ESA yapısı .....	36
Şekil 3.19 Yoğun DenseNet element ekleme yapısı.....	36
Şekil 3.20 Yoğun DenseNet blok yapısı .....	37
Şekil 4.1 VGG16 başarı grafiği .....	39
Şekil 4.2 VGG16 kayıp grafiği.....	39
Şekil 4.3 VGG19 doğruluk grafiği .....	40
Şekil 4.4 VGG19 kayıp grafiği.....	41
Şekil 4.5 DenseNet doğruluk grafiği .....	42
Şekil 4.6 DenseNet kayıp grafiği.....	42
Şekil 4.7 ResNet50 ROC eğrisi .....	44
Şekil 4.8 Karmaşıklık matrisi .....	45
Şekil 4.9 Doğruluk grafiği.....	46
Şekil 4.11 Kayıp grafiği .....	46

## TABLULAR DİZİNİ

	<b><u>Sayfa</u></b>
Tablo 4.1 VGG16 verilerin doğruluk ve kayıp oranları .....	38
Tablo 4.2 VGG16 başarımları metrikleri .....	40
Tablo 4.3 VGG19 verilerin doğruluk ve kayıp oranları .....	40
Tablo 4.4 VGG19 başarımları metrikleri .....	41
Tablo 4.5 DenseNet verilerin doğruluk ve kayıp oranları.....	41
Tablo 4.6 DenseNet başarımları metrikleri .....	43
Tablo 4.7 ResNet50 başarımları metrikleri .....	43
Tablo 4.8 ResNet50 verilerin doğruluk ve kayıp oranları.....	45



## SİMGELER VE KISALTMALAR DİZİNİ

### Kısaltmalar

<b>AİK</b>	: Alıcı İşlem Karakteristiği
<b>BT</b>	: Bilgisayarlı Tomografi
<b>CAD</b>	: Bilgisayar Destekli Tanı
<b>CXR</b>	: Chest X-Ray (Göğüs Röntgeni)
<b>DenseNet</b>	: Yoğun Bağlantılı Evrişimli Ağlar
<b>DNN</b>	: Derin Sinir Ağları
<b>DN</b>	: Doğru Negatif
<b>DP</b>	: Doğru Pozitif
<b>DSÖ</b>	: Dünya Sağlık Örgütü
<b>EAA</b>	: Eğri Altındaki Alan
<b>ESA</b>	: Evrişimli Sinir Ağları
<b>PZR</b>	: Polimeraz Zincir Reaksiyonu
<b>RNA</b>	: Ribonükleik Asid
<b>ROC</b>	: Başarım Eğrisi
<b>VGGNet</b>	: Çok Derin Evrişimli Ağlar
<b>YSA</b>	: Yapay Sinir Ağları
<b>YP</b>	: Yanlış Pozitif
<b>YN</b>	: Yanlış Negatif

## 1. GİRİŞ

Şiddetli solunum yetmezliği, ateş, eklem ağrıları, koku ve tat kaybı gibi belirtileri bulunan Koronavirüs (Coronavirus Disease 2019, Covid-19) hastalığının etkeni olan Severe Acute Respiratory Syndrome-Coronavirus 2 (SARS-CoV-2), Çin'in Wuhan kentinde 2019 yılında ortaya çıkmış olup çok kısa sürede tüm dünyayı etkisi altına alan dünyanın en büyük pandemisine sebep olan 65-125 çapında zarflı, tek zincirli, pozitif polariteli RNA virüsleridir. Virüs, o zamandan beri hızlı bir biçimde yayılmış ve küresel bir salgın olarak raporlanmıştır (WHO, 2020). Günümüzde hala etkileri görülmekte olup, mutasyonlar sonucu etkisinin zayıfladığı araştırmacılar tarafından belirtilmiştir.

Dünya Sağlık Örgütü (DSÖ) tarafından yayınlanan raporda, Aralık 2022 tarihinde dünya genelinde 649753806 (yaklaşık 6,5 milyon) onaylanan vaka ve 6648457 (yaklaşık 6 milyon) onaylanan ölüm belirtilmiştir. Birçok tespit edilmemiş asemptomatik Covid-19 vaka nedeniyle, gerçek Covid-19 enfeksiyonu sayısı tahmin edilenden daha fazla olabilir. Ayrıca asemptomatik hastalar da semptomatik hastalar kadar bulaşıcıdır ve enfekte olan her bireyin yaklaşık üç kişiyi daha enfekte edebileceği tahmin edilmektedir (Liu vd., 2020). Bu nedenle, SARS-CoV-2 tespiti için hızlı ve doğru teknikler geliştirmek, virüsün daha fazla yayılmasını önlemek için çok önemlidir.

Koronavirüs tespiti için üç yöntem bilinmektedir. Şu şekilde sıralanabilir: Kan testi, göğüs radyografisi (CXR) ile tespit ve burun-boğaz bölgesinden uzun bir çubuk yoluyla alınan sürüntü, PZR (Polimeraz Zincir Reaksiyonu) ile tespit edilebilmektedir. Kan testinde virüse karşı gelişen antikorların varlığı ile tespit edilebilmektedir. PZR (Polimeraz Zincir Reaksiyonu) testinde ise sürüntüde virüs genomu (Koronavirüs için RNA) aranmaktadır. Fakat test sonuç süreleri ve hastalığın ilk evrelerinde oldukça fazla sayıda yanlış sonuçlar vermesi göz ardı edilemeyecek kadar fazladır.

Hastalığın ilk bulaşma zamanında hızlı ve doğruluk payı oldukça yüksek test veya tespit yöntemlerine ihtiyaç duyulmuştur. Alınan her türlü önleme rağmen yayılımı

engellenemeyen dünyanın kontrol edemediği bir salgın haline gelmiştir. Dünya salgınla mücadele etmek için radikal önlemler almıştır. Neredeyse tüm dünyada maske kullanımı zorunlu hale getirilmiş, toplu kullanım alanları kısıtlanmış, birçok iş yeri bulaşma riskini artırdığı için geçici süreliğine kapatılmış, uzaktan çalışma ve online eğitim çalışmaları ağırlık kazanmıştır. Ayrıca ülke genelinde sokağa çıkma yasakları getirilmiş ve bunlara rağmen virüsün yayılmasına bir türlü engel olunamamıştır.

Hastanelerdeki yoğun bakım ünitelerine kapasitelerinin çok üzerinde hasta yerleştirilerek tedavi edilmeye çalışılmıştır. Farklı ilaç firmaları tarafından aşılar üretilmiş, tüm dünyada durdurulamayan bu virüs sebebiyle büyük bir kaos yaşanmıştır.

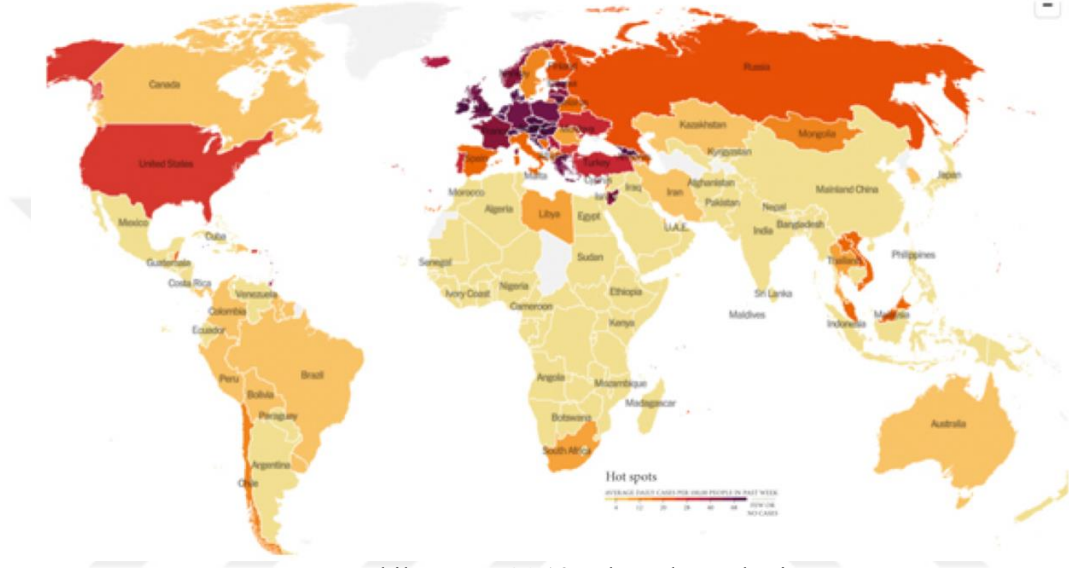
Hastalığın en çok hasar verdiği organlar başta akciğer olmak üzere sırasıyla beyin ve kalp gibi diğer organlardır. Ayrıca kalpte, pıhtı oluşumu, iltihaplanma, kalp yetmezliği gibi etkilere de sebep olmuştur. Yapılan araştırmalarda Parkinson, beyin damar hastalığı, yüksek tansiyon, Multipl Skleroz (MS), epilepsi, Amitrofik Lateral Skleroz (ALS) gibi nörolojik rahatsızlıkları olan hastalara bu virüs daha hızlı bulaşacağı kanıtlanmıştır.

Gerçek zamanlı ters transkriptaz polimeraz zincir reaksiyonu testleri (RT-PZR (Polimeraz Zincir Reaksiyonu)), viral RNA tespiti ile Covid-19 tanı doğrulaması gerçekleştiren standart bir yöntem olarak kabul edilmektedir (Da Silva vd., 2020). Hızlı teşhisin önemine rağmen, bu testler numune alımından itibaren yaklaşık 6 saat kadar sürebilir ve yanlış negatif ve yanlış pozitif sonuçları ayırt etmek için ardışık testler gerektirebilir. Semptomlar, CXR bulguları, bilgisayarlı tomografi (BT) bulguları ve rutin laboratuvar kan testi sonuçları gibi bilgileri kullanarak makine öğrenimi veya yapay zekâ yardımıyla Covid-19'u hızlı ve doğru bir şekilde teşhis etmek için çeşitli çabalar sarf edilmiştir.

En büyük hasarı akciğerlere verdiği gözlemlenmiştir. Akciğerler alveollere zarar veren hücreler hastalarda kalıcı sorunlara neden olmaktadır. Alveoller kılcal damarlardaki karbondioksiti alıp yerine oksijen vermektedirler. SARS-CoV2'nin S

proteini hücre yüzeyi reseptörü, alveollere tutunup burada bulunan anjiyotensin dönüştürücü enzim 2 (ACE2) reseptörlerine tutunarak burada genetik olarak çoğalarak akciğer hücrelerini ele geçirdikten sonra böbrek ve kalp gibi organlara doğru yayılmaktadır.

Şekil 1.1’de dünyada seyreden Covid-19 vaka dağılım haritası yer almaktadır.

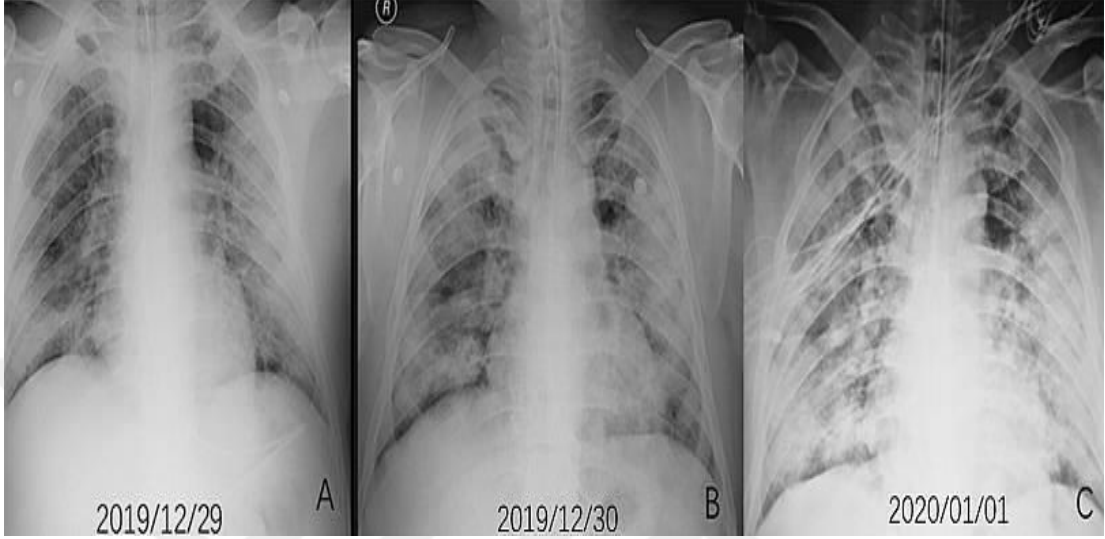


Şekil 1.1 Covid-19 vakası dünya haritası

Hastalığın tespitinde ve tedavisinde en büyük öneme sahip sağlık uzmanları ve diğer sağlık birimlerinde çalışanları ise tespit aşamasında bulaşma riskine maruz kalmaktadır. Sürüntü yöntemleri kullanılarak burundan, boğazdan ya da solunum yolundan alınan numune veya kan testi ile tespit edilmek istendiğinde sağlık çalışanları hastaya yakın temasta buldukları için virüs bulaşma riski en üst seviyelere çıkmaktadır. Bu da sağlık zincirini sekteye uğratarak sonuçta birçok geri dönüşmez kayıplara yol açmaktadır.

Hastalığın analizi ancak uzman radyologlar tarafından akciğer görüntüleri yorumlanarak belirlenebilir. Şekil 1.2’de hastalıklı bir akciğere ait radyolojik görüntü gösterilmiştir. Üç gün arayla çekilmiş röntgen görüntülerinde A görüntüsünde tahribat az iken, C görüntüsünde tahribatın oldukça arttığı görülmektedir. İnsan gözüyle bile ayırt edilen bu değişiklik makine tarafından piksel bazında tarandığında başarı elde edilmesi beklenmektedir. Akciğer görüntülerinden hastalığı tespit etmek için yakın temasa gerek olmadığı için hem hasta hem sağlık çalışanları açısından

daha güvenilir olduđu düşünölmektedir. Ancak akciđer görüntüsünün uzman bir radyolog tarafından incelenmesi durumunda tanı konması ortalama 5-6 dakika sürebilir.



Şekil 1.2 Koronavirüslü akciđer röntgen görüntüsü

Halen çok sigara içen ve eski sigara içenlerde akciđer kanserinden ölüm oranı, düşük doz bilgisayarlı tomografi (BT) tekniđi kullanılarak tarama yapılarak erken teşhis ile azaltılabilir (Ciompi vd., 2015). Amerikan Ulusal Akciđer Tarama Denemesinin bir sonucu olarak sadece göđüs röntgeni çekilen deneklerle karşılaştırıldığında, BT taramaları ile tarama yapılan kişilerde akciđer kanseri mortalitesinde %20 oranında bir azalma bildirilmiştir.

Röntgen görüntüleri üzerinde hastalık teşhisi için maliyet ve zaman kaybı yaşamamak için röntgen görüntüleri üzerinden bilgisayar destekli tespit sistemlerinin tasarımı ile lezyon tespiti sorunu ele alınarak hasta ve sađlık çalışanı için zaman, maliyet ve kesinlik yönüyle mutlak bir sonuç elde edilmesi hedeflenmektedir. Radyoloji görüntülerinin yüksek doğruluk ve verimliliđe sahip olduđu göz önüne alındığında, araştırmacılar Covid-19 hastalarını BT taramaları ve radyografilere göre sınıflandırma işlemine daha fazla önem vermişlerdir.

Covid-19 hastalığı, çok hızlı yayılan ve dünyayı etkisi altına alan milyarlarca insanın sađlığını tehdit eden bir bulaşıcı hastalıktır. Vaka sayısının hızla artmasıyla birlikte çođu ülke test kiti ve kaynak sıkıntısı sorunuyla karşı karşıya kalması nedeniyle bu

test kitlerine başka alternatif olarak farklı teşhis yöntemlerinin kullanılmasına ihtiyaç duyulmuştur. Tıbbi biyoloji, biyoistatistik ve bilgisayar bilimi alanındaki araştırmacılar tarafından Covid-19 vakalarını daha iyi tanımlamak ve teşhis etmek için göğüs görüntüsü sınıflandırmasında çeşitli yöntemler önerilmiştir. Tıpta yapay zekâ, tıbbi verileri aramak ve sağlık sonuçlarını ve hasta deneyimlerini iyileştirmeye yardımcı olacak iç görüleri ortaya çıkarmak için makine öğrenimi modellerinin kullanılmasıdır. Bilgisayar bilimi ve bilişim alanındaki son gelişmeler sayesinde, yapay zekâ (AI) hızla modern sağlık hizmetlerinin ayrılmaz bir parçası haline gelmiştir. Yapay zekâ algoritmaları ve yapay zekâ tarafından desteklenen diğer uygulamalar, tıp uzmanlarını klinik ortamlarda ve devam eden araştırmalarda desteklemek için kullanılır (Mahmud vd., 2020). Yapay zekâ ve makine öğrenim teknikleri, tıptaki birçok alan da dahil olmak üzere görüntülerden belirli bir örüntüyü tespit etme yeteneğine sahiptir.

Hasta durumunun gelişimini ölçmek, akciğer dokusu için otomatik sınıflandırma araçlarının geliştirilmesini zorunlu kılmıştır. Bilgisayar destekli tasarım sistemlerinin büyük çoğunluğu için bu tür bir sınıflandırma, eksenel BT görüntülerinin iki boyutlu analizine dayanır. Ancak böyle bir sistem, hastalıklı bölgeleri tespit etmede iyi performans gösteren çok ölçekli bir morfolojik analizden yararlanabilir, ancak bazen patolojik alanları fazla tahmin etmekten ve farklı tipte akciğer modellerini karıştırmak gibi dezavantajları olabilir.

Tarando vd. (2016) çalışmasında, göğüs BT'leri ile hastalığa ait görüntüleri kullanarak sınıflandırma yapmak için derin öğrenme kavramına ait temel mimari olarak kabul edilen Evrişimli Sinir Ağları (ESA) mimarisi ile bilgisayar destekli hastalık tespit uygulaması geliştirmişlerdir. CAD yöntemlerini radyolog tanı sistemlerine entegre etmek, doktorların iş yükünü büyük ölçüde azaltır ve güvenilirliği ve kantitatif analizi artırmaktadır. Yapay zekâ alanının alt dallarından bir olan derin öğrenme yöntemlerini kullanmanın avantajı, sınıflandırma problemlerinin çözümünde yüksek doğruluk değerleri ile sonuçların elde edilmesidir.

Shen vd. (2015) çalışmasında BT akciğer taramalarından tanısız akciğer nodülü sınıflandırması için çok ölçekli evrişimli sinir ağlarını (MCNN) kullanmışlardır. Her

birinde 2 (iki) evrişim katmanı bulunan paralel 3 (üç) ESA ile malign tümör ve iyi huylu tümör sınıflandırılmasında %86 doğruluk oranı elde edilmiştir. ESA, tıbbi görüntülerdeki oldukça ayırt edici özellikleri öğrenmek için geçerli bir çerçeve sunsa da ağın karmaşıklığı üç boyutlu verilerle beslendiğinde artabilir. Nodülün üç boyutlu olarak sınıflandırılması, nodülün 2 boyutlu görünümüne dayalı olarak pulmoner perifissural nodülleri tanımak için eğitilmiş bir sınıflandırıcı topluluğu uygulanabilir. Ciompi vd. (2015), pulmoner perifissural nodüllerinde özellik çıkarımı için kullanıma hazır, önceden eğitilmiş bir ESA mimarisi kullanılmıştır. Sonuç olarak doğal görüntüler gibi tamamen farklı bir veri alanından öğrenilen görsel çekirdeklerin tıbbi görüntülemedeki bir sorunu çözmek için yararlı bilgiler sağlayabileceği gösterilmiştir.

Covid-19 hastalığına yakalanan insanların akciğerlerinde ciddi deformelerin varlığı hem hasta şikayetleri hem de görüntüleme sistemleri tarafından tespit edilmektedir. Covid-19 virüsüne maruz kalan akciğerde hava kesecikleri iltihaplanması görülmektedir. İltihaplanma sonucu kandaki oksijen oranını düşürerek doku ve organların oksijen yoksunluğu çekmesine sebep olmaktadır. Pneumonia ise zatürre ile aynı etkileri göstermektedir. Akciğerdeki hava keseciklerinin sıvı ile dolması durumu pneumonia olarak tanımlanmaktadır. Bilgisayar destekli tanı (CAD) sayesinde CXR'den pnömoniyi daha hızlı ve doğru bir şekilde teşhis edilmesi öngörülmektedir. Derin öğrenme özellikle bilgisayarlı görü (vision) alanındaki ESA başarılı sonuçları elde etmesi nedeniyle yaygın olarak kullanılmaktadır (Lecun vd., 2015).

Dünya genelinde hasta-sağlık çalışanı arasındaki temas sebebiyle bulaşma riski çok artmaktadır, bu durumu en aza indirmek için x-ray cihazı tarafından alınan görüntünün otomatik olarak bilgisayar tarafından sınıflandırılması ve hastanın virüs taşıyıp taşımadığının hızlı bir şekilde tespit edilmesi bulaşma riskini azalttığı gibi hasta ve sağlık çalışanı güvenliğini sağlamalıdır. Bu tez çalışmasının temel amacı ise hasta ve sağlık çalışanları için daha izole bir ortamda hastalıkların tespitini sinir ağları yardımıyla sağlık çalışanları ve hasta arasındaki teması en aza indirgeyerek bilgisayar sistemlerinde uygulanması ile otomatik olarak belirlenmesi amaçlanmaktadır.

İkinci bölümde, Covid-19 tanısı alan hastaların sonuçlarına ait röntgen ve tomografi görüntüleri ile hastalık tespiti yapan derin öğrenmeye ilişkin literatür araştırması yapılmıştır.

Üçüncü bölümde, Covid-19'u teşhis etmek için kullanılan ResNet50, VGG16, VGG19 ve DenseNet derin öğrenme yöntemleri özetlenmiştir. Ayrıca veri toplama adımları, görüntüleme sistemleri, Yapay sinir ağları (YSA), ESA ve katmanları, başarımlar ve istatistiksel analiz konuları açıklanmıştır.

Dördüncü bölümde, çalışmada kullanılan derin öğrenme mimarilerinin deneysel sonuçları ve bu röntgen görüntü sonuçlarının ROC eğrisi grafikleri ve açıklamaları, karmaşıklık matrisi, transfer öğrenme, doğruluk, kesinlik, duyarlılık ve F1-skor sınıflandırma metrikleri kullanılarak istatistiksel performans sonuçları karşılaştırılarak tablo ve grafiklerle sunulmuştur.

Beşinci bölümde tez çalışmasından elde edilen sonuçlar ve sonuçlara bağlı öneriler yer almaktadır.

## 2. LİTERATÜR ARAŞTIRMASI

Tıbbi görüntüleme sistemleri ile hastalık tespiti yapmak tıbbi tanı alanında oldukça önemlidir ve bu işlemin insan gücüyle değil de makine (bilgisayar) gücüyle yapılması tıp ve insanlık tarihi için dönüm noktası olabilecek niteliktedir. Tıbbi görüntüleme sistemleri ile ilgili hastalık tespitine yönelik çalışmalara bu bölümde yer verilmektedir.

Tıbbi görüntüleme sistemlerinde X-ray, bilgisayarlı tomografi, manyetik rezonans görüntüleme gibi teknolojilerle elde edilen radyolojik görüntüler üzerinden görüntü sınıflandırması; nesne sınıflandırma amacıyla kullanılmaktadır. Tıptaki tüm bilim dallarında yaygın olarak tercih edilmektedir ve tıbbi teşhise destek sağlamaktadır (Ker vd., 2017).

Siar vd. (2019), insan beynine ait Manyetik Rezonans Görüntüleme (MRI) tekniği ile elde edilen görüntüleri kullanarak, ESA yöntemiyle kurulan ağ ile tespit etmek için çalışmışlardır. İlk etapta %98 başarı elde etmişlerdir. Daha sonra makine öğrenmesi ile görüntüleri işledikten sonra yeniden ESA yöntemi kullandıklarında %99 başarı elde etmişlerdir.

Rubin vd. (2018), MIMIC röntgen görüntülerini kullanarak toraks hastalığının tespit edilmesi için ESA modeli sunulmuştur. Görüntü işleme yöntemleri kullanarak ağ performansında yüksek oranlarda başarı elde etmişlerdir. Çalışmada %72 doğruluk değeri elde edilmiştir. Pnömoni (zatürre) şüphelenildiğinde bir göğüs röntgeni çekilmesi önerilmektedir.

Ayan vd. (2019) çalışmasında pnömoni hastalığının tespiti için VGG16 ve Xception modelleri kullanılmıştır. Röntgen görüntülerinden sınıflandırma başarı oranı VGG16 ağı için %87 ve Xception ağı için %82 elde etmişlerdir.

Gifani vd. (2021), önceden eğitilmiş ESA mimarileri kullanarak transfer öğrenme yöntemi kullanmışlardır. EfficientNet, SeResnet50, InceptionV3, ResNet50, Xception, DenseNet121, NasNetLarge ve NasNetMobile olmak üzere çeşitli ESA

mimarileri kullanarak toplu öğrenme yöntemi ile %85 başarı elde ettiklerini bildirmişlerdir.

Hammouidi vd. (2020), zatürre haslığı tespiti için ResNet34, ResNet50, DenseNet, VGG19 gibi çeşitli derin öğrenme modelleri kullanarak röntgen sonuçlarını değerlendirmeye alarak viral zatürre, normal, bakteriyel zatürre olmak üzere sınıflandırmaya çalışmışlar ve oluşturdukları ESA modellerinde başarılı sonuçlar elde etmişlerdir.

Talo (2019), beş yaş altı çocuklara ait akciğer grafisi görüntüleri ile pnömoni tespitinde transfer öğrenme tekniği ile ESA mimarisi ile modelledikleri ResNet-152 evrimsel sinir ağı modeli kullanılarak %97,4 oranında tanıma başarıları elde etmişlerdir.

Kogilayani vd. (2022), göğüs BT görüntüleri üzerinde sınıflandırma yapmak için bazı modeller kullanmışlar ve %80 ile %98 arası başarı elde etmişlerdir. Şöyle ki VGG16 için %98, DenseNet için %98, MobileNet için %96, NasNet için %90, Xception için %92, EfficientNet için %80 başarı elde etmişlerdir.

Jain vd. (2020), göğüs röntgen görüntülerinden hastalık tespit etmek için ESA ağı kullanmışlardır. Bazı metrikleri ve katman sayılarını değiştirerek hastalıklı ve normal olarak verileri sınıflandırmışlardır. Alt adet model oluşturup bu modeller arasında en yüksek olarak %92 oranında başarı elde etmişlerdir.

Dou vd. (2017), tomografi görüntüleri ile pulmoner nodül tespit edebilmek için üç boyutlu ESA mimarisini kullanan yeni bir yöntem önermişlerdir. Üç boyutlu ESA mimarileri, üç boyutlu örneklerle eğitilmiş hiyerarşik mimarileri aracılığıyla daha zengin uzamsal bilgileri kodlayabilir ve daha temsili özellikler çıkarabilir.

Shin vd. (2016), abdominal lenf nodu tespiti ve interstisyel akciğer hastalığı sınıflandırması olmak üzere iki özel bilgisayar destekli tespit problemi incelenmiştir. Alex-Net, Cifar ve GoogleNet gibi ESA modellerini farklı parametrelerle deneyerek sınıflandırma yapılmıştır. Abdominal lenf nodu tespitinde AUC değeri olarak %92 elde eden GoogleNet olmuştur.

Tarando vd. (2016), akciğer tomografi görüntüleri üzerinden ESA mimarisi ile bilgisayar destekli tanı çalışması gerçekleştirmişlerdir. Pulmoner perifissural nodülleri üzerinde bilgisayar destekli tanı yöntemi geliştirmişlerdir.

Shah vd. (2021), farklı derin öğrenme teknikleri kullanılarak COVID-19 ve COVID-19 olmayan BT'nin CT tarama görüntülerini ayırt etmeye odaklanmaktadır. COVID-19 teşhisi için %82,1 doğruluk oranına sahip CTnet-10 adlı bir model tasarlanmıştır. Ayrıca DenseNet, ResNet-50, InceptionV3, VGG-16, VGG-19 modelleri de test edilmiştir. VGG-19, diğer tüm derin öğrenme modellerine göre elde edilen %94,52 doğrulukla üstün olduğunu kanıtlamışlardır.

Deepak vd. (2019), ESA transfer öğrenme yoluyla üç önemli beyin tümörü tipini oluşturan glioma, menenjiyom ve hipofiz tümörlerini ayırt etmek için 3 sınıflı bir sınıflandırma problemine odaklanılmıştır. Önerilen sınıflandırma sistemi, derin transfer öğrenme kavramını benimser ve beyin MRI görüntülerinden özellikleri çıkarmak için önceden eğitilmiş bir GoogLeNet kullanır. Kanıtlanmış sınıflandırıcı modelleri, çıkarılan özellikleri sınıflandırmak için bütünleştirilmiştir. Deney, Figshare'den alınan MRI veri setinde hasta düzeyinde beş katlı bir çapraz doğrulama sürecini izler. Önerilen sistem, tüm son teknoloji yöntemleri geride bırakarak ortalama %98 oranında bir sınıflandırma doğruluğu elde edilmiştir.

Loey vd. (2020), göğüs BT radyografileri dijital görüntüleri üzerinde veri genişletme, veri çoğullama ve CGAN kullanarak, VGG16, VGG19, AlexNet, ResNet50 ve GoogleNet mimarilerini olmak üzere beş farklı derin evrişimli sinir ağı tabanlı model seçilmiştir. Sonuçlar, ResNet50'nin %82 oranında test doğruluğu, %77 oranında hassasiyet ve %87 oranında özgüllük ile klasik veri artırmayı kullanarak sınırlı göğüs BT veri kümesinden Covid-19'u saptamak için en uygun derin öğrenme modeli olduğunu göstermektedir.

Abbas vd. (2021), Covid-19 göğüs görüntülerinin sınıflandırılması için Ayrıştır, aktar ve oluştur adlı bir ESA mimarisi önerilmiştir. Ayrıştır, aktar ve oluştur, bir sınıf ayrıştırma mekanizması kullanarak sınıf sınırlarını araştırarak görüntü veri kümesindeki herhangi bir düzensizliğin üstesinden gelmek amacıyla kullanılmıştır.

Deneysel sonuçlar, çeşitli hastanelerden toplanan kapsamlı bir görüntü veri setinden Covid-19 vakalarını tespit etme işleminde %93 doğruluk başarısı ile %100 hassasiyet elde etmişlerdir.

Antin vd. (2019) çalışmasında, Ulusal Sağlık Enstitüleri tarafından derlenen ve 30805 benzersiz hastadan alınan yaklaşık 112120 göğüs röntgen görüntülerini içeren bir veri seti üzerinde DenseNet-121 derin öğrenme modelini kullanarak eğitimden sonra AUC değeri %69 ve testten sonra ise AUC değeri %61 oranlarında elde edilmiştir.

Jain vd. (2021), kaggle sitesinden aldıkları göğüs röntgen görüntüleri üzerinde ESA mimarisi ile çalışmışlardır. İlk etapta görüntü temizleme ve veri artırımı uyguladıktan sonra Inception V3, Xception ve ResNetX modelleri ile çalışarak sırasıyla %89, %76 ve %97 yüksek başarı elde etmişlerdir.

Chen vd. (2019), ImageNet veriseti ile eğittikleri CaffeNet modelini kullanarak, akciğer lezyonlarını iyi huylu (benign) ve kötü huylu (malign) sınıflandırılmasını yaparak %90 başarı elde etmişlerdir.

Apostolopoulos vd. (2020), göğüs röntgen görüntüleri ile ESA mimarisini kullanmışlardır. Çalışmalarında VGG19, MobileNet V2, Inception, Xception, Inception ResNet modelleri ile çalışarak sırasıyla %98, %97, %86, %85 ve %84 başarı elde etmişlerdir.

Tsung vd. (2020), göğüs röntgen görüntülerini ESA mimarisi ile kullanarak, görüntü ön işleme, kılavuzlu Grad-Cam katman görselleştirmesi ile ResNet50 modeli ile %93 başarı elde etmişlerdir.

Urey vd. (2019), göğüs görüntülerini ön işlemlerden geçirerek, öznetelik haritası çıkarmak için ESA kullanmışlardır. Yapay sinir ağları ve ResNet mimarisi kullanarak %78 başarı elde etmişlerdir.

Kieu vd. (2018), göğüs röntgen görüntüleri üzerinde ESA mimarisi geliştirmişlerdir. Fusion kuralı adında bir yöntem kullanarak %96 başarı elde etmişlerdir. Subhash vd.

(2021) çalışmasında göğüs röntgen görüntüleri üzerinde ImageNet üzerinde eğitilmiş farklı evrişimli sinir ağları mimarisi kullanılmıştır. ESA'lar daha sonra k-En Yakın Komşu, Bayes, Rastgele Orman, çok katmanlı algılayıcı (MLP) ve destek vektör makinesi (SVM) gibi birleştirilmiş makine öğrenimi yöntemleriyle birleştirilmiştir. Sonuçlar, veri kümelerinden biri için en iyi çıkarıcı-sınıflandırıcı çiftinin, %98 oranında bir doğruluk ve F1 puanı alan doğrusal bir çekirdek kullanan SVM sınıflandırıcısı Mobil Ağ mimarisi olduğunu gösteriyor. Diğer veri grubu için en iyi kombinasyon; %95 oranında doğruluk ve F1 puanı ile DenseNet201 ve MLP'dir. Dolayısıyla önerilen yöntem, X-ışını görüntülerinde Covid-19'u tespit etmek için iyi çalıştığı sonucunu elde etmişlerdir.


Covid-19 semptomlarının viral pnömoniye benzer olmasıyla birlikte Ayan vd. (2019) çalışmasında BT pnömoninin tespiti için ESA mimarilerinden VGG16 ve Xception olmak üzere 2 adet model kullanılmıştır. Çalışma sonucunda VGG16 için %87 oranı ve Xception modeli için %82 başarı oranı elde edilmiştir.

### 3. MATERYAL VE YÖNTEM

#### 3.1 Veri Seti

Bu tez çalışmasında göğüs röntgeni veri tabanları içerisinde oldukça popüler olan açık kaynaklı Kaggle'ın (URL-1, 2022) Covid-19 radyografi görüntü verileri kullanılmıştır. Kullanılan veri seti, Katar Üniversitesi, Doha, Katar ve Bangladeş Dhaka Üniversitesi'nden bir araştırmacı ekibi, Pakistan ve Malezya'daki işbirlikçileriyle birlikte tıp doktorlarıyla iş birliği içinde Covid-19 pozitif vakalar için göğüs röntgeni görüntülerinden (Chowdhury vd., 2020) oluşmaktadır. Veri seti %60 eğitim verisi, %15 doğrulama verisi ve %25'i de test verisi olarak hazırlanmıştır.

Eğitilecek veri kümesindeki görüntülerin boyutları 256x256px ve 1024x1024px boyutundadır. Veri tabanında 1200 adet Covid-19 akciğerine ait radyolojik görüntü, 1345 adet viral pneumonia akciğere ait görüntü, 1341 adet sağlıklı (normal) akciğerlere ait radyolojik görüntü olmak üzere toplamda üç farklı sınıflandırma kapsamında görüntüler bulunmaktadır. Viral pneumonia, solunum yolu hastalıkları sonucu meydana gelen akciğer hava keseciklerinin sıvı ile dolması haline denilmektedir. Şekil 3.1'de Covid-19, viral pneumonia ve normal olarak sınıflandırılan üçlü sınıflandırmaya ait veri setinden örnek X-Ray görüntüler verilmiştir.



Şekil 3.1 Veri kümesinden etiketli X-Ray örnekleri

Covid-19'a maruz kalan akciğerlerde meydana gelen komplikasyonlardan biri de hava keselerinin sıvı ile dolması durumu pnömoni olarak adlandırılmaktadır. Bu

nedenle, Covid-19'un neden olduđu pnömoni bir Covid-19 enfeksiyonunun varlığını doğrulayabildiğinden, göğüs röntgenlerinin araştırılması burada önemli hale gelmektedir. Bununla birlikte, Covid-19 ve diğeri akciğer enflamatuvar enfeksiyonlarının semptomları örtüşüyor, bu da hastalıkta yanlış teşhisli vakalara eğilimli hale getirmektedir.

### 3.2 Görüntüleme Sistemleri


1895 yılında fizik profesörü Wilhelm Conrad Röntgen tarafından X ışınları keşfedilmiştir. Tıbbi olarak elde edilen ilk direkt grafi Röntgen'in eşinin elinden bizzat Röntgen tarafından alınmıştır.

X ışınlarının vücuttan geçerek siyah beyaz formatta görüntüye dökülme işlemi olarak tanımlanmaktadır. X Ray (Röntgen) görüntüleme sistemi, X ışınları kullanılarak kemik ve doku görüntüleme yapılmasını sağlamaktadır. X ışınları insan vücudundan geçirilerek bir kısmı dokular tarafından emilir, bir kısmı dağılır, bir kısmı ise dedektör tarafından çekilir. Radyologlar CXR görüntülerini hızlı şekilde değerlendirebilirler. Covid-19'un tıbbi görüntüleri ile yaygın grip gibi diğeri viral enfeksiyonların neden olduđu pnömoni arasında birçok ortak özellik vardır. Bu benzerlik, uzman radyologların Covid-19 vakalarını ayırmada tanı koymalarını zorlaştırmaktadır (Liu vd., 2020).

Röntgen görüntüleme tekniği, adını X ışınlarını keşfeden CW röntgenden almıştır. Çok basit bir CW X-ışını kaynağı, çeşitli X-ışını teşhis hizalama prosedürlerini lazer atışlarına olan ihtiyaçtan kurtarmak için lazer plazma deneylerinde kullanılmak üzere yapılmıştır (Hares, 1981). Röntgen ve BT, X ışınları ile kemik ve doku görüntüleme teknolojisine sahip tıbbi görüntüleme cihazlarıdır. Tez çalışmasında kullanılan veri seti, insanların akciğer röntgen görüntülerinden oluşmaktadır.


Röntgen cihazları X ışınları ile hastaların vücut bölgesinin değişik açılardan çok sayıdaki doku ve kemiklerin iç yapılarının 2 boyutlu tanı ve görüntüleme amaçlı olarak kullanılmaktadır. Şekil 3.2'de röntgen cihazı ile elde edilen göğüs görüntüsü bulunmaktadır.

Bilgisayarlı Tomografi (BT), 1972’de Geoffrey Housfield tarafından keşfedilmiştir. Röntgen teknolojisinde bölgesel görüntüleme kullanılırken BT’de enine kesitlerde görüntüleme alınmıştır. Röntgen cihazı ile benzer prensipte çalışan tomografi cihazı vücuttaki kemik ve dokuları 3 boyutlu olarak görüntüleyen cihazlardır. Röntgen teknolojisi iki boyutlu, tomografi ise üç boyutlu bir görüntüleme teknolojisine sahiptir.



Şekil 3.2 Göğüs röntgen verisi

Bilgisayarlı tomografi damar yapılarını dahil ayrıntılı görüntüleme imkânı sağlar ve işlem süresi röntgen kadar kısadır. Şekil 3.3’te tomografi teknolojisi ile elde edilen göğüs görüntüsü bulunmaktadır.



Şekil 3.3 Göğüs tomografi verisi

### 3.3 Kullanılan Materyal ve Yazılım Dili

Bu tez çalışmasında Visual Studio Code platformu kullanılmıştır. Visual Studio Code, geliştiricilere, bir kod düzenleyicinin basitliği ve kolaylaştırılmış deneyimi ile geliştiricilerin temel kod-oluşturma-hata ayıklama döngüleri için ihtiyaç duyduğu şeylerin en iyisini birleştiren yeni bir geliştirici araçtır (Kahlert ve Giza, 2016). Literatüre girmiş çalışmalar incelendiğinde en çok kullanılan kod geliştirme ortamı olduğu görülmüştür. Python (Python, 2021), programlama dili kullanılmıştır. Python dilinin tercih edilmesinin sebebi açık kaynak kodlu olması ve yazılım kurallarının esnek olmasıdır. Çeşitli sınıf kavramlarını destekler ve birçok kütüphane içermektedir. Bu tez çalışmasında Python kütüphanelerinden Numpy, Keras, Sklearn, Pandas, Seaborn, tensorflow, matplotlib gibi çeşitli açık kaynak kodlu olarak kullanılmıştır.

NumPy, dizilerle çalışmak için kullanılan bir Python kütüphanesidir. Ayrıca doğrusal cebir, fourier dönüşümü ve matrisler alanında çalışmak için çeşitli fonksiyonlara sahiptir (NumPy, 2022).

Google tarafından oluşturulan TensorFlow, matematiksel modeller, sayısal hesaplama, görüntü işleme ve daha fazlasını oluşturmak için kullanılan açık kaynaklı bir Derin Öğrenme kütüphanesidir. Karmaşık matematiksel işlemler yapan derin sinir ağlarını eğiten ve yöneten bir yazılımdır (Abadi vd., 2016).

Keras, makine öğrenimi platformu TensorFlow üzerinde çalışan Python'da yazılmış bir derin öğrenme API'sidir. Keras, derin sinir ağı kodu yazmak için gerekli kodlamayı basitleştirmek üzere görüntü ve metin verileriyle çalışmayı kolaylaştırmak için katmanlar, hedefler, aktivasyon işlevleri, optimize ediciler ve bir dizi araç gibi yaygın olarak kullanılan sinir ağı yapı taşlarının çok sayıda uygulamasını içerir (Keras, 2022).

Pandas, veri bilimi/veri analizi ve makine öğrenimi görevleri için en yaygın şekilde kullanılan açık kaynaklı bir Python kütüphanesidir. Pandas, sayısal tablolar ve zaman serileri için veri yapısı oluşturup çeşitli işlemler için Python programlama dilinde yazılmış bir yazılım kütüphanesidir (URL-2, 2022).

Sklearn (Scikit Learn), Numpy, Scipy ve Matplotlib üzerine oluşturulmuş, veri işleme, model seçimi, sınıflandırma, küme analizi, regresyon gibi işlemleri gerçekleştirmeye yarayan bir kütüphanedir.

Seaborn, Matplotlib tabanlı bir Python veri görselleştirme kütüphanesidir. Güzel ve bilgilendirici istatistiksel grafikler çizmek için üst düzey bir arayüz sağlar (Hafeez ve Sial, 2021).

Python'da veri görselleştirme için birçok kütüphane vardır. Bunlardan biri, belki de en basit uygulama aşaması ve işlevi en yüksek olan Matplotlib kütüphanesidir. Matplotlib, biz analistlerin şekilleri görselleştirmesine yardımcı olan bir 2-Boyutlu, 3-Boyutlu çizim kütüphanesidir. Matplotlib barplot, dağılım grafiği, pasta grafiği ve histogram gibi popüler grafikleri içerir (Cansdale, 2021).

### **3.4 Yapay Sinir Ağları**

Düşünme, öğrenme ve karar verme gibi insani özelliklerin mühendislik uygulamalarına aktarımı, makine öğrenmesi adıyla uzun yıllardır ilgi gören ve gittikçe popülerliğini arttıran bir alandır (Goldberg ve Holland, 1988; Quinlan, 1986).

Makine öğrenimi, yapay zekanın bir alt alanıdır. Derin öğrenme, makine öğreniminin bir alt alanıdır ve sinir ağları, derin öğrenme algoritmalarının bel kemiğini oluşturur. Aslında, tek bir sinir ağını üçten fazla olması gereken bir derin öğrenme algoritmasından ayıran, sinir ağlarının düğüm katmanlarının sayısı veya derinliğidir. Derin öğrenmenin başarıyla kullanıldığı başlıca alanlar bilgisayarla görme, ses tanıma ve doğal dil işlemedir (Bozkurt, 2021).

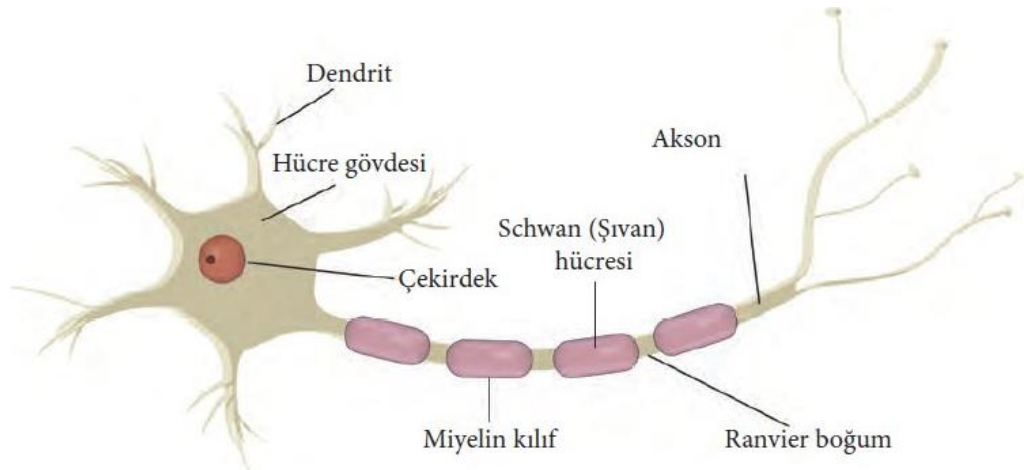
YSA, tarihsel gelişimi 1943 yılında başlayıp günümüze kadar devam etmektedir. 1943 yılında ilk kez biyolojik sinir sistemi fonksiyonlarına karşılık gelen yapay mantıksal bir modelleme gerçekleştirilerek yapay sinir ağlarının (YSA) temelleri oluşturulmuştur (Pitts ve McCulloch, 1943).

1949 yılında “Hebbian Learning” hücrelerin beraber çalışması ve nöronların etkisini artırma gibi sorunlara yönelik kuralların temelini oluşturmuştur.

1957 yılında Frank Rosenblatt tarafından tek nöron ile çalışan YSA’nın en küçük parçası olarak bilinen perseptron tasarlanmıştır. Böylece yapay sinir ağlarının tarihsel gelişme süreçlerinden birincisi yani temellerinin oluşturulduğu geri bildirim gibi döngüsel nedensel süreçlerle ilgili geniş kapsamlı bir alan olan sibernetik (cybernetics) süreci sona ermiştir (Goodfellow vd., 2016; Hebb, 1949).

10 yıllık duraklamanın ardından 1980 yılında Neocognitron mimarisi geliştirilmiştir. Neocognitron mimarisi görsel örüntü tanımayı mümkün hale getirmiştir (Fukushima, 1980). 1986 yılında ise çok katmanlı ağlar için geliştirilen geri yayılım (back-propagation) algoritması uygulanarak çok katmanlı yapılar oluşturulmuştur. Bu ikinci evrede yapılan çalışmalar derin öğrenme için temel hazırlamıştır. Ardından 2006 yılına gelindiğinde yapay sinir hücre mantığı daha ileri seviyelere taşınarak derin öğrenme mantıklı modeller kullanılmaya başlanmıştır.

Yapay sinir ağları makine öğrenmesinin kollarından biri olup son günlerde oldukça ilgi çeken bir ağ olduğu bilinmektedir. Sinir ağları insan beyninden esinlenerek karar mekanizmasını örnek alarak oluşturulmuş bir modeldir. Biyolojik sinir ağı hücresinde dendrit adı verilen uzantılar veri girişi, akson adı verilen uzantılar ise çıkış yani sonuç verilerinin elde edilmesini sağlamaktadır. Şekil 3.4’de biyolojik sinir hücresinin görüntüsü verilmiştir.

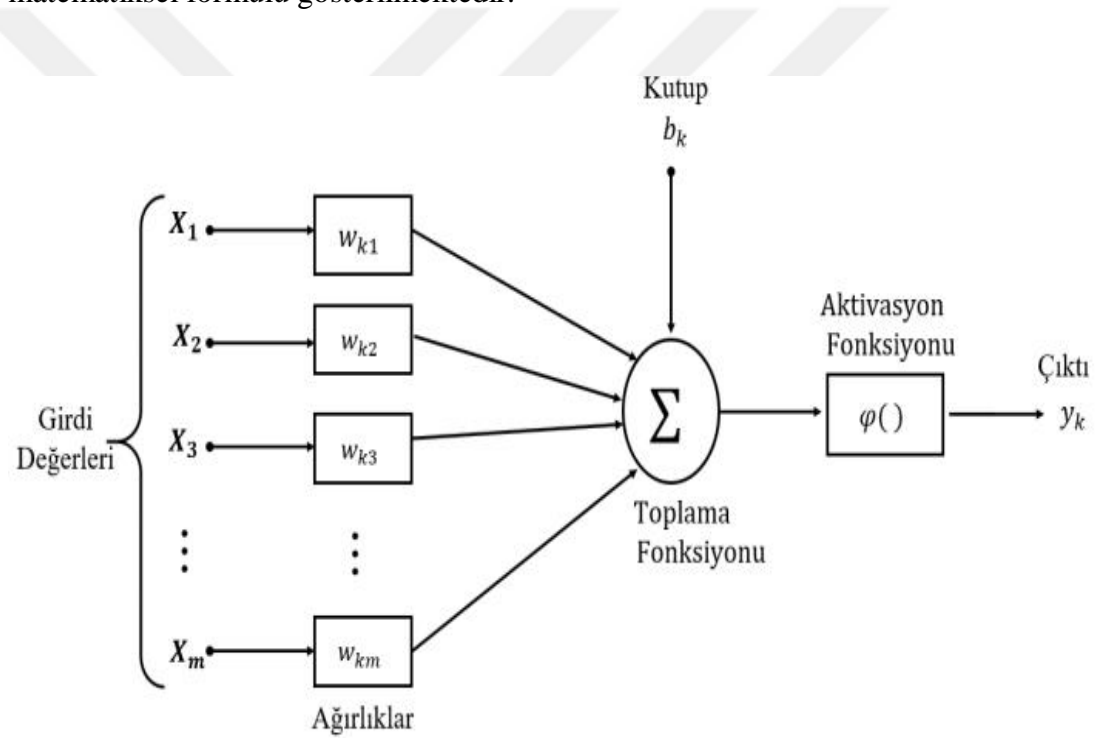


Şekil 3.4 Biyolojik sinir hücresi

Dendrit, hücrelerden gelen sinyalleri çekirdeğe iletmektedir. Akson, toplanan verileri diğer hücelere transfer etmektedir. Sinaps, aksonlardan gelen bilgiyi işlemlerden geçirerek diğer hücelere transfer etmektedir.

Şekil 3.5’de gösterilen yapay sinir yapısı temel olarak girdi değerleri ile ağırlık değerlerini çarpılarak nöron çıktısı elde edilmek üzere tasarlanmıştır.

Denklem 3.1’de sinir ağına ait matematiksel formül gösterilmektedir. Bu değer daha sonra kutup değeri ile toplanarak elde edilen değer aktivasyon fonksiyonuna girilerek ağ çıktısı elde edilmektedir. Denklem 3.2’de yapay sinir ağının çıktısının matematiksel formülü gösterilmektedir.



Şekil 3.5 Yapay sinir ağı modeli

$$u_k = \sum_{j=1}^m w_{kj} X_j \quad (3.1)$$

$$y_k = \varphi(u_k + b_k) \quad (3.2)$$

Girdi değerleri  $x_1, x_2, \dots, x_m$ ;  $w_{k1}, w_{k2}, \dots, w_{km}$   $k$  ile sayılan nöron ağırlıkları; nöronların çıktısı  $u_k$ , kutup değeri  $b_k$ ;  $\varphi ()$  aktivasyon fonksiyonu ve yapay sinir ağının çıktısı ise  $y_k$  şeklinde ifade edilmiştir. Farklı aktivasyon fonksiyonları bulunmaktadır, bunlar ağın gereksinimlerine göre tercih edilmektedir.

### 3.5 Derin Öğrenme (Derin Sinir Ağı)

Derin öğrenme, insanların belirli bilgi türleri öğrenme şeklini taklit eden makine öğrenimi ve yapay zekâ olarak tanımlanabilir. Derin öğrenme, istatistik ve tahmine dayalı modellemeyi içeren veri bilimi türüdür. Geleneksel makine öğrenimi uygulamaların aksine doğrusal değil karmaşıklık ve soyutlama hiyerarşisine sahiptir.

1940'lı yıllarda ilk kez derin öğrenme kavramı bilim insanları arasında konuşulmaya başlanmıştır. Hinton çalışmalarında yeni bir öğrenme sistemi modellemiştir. Bu yaklaşım derin öğrenme (Deep Neural Network) olarak adlandırılmıştır (Hinton vd., 2006).

Derin sinir ağları, derin öğrenme adıyla da kullanılmaktadır. Derin öğrenme YSA'nın geri yayılım algoritması ile eğitilmesi sonucu oluşan bir ağıdır. Çok katmanlı yapay sinir ağları (multi layer artificial neural networks) ve geri yayılım eğitilince yeni bir öğrenme sistemi olarak tanımlandığı literatürde taranan çalışmaların bazılarında kullanılmıştır. Derin sinir ağları teorik olarak YSA'nın daha kapsamlı ve detaylı hali olarak tanımlanabilir. Giriş ve çıkış katmanları arasında birden fazla gizli katman bulunmaktadır. YSA'da nöronlar birbirleri ile ilişki kuramazken derin sinir ağlarında nöronlar katmanlardan aldıkları aktivasyon verileri ile etkileşimde bulunmaktadır.

Derin öğrenme denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme olmak üzere üç yaklaşıma sahiptir. Denetimli öğrenme, sinir ağına giriş verisi  $x$ , çıkışta  $y$  olarak çıkacağı bilgisini de ağa verilmektedir. Sinir ağı içerisinde ağırlıklar belirlenir, ağırlık değerlerine göre  $x$  girişinin çıkışta vereceği  $y$  verisi güncellenir. Güncelleme işlemi iterasyon sayısı kadar devam etmektedir. İterasyon sayısı öğrenme işlemi gerçekleşene kadar güncelleme işlemi devam ettirecek sayısal değere sahiptir. Denetimli öğreniminin kullanışlı olduğu iki ana alan vardır: Sınıflandırma problemleri ve regresyon problemleri.

İyi bir performans elde etmek için, bir sınıflandırıcının denetimli öğrenmesi genellikle büyük bir etiketli veri eğitim seti gerektirir. Eğer bu küme prensipte çok sınırlıysa, benzer bir sınıflandırıcının oluşturulmasından elde edilen ek bilgi, transfer

öğrenimi yoluyla dahil edilebilir. Özellikle, derin bir CNN'ye dayalı hedef sınıflandırıcı, benzer görevleri çözmek için öğrenilen başlangıç ağırlıklarını kullanabilir (Hosseini-Asl vd., 2018).

Denetimsiz öğrenme  $x$  giriş verisi verilirken  $y$  çıkış verisi ağa tanıtılmaz. Ağ katmanları sonuç verilerini oluşturur ve benzer sonuçlar kümelenir. Her küme bir sınıfı temsil etmektedir. Takviyeli öğrenme ise ağa  $x$  girişi verilir  $y$  çıkış verisi tanıtılmaz. Girdi  $x$  verisinin ağ katmanlarında hesaplanarak, çıkış verisini üretmesi beklenir.  $Y$  çıkış verisinin doğruluğu test edilir. Sonuç yanlış ise ağın doğru sonucu üretmesi için ağ güncelleme işlemine devam etmektedir.

Sınıflandırma, tanı, tespit, teşhis gibi sonuçlar elde edilmesi için farklı derin sinir ağları modellenir. Kullanılacak verinin ses, görüntü, sinyal gibi etmenler ağın modelini belirlemede yardımcı olmaktadır. Derin sinir ağları mimarileri bilgisayarlı görü, doğal dil işleme, görüntü işleme, ses tespit, sosyal ağ filtreleme, bilişim, ilaç, tasarım, medikal, tıp gibi alanlarda uygulanmaktadır.

### **3.6 Evrişimli Sinir Ağı**

Derin öğrenme teknolojisindeki temel amaç yüksek boyutlu verileri işleyip bunlardan bazı özellikler elde edilmesi ile girdi-çıkış arasındaki ilişkiye yönelik sonuç vermesidir. Farklı karmaşık özelliklere yönelik sonuç elde etmek isteyen derin öğrenme algoritmaları çok katmanlı yapıya sahiptirler. Evrişimsel sinir ağları (ESA) ise derin öğrenmede kullanılan bir çeşit ağ modelidir.


ESA, derin öğrenme modelleri arasında popülerliğini korumaktadır. Beyindeki sinir hücrelerinin bağlantılarından esinlenerek insan gibi karar verme ve sınıflandırma yetkisine sahip olması amaçlanmıştır. ESA, makine öğrenmesinin bir alt kademesi olup çeşitli veri türleri (görüntü, ses, sinyal vb.) için kullanım alanı sağlamaktadır. Özellikle görüntü tanılama, sınıflandırma, kümeleme gibi işlemlerde yüksek başarı sağlamaktadır. Çeşitli ağ türleri oldukça fazladır fakat nesne sınıflandırma ve tanılama alanında en çok tercih edilen ve başarı oranına sahip ağ türüdür.

Lecun vd. (1998), ticari amaçla ilk ESA ağı olan LeNet-5 modelini önermişlerdir. İki boyutlu girdi değişkenlikleri için tasarlanmış olan LeNet-5 ile el yazısı tanıma uygulaması geliştirmişlerdir. Çalışmalarında LeNet-5'in klasik makine öğrenmesi algoritmalarına göre daha yüksek başarımlar verdiğini göstermişlerdir.

ESA mantıksal olarak görüntüleri matris formatında alır ve işler çıkışta istenen sonucu verir. ESA nöronlardan oluşur, öğrenme yapabilmesi için ağırlık ve bias değerlerini kullanırlar. ESA, evrimsel katmanlar, havuzlama katmanı, aktivasyon katmanı, sınıflandırıcı katmanı, bağlı katman gibi ana katmanların yanı sıra ek (yardımcı) katmanlara da sahiptir.

ESA mimari olarak insan beynindeki karar veren sinapsları rol model almıştır ve üç ana katmandan oluşan bir öğrenme mimarisidir. Bu derin öğrenme algoritması temel olarak üç katmandan oluşur: Evrimsel Katman (Convolutional Layer), Havuzlama (Pooling) Katmanı ve Tam Bağlantılı (Full Connect) Katman.

Son yıllarda özellikle görüntü tanıma sınıflandırma alanında oldukça popüler olduğu gibi yüksek başarımlar da vermektedir. Ses ve sinyal üzerine yapılan bilimsel çalışmalarda da başarılı sonuçlar sağlayarak literatürde yerini korumuştur. Şekil 3.6'da ESA mimarisi katmanları belirtilmiştir.



Şekil 3.6 ESA katman yapısı

ESA katmanlarının her katmanındaki nöron sayısı sabit olmamaktadır. Girdi katmanındaki nöron sayısı işlenecek veriye ait özellik sayısı ile belirlenirken ara katmandaki nöron sayısı için herhangi bir etkileyici unsur bulunmamaktadır.

Şekil 3.6’da gösterilen örnek ESA katman yapısında çıkış katmanından elde edilecek başarıya göre gizli katman nöron sayısını deneme-yanılma yoluyla bulunmaktadır. Çıkış katmanı ise istenen sınıflandırma koşullarına göre belirlenmektedir.


Sinir Ağları bir girdi (tek bir vektör) alır ve onu bir dizi gizli katman aracılığıyla dönüştürür. Her gizli katman, her bir nöronun bir önceki katmandaki tüm nöronlara tamamen bağlı olduğu ve tek bir katmandaki nöronların tamamen bağımsız çalıştığı ve herhangi bir bağlantıyı paylaşmadığı bir dizi nörondan oluşur. Tamamen bağlantılı son katman “çıktı katmanı” olarak adlandırılır ve sınıflandırma ayarlarında sınıf puanlarını temsil eder. YSA derinleştikçe yüksek boyutlu verilerin işlenmesi zorlaşmıştır, bu sorunu çözmek için ResNET mimarisi önerilmiştir. Bu mimari yeni bir öğrenme çerçevesine sahip 152 katmana kadar derinliğe sahip bir derin evrişimli sinir ağı içermektedir (Louati vd., 2021).

### **3.6.1 Evrişim Katmanı**

Evrişim katmanı ağ için en önemli katmandır. Filtrenin girişte alınan görüntü üzerinde kayma işlemi yapılmasına evrişim işlemi denilmektedir. Filtre özellikleri (boyut ve sayı) bu işlem esnasında değişkenlik göstermektedir. Sırasıyla, kenarlar, şekiller ve görüntü özelliklerini öğrenerek aktivasyon haritasını şekillendirir. Devamlı bir matris çarpımı ve her çarpımda kümülatif toplam elde edilir. Buradaki nöron sayısı verinin özellikleriyle doğrudan alakalıdır.

Bu çalışmada akciğer röntgen görüntüleri girdi olarak kullanılacağı için piksel sayısı önem arz etmektedir. Burada görsel, matris olarak işleme alınır. Örneğin 10x10 boyutunda bir matris 3x3 boyutunda küçük matrisler halinde işlenerek veri elde edilmeye çalışılır. Burada elde edilen veriler görüntüye ait temel ayırt edici özelliklerdir, bu özellikler ESA için öğrenilen temel verilerdir.

Model sürekli kendini yenileyerek daha iyi tespiti yarayan özellikleri keşfeder ve öğrenir. Şekil 3.7’de evrişim katmanında yapılan özellik çıkarma işleminin modellenmesi verilmektedir.



Şekil 3.7 Evrişim katmanı işlem şeması

Çıktı hacmi, derinlik, sıfır boyutu ve adım olmak üzere üç metrik tarafından nitelendirilir. Görüntünün filtrelenmesi, kenar algılama, bulanıklaştırma, keskinleştirme, çoğaltma gibi işlemler uygulanmaktadır. Tüm bu işlemler sonucunda öznitelik haritası adı verilen yeni bir matris oluşmaktadır.

### 3.6.2 Gizli Katman

Giriş katmanından gelen veriler gizli katman ya da ara katmana gelerek ağırlık bias değerleri ile tekrar işlenmektedir. Bias değeri nöronlardan elde edilen önem veya ağırlık değeri olarak tanımlanmaktadır. Bu katmanda kullanılacak nöron sayısı, başarımı artırmak için kullanıcının kabiliyetine bağlı olmaktadır. Bir ağda birden fazla gizli katman olabilir.

Gizli katmanda her katman kendine veri gönderen katmanın ağırlık, bias ve aktivasyon fonksiyonu ile işlediği verileri alarak tekrar ağırlık ve bias değerleri hesaplayarak aktivasyon fonksiyonu ile veriyi işler ve bir sonraki katmana iletir. Aktivasyon fonksiyonu uygulanmazsa, çıkış sinyali basit bir doğrusal fonksiyon haline gelir.

### 3.6.3 Dolgu İşlemi

Katmanlardan gelen değerlerle ve filtreleme işlemi sonucu boyutu azalan görüntülerin boyutu öznitelik haritası boyutu ile eşit olmadığı durumlarda bilgi kaybı yaşanmaması için dolgu (padding) işlemi uygulanmaktadır. Dolgu işlemi boyutu tamamlamak için görüntünün çerçevesini sıfırlar ile doldurmaktadır. Kaç sıra sıfır eklenmesi gerektiği filtreleme işlemi esnasında azalan piksel sayısı ile orantılıdır. Dolgu işlemi görüntü boyutunu korumak için kullanılmaktadır.

### 3.6.4 Havuzlama Katmanı

Öznitelik haritası adı verilen, evrimsel katman sonrası elde edilen verilerin boyutunun azaltılması işleminin yapıldığı katmandır. Havuzlama katmanının kullanım amacı çok büyük boyuttaki görüntülerin parametre sayısını azaltarak daha küçük boyutlu görüntülere küçültmesidir. Boyut azaltma işlemi esnasında veri kaybı önlenir. Matris boyutu azaldığında sonraki katmanlarda kullanılan ağdaki nöron sayısı da azalmaktadır. Nöron sayısının azalması hesaplama esnasında işlem yükünü azaltmaya etki etmektedir. Bu özellikler bellek ihtiyacını azaltırken orantılı olarak ağ hızını artırmaktadır.

Filtre matrisi, ortalama ve maksimum havuzlama işlemleri de bu katmanda yer almaktadır. Genellikle maksimum havuzlama yöntemi kullanılır ve konum ve rotasyonda değişim olmadan boyut azaltılarak önemli özelliklerin çıkarılıp modelin başarılı bir şekilde eğitilmesini sağlamaktadır.

Özçelik vd. (2021) çalışmasında seyreltme katmanı adı verilen ağın aşırı öğrenmesini ve ağdaki değerlerin ezberlemesini engelleyen bir ara katman daha olduğunu belirtmiştir. Seyreltme katmanı ağ katmanlarına uygulanarak metrikleri düzenlileştirmektedir. Srivasta vd. (2014) çalışmasında seyreltme işleminden bahsederken eğitim esnasında nöronları pasif hale getirmekte olduğunu ve nöron pasifleştirme işlemi nöronun ağırlık değerini ve ona bağlı nöronların ağırlık değerlerini sıfır yaparak kullanıldığını ve bu seyreltme işlemlerinin ağdaki tüm nöronlara uygulanabileceğini belirtmiştir.


### 3.6.5 Tam Bağlı Katman

YSA ile aynı şekilde çalışan bu katman, evrişim ve havuzlama sonucu elde edilen veriler bu katmana girdi olarak verilir, çıkış katmanına sınıf sayısı kadar sonuç üretmektedir. ESA'da tüm nöron ve katmanlardan gelen önemli verilerin hesaplandığı karmaşık katmandır. Elde edilen bu veriler düzleştirme işlemine tabi olduktan sonra öğrenme adımı için hazırlanmaktadır. Matris halindeki veri vektör haline dönüştürülmektedir. Bu aşamadan sonra verilerin düğüm, ağırlık ve bias değerlerinde sürekli güncellemeler yapılarak öğrenme süreci etkinleşmektedir.

### 3.6.6 Çıkış Katmanı


Bu katmanda gizli katmandan gelen veriler sigmoid, softmax, tanh, ReLu, Leaky gibi fonksiyonlar ile sonucu beslemektedir. Bu katmanda hatasız tahminde bulunmak için çaprazlama, geri yayılım, hata, kayıp indirgeme gibi ağırlık ve bias güncelleme işlemlerini yapmaktadır.

Sinir hücrelerinde akson, çıkış etkisinin olduğu elektriksel gövde de tek yönlü iletim sağlanır. Sinir hücrelerinin sistem çıkışıdır. Dendrit, diğer hücrelerden gelen verileri toplayan pasif kollarıdır, sistem girişidir. Sinaps, aksonların diğer dendritlere bağlantısını sağlamaktadır. Çekirdek, aksondan gelen verilerin devamlı ve düzenli olarak yeniden üretimini sağlar. Çıkış katmanında nöron sayısı birden fazla olabilmektedir. Şekil 3.8' da biyolojik sinir hücresindeki akson ile dendrit bağlantısına ait örnek görsel verilmiştir.



Şekil 3.8 Biyolojik sinir hücresi

İnsan beynindeki öğrenme yapısı modellenmeye çalışılmış ve insan gibi düşünme, ilişkilendirme ve bağlantı kurma gibi özellikler yapay sinir ağlarında da kullanılmıştır. Şekil 3.9’da insandaki bir sinir hücresinin matematiksel bir modeli gösterilmiştir.




Şekil 3.9 Sinir hücresi matematiksel modeli

### 3.6.7 Aktivasyon Fonksiyonu

ESA’da doğrusal olmayan özelliklerin tanıtılması ve eğitilip işlenmesi için aktivasyon fonksiyonuna ihtiyaç duyulmaktadır. Evrişim katmanından sonra gelen aktivasyon fonksiyonunun kullanım alanı üretilen çıktıyı düzenlemek ve sınırlandırmaktır. Ağda meydana gelen negatif değerleri yok ederek ağı doğrusal olmaktan kurtararak ve daha hızlı öğrenmesini sağlamaktadır. Girdi verileri  $x$ , ağırlıklar  $w$  ve ağı çıkışına uygulanan aktivasyon fonksiyonu  $f(x)$  olarak ifade edilmektedir. Tanh, ELU, RELU, sigmoid, softmax, gaussian, step ve eşik değeri gibi farklı aktivasyon fonksiyonları da bulunmaktadır.

Şekil 3.10’da bazı aktivasyon fonksiyonlarının grafikleri bulunmaktadır. Çalışmanın özelliklerine göre farklı aktivasyon fonksiyonları kullanılmaktadır. Literatürde en çok tercih edilen aktivasyon fonksiyonu ise Düzenlenmiş Doğrusal Birim (RELU)

fonksiyonudur. Aktivasyon katmanında yapılan işlem sonucu elde edilen değer negatif ise 0, pozitif ise 1 değerini almaktadır.



Şekil 3.10 Aktivasyon fonksiyonlarının eğrileri

### 3.6.8 Transfer Öğrenme

Transfer öğrenme (öğrenim aktarımı), önceden kazanılmış bilgi ve becerilerin, öğrenme ve problem çözme durumlarında kullanılmasına ve makine öğrenmesi algoritmalarında çözülen probleme dair edinilen bilginin depolanıp, bu bilginin farklı türde uygulamalarda kullanılmasına ilişkin bir çalışmanın sonucudur. Öğrenilen bilginin yeni problemlerde kullanılmaktadır.

Transfer öğrenme, bir ağda eğitilen veri kümesinden elde edilen bilgiler farklı bir ağ ve veri kümesinin eğitilmesi için kullanılmaktadır. Transfer öğrenme önceki bilgilerden faydalanarak az eğitim verisi, yüksek başarı ve hızlı öğrenme modeli sağlamaktadır. Uygulamalarda çok nadiren sıfırdan ESA modeli eğitilmektedir. Çünkü eğitilecek kadar büyük veri kümesine sahip olmak veya eğitmek oldukça zor olmaktadır. Bu sebepten dolayı ESA'nın büyük boyutlu hazır veri setleri ile önceden eğitilip daha sonra mevcut veri setinde kullanılmaktadır. Eğitim için seçilecek veri setinin eğitilecek veri seti ile uyumlu veya benzer olması başarıyı artırmaktadır.

### 3.7 Başarım Ölçütleri ve İstatiksel Analiz

Bir sınıflandırma probleminin ne kadar başarılı olduğunu anlamak için çeşitli değerlendirme kriterleriyle sonuçların analiz edilmesi gerekir. Derin öğrenmesinde performans değerlendirmesi önemli bir husus olup, bu amaçla birçok performans değerlendirme kriteri geliştirilmiştir. Bu tez çalışmasında başarıml ölçütü olarak en sık kullanılan performans değerlendirme ölçütlerinden hassaslık veya kesinlik (precision), duyarlılık (recall), f1-score ve doğruluk (accuracy) kullanılmıştır.

Hesaplamalar için, gerçek sınıf etiketleri ile tahmin edilen sınıf etiketlerinin karşılaştırılmasında karmaşıklık matrisi (confusion matrix) kullanılmaktadır. Bu ölçütler temel olarak, Şekil 3.11’de gösterilen karmaşıklık matrisi tablosu kullanılarak hesaplanmaktadır.

		Tahminlenen (Predicted)	
		Doğru Pozitif (DP)	Yanlış Negatif (YN)
Gerçekleşen (Actual)	Doğru Pozitif (DP)	Doğru Pozitif (DP)	Yanlış Negatif (YN)
	Yanlış Pozitif (YP)	Yanlış Pozitif (YP)	Doğru Negatif (DN)

Şekil 3.11 Karmaşıklık matrisi

Şekil 3.11’de yer alan Doğru Pozitif (DP), hastalığa sahip görüntünün test sonuçlarında hasta olarak tespit edildiğine, Doğru Negatif (DN) hastalığa sahip olmayan görüntünün test sonuçlarında sağlıklı olarak tespit edildiğine, Yanlış Pozitif (YP), hastalığa sahip görüntünün test sonuçlarında sağlıklı olarak tespit edildiğine ve Yanlış Negatif (YN), hastalığa sahip olmayan görüntünün test sonuçlarında hasta olarak tespit edildiği olarak tanımlanmasıdır.

DP, bireyin hasta olduğu ve test sonucunun pozitif olduğu hasta sayısını ifade etmektedir. YP, bireyin hasta olmadığı fakat test sonucunun pozitif olduğu hasta sayısını ifade etmektedir. DN, bireyin hasta olmadığı fakat test sonucunun negatif olduğu hasta sayısını ifade etmektedir. YN, bireyin hasta olduğu fakat testinin negatif olduğu hasta sayısını ifade etmek için kullanılmaktadır. DP, FP, DN, DP değişkenleri karmaşıklık matrisini oluşturarak doğruluk, kesinlik, duyarlılık ve F-1 skor değerlerinin hesaplanmasını sağlamaktadır.

Performans kıyaslaması için genellikle doğruluk değeri kullanılmaktadır. Doğruluk, modelde doğru tahmin edilen örnek sayısının toplam örnek sayısına oranıdır. Doğru tahmin sayısının toplam tahmin sayısına oranı olarak ifade edilmektedir. Doğruluk değeri, Denklem 3.3'te gösterildiği şekilde ifade edilmektedir.

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (3.3)$$

Kesinlik, modelde pozitif olarak tahmin edilen örneklerin doğruluğu olarak ifade edilir. Pozitif olarak tahmin edilip etiketlenen verilerin ağın çalışması esnasında gerçekte kaç tanesinin pozitif olarak tahmin edilen sınıfa ait olduğunu ifade etmektedir. Denklem 3.4'te matematiksel formülü gösterilmektedir.

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (3.4)$$

Duyarlılık, modelin test verileri üzerindeki doğruluğunu ifade etmektedir. Pozitif olması gereken verilerden kaçının pozitif tahmin edildiğini ifade etmektedir. Denklem 3.5'te matematiksel formülü gösterilmektedir.

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (3.5)$$

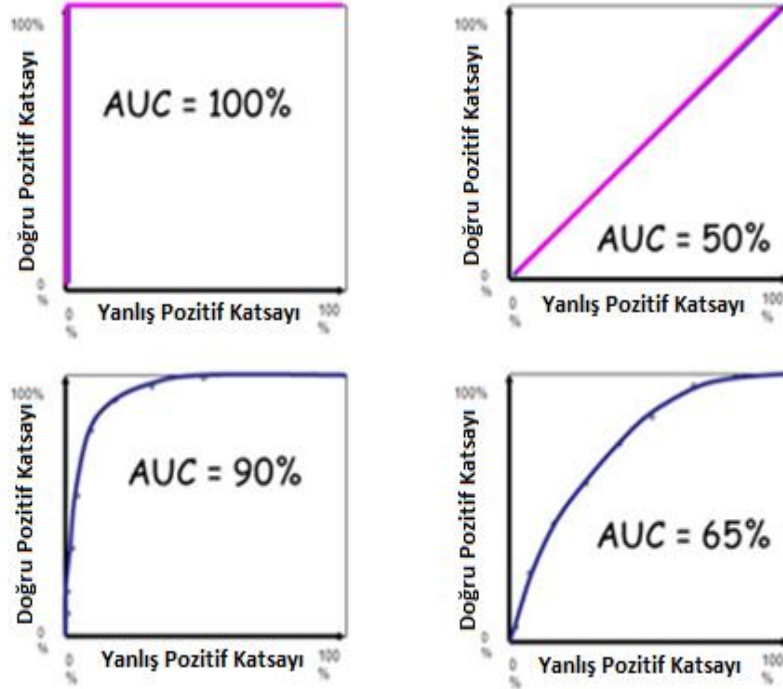
F1-skor, kesinlik ve duyarlılığın harmonik ortalamasıdır. Uç durumların göz ardı edilmemesi gerektiği için sıradan ortalama yerine harmonik ortalama kullanılmaktadır. Denklem 3.6'da matematiksel formülü gösterilmektedir.

$$F1 - \text{Score} = 2 * \frac{DP}{YN+YP+2*2} \quad (3.6)$$

### 3.7.1 Alıcı İşlem Karakteristiği Eğrisi

Alıcı İşlem Karakteristiği (AİK, Receiver Operating Characteristics (ROC)) eğrisi, hassasiyetin kesinliğe oranı ile hesaplanmaktadır. Sınıflandırma işlemi için yapılan modellerde, modelin performansını gösteren metrik olarak kabul edilmektedir. Değişken sınıflandırma eşik değerleri baz alınarak doğru pozitif sonuçların sayısının yanlış pozitif sonuçların sayısını fonksiyon olarak değerlendirilmesi olarak kabul edilir. AİK eğrisi altında kalan alan başarıyı ifade etmektedir. Günümüzde en yaygın kullanılan ölçütlerindendir.

Eğri altındaki alan (EAA, Area Under Curve (AUC)), AİK eğrisi altındaki alanı ifade etmektedir. Şekil 3.12' de verilen eğrilerde kapsanan alan ne kadar büyükse başarı o kadar yüksektir. Ağdan alınan performans o kadar yüksek kabul edilmektedir. AİK eğrisi altında kalan alan için ideal değer 1'dir.



Şekil 3.12 AİK eğrisinde EAA değerleri

EAA değerinin 1 olduğu grafik mükemmel sonucu ifade etmektedir. EAA değerinin 1 olması pozitif sonuçların negatif sonuçlardan tamamen ayrıldığı ve hatanın olmadığı durumları ifade etmektedir. EAA değerinin 0 olduğunda sonuçlarda pozitif sonucun olmadığını tüm sonuçların negatif olduğunu ifade etmektedir.

### 3.8 ResNet Ađı

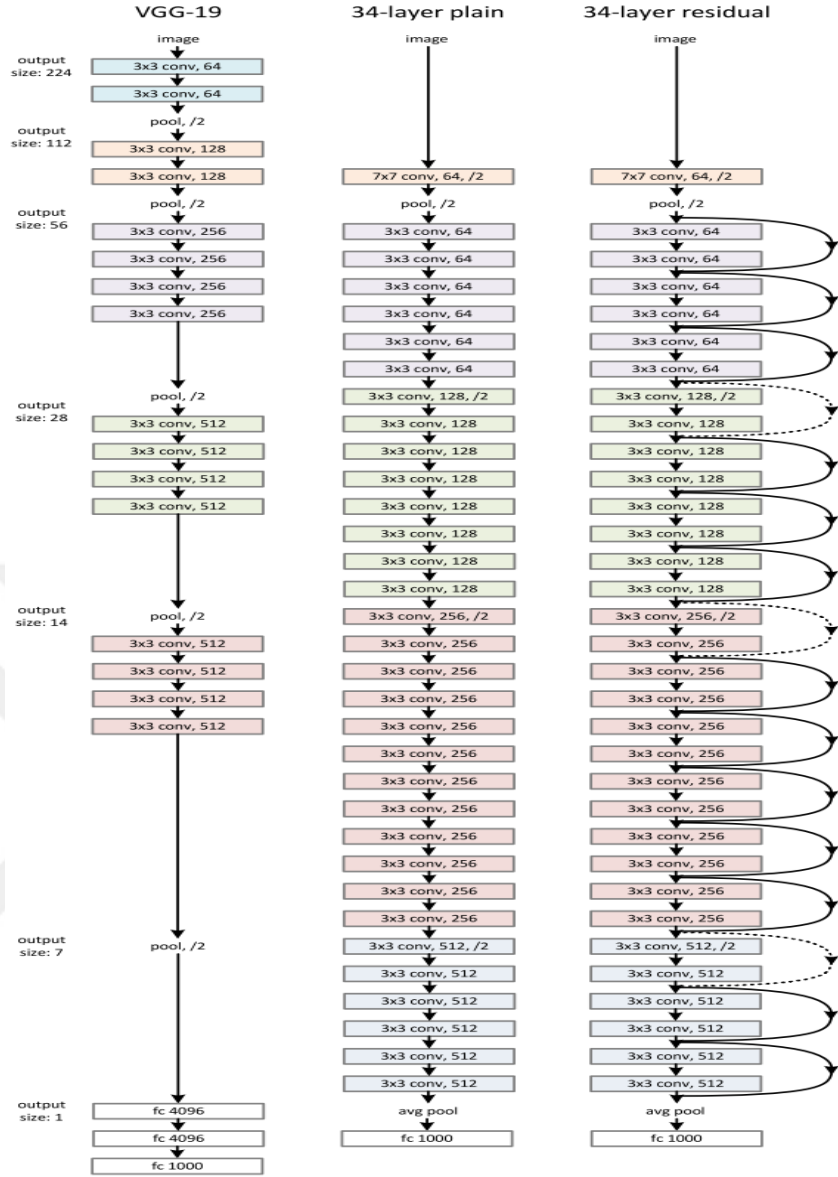
ResNet (Residual Neural Network) 2015 yılında Kaiming He, Xiangyu Zhang, Shaoqing Ren ve Jian Sun tarafından “Deep Residual Learning for Image Recognition” makalesinde tanıtılan belirli bir sinir ađı türüdür. ImageNet veri setinde VGG ađlarından daha derin 152 katman derinlikle %3,57 hata oranı ile ILSVRC 2015 sınıflandırmada birinci olmuştur. ILSVRC ve COCO2015 yarışmasında ImageNet algılama, ImageNet yerelleştirme, COCO algılama ve COCO bölütlemesinde (segmentasyonunda) yine birinci olmuştur. Diđer derin öğrenme mimarilerine göre katman sayısı daha fazladır. Artık ađ mimarisi olarak da isimlendirilmektedir. Eğitimde alınan hataları azaltma amacıyla çok sayıda katmana sahip artık bloklar kullanılmaktadır.

ResNet mimarisi iki ana tasarım ilkesine uymaktadır. Birinci ilkesi, çıktı özellik haritasının boyutuyla orantılı olarak her katmanda kullanılan filtre sayısı aynı olmaktadır. İkinci ilkesi, özellik haritasını boyutu hangi oranda azalırsa, tüm katmanlar zaman karmaşıklığına karşı engel olmak için filtre sayısını aynı oranda artırmaktadır.

ResNet ađı, VGG19 mimarisinden esas alınarak VGG ađlarından daha az filtreye ve daha düşük karmaşıklığa sahip 34 katmanlı düz bir ađ mimarisi kullanır. Daha sonra bu düz ađa atlama bağlantıları veya artık bloklar eklenerek mimari artık ađa dönüştürülür.

Şekil 3.13’te referans olarak alınan VGG19 modelini, ortada 34 parametre katmanına sahip düz bir ađı ve sağda 34 parametre katmanına sahip artık ađ modelini gösterilmektedir. Model, VGG ađlarından daha az filtreye ve daha düşük karmaşıklığa sahiptir. 34 katmanlı model, VGG-19’un (19,6 milyar FLOP) yalnızca %18’i olan 3,6 milyar FLOP’a (çarpma-ekleme) sahiptir.

ResNet ađ mimarisinin katman yapısı diđer ađ yapılarına göre daha kompleks yapıda tasarlanmıştır. ResNet ađı, VGG-19 mimarisi referans alınarak VGG ađlarına göre daha az filtre ve daha az karmaşıklık ile 34 katmanlı düz ađ mimarisi bağlantı ve blokların eklenmesiyle ađa dönüşüm sağlar.




Şekil 3.13 ResNET ağ mimarisi

### 3.9 ResNet50

Şekil 3.14' de gösterilen darboğaz yapısı, Residual Neural Network (Artık Ağ) yani ResNet50, ImageNet veri kümesi üzerinde eğitilmiş 50 katmanlı, 2 adet (3x3) evrişim yerine (1x1), (3x3) ve (1x1) şeklinde 3 katman darboğaz kullanır.


ResNet50, VGG16 ve VGG19 ağından çok daha derin olsa da ResNet50 için model boyutu 102 MB'a indiren tam bağlantılı katmanlar yerine global ortalama havuz kullanımı nedeniyle model boyutu aslında önemli ölçüde daha küçüktür (Rosebrock, 2017).

ImageNet Large Scale Visual Recognition Challenge (ILSVRC 2015) yarışmasında veri kümesi üzerinde eğitimi tamamlanmış 50 gizli katman ve 23 milyondan fazla eğitilebilir parametreye sahip evrişimli bir ağıdır (He vd., 2016).



Şekil 3.14 ResNet50 için darboğaz yapısı

ResNet iki adet 3x3'lük evrişim katmanı yerine 1x1, 3x3 ve 1x1'lik evrişim katmanları kullanır. Bu mimari giriş boyutu olarak 224x224 piksellik görüntüler ve 3x3 filtreler kullanır. Şekil 3.15'te ResNet50 mimarisinin katman yapısını gösterilmektedir.




Şekil 3.15 ResNet50 ağ mimarisi

### 3.10 VGG16

VGG16, Oxford Üniversitesi'ndeki Visual Geometry Group tarafından geliştirilen bir CNN mimarisidir (Faisal vd., 2021). 2014 yılında ImageNet yarışmasını kazanmak için kullanılmıştır. VGG16, 1 adımlı on üç evrişimli  $3 \times 3$  filtre katmanından oluşur. 2 adımlı  $2 \times 2$  filtrenin aynı dolgusunu ve maksimum havuz


katmanını kullanır. Mimari boyunca bu evrişim düzenini ve maksimum havuz katmanlarını korur. Son olarak, tamamen bağlantılı iki katmana ve bir çıktı katmanına sahiptir. Ağ, 1000 sınıfla 1,2 milyon görüntü üzerinde eğitilmiştir. Şekil 3.16'da VGG16 mimarisine ait modelleme bulunmaktadır.



Şekil 3.16 VGG16 ağ mimarisi

### 3.11 VGG19

Oxford Üniversitesi Visual Geometry Group isimli grup ve 19 katman sayısının harmanlanması ile VGG19 ismini alan ağ, 16 convolution, 3 layer, 5 MaxPool, 1 SoftMax katmanından oluşmakta olup Relu aktivasyon fonksiyonları ile tanımlı derin öğrenme ağ modelidir. 19,6 milyar flop bulunmaktadır. VGG19 ImageNet veri seti ile eğitilerek her katmanda birden fazla 3x3 filtre kullanılarak modellenen en popüler ESA ağlarından biridir. Özellik çıkarma işlemi için 16 evrişim katmanı ve 3 sınıflandırma katmanı bulunmaktadır. Giriş verisi boyutu 224x224 olmaktadır. Şekil 3.17'de VGG19 mimarisine ait modelleme gösterilmektedir.




Şekil 3.17 VGG19 ağ mimarisi

### 3.12 DenseNet

Densely Connected Convolutional Network (Yoğun Bağlı Evrişimli Sinir Ağları), ileri beslemeli şekilde katmanlar arası bağlantı sağlar. Kayıp gradyan azalır, parametre sayısı oldukça azalır, özellik kullanımını devamlı kullanılır hale getirir,


özelliik yayılımını güçlendirir. Girdiye yakın katmanlar ile çıktıya yakın katmanlar arası kısa bağlantılı olması ESA'ya göre daha derin, doğru ve verimli eğitim olması için tasarlanıp çalışmasına olanak sağlamaktadır.

Şekil 3.18'de standart ağ, giriş verilerine ile çoklu evrişim uygulanır ve maksimum düzeyde özellikler elde edilir.



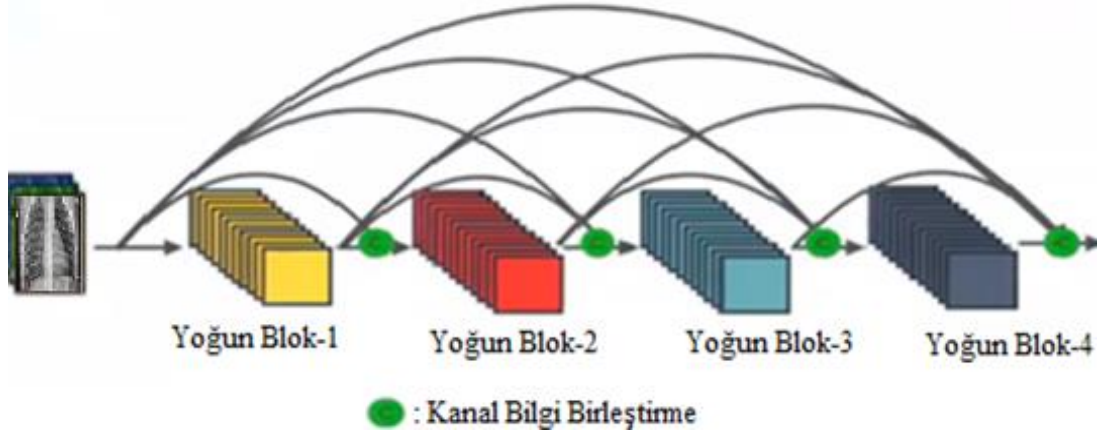
Şekil 3.18 Standart ESA yapısı

ResNet ağında gradyan yayılımı destekleme işlemi, kimlik eşleşmesi önerilip, eleman toplama ile sağlanabilir. Bu durum Şekil 3.19'de gösterildiği gibi ResNet ağından diğer ağlara geçiş yapan bir algoritma olarak görülebilmektedir.



Şekil 3.19 Yoğun DenseNet element ekleme yapısı

DenseNet mimarisinde her katman kendisinden önceki tüm katmanların özelliklerini girdi olarak kullanır ve katmandaki kendi özellikleri sonraki katmanlara girdi olarak verilir. DenseNet mimarilerinin avantajı, özellik yayılımı sağlaması ve özelliklerin yeniden kullanılmasına izin vererek parametre sayısını azaltmasıdır. Şekil 3.20'da gösterildiği gibi her katman önceki katmanın bilgileri ile işleme girmektedir.



Şekil 3.20 Yoğun DenseNet blok yapısı

## 4. BULGULAR

### 4.1 Kullanılan Materyal

Bu çalışmada kullanılan bilgisayar 12.nesil i7 işlemcili, 2.30GHz, Windows11, 512gb SSD ve 16gb sistem belleğine sahiptir. Kodlama esnasında Python 3.10 sürümü kullanılıp, virtual environment sanal ortamında, derleyici olarak Visual Studio Code tercih edilmiştir.

VGG16, VGG19, DenseNet ve ResNet50 mimarileri için kodlama yapıp sonuçlar sınıflandırma modelleri için başarımleri ile değerlendirilmiştir.

### 4.2 VGG16 Mimarisi Sonuçları


VGG16 mimarisi için eğitim (train) için doğruluk ve kayıp oranları, doğrulama (validation) için doğruluk ve kayıp oranları, test (test) için doğruluk ve kayıp oranları yapılan çalışmalar sonucunda elde edilen eğitim-doğrulama-test verilerine ait doğruluk ve kayıp oranları Tablo 4.1’de gösterilmiştir.

Eğitim verilerinde %91 doğruluk ve %15 kayıp elde edilmiştir. Doğrulama verilerinde %83 doğruluk ve %32 kayıp elde edilmiştir. Test verilerinde %90 doğruluk ve %18 kayıp elde edilmiştir. Elde edilen en yüksek doğruluk oranı %91 değeridir.

Tablo 4.1 VGG16 verilerin doğruluk ve kayıp oranları

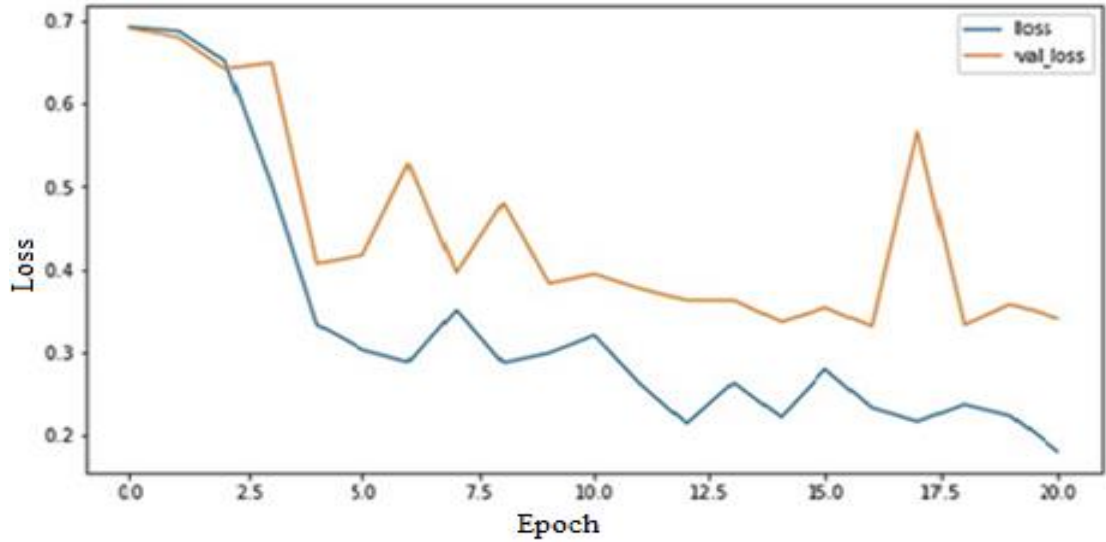
	<b>Eğitim</b>	<b>Doğrulama</b>	<b>Test</b>
<b>Doğrululuk</b>	%91	%83	%90
<b>Kayıp</b>	%15	%32	%18

Şekil 4.1’de verilen epoch (eğitim turu) sayıları bazında model doğruluk başarı grafiğinde, VGG16 modelinde elde edilen deneysel sonuçlar doğruluk grafiği için altta kalan alan ne kadar büyükse başarımın o kadar yüksek olacağı bilinmektedir.



Şekil 4.1 VGG16 başarı grafiği

Şekil 4.2’de verilen grafikte, VGG16 mimarisi tasarımı sonucu elde edilen loss ve val\_loss grafikleri mevcuttur. Kayıp grafiği değerlendirilirken altta kalan alana bakılmaktadır. Kayıp grafiği için altta kalan alan ne kadar küçükse hata-kayıp o kadar azalmaktadır.



Şekil 4.2 VGG16 kayıp grafiği

Karmaşıklık matrisinden faydalanarak hesaplanan doğruluk, duyarlılık, f1-skor, kesinlik sonuçları Tablo 4.2’de gösterilmiştir.

Tablo 4.2 VGG16 başarımlık metrikleri

	Doğruluk	Duyarlılık	F-1 Skor	Kesinlik
<b>VGG16</b>	%92	%86	%91	%89


### 4.3 VGG19 Mimarisi Sonuları

VGG19 mimarisi için eğitim, doğrulama ve test verileri için doğruluk ve kayıp değeri Tablo 4.3'te gösterilmiştir. Eğitim verilerinde %96 doğruluk ve %15 kayıp, doğrulama verilerinde %86 doğruluk ve %28 kayıp, test verilerinde ise %94 doğruluk ve %13 kayıp tespit edilmiştir.

Tablo 4.3 VGG19 verilerin doğruluk ve kayıp oranları


	Eğitim	Doğrulama	Test
<b>Doğruluk</b>	%96	%86	%94
<b>Kayıp</b>	%15	%28	%13

Şekil 4.3'te verilen doğruluk grafiğinde VGG16 mimarisinin kodlanması sonucu elde edilen grafikte altta kalan alan ne kadar büyükse başarı o kadar yüksek kabul edilmektedir.



Şekil 4.3 VGG19 doğruluk grafiđi

Şekil 4.4'te verilen VGG19 mimarisi sonucu elde edilen kayıp grafiğinde altta kalan alan ne kadar küçükse hata-kayıp o kadar az kabul edilmektedir.



Şekil 4.4 VGG19 kayıp grafiği

Karmaşıklık matrisinden faydalanarak hesaplanan doğruluk, duyarlılık, f1-skor, kesinlik sonuçları Tablo 4.4'te gösterilmiştir.

Tablo 4.4 VGG19 başarımleri

	Doğruluk	Duyarlılık	F-1 Skor	Kesinlik
<b>VGG19</b>	%97	%89	%93	%91


#### 4.4 DenseNet Mimarisi Sonuçları

DenseNet mimarisi için eğitim, doğrulama ve test verileri için doğruluk ve kayıp değerleri Tablo 4.5'te gösterilmiştir. Eğitim verilerinde %93 doğruluk ve %13 kayıp, doğrulama verilerinde %87 doğruluk ve %29 kayıp, test verilerinde ise %89 doğruluk ve %17 kayıp tespit edilmiştir.

Tablo 4.5 DenseNet verilerin doğruluk ve kayıp oranları

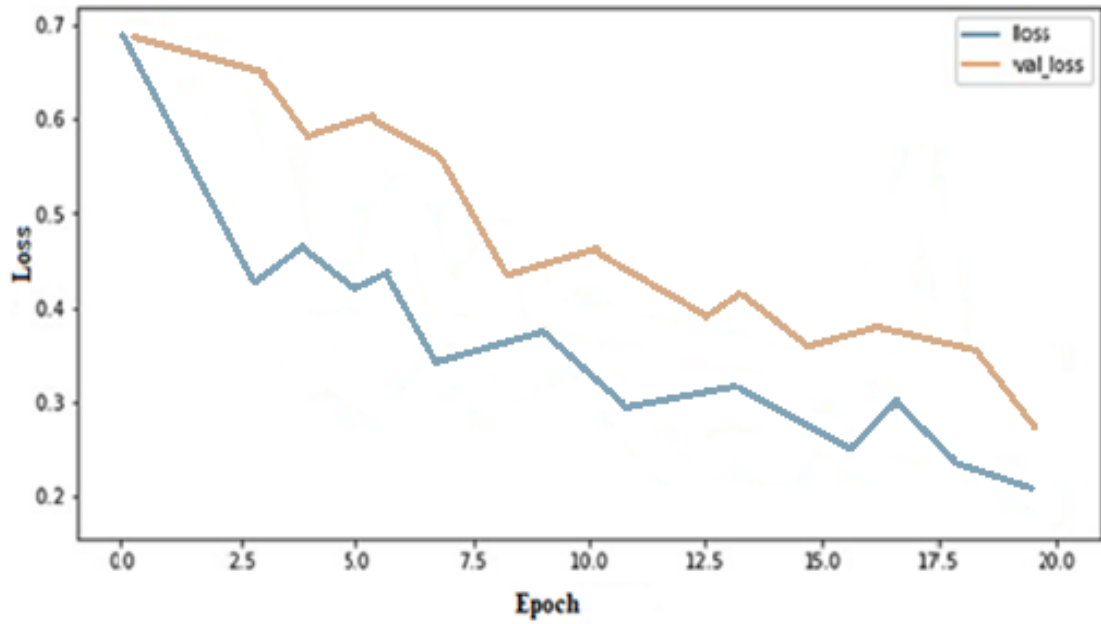
	Eğitim	Doğrulama	Test
<b>Doğruluk</b>	%93	%87	%89
<b>Kayıp</b>	%13	%29	%17

Şekil 4.5'te verilen DenseNet mimarisinin kodlanması sonucu elde edilen doğruluk grafiğinde altta kalan alan ne kadar büyükse başarı o kadar yüksek kabul edilmektedir.



Şekil 4.5 DenseNet doğruluk grafiği

Şekil 4.6'da verilen DenseNet mimarisi sonucu elde edilen kayıp grafiğinde altta kalan alan ne kadar küçükse hata-kayıp o kadar az kabul edilmektedir.



Şekil 4.6 DenseNet kayıp grafiği

Karmaşıklık matrisinden faydalanarak hesaplanan doğruluk, duyarlılık, f1-skor, kesinlik sonuçları Tablo 4.6’de gösterilmiştir.

Tablo 4.6 DenseNet başarımları metrikleri

	<b>Doğruluk</b>	<b>Duyarlılık</b>	<b>F-1 Skor</b>	<b>Kesinlik</b>
<b>DenseNet</b>	%95	%88	%94	%89

#### 4.5 ResNet50 Mimarisi Sonuçları

ResNet50 için kodlama esnasında tüm veri seti için epoch değeri 20, lr\_init değeri  $3 \cdot 10^{-2}$  ve Bs 32 olarak kaydedilerek en iyi sonuçlara ulaşılmıştır. ResNet50 Ağ işlemleri ve grafikleri oluşturmak için geçen toplam süre 6 saat 17 dk yani 377 dakikadır. Başarımları metrikleri doğruluk, duyarlılık, F-1 skor, Kesinlik değerleri Tablo 4.7’de verilmiştir. Kesinlik değeri, doğru pozitif sayısının doğru pozitif ve yanlış pozitif sayının toplamına bölünmesi ile elde edilmektedir. Kesinlik gerçekte kaç değer pozitif sonuç verdiğini ifade etmektedir. Duyarlılık değeri, doğru pozitif sayısını doğru pozitif ve yanlış negatif sayısının toplamına bölünmesi ile elde edilmektedir. Maliyetin yüksek olduğu durumlarda katkı sağlayacak bir metrik olduğu gibi alabileceği en yüksek değeri alması gerekmektedir. F-1 skor kesinlik ve duyarlılığın harmonik ortalaması olarak değerlendirilmektedir. Doğruluk değeri yerine F-1 skor değerinin önemsenmesi ve kullanılmasının sebebi eşit dağılıma sahip olmayan veri kümelerinin uygun olmayan model seçimi yapılmasının engellenmesi istenmesidir. F-1 skor bütün hata maliyetlerinin belirlenmesi için kullanılan metriktir.

Tablo 4.7 ResNet50 başarımları metrikleri

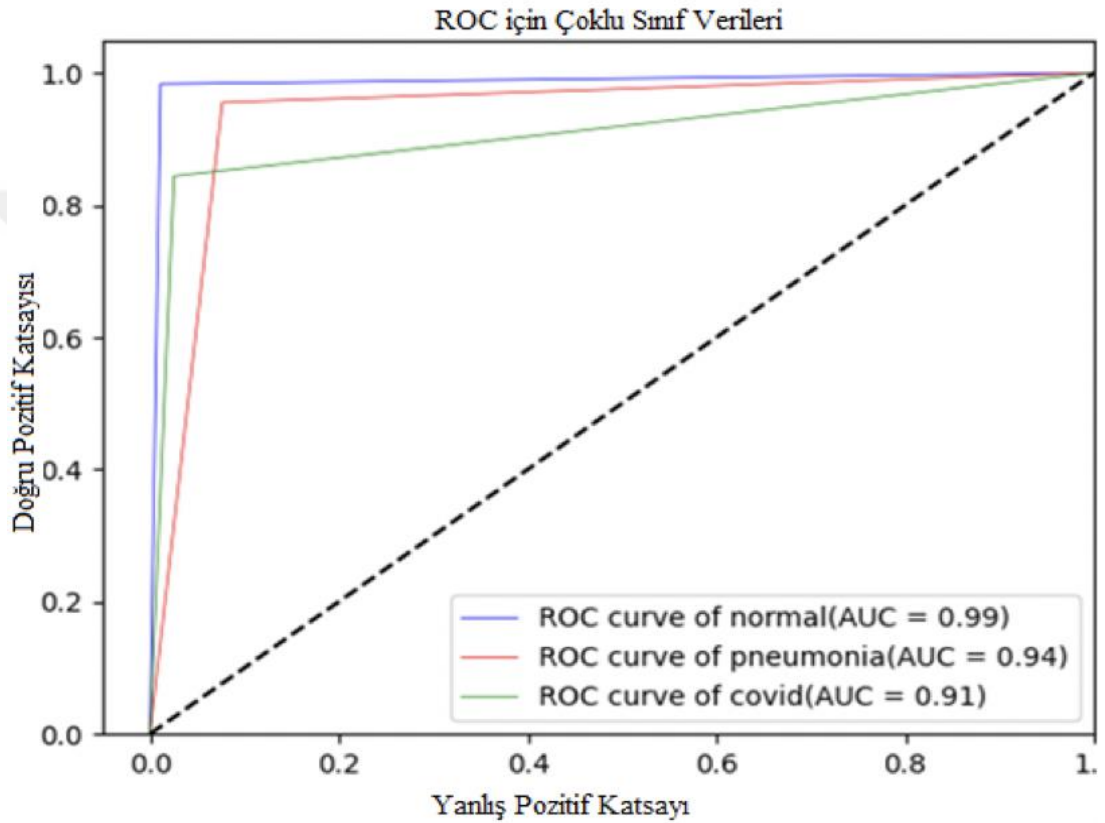
	<b>Doğruluk</b>	<b>Duyarlılık</b>	<b>F-1 Skor</b>	<b>Kesinlik</b>
<b>ResNet50</b>	%97	%98	%97	%92

##### 4.5.1 Röntgen Görüntülerine Yönelik Sonuçlar

ResNet50 ağı ile kodlanan programda Eğitim doğrulama ve test sonuçlarına yönelik çıktılar alınmıştır. Pneumonia akciğer röntgen görüntülerinin ResNet50 ağına

verilmesi sonucu elde edilen ROC eğrisi grafiği sonuçlarına göre hesaplanan ROC eğrisi altında kalan alan %94 olarak kaydedilmiştir.

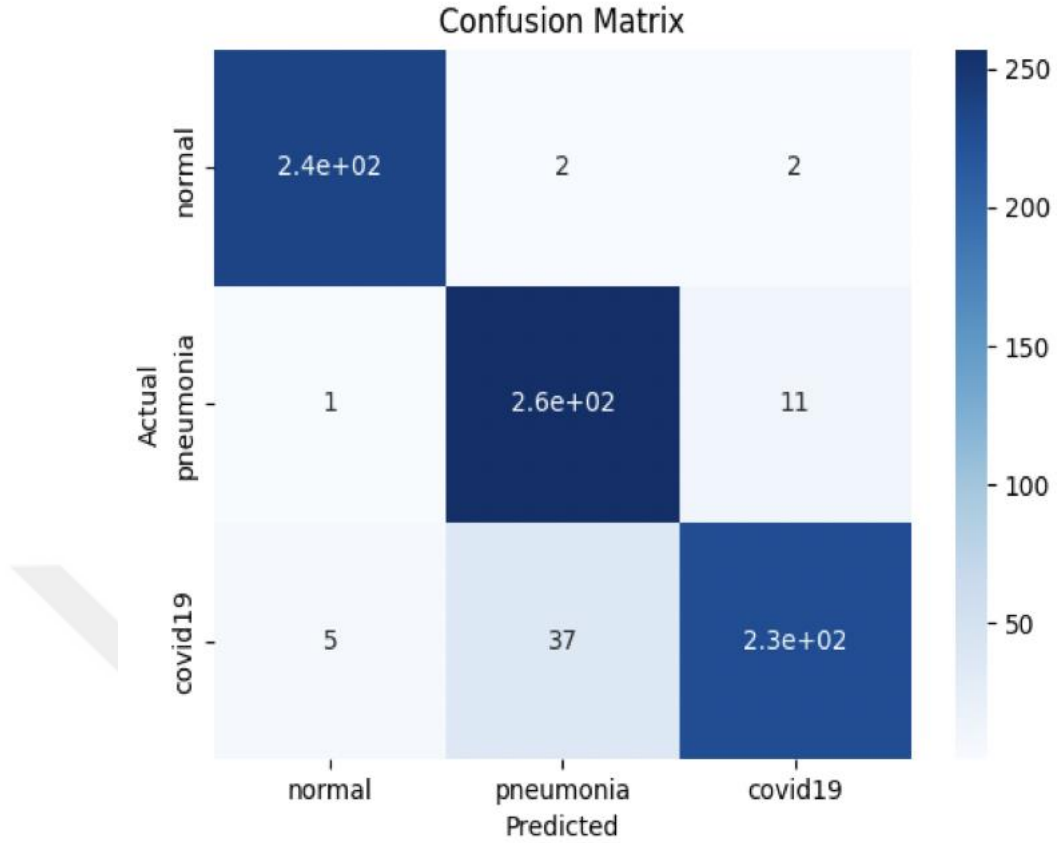
Covid-19 akciğer röntgen görüntülerinden elde edilen ROC eğrisi grafiği sonuçlarına göre hesaplanan ROC eğrisi altında kalan alan %91 olarak kaydedilmiştir. Şekil 4.7'de ROC eğrisi çalışmanın başarısı hakkında başarılı sonuçlar vermiştir.



Şekil 4.7 ResNet50 ROC eğrisi

Karmaşıklık matrisi makine öğrenimi alanında istatistiksel sınıflandırmada hata matrisi olarak bilinen bir karışıklık matrisidir. Algoritmanın performansını görsel olarak sunan bir tablodur.

ResNet50 ağından alınan sonuçta ise Doğru Pozitif, Yanlış Pozitif, Doğru Negatif, Yanlış Negatif değerlerini normal, pneumonia ve Covid-19 akciğer görüntülerini sınıflandırdıktan sonra karmaşıklık matrisine yerleştirilmiştir. Şekil 4.8'de karmaşıklık matrisi gösterilmiştir. Verilerin test verisi olarak 240 tanesi Covid-19, 269 tanesi normal, 269 tanesi pneumonia olarak ağıdan çıkışları alınmıştır.



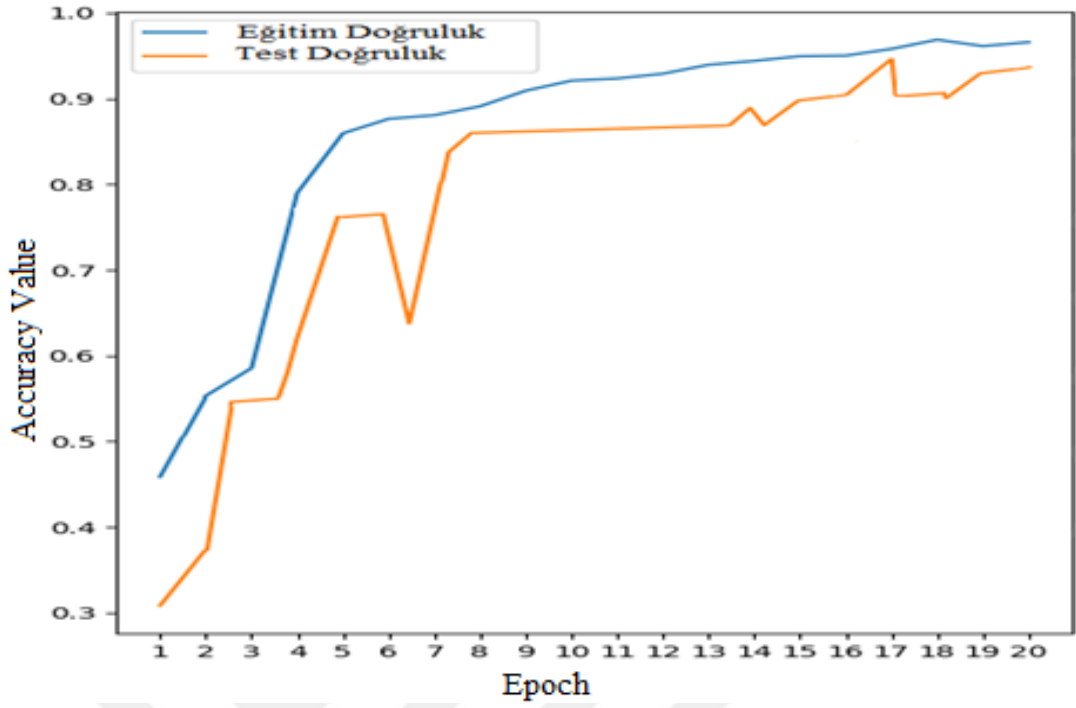
Şekil 4.8 Karmaşıklık matrisi

ResNet50 mimarisi için eğitim (train), doğrulama (validation) ve test (test) verileri için doğruluk ve kayıp değerleri Tablo 4.8’de gösterilmiştir. Eğitim verilerinde %96 doğruluk ve %11 kayıp, doğrulama verilerinde %86 doğruluk ve %17 kayıp, test verilerinde ise %97 doğruluk ve %09 kayıp tespit edilmiştir. Doğruluk değeri için 1 değeri mükemmel kabul edilmektedir. Kayıp değeri için mükemmel değer 0 kabul edilmektedir.

Tablo 4.8 ResNet50 Verilerin doğruluk ve kayıp oranları


	<b>Eğitim</b>	<b>Doğrulama</b>	<b>Test</b>
<b>Doğruluk</b>	%96	%86	%97
<b>Kayıp</b>	%11	%17	%9

Şekil 4.9’da gösterilen grafikte, eğitim performans metriklerinde eğitim doğruluk ve test doğruluk verileri için başarı, kayıp ve epoch değerleri görülmektedir.



Şekil 4.9 Doğruluk grafiği

Şekil 4.10'da verilen grafikte, eğitim kayıp, test kayıp değerleri için veri grafiği (kayıp grafiği), altta kalan alan ne kadar küçükse hata o kadar düşük kabul edilmektedir.



Şekil 4.10 Kayıp grafiği

## 5. SONUÇ VE ÖNERİLER

Covid-19 tespitinde akciğer röntgen veya BT görüntüleri çok sık kullanılmaktadır. Hasta ile temasın en aza indirildiği bu yöntemde sağlık çalışanlarının güvenliği de sağlanmıştır.

Bu görüntüleri sinir ağları ile tespiti birçok konuda kolaylık sağlayacağı düşünüldüğü için bu çalışma yapılmıştır. Çalışmada Tawsifur ve ekibinin hazırladığı 256x256px boyutunda akciğer röntgen görüntülerinden oluşan veri seti kullanılmıştır. Önerilen modeller, göğüs röntgeni görüntülerini sınıflandırmada etkinliğini ve doğruluğunu sağlamak için çeşitli mimariler üzerinde eğitildi ve test edildi. Bu veri seti ResNet50, VGG19, VGG16 ve DenseNet ağlarında işleme tabi tutulmuş, ResNet50, VGG16, VGG19 ve DenseNet ağ mimarileri performans metrikleri de değerlendirilmiş ve sonuç olarak ResNet50 ağının %97 f1-score değeri ile bu dört ağ içerisinde en yüksek başarı verdiği gözlemlenmiştir.

Çalışma genel olarak değerlendirildiğinde Covid-19 tespitinde akciğer röntgen görüntüleri ResNet50 ağı ile işlendiğinde, giriş ve ara katman nöron sayıları, epoch değeri ile ilgili kombinasyonlar denendi ve en uygun sayısal değerler bulunarak sonuç çıktısı %91 ile %99 arasında stabil hale getirildi. Hastaların röntgen görüntüleri rastgele şekilde ağ tarafından işlendiğinde yüksek başarı elde edileceği belirlenmiştir.

Bu çalışmada modellenen ağların her birinde başarı elde edilmiştir. Daha fazla veri toplanarak çalışıldığında ve modellenen ağlar üzerinde hassas çalışma yapıldığında daha yüksek başarı elde edileceği öngörülmektedir. Derin sinir ağları kullanılarak, sağlık alanında hastalık tespiti için sağlık çalışanlarına olan ihtiyacı minimuma indirildiği bilgisayarlı sistemlerle hastalık tespitinin daha kolay olacağı öngörülmektedir. Bu alanda çalışmalar desteklendiği takdirde teorikte olduğu gibi pratikte de başarı elde edilecektir.

## KAYNAKLAR

- Abadi, M., Barham, P., Chen, J., Chen, Z., vd. (2016). Tensorflow: A system for large-scale machine learning. 12th USENIX symposium on Operating Systems Design and Implementation, 265-283.
- Abbas, A., Abdelsamea, M. M., & Gaber, M. M. (2021). Classification of Covid-19 in chest X-ray images using DeTraC deep convolutional neural network. *Application Intelligence*, 51, 854-864.
- Antin, B., Kravitz, J., & Martayan, E. (2019). Detecting pneumonia in Chest X-Rays with supervised learning. *Semanticscholar*, <https://pdfs.semanticscholar.org/>, ErişimTarihi: 07/05/2017.
- Anthimopoulos, M., Christodoulidis, S., Ebner, L., Christe, A., & Mougiakaou, S. (2016). Lung pattern classification for interstitial lung diseases using a deep convolutional neural network. *IEE Transactions on Medical Imaging*, 35(5), 1207-1216.
- Apostolopoulos, I. D., & Mpesiana, T. A. (2020). Covid-19: Automatic detection from X-ray images utilizing transfer learning with convolutional neural networks. *Physical and Engineering Sciences in Medicine*, 43, 635–640, <https://doi.org/10.1007/s13246-020-00865-4.ical>.
- Ayan, E., & Ünver, H. M. (2019). Diagnosis of pneumonia from chest X-Ray images using deep learning. 2019 Scientific Meeting on Electrical Electronics and Biomedical Engineering and Computer Science (EBBT), Istanbul, Turkey, 1-5.
- Bozkurt (2021). Derin öğrenme tekniklerini kullanarak akciğer X-Ray görüntülerinden Covid-19 tespiti. *European Journal of Science and Technology Special*, 24(2), 149-156.
- Cansdale, A. (2021). How exploring Python can level up your data visualizaiton. *Biochemist*, 43(5).
- Charbonnier, J. P., Rikxoort, E. M. va., Setio, A. A. A., Schaefer-Prokop, C. M., Ginneken, B. van, & Ciompi, F. (2017). Improving airway segmentation in computed tomography using leak detection with convolutional networks. *Medical Image Analysis*, 36, 52–60. <https://doi.org/10.1016/j.media.2016.11.001>.
- Chen, C., Lee, Y., Huang, Y., Lan, W., Chang, R., Tu, C., Chen, C., & Liao, W., 2019, Computer-aided diagnosis of endobronchial ultrasound images using convolutional neural network. *Computer Methods and Programs in Biomedicine*, 177, 175-182.
- Chowdhury, M. E. H., Rahman, T., Khandakar, A., Mazhar, R., Kadir, M. A., Mahbub, Z. B., Islam, K. R., Khan, M. S., Iqbal, A., Al-Emadi, N., Reaz, &

- M.B.I., Islam, M. T. (2020). Can AI help in screening Viral and COVID-19 pneumonia? *IEEE Access*, 8, 132665-132676.
- Ciampi, F., de Hoop, B., van Riel, S. J., Chung, K., Scholten, E. T., Oudkerk, M., de Jong, P. A., Prokop, M., & van Ginneken, B. (2015). Automatic classification of pulmonary peri-fissural nodules in computed tomography using an ensemble of 2D views and a convolutional neural network out-of-the-box. *Medical Image Analysis*, 26(1), 195-202.
- Da Silva, S. J. R., Silva, C. T. A. Da Guarines, K. M., Mendes, R. P. G., Pardee, K., Kohl, A., & Pena, L. (2020). Clinical and laboratory diagnosis of SARS-CoV-2, the virus causing COVID-19. *ACS Infectious Diseases*, 6(9), 2319-2336.
- Deepak, S., & Ameer, P. (2019). Brain tumor classification using deep CNN features via transfer learning. *Computers in Biology and Medicine*, 111, 103345.
- Dou, Q., Chen, H., Yu, L., Qin, J., & Heng, P. A. (2017). Multilevel contextual 3-D CNNs for false positive reduction in pulmonary nodule detection. *IEEE Transactions on Biomedical Engineering*, 64(7), 1558–1567.
- Faisal, A., Dharma, T. N. A., Ferani, W., Widi, P. G., & Rizka, S. F. (2021). Comparative study of VGG16 and MobileNetv2 for masked face recognition. *J. Ilm. Tek. Elektro Komput.* 7, 230–237. doi: 10.26555/jiteki.v7i2.20758.
- Gifani, P., Shalhaf, A., & Vafaezadeh, M. (2021). Automated detection of COVID-19 using ensemble of transfer learning with deep convolutional neural network based on CT scans. *International Journal of Computer Assisted Radiology and Surgery*, 16(1), 115–123.
- Goldberg, D. E., & Holland, J. H. (1988). Genetic algorithms and machine learning. *Machine Learning*, 3, 95-99.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <http://www.deeplearningbook.org>.
- Hafeez, A., & Sial, A. H. (2021). Comparative analysis of data visualization libraries Matplotlib and Seaborn in Python. *International Journal of Advanced Trends in computer Science and Engineering*, 10(1), 277-281.
- Hares, J. D. (1981). A simple CW X-ray source for laser plasma X-ray diagnostic alignment. *Journal of Physics E: Scientific Instruments*, 14(11).
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 770-778.
- Hinton, G., Deng, L., Yu, D., Dahl, G. E., Mohamed, A. R., Jaitly, N., & Kingsbury, B. (2012). Deep neural networks for acoustic modeling in speech recognition: The shared views of four research groups. *IEEE Signal Processing Magazine*, 29(6), 82-97.

- Hosseini-Asl, E., Ghazal, M., Mahmoud, A., Aslantas, A., Shalaby, A., Casanova, M., Barnes, G., Gimel'farb, G., Keynton, R., & Baz, A. El. (2018). Alzheimer's disease diagnostics by a 3D deeply supervised adaptable convolutional network. *Frontiers in Bioscience-Landmark*, 23(3), 584–596. <https://doi.org/10.2741/4606>.
- Jain, R., Gupta, M., & Taneja, S. (2021). Deep learning based detection and analysis of COVID-19 on chest X-ray images. *Applied Intelligence*, 51, 1690-1700. <https://doi.org/10.1007/s10489-020-01902-1>.
- Jain, R., Nagrath, P., Kataria, G., Sirish Kaushik, V., & Jude Hemanth, D., (2020), Pneumonia detection in chest X-ray images using convolutional neural networks and transfer learning. *Measurement*, 165, 108046.
- Kahlert, T., & Giza, K. (2016). Visual studio code tips & tricks. Microsoft, Deutschland GmbH.
- Ker, J., Wang, L., Rao, J., & Lim, T. (2017). Deep learning applications in medical image analysis. *IEEE Access*, 6, 9375-9379.
- Keras (2022). Keras & TensorFlow2, Erişim Tarihi: 10/01/2022.
- Kieu, P. N., Tran, H. S., Le, T. H., Le, T., & Nguyen, T. T. (2018). Applying multi-cnns model for detecting abnormal problem on chest X-Ray images. 10th International Conference on Knowledge and Systems Engineering.
- Kogilayani, S. V., Prabhu, J., Sandhiya, R., Kumar, M. S., Subramaniam, U. S., Karthick, A., Muhibbullah, M., & Imam, S. B. S. (2022). COVID-19 detection based on lung CT scan using deep learning techniques. *Computational and Mathematical Methods in Medicine*, 2022.
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444.
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278-2323.
- Liu Y., Gayle A. A., Wilder-Smith A., & Rocklov J. (2020). The reproductive number of COVID-19 is higher compared to SARS coronavirus. *Journal of Travel Medicine*, 27(2).
- Loey, M., Manogaran, G., & Khalifa, N. E. M. (2020). A deep transfer learning model with classical data augmentation and CGAN to detect COVID-19 from chest CT radiography digital images. *Neural Computing and Applications*, 0123456789.
- Louati, H., Bechikh, S., Louati, A., & Hung, C.-C. (2021). Deep convolutional neural network architecture design as a bi-level optimization problem. *Neurocomputing*, 439(2).

- Mahmud, T., Rahman, M. A., & Fattah, S. A. (2020). CovXNet: A multi-dilation convolutional neural network for automatic COVID-19 and other pneumonia detection from chest X-ray images with transferable multi-receptive feature optimization. *Computers in biology and medicine*.
- Narin, A., Kaya, C., & Pamuk, Z. (2020). Automatic detection of coronavirus disease (COVID-19) using x-ray images and deep convolutional neural networks. *ArXivPreprint ArXiv:2003.10849*.
- NumPy (2023). Numpy documentation. <https://numpy.org/>, Erişim Tarihi: 13/10/2022.
- Ohata, E. F., Bezerra, G. M., Chagas, J. V. S., Neto, A. V. L., Albuquerque, A. B., Albuquerque, V. H. C., & Filho, P. P. R. (2021). Automatic detection of COVID-19 infection using chest X-ray images through transfer learning. *IEEE/CAA Journal of Automatica Sinica*, 8(1), 239-248.
- Pitts, W., & McCulloch, W. S. (1943). A logical calculus of the ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5.
- Rubin, J., Sanghavi, D., Zhao, C., Lee, K., Qadir, A., & Xu-Wilson, M. (2018). Large scale automated reading of frontal and lateral chest X-Rays using dual convolutional neural networks. *Computer Vision and Pattern Recognition*.
- Rosebrock, A. (2017). Deep learning for computer vision with Python starter bundle. *PyimageSearch*.
- Shah, V., Keniya, R., Shridharani, A., Punjabi, M., Shah, J., & Mehendale, N. (2021). Diagnosis of COVID-19 using CT scan images and deep learning techniques. *Emergency Radiology*, 28(3), 497–505.
- Shen, W., Zhou, M., Yang, F., Yang, C., & Tian, J. (2015). Multi-scale convolutional neural networks for lung nodule classification. *International Conference on Information Processing in Medical Imaging*.
- Shin, H.-C., Roth, H. R., Gao, M., Lu, L., Xu, Z., Nogues, I., Yao, J., Mollura, D., & Summers, R. M. (2016). Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning. *IEEE Transactions on Medical Imaging*, 35(5), 1285-1298.
- Siar, M., & Teshnehlab, M. (2019). Brain tumor detection using deep neural network and machine learning algorithm. 9th International Conference on Computer and Knowledge Engineering, Mashhad, Iran, 2019, 363-368
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *The Journal of Machine Learning Research*. 15(1), 1929-1958.

- Talo, M. (2019). Pneumonia detection from radiography images using convolutional neural networks. *27th Signal Processing and Communications Applications Conference (SIU)*, Sivas, Turkey, 2019, 1-4.
- Tarando, S. R., Fetita, C., Faccineto, A., & Brillet, P. Y. (2016). Increasing CAD system efficacy for lung texture analysis using a convolutional network. *Medical Imaging 2016: Computer-Aided Diagnosis*.
- Tsung, C. L., & Hsi, C. L. (2020). Covid-19 chest radiography images analysis based on integration of image preprocess, Guided Grad-CAM, machine learning and risk management. *4th International Conference on Medical and Health Informatics*. Association for Computing Machinery, New York, NY, USA, 281-288. <https://doi.org/10.1145/3418094.3418096>.
- Urey, D. Y., Saul, C. J., & Taktakoglu, C. D. (2019). Early diagnosis of pneumonia with deep learning. *arxiv: 1904.00937*.
- URL-1. Chest X-ray images and Lung masks Database. (2021). [www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database](http://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database), Erişim Tarihi: 13/10/2021.
- URL-2. Pandas development began at AQR Capital Management. (2008). <https://pandas.pydata.org/about/>, Erişim Tarihi: 15/8/2022.