

**T.C.  
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**X-RAY GÖRÜNTÜLERİ İLE DERİN ÖĞRENME  
KULLANILARAK COVID-19 VAKALARININ TESPİTİ**

**YÜKSEK LİSANS TEZİ**

**Muhammed Mustafa AYDIN**

**Enstitü Anabilim Dalı : BİYOMEDİKAL MÜHENDİSLİĞİ**

**Tez Danışmanı : Prof. Dr. Raşit KÖKER**

**Temmuz 2023**

T.C.  
SAKARYA UYGULAMALI BİLİMLER ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

X-RAY GÖRÜNTÜLERİ İLE DERİN ÖĞRENME  
KULLANILARAK COVID-19 VAKALARININ TESPİTİ

YÜKSEK LİSANS TEZİ

Muhammed Mustafa AYDIN

Enstitü Anabilim Dalı : BİYOMEDİKAL  
MÜHENDİSLİĞİ

Bu tez 06/07/2023 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

JÜRİ	BAŞARI DURUMU
Jüri Başkanı: Prof. Dr. Raşit KÖKER	BAŞARILI
Üye: Dr. Öğr. Üyesi Serap ÇAKAR	BAŞARILI
Üye: Dr. Öğr. Üyesi Murat Erhan ÇİMEN	BAŞARILI

## **BEYAN**

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim

Muhammed Mustafa AYDIN

06/07/2023

## TEŐEKKÜR

Yüksek lisans eğitimim boyunca değerli bilgi ve deneyimlerinden faydalandığım, her konuda bilgi ve desteğini almaktan çekinmediğim, araştırmanın planlanmasından yazılmasına kadar tüm aşamalarında yardımlarını esirgemeyen, teşvik eden, beni yönlendiren değerli danışman hocam Prof. Dr. Raşit KÖKER'e, değerli hocam Mehmet DEMİR'e ve değerli hocam Yasin Burak AYDIN'a teşekkürlerimi ve saygılarımı sunarım.

Hayatım boyunca her zaman yanımda olan, kıymetli destekleri sayesinde yükseköğretim eğitimimi ve bu çalışmayı tamamlamamı sağlayan değerli aileme teşekkürlerimi ve saygılarımı sunarım.

# İÇİNDEKİLER

TEŞEKKÜR .....	i
İÇİNDEKİLER .....	ii
KISALTMALAR .....	iv
TABLolar LİSTESİ.....	v
ŞEKİLLER LİSTESİ.....	vi
ÖZET.....	vii
ABSTRACT.....	viii

## BÖLÜM 1.

GİRİŞ .....	1
1.1. Tezin Amacı.....	3
1.2. Tezin Kapsamı .....	3

## BÖLÜM 2.

TEMEL KAVRAMLAR .....	4
2.1. X-Işını.....	4
2.2. COVID-19 .....	6
2.3. Pnömoni .....	9
2.4. Yapay Zeka .....	10
2.5. Makine Öğrenmesi .....	12
2.6. Yapay Sinir Ağları .....	13
2.7. Derin Öğrenme .....	17
2.7.1. Derin öğrenme katmanları .....	18
2.7.1.1. Giriş katmanı .....	18
2.7.1.2. Evrişim (konvolüsyon) katmanı .....	18
2.7.1.3. Aktivasyon katmanı .....	19
2.7.1.4. Havuzlama (pooling) katmanı .....	19
2.7.1.5. Normalizasyon katmanı .....	20
2.7.1.6. Tam bağlı katman.....	20
2.7.1.7. Seyreltme (dropout) katmanı.....	20
2.7.1.8. Softmax katmanı .....	21
2.7.1.9. Sınıflandırma katmanı .....	21

2.7.2. Derin öğrenme mimari yapıları .....	21
2.7.2.1. Evrişimli sinir ağları.....	22
2.7.2.2. Tekrarlayan sinir ağı .....	22
2.7.2.3. Derin inanç ağı .....	22
2.7.2.4. Oto-kodlayıcılar .....	22
2.7.2.5. Derin nöron ağlar .....	23
2.7.2.6. Boltzmann makineleri .....	23
2.7.2.7. Kısıtlı boltzmann makinesi .....	23
2.8. Öğrenme Aktarımı (Transfer Learning).....	23
2.9. Literatür Araştırması .....	24

### **BÖLÜM 3.**

<b>MATERYAL VE YÖNTEM.....</b>	<b>32</b>
3.1. Veri Seti.....	32
3.2. Derin Öğrenme Uygulamasında Kullanılan Programlama Dili .....	34
3.3. Derin Öğrenme Uygulamalarında Kullanılan Programlama Kütüphaneleri.....	34
3.4. Çalışmada Kullanılan Derin Öğrenme Modelleri .....	35
3.4.1. CNN modeli .....	35
3.4.2. Alexnet modeli .....	36
3.4.3. VGG19 modeli .....	37
3.4.4. Resnet50 modeli.....	37
3.4.5. Xception modeli .....	38
3.5. Derin Öğrenmede Kullanılan Hiperparametreler .....	38
3.5.1. Veri seti boyutu .....	39
3.5.2. Öğrenme oranı.....	39
3.5.3. Epoch (döngü) sayısı.....	39
3.5.4. Batch size .....	39
3.6. Model Değerlendirme Metrikleri .....	39

### **BÖLÜM 4.**

<b>SONUÇLAR VE ÖNERİLER .....</b>	<b>42</b>
4.1. CNN Modeli Sonuçları.....	42
4.2. VGG19 Modeli Sonuçları .....	44
4.3. Xception Modeli Sonuçları .....	46
4.4. Alexnet Modeli Sonuçları .....	48
4.5. Resnet50 Modeli Sonuçları .....	50
4.6. Sonuçların Değerlendirmesi ve Öneriler .....	53

<b>KAYNAKLAR .....</b>	<b>55</b>
------------------------	-----------

## **KISALTMALAR**

COVID-19	: Koronavirüs Hastalığı
RT-PCR	: Real Time Polymerase Chain Reaction
MRI	: Magnetic Resonance Imaging
BT	: Bilgisayarlı Tomografi
CNN	: Convolutional Neural Network
MERS	: Orta Doğu Solunum Sendromu
SARS	: Şiddetli Akut Solunum Sendromu
DSÖ	: Dünya Sağlık Örgütü
GPU	: Graphics Processing Unit
RELU	: Rectifier Linear Unit
ILSVRC	: ImageNet Large Scale Visual Recognition Challenge
TP	: True Positive (Gerçek Pozitif)
TN	: True Negative (Gerçek Negatif)
FP	: False Positive (Yanlış Pozitif)
FN	: False Negative (Yanlış Negatif)

## TABLolar LİSTESİ

Tablo 3.1: Veri seti.....	33
Tablo 3.2: Veri setinde bulunan sınıflara ait X-Ray görüntü örnekleri. ....	33
Tablo 3.3: Karışıklık matrisi. ....	41
Tablo 4.1: CNN modeli performans değerlendirmesi.....	44
Tablo 4.2: VGG19 modeli performans değerlendirmesi.....	46
Tablo 4.3: Xception modeli performans değerlendirmesi.....	48
Tablo 4.4: Alexnet modeli performans değerlendirmesi.....	50
Tablo 4.5: Resnet50 modeli performans değerlendirmesi. ....	52



## ŞEKİLLER LİSTESİ

Şekil 2.1: İlk X ışını görüntüsü. ....	5
Şekil 2.2: X ışını oluşumu. ....	6
Şekil 2.3: Virüs yapısı. ....	7
Şekil 2.4: COVID-19 yaygın semptomları. . ....	8
Şekil 2.5: Sürüntü testi uygulama örneği. ....	9
Şekil 2.6: Pnömoni dokusu örneği. ....	10
Şekil 2.7: Yapay zeka venn şeması gösterimi. ....	12
Şekil 2.8: Biyolojik nöron yapısı. . ....	13
Şekil 2.9: Yapay sinir ağları algoritması. ....	14
Şekil 2.10: Yapay sinir ağı katmanları. ....	16
Şekil 2.11: Evrişim katmanı. ....	19
Şekil 2.12: Aktivasyon katmanı. ....	19
Şekil 2.13: Havuzlama katmanı. ....	20
Şekil 2.14. Dropout katmanı. ....	21
Şekil 2.15. Öğrenme aktarımı algoritması. ....	24
Şekil 3.6: CNN model mimarisi. ....	36
Şekil 3.7: Alexnet model mimarisi. . ....	36
Şekil 3.8: VGG19 model mimarisi. . ....	37
Şekil 3.9: Resnet50 model mimarisi. . ....	38
Şekil 3.10: Xception model mimarisi. . ....	38
Şekil 4.1: CNN modeli karışıklık matrisi. ....	43
Şekil 4.2: CNN modeli ROC eğrisi. ....	44
Şekil 4.3: VGG19 modeli karışıklık matrisi. . ....	45
Şekil 4.4: VGG19 modeli ROC eğrisi. ....	46
Şekil 4.5: Xception modeli karışıklık matrisi. ....	47
Şekil 4.6: Xception modeli ROC eğrisi. ....	48
Şekil 4.7: Alexnet modeli karışıklık matrisi. ....	49
Şekil 4.8: Alexnet modeli ROC eğrisi. ....	50
Şekil 4.9: Resnet50 modeli karışıklık matrisi. . ....	51
Şekil 4.10: Resnet50 modeli ROC eğrisi. . ....	52

# X-RAY GÖRÜNTÜLERİ İLE DERİN ÖĞRENME KULLANILARAK COVID-19 VAKALARININ TESPİTİ

## ÖZET

2019 yılının sonlarında tüm dünyaya yayılıp pandemiye sebep olan koronavirüs hastalığı, solunum yolu enfeksiyonu belirtileri ile ortaya çıkan salgın bir hastalıktır. COVID-19 salgını, insan hayatını ciddi şekilde etkilemekte, sağlık, eğitim, ekonomi gibi günlük sosyal aktivitelerin aksamasına sebep olmaktadır. Bu sebeple hızlı ve zamanında teşhis yapılabilmesi çok önemlidir. COVID-19'un yayılımını engellemekte hayati bir faktör olan teşhis için en yaygın kullanılan yöntem RT-PCR testi yöntemidir. Ancak, RT-PCR test yöntemi karmaşık manuel prosedürler içermekte ve fazla zaman kaybına neden olmaktadır.

Yapay zeka bilgisayarların insanlar düşüncelerini sağlayarak öğrenmelerini, problemleri çözmelerini ve karar vermelerini hedefleyen sistemdir. Derin öğrenme, yapay sinir ağlarını kullanarak büyük miktarda veriyi analiz ederek karmaşık ilişkileri öğrenme yöntemidir. X-Ray, MRI ve Bilgisayarlı Tomografi gibi tıbbi görüntüleme yöntemlerinden sağlanan görüntü ve sinyal verileri, çeşitli derin öğrenme mimarileri kullanılarak analiz edilebilir. Derin öğrenme yöntemleri ile tümör ve kanser teşhisi alanında çalışmalar yapılmaktadır. Derin öğrenme yöntemleri, birçok alanda olduğu gibi medikal alanında da önemli bir çalışma alanı olmuştur.

Bu çalışmada, derin öğrenme metotları kullanılarak COVID-19 vakalarının tespiti amaçlanmıştır. Derin öğrenme modelleri ile COVID-19, Normal ve Pnömoni sınıfları arasında doğru sınıflandırmalar yapılması hedeflenmiştir. Çalışmada programlama dili olarak Python kullanılmış, programlama Google Colaboratory ortamında gerçekleştirilmiştir. Derin öğrenme uygulaması için Kaggle'da halka açık olarak toplanıp paylaşılan X-Ray görüntülerinden oluşan veri seti kullanılmıştır.

Çalışmada CNN (Evrşimli Sinir Ağı) tabanlı CNN, Alexnet, VGG19, ResNet50 ve Xception modellerinden oluşan derin öğrenme modelleri önerilmiştir. Çalışmada 576 adet COVID-19 pozitif, 1583 adet normal ve 4273 adet pnömoni teşhisi olan toplamda 6432 adet adet göğüs röntgen görüntüsü içeren veri seti kullanılmıştır. Çalışma sonucu oluşturulan derin öğrenme modellerinin doğruluk, duyarlılık, kesinlik ve F1 Puanı oranları gösterilmiştir. CNN modeli %92,62 doğruluk oranı, VGG19 modeli %93,71 doğruluk oranı, Xception modeli %85,87 doğruluk oranı, Alexnet modeli %51,47 doğruluk oranı, Resnet50 modeli %52,10 doğruluk oranı sonuçları elde edilmiştir. Modellerin elde ettiği sonuçlar, COVID-19 ve benzeri hastalıkların tespiti için derin öğrenme modellerinin sağlık sistemlerine büyük katkılar sağlayabileceğini göstermektedir.

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

# **DETECTION OF COVID-19 CASES BY USING DEEP LEARNING WITH X-RAY IMAGES**

## **ABSTRACT**

The new type of Coronavirus Disease (COVID-19), which emerged in the last months of 2019, is an epidemic that occurs with respiratory tract infection symptoms. The COVID-19 pandemic has a serious impact on people's lives, disrupting daily social activities such as health, education and economy, which is why rapid and timely diagnosis is so important. RT-PCR testing is the most widely used method for diagnosis, which is a vital factor in preventing the spread of COVID-19. However, RT-PCR testing involves complex manual procedures and can be time-consuming.

Artificial intelligence enables computers to think like humans, enabling them to solve complex problems, make decisions and learn. Deep learning is a method of learning complex relationships by analyzing large amounts of data using complex structures called artificial neural networks. Image and signal data from medical imaging methods such as X-Ray, MRI and CT can be analyzed using various deep learning architectures. These analyses facilitate the detection and diagnosis of diseases such as skin cancer, breast cancer and brain tumors. Deep learning methods have become an important field in medical image processing.

This thesis aims to detect COVID-19 cases using deep learning models. With deep learning models, it is aimed to make correct classifications between COVID-19, Normal and Pneumonia classes. Python was used as the programming language in the study, and programming was carried out with Google Colaboratory. The COVID-19 X-Ray database provided from Kaggle was used as the dataset.

In the study, CNN (Convolutional Neural Network) based Simple CNN was proposed with deep learning models consisting of Alexnet, VGG19, ResNet50 and Xception models. In the study, a dataset containing 6432 chest X-ray images, 576 of which are COVID-19 positive, 1583 of which are normal and 4273 of which are diagnosed with pneumonia, was used. The accuracy, precision, sensitivity and F1 score rates of the deep learning models created as a result of the study were evaluated. An accuracy rate of 92.62% was obtained with the simple CNN model, 93.71% with the VGG19 model, 85.87% with the Xception model, 51.47% with the Alexnet model, and 52.10% with the Resnet50 model. The results show that deep learning models can make great contributions to health systems for the detection of COVID-19 and similar diseases.

Keywords: COVID-19, Artificial Intelligence, Deep Learning, X-Ray

## BÖLÜM 1. GİRİŞ

2019 yılının sonlarında tüm dünyaya yayılıp pandemiye sebep olan koronavirüs hastalığı, solunum yolu enfeksiyonu belirtileri ile ortaya çıkan bir hastalıktır. Bu yeni tip koronavirüs, insanları ve hayvanları etkileyebilen geniş bir koronavirüs ailesinin üyesidir. Son zamanlarda SARS, MERS ve COVID-19 gibi küresel ölçüde salgına yol açan koronavirüsler tespit edilmiştir [1].

Bu virüs ailesi mikroskop ile incelendiğinde taç yapısına benzerliği dolayısıyla İngilizce'de taç anlamına gelen "Corona" adı verilmiştir. Dünya Sağlık Örgütü (DSÖ), 2019 yılının son aylarında ortaya çıkan koronavirüsün bu yeni türüne "COVID-19" adını vermiştir. Bu isimlendirme için DSÖ, "co" kelimesini korona, "vi" kelimesini virüs ve "d" harfini İngilizce "disease" (hastalık) kelimesinin baş harfi olarak kullanmıştır. Dünya Sağlık Örgütü 11 Mart 2020 tarihinde COVID-19 virüsü hastalığını pandemi olarak duyurmuştur. COVID-19'un yaygın belirtileri arasında yüksek ateş, boğaz ağrısı, tat ve koku kaybı, kas ve eklem ağrısı, nefes darlığı gibi belirtiler bulunmaktadır [2].

COVID-19 salgını, insan hayatını ciddi şekilde etkilemekte, sağlık, eğitim, ekonomi gibi günlük sosyal aktivitelerin aksamasına sebep olmakta ve bu sebeple hızlı ve zamanında teşhis yapabilmek salgının yayılımını önleyebilmek için çok önemlidir. COVID-19'un yayılımını engellemekte hayati bir faktör olan teşhis için en yaygın kullanılan yöntem RT-PCR testi yöntemidir. Ancak, RT-PCR test yöntemi karmaşık manuel prosedürler içermekte ve fazla zaman kaybına sebep olmaktadır. RT-PCR test kapasitesi, salgının etkili olduğu bölgelerde yetersiz kalmaktadır. COVID-19 ve diğer göğüs hastalıklarının erken teşhisi için kullanılan diğer yöntemler, göğüs röntgeni ve bilgisayarlı tomografi gibi standart radyolojik görüntüleme araçlarıdır [3].

Geleneksel tıbbi görüntüleme yöntemleri, COVID-19 gibi hastalıkların yayılmasının kontrolünde büyük fayda sağlamaktadır. Tıbbi görüntüleme yöntemlerinin avantajı, bazı durumlarda tarama sonuçları negatif olsa bile hastalığın erken aşamalarında teşhis

edilebilmesi ve hızlıca tedaviye başlanmasını sağlamasıdır. Ancak röntgen görüntüsü analizi bir radyoloji uzmanının katılımını gerektirir ve manuel olarak yorumlanması zaman bakımından dezavantaj sağlamaktadır. Bu sebeple, sağlık uzmanlarının zaman kazanması için taramalarda otomatik anormallik tespiti yapabilen bir analiz sisteminin geliştirilmesi gereklidir [4].

Son yıllarda SARS, H1N1 ve MERS gibi çeşitli salgınlar ortaya çıkmış ve canlı yaşamını tehdit etmişlerdir. Salgınlarla mücadelede bilim dünyası, geleneksel yöntemlerin yanı sıra yeni mücadele yöntemlerini araştırmaya başlamıştır. COVID-19 gibi salgın hastalıkların yayılmasının önüne geçebilmek için tarama, tahmin, temas takibi ve ilaç geliştirme gibi alanlarda yapay zekanın verimli olarak kullanılabilmesi için çalışmalar başlatılmıştır. Bu çalışmalar, yapay zekanın sağladığı analitik ve öngörü yeteneklerinin salgınlarla mücadelede önemli bir araç olabileceğini göstermektedir [5].

Hastalığın yayılım hızı ve yüksek ölüm oranı, etkili bir tedavi yöntemi geliştirme ihtiyacını ortaya koymuştur. Hastalığın hızlı teşhis edilmesi ve karantinya alarak takip edilmesi gibi önlemler salgının yayılımını engellemede hayati önem taşımaktadır. Derin öğrenme teknikleri, salgının kontrolünde önemli katkılar sağlama potansiyeline sahiptir. Derin öğrenme, manuel özellik çıkarımına gerek duymadan girdi verilerini kullanıp uçtan uca modeller oluşturarak istenilen sonuçlara ulaşmayı mümkün kılmaktadır. Derin öğrenme, popüler bir araştırma alanı olup hastalık teşhisinde, epidemiyolojik analizlerde ve ilaç geliştirme süreçlerinde kullanılarak hastalığın kontrolünü sağlamada ciddi rol oynama potansiyeline sahip olduğunu göstermiştir. [3].

Derin öğrenme, tıbbi veri setlerini kullanarak göğüs röntgeni görüntülerinden zatürre tespiti, cilt kanseri tespiti, meme kanseri tespiti, patojenik bakterilerin sınıflandırılması ve beyin anormalliklerinin tespiti gibi alanlarda kullanılarak başarılı sonuçlar elde edilen yöntem olmuştur.

X-ray görüntüleri ile hastalığın tespit edilebildiği COVID-19 salgını, radyoloji alanında uzman hekim ihtiyacını artırmıştır ancak bu alandaki uzman hekimlerin sınırlı sayıda olması, hatta bazı bölgelerde bulunamaması sebebiyle, hızlı ve doğru teşhis yapabilen derin öğrenme modelleri COVID-19 vakalarının tespit edilmesinde büyük fayda sağlayabilme potansiyeline sahiptir [6].

## 1.1. Tezin Amacı

Bu çalışma, COVID-19 vakalarının tespiti için derin öğrenme yöntemlerini kullanmayı amaçlamaktadır. Literatürde, COVID-19 pozitif ve negatif vakalarını ayırt etmek yaygın bir uygulamadır ancak COVID-19 pozitif vakalarını diğer akciğer hastalıklarından ayırt edilebilmesi önemlidir. Derin öğrenme yöntemleri, X-Ray görüntülerinden elde edilen özellikleri tanımlamak ve bu özelliklere dayanarak doğru sınıflandırmalar yapmak için kullanılmıştır. Bu çalışmada, COVID-19, normal ve pnömoni sınıflarını içeren çoklu sınıflandırma ile derin öğrenme yöntemleri kullanılmıştır. Önceden eğitilmiş olan evrişimli sinir ağı tabanlı CNN, VGG19, Resnet50, Alexnet ve Xception modelleri seçilmiştir. Sınırlandırma amaçlı kullanılan bu modeller, derin öğrenme alanında yaygın olarak kullanılan, başarılı sonuçlar vermiş modellerdir. Bu modeller sayesinde, COVID-19 teşhisi konulması ve diğer akciğer hastalıklarından ayırt edilmesi amaçlanmıştır.

Bu çalışmada çeşitli derin öğrenme metotları kullanılarak COVID-19, normal ve pnömoni vakaları arasında doğru sınıflandırmalar yapılması hedeflenmiştir. Bu çalışma, COVID-19 teşhisinde yardımcı olabilecek etkili bir modelin geliştirilmesine katkıda bulunmayı amaçlamaktadır.

## 1.2. Tezin Kapsamı

Bu tez çalışması, giriş bölümü, temel kavramlar bölümü, materyal ve yöntem bölümü, ile sonuçlar ve öneriler bölümü olarak dört ana başlık altında hazırlanmıştır.

Giriş bölümünde COVID-19 hastalığı, bu hastalığın belirtileri, bulaş yolları ve teşhis yöntemleri hakkında bilgiler sunulmuştur.

Temel kavramlar bölümünde, X-ışını, COVID-19, yapay zeka, yapay sinir ağları, makine öğrenmesi, derin öğrenme kavramları hakkında detaylı bilgiler sunulmuş, konu ile ilgili daha önce yapılan çalışmalardan bahsedilen literatür araştırması bölümüne yer verilmiştir.

Materyal ve yöntem bölümünde bu çalışmada kullanılan derin öğrenme yöntemlerinin mimarileri hakkında bilgiler verilmiş, kullanılan veri setinin içeriği ve sonuçların değerlendirilmesinde kullanılan hiperparametrelere bahsedilmiştir.

Sonuçlar ve öneriler bölümünde, derin öğrenme modellerinin deneysel sonuçları sunulmuş, sonuçlar analiz edilip açıklanmıştır.

## **BÖLÜM 2. TEMEL KAVRAMLAR**

### **2.1. X-Işını**

X-ışınları, iyonize radyasyon içeren ve gözle görülemeyen elektromanyetik dalgalardır. Yüksek enerjili ve çok düşük dalga boyuna sahiptirler. X-ışınları 0,125 – 125 keV enerji aralığına sahip olup dalga boyu 10-0,01 nm aralığındadır. X-ışınları Wilhelm Röntgen tarafından 1895 yılında elektron tüpleri üzerinde çalıştığı esnada tesadüf eseri bulunmuştur. Bu sebeple "Röntgen ışınları" olarak adlandırılmıştır. Röntgen içi boş cam tüpte elektriğin etkilerini gözlemlemek amacıyla deney yaptığı esnada katottan kopan elektronların anoda ulaşmadan cama çarparak, floresan adı verilen ışık parlamalarının ortaya çıkarttığını farketmiştir. Daha sonra tüpü siyah bir karton ile kaplayarak aynı zamanda ışık geçirgenliğini anlayabilmek için odayı karanlık hale getirip deneyi tekrardan gerçekleştirmiştir. Ardından deney tüpünden 2 metre uzaklıkta baryum platinosyanüre sarılı olan kağıtta bir parlama fark etmiştir. Deneyi defalarca tekrarlayıp olayı tekrar tekrar gözlemleyip, mat yüzeyden geçebilen yeni bir ışın bulmuş, ve bu yeni ışına "X-Ray" ismini vermiştir. Wilhelm Röntgen'in X-ışınları ile ilgili yaptığı çalışmalara eşi Anna Bertha Ludwig' de destek vermiştir. X-ışınını denemek için elini radyoaktif madde ve floresan plaka arasına yerleştiren Anna Bertha 15 dakika boyunca bekleyip, sonunda elinde bulunan kemiklerin görüntüsüne ulaşmıştır. Bu sayede Anna Bertha Ludwig, X-ışınını ilk tecrübe den kişi olmuştur [7]. Şekil 2.1'de Anna Bertha'nın elinin ve parmağındaki yüzüğünün görüntüsünü içeren ilk X-Ray görüntüsü gösterilmiştir. X-ışınlarının başta tıp olmak üzere endüstri, sanayi, tarım, hayvancılık, jeoloji gibi çok geniş kapsamlı kullanım alanları vardır. Özellikle tıp alanında radyolojik görüntüleme yöntemlerinde kullanılarak ulaşılabilen hastalık tespiti sayesinde milyonlarca yaşamın kurtulmasına vesile olmuştur.



Şekil 2.1: İlk X-ışını görüntüsü [7].


X-ışınları vücuttan geçme özelliğine sahip olup vücudun farklı bölgelerinde farklı derecelerde değişime uğrarlar. Vücuttan geçen X-ışınları tespit edilerek grafi haline getirilebilmektedir. X-ışınları, atomu iyonize edebilecek ve moleküler bağları kırabilecek enerjiye sahiptir. Bu durum X-ışınlarının, canlı dokuya zararlı olan iyonlaştırıcı radyasyon sınıfına girdiğini göstermektedir. Kısa sürelerde dahi olsa maruz kalınan yüksek dozda X-ışını, radyasyon maruziyetine sebep olur ve kanser riskini artırmaktadır. Ancak X-ışınlarını görüntüleme anlamında potansiyel faydası düşünüldüğünde verdiği zarardan çok faydası olduğu kanaatine varılmıştır. X-ışınları, bilgisayarlı tomografi, anjiyografi, mamografi, nükleer görüntüleme tıpta ve endüstride kullanılmaktadır.

Röntgen çekimi yapılacak olan kişi, X-ışını tüpü ve cihazın masası arasında konumlandırılır. Çekim başladığında kişinin vücudundan röntgen ışınları geçer. Röntgen cihazında yer alan X-ışınları çekim yapılan hastayı geçerek cihazın masasına ulaşma sağlar. Kemikler diğer dokulara göre daha yoğun olduğundan ve daha fazla X-ışını soğurduklarından dolayı röntgen filminde daha belirgin halde görüntülenme sağlarlar.

Günümüzde birçok alanda kullanılan X-ışınları, X-ışını tüpü ile üretilebilmektedir. Vakumlu bir ortamda cam tüpün içinde flamen bulunmaktadır. Flamenler eski



ampullerdeki küçük tellerden kıvrılması ile oluşan yapıya benzer. Flamenler genelde tungstenden oluşmaktadır. Bu flamenin 2 veya 3 amper geçirilir. Cam tüpün diğer köşesinde de bir pencere bulunmaktadır. Pencerenin hemen altında hedef malzeme bulunmaktadır. Bu malzeme genelde bakırdan meydana gelmektedir. Bakır çok ısındığı için ve soğutma amaçlı üzere boru vasıtasıyla içinden su giriş çıkışı sağlanmaktadır. Cam tüp içinde bakır ve flamen arasında grid ismi verilen ızgara bulunmaktadır. Flamen ile grid arasında 25.000-30.000 Volt gerilim uygulanır. Vakum üzerinde yüksek gerilim uygulandığı için elektronlar flamenin çıkıp grid üzerinden geçip hedef malzeme olan bakıra doğru çok yüksek hızla giderler. Çok yüksek hıza ulaşan elektron demetleri birden hedefe vurdukları için ivmelerini kaybederler. İvmelenen yük yani elektron elektromanyetik dalga üretir. Aniden yavaşlayan elektronlar cam tüp üzerinde bulunan pencereden dışarıya X-ışını olarak ortaya çıkar. Hastanelerde kullanılan röntgen cihazı tamamen bu şekilde çalışmaktadır. Örnek olarak açıklayacak olursak, el röntgeni çekilirken, X-ışınının dozu ayarlanıyor ve el ile kemik yoğunluğu arasında el yoğunluğunu geçip film üzerinde yakarken, kemik yoğunluğunda filme beyaz bir görüntü oluşmasını sağlamaktadır. Şekil 2.2’de X-ışını oluşumu gösterilmektedir.




Şekil 2.2: X-ışını oluşumu [44].

## 2.2. COVID-19

Latince zehir anlamına gelen virüsler, bakterilerden farklı olarak sadece enfekte olduğu hücre içerisinde canlı özellik gösteren yapılardır. Hücre dışında canlı özellik göstermeyen virüsler çoğalabilmek için canlı hücreye ihtiyaç duyarlar. Virüsler canlı yaşamını sonlandırabilecek kadar olumsuz etkilere sahiptirler. Virüslerin genelde

kendine özgü konak hücreleri vardır ancak kuduz virüsü gibi bazı virüslerin hem insan hem de hayvan hücrelerini konak olarak kullanabilen çeşitleri vardır. Virüslerin bakterilerden bir diğer farkı da hücre içinde sadece parazit durumunda olmalarıdır. Büyüklükleri 20 ile 300 nanometre arasında değişen virüsler oldukça küçük yapıdadırlar ve sadece elektron mikroskopu ile gözlemlenebilmektedir. Virüsler bakterilerden farklı olarak antibiyotiklere karşı duyarlı değildir, bu sebeple bakterilere göre çok daha dayanıklıdırlar. Antibiyotik gibi ilaç yöntemleriyle tedavi edilemeyen viral hastalıklara karşı aşı yöntemiyle tedavi yolları geliştirilmektedir. Virüslerin yapısında, kendi genomlarını oluşturan RNA veya DNA bulunmaktadır ve buna viral genom adı verilmektedir. Viral genom konak hücreye aktarılacak bilgiyi depo etmektedir. Virüslerin nükleik asitlerinin etrafı protein yapısında olan kapsomer adında birimlerden oluşur ve bu yapıya kapsid adı verilir. Diken proteini virüsün konak hücreye tutunmasını sağlar. Virüsü çevreleyen yapıya zarf adı verilir. Bu yapı protein, lipid ve karbonhidrattan oluşmaktadır [9]. Şekil 2.3. virüsün yapısı gösterilmiştir.




Şekil 2.3: Virüs yapısı [9].

Tarih boyunca birçok türü keşfedilen virüsler genellikle ölümcül değildir. Koronavirüs ailesi 1960'lerde keşfedilmiş, 2003 SARS virüsü, 2012 de MERS virüsü ve son olarak 2019 yılının sonlarında Çin'in Vuhan eyaletinde yeni koronavirüs hastalığı ortaya çıkmış ve çok kısa sürede tüm dünyaya yayılarak pandemiye yol açmıştır. Salgının ilk olarak o bölgede bulunan deniz ürünlerinde ve hayvan pazarlarında bulunduğu tespit edilmiş olup insandan insana solunum yoluyla geçtiği belirlenmiştir.

Koronavirüs tek zincirli, pozitif polariteli, zarflı RNA'ya sahip boyutları 80 ila 120 nm arasında değişen insan patojeni haline gelebilen bir virüs ailesidir. Bu virüslerin

yarasalar veya fareler olmak üzere hayvan kaynaklı olduğu düşünülmektedir. COVID-19'un yarasadan insana bulaştığı yönünde çalışmalar gerçekleştirilmiştir [10].

Sağlık Bakanlığı tarafından belirtilen verilere göre en çok karşılaşılan belirtilerin yüksek ateş, tat ve koku kaybı, kuru öksürük ve nefes darlığı olduğu yönündedir. Şiddetli olgularda zatürre, ağır solunum yetmezliği, böbrek yetmezliği ve ölüme sebep olabilmektedir [11]. COVID-19 yaygın semptomları şekil 2.4'te gösterilmiştir.



Şekil 2.4: COVID-19 yaygın semptomları [12].

COVID-19 salgınının önüne geçmek ve etkilerini azaltmak için yayılımının önüne geçmek son derece önemli hale gelmiştir. İnsanlar arasında bulaşan ve hızla yayılan virüsün yayılımının engellenmesi için hızlıca teşhis edilmesi ve teşhis edilen kişilerin diğer insanlardan izole edilmesi gerekmektedir. COVID-19 ile enfekte olmuş vakaların teşhisi için PCR testi adı verilen yöntem geliştirilmiştir. COVID-19 semptomları gösterdiği tespit edilen hastadan solunum yolu kullanılarak sürüntü testi yapılmaktadır. Bu test yapılırken hastanın başı 70 derece arkaya doğru eğilir. Eküvyon çubuğu ile burun deliğinden farinks duvarına değinceye kadar itilir. Hedef noktaya ulaşıncaya kadar birkaç saniye beklenir ve yavaş yavaş dışarıya çekilir. Alınan sürüntü numunesi laboratuvar ortamında test edilip, test sonucu COVID-19 virüsüne ait RNA bulunursa hastaya COVID-19 pozitif teşhisi konulmaktadır [13]. Şekil 2.5'te sürüntü testi uygulama örneği gösterilmiştir.




Şekil 2.5: Sürüntü testi uygulama örneği [14].

Her ne kadar sürüntü yöntemi COVID-19 teşhisi koymak tüm dünyada yaygınlaşmış olsa da kişide hastalığın erken dönemlerinde negatif sonucu verme durumu ortaya çıktığından en ideal yöntemin PCR testine göre röntgen cihazı, bilgisayarlı tomografi ya da benzeri tıbbi görüntüleme cihazları olduğu ve bu yöntemlerin deha başarılı sonuçlar verdiği tespit edilmiştir. Ayrıca sürüntü yöntemi ile hasta ile çok yakın temasta bulunulduğundan tıbbi görüntüleme yöntemleri ile hastaya teşhis koyarken bulaş ihtimalinin daha az olacağı anlaşılmaktadır.

### 2.3. Pnömoni

Halk arasında zatürre 25 adlandırılan pnömoni akciğerdeki hava keseciklerinde ortaya çıkan iltihaplanmadır. Başta bakteriler olmak üzere çeşitli mikroorganizmalar sebebiyle oluşabilmektedir. Pnömoninin oluşmasına bulaş yolundan çok, hastanın bağışıklığının düşmesi sebep olmaktadır. Normal zamanda hastalığa dönüştürmeyecek bazı mikroorganizmalar, vücut bağışıklığının zayıfladığı durumlarda insanı hasta edebilmektedir. Pnömoni genellikle hastanın kendi ağız ve boğaz yollarında bulunan mikropların akciğerlere nüfuz etmesiyle meydana gelmektedir. Bu sebeple pnömoni genellikle bulaş yoluyla değil, genellikle insanın kendi vücut savunmasının zayıf olduğu zamanlarda ortaya çıkan bir hastalıktır [15]. Şekil 2.6'da sağlıklı ve iltihaplı akciğer dokusu örneği gösterilmiştir.



Şekil 2.6: Pnömoni dokusu örneği [16].

Pnömoninin belirtileri arasında üşüme, titreme, öksürük, iltihaplı balgam çıkarma gibi semptomlar bulunmaktadır. Pnömoni hem bakteriyel hem viral kaynaklı olabilmekte, COVID-19 ise sadece viral kaynaklı enfeksiyonlarla ortaya çıkmaktadır. Pnömoninin belirtileri COVID-19'un belirtileri ile benzer özellikler göstermektedir ve kişi rahatsızlandığında bunun COVID-19 veya pnömoni olabileceği konularında yanılgılar olabilmektedir. Bu tez çalışmasında da sağlıklı bireylerin, covid-19 bireylerin ve pnömoni bireylerin akciğer grafilerini inceleyip derin öğrenme yöntemi ile çıkarımlarda bulunulması hedeflenmektedir.

#### 2.4. Yapay Zeka

Yapay zeka bilgisayarların insanlar gibi düşüncelerini sağlayarak öğrenmelerini, problemleri çözmelerini ve karar vermelerini hedefleyen sistemdir. Yapay zekanın temel amacı, makineleri daha verimli ve daha etkin hale getirmektir. Yapay zeka, bilgisayar bilimleri, matematik, istatistik, psikoloji ve beyin bilimleri gibi çeşitli disiplinlerin birleşimiyle oluşmuş geniş bir alandır.

Modern anlamda yapay zeka kavramı, Alan Turing'in 1950 yılında yayınladığı makalesinde ortaya konulmuştur. Bu makalede, akıllı makinelerin nasıl oluşturulacağı ve özellikle zekalarının nasıl test edileceği ele alınmıştır. İnsan makineyle etkileşime geçtiğinde makineyi insan gibi algılıyorsa, bu durumda makinenin akıllı olduğu söylenebilmektedir. Alan Turing bilgisayarlardaki akıllı davranışı, bilişsel görevlerde

insan düzeyinde performans elde etme yeteneđi olarak tanımlamış, bu daha sonra Turing testi olarak popüler hale gelmiştir [17].

Günümüzde yapay zeka, birçok alanda kullanılan bir teknolojidir. Örneđin sesli asistanlar, görüntü tanıma sistemleri, otomatik sürüş teknolojileri gibi birçok yapay zeka uygulaması mevcuttur. Yapay zeka, gelecekte daha da gelişerek farklı alanlarda daha karmaşık görevleri yerine getirebilecek hale gelmesi beklenmektedir. Geçen yüzyılın ortalarından bu yana, araştırmacılar tıp alanında yapay zeka tekniklerinin uygulamalarını araştırmışlardır. Tıbbi yapay zekanın gelişimi, bir teşhisin formüle edilmesinde, terapötik kararların alınmasında ve sonucun tahmin edilmesinde klinisyene yardımcı olmayı amaçlayan yapay zeka programlarının geliştirilmesiyle ilgilidir. Sağlık çalışanlarını günlük görevlerinde desteklemek, veri ve bilginin manipülasyonuna dayanan görevlere yardımcı olmak için tasarlanmıştır. Yapay zeka, gelecekte daha da gelişerek farklı alanlarda daha karmaşık görevleri yerine getirebilecek hale gelmesi beklenmektedir.

Yapay zeka alanında kullanılan tekniklerden biri olan makine öğrenmesi, bilgisayarlara veriye dayalı olarak öğrenme ve karar verme yetenekleri kazandırır. Makine öğrenmesi, veri analizi ve istatistiksel yöntemler kullanarak modeller oluşturur ve bu modelleri kullanarak gelecekteki olayları tahmin eder veya belirli görevleri gerçekleştirir.

Yapay zekanın kollarından olan derin öğrenme, yapay sinir ağları olarak isimlendirilen karmaşık yapılar kullanarak büyük miktarda veriyi analiz ederek karmaşık ilişkileri öğrenme yöntemidir. Derin öğrenme algoritması, yapay sinir ağları aracılığıyla verileri işleyerek karmaşık desenleri tanımaya ve anlamaya çalışır. Şekil 2.7'de yapay zeka venn şeması gösterilmiştir.



Şekil 2.7: Yapay zeka venn şeması gösterimi [18].

## 2.5. Makine Öğrenmesi

Makine öğrenmesi, bilgisayarların kendi kendilerine öğrenme yeteneğine dayanan bir yöntemdir. Bu süreçte, bilgisayarlar yeterli miktarda veriye sahip olmalıdır. Verilerin bilgisayarlara aktarılabilmesi için sistem, öncelikle bir örnek üzerinden veri özelliklerini öğrenir ardından yeni örneklerle sistemi geliştirir. Sistem, yeni örneklerle birlikte veriler arasında ilişkiler kurarak öğrenme sürecini ilerletir. Makine öğrenmesi genellikle büyük ve karmaşık veri kümeleriyle çalışır. Sistemin öğrenme hızı, sisteme daha fazla örnek verildikçe artar. Makine öğrenimi alanı, gelecekteki sonuçları tahmin etmek için geçmiş bilgilerden faydalanarak birçok uygulamada başarılı olarak kullanılmaktadır. Makine öğrenmesi teknikleri genellikle üç gruba ayrılır:

Denetimli öğrenme modelin daha önceden sınıflandırılmış veriler üzerinden tahminler yaptırmak üzere eğitildiği makine öğrenimi çeşididir. Denetimli öğrenme eğitim için etiketli veriye ihtiyaç duyar. Denetimli öğrenmede, modele örnekler sunulur ve her örnek hem girdi verilerini hem de bu verilere karşılık olan etiketleri içerir. Model tahmin yapabilmek için girdi verilerini kullanır ve doğruluğunu kontrol edebilmek için bu tahminleri sonuçlar ile karşılaştırır. Denetimli öğrenmenin amacı, eğitim verileri sayesinde öğrenimi gerçekleştirerek yeni ve bilinmeyen veriler hakkında doğru tahminler yapabilmektir. Denetimli öğrenme sınıflandırma ve regresyon gibi uygulamalarda kullanılmaktadır.


Denetimsiz öğrenme verilerde etiketli veriye ihtiyaç duymayan makine öğrenmesi çeşididir. Denetimsiz öğrenmede modele çok sayıda örnek sunulur. Bu örneklerde yalnızca girdi verileri bulunur, bu verilere karşılık olan etiketler bulunmaz. Çok sayıda veri olması ve bu verilerin etiketlenme imkanı olmayan durumlarda denetimsiz öğrenme kullanılabilir.

Pekiştirmeli öğrenmede girdilere göre herhangi bir önceden belirlenmiş çıktı değeri verilmemektedir. Bunun yerine, elde edilen çıktılar doğru ve yanlış olarak etiketlenir. Yanlış sonuçlar tespit edildiğinde, program güncellenerek tekrar öğrenme süreci gerçekleştirir [19].

## 2.6. Yapay Sinir Ağları

Yapay sinir ağları insan beyindeki nöronlardan ilham alınarak oluşturulan modellerdir. Bu ağlarda, nöronlar arasında bağlantılar vardır ve bu bağlantılar, nöronların birbirleriyle etkileşimini sağlar. Her bir nöron, girdileri alır, bu girdileri işler ve bir çıktı üretir. Bu çıktılar diğer nöronlara iletilir ve yapay sinir ağının öğrenme süreci devam eder.

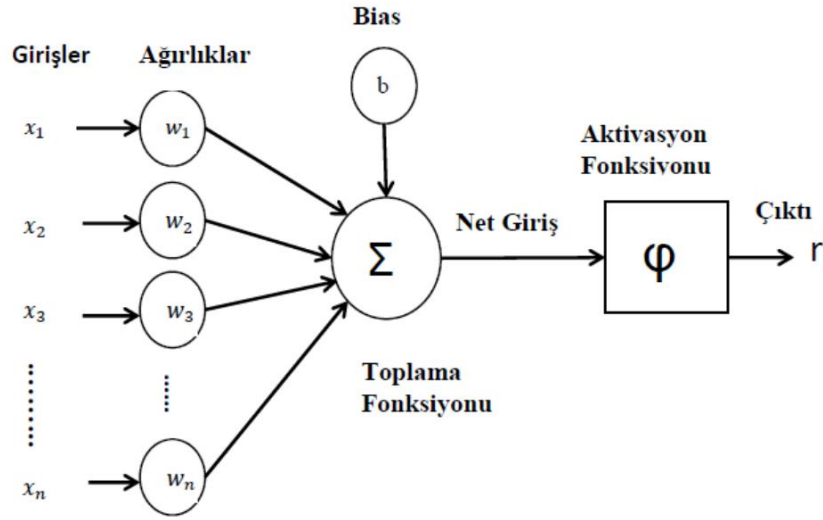
Temel olarak, bir dendrit giriş sinyalini diğer nöronlardan alır, alınan sinyali soma işler, akson bu nöronun çıktısını iletir, sinapslar diğer nöronlar ile bağlantı kurulmasını sağlarlar. Biyolojik nöronun bu modeli yapay sinir ağlarının tasarlanmasında ilham kaynağı ve temeli olmuştur. Yapay sinir ağları öğrenme süreçlerini yapay nöronlar arasındaki iletişim sayesinde meydana gelmiş ve bu sayede öğrenebilen modeller oluşturabilmek mümkün hale gelmiştir. Şekil 2.8'de biyolojik nöronun yapısı gösterilmiştir.



Şekil 2.8: Biyolojik nöron yapısı.



Yapay sinir ağı, insan beyindeki gibi bilgi işleme ve karar verme süreçlerini gerçekleştirir. Yapay sinir ağlarında veri girdileri ağırlıkları ile çarpılarak, sonuçta elde edilen değerler bir araya getirilir ve elde edilen değere bilgi değeri de eklenerek aktivasyon fonksiyonu uygulanır. Fonksiyon uygulaması sonucunda çıktı değerine ulaşılır. Bu ulaşılan değer, bir sonraki katmandaki nöronların girişi olarak kullanılır ve bu süreç öğrenme başarılı olana kadar devam eder. Yapay sinir ağı sınıflandırma yapmak amacıyla üretilmişse, giriş değeri en son katmandaki en yüksek değere sahip nöron tarafından etiketlenir. Şekil 2.9’da yapay sinir ağı algoritması gösterilmiştir.



Şekil 2.9: Yapay sinir ağı algoritması [57].

İnsan nöronlarında olduğu gibi yapay sinir ağlarında da nöronlar birbirlerine art arda bağlanabilmektedirler. Yapay sinir ağlarında nöronların tek veya çok sayıda girişi bulunmaktadır. Nöronların her girişinin ağırlıkları farklıdır. Bazı nöronlara farklı olarak besleme bilgi değerleri de eklenmektedir. Genel olarak nöron yapısının çıkış denklemi 3.1’deki gibi elde edilmektedir.

$$r = \sum_{i=1}^N w_i \cdot x_i + b \quad (3.1.)$$

Bu denklemdeki “N” giriş sayısı, “w” her bir girişin ağırlığı, “x” giriş değeri ve “b” bilgi değerini belirtmektedir. Bu denklem sonucu ulaşılan değer aktivasyon

fonksiyonundan geçirilir ve nöron çıkış değeri üretir. Bu çıkış denklemi 3.2'de gösterilmiştir.

$$y = \varphi(r) = \varphi\left(\sum_{i=1}^N w_i \cdot x_i + b\right) \quad (3.2.)$$

Yapay sinir ağlarının öğrenme işlemi esnasında farklı algoritmalar kullanılmaktadır. Hücrenin çıkış verisi her zaman en doğru değeri üretemeyebilir. Bazı durumlarda bilgi taşıyan ağırlıkların güncellenmesi gerekebilir. Ağırlıkların güncellenme süreci, yapay sinir ağlarında öğrenme işlemi olarak adlandırılmaktadır ve bunu yapabilmek için geri yayılım algoritması kullanılmaktadır. Bu algoritmanın denklemi 3.3'te gösterilmiştir.

$$e_i = d_i - y_i \quad (3.3.)$$

Bu denklemde nöron hücresinden elde edilmek istenen asıl değer  $d_i$ , elde edilen çıkış değeri  $y_i$  olarak adlandırılır. Geri yayılım algoritması uygulanarak hücre çıkışında bulunan hataların karesel toplamı olan maliyet fonksiyonu minimum hale getirilmektedir. Maliyet fonksiyonunun denklemi 3.4'te gösterilmiştir.

$$E = \frac{1}{2} \sum_1 \cdot (e)^2 = \frac{1}{2} \sum_i (d_i - y_i)^2 \quad (3.4.)$$

Maliyet fonksiyonunun minimum değerine ulaştırmak için geliştirilen delta fonksiyonu, çıkışta oluşan hata nedeniyle oluşan ağırlıklardaki değişimi ifade eder, bu değer aktivasyon fonksiyonunun türevidir. Nöron için ağırlık değerinin hesaplaması denklem 3.5'te delta değerinin hesaplanması denklem 3.6'da gösterilmiştir.

$$\delta_i = \varphi'(y_i) * e_i \quad (3.5.)$$


$$w_i^* = w_i + \delta * x_i \quad (3.6.)$$

Bu denklemlerin uygulanması ağıın öğrenme hızını etkilemektedir ve yapay sinir ağıının öğrenme işlem süresi uzayabilmektedir. Bu sebeple  $\eta$  öğrenim katsayısı kullanılmaktadır. Bu sayede öğrenim süreci kademeli olarak gerçekleşir. Bu süreç kademeli azalış olarak adlandırılmaktadır. Bu hesaplama denklem 3.7’de gösterilmiştir.

$$w_i^* = \eta * \delta * x_i \quad (3.7)$$

Geri yayılım algoritması uygulanırken her bir tekrarlama işleminde ileri yayılım yapılır ve çılış değerleri bulunur. Hata değerleri için tekrar geri yayılım algoritması uygulanır ve bir devir tamamlanmış olur. Bu süreç hata fonksiyonu minimum değere erişene kadar devam ettirilir [20].

Yapay sinir ağıları, giriş katmanı, ara katmanlar ve çıkış katmanı olmak üzere üç temel katmandan oluşmaktadır. Giriş katmanı verilerin yapay sinir ağıına verildiği ve sonraki katmanlara iletiildiği katmandır. Ara katmanlar, giriş ve çıkış katmanları arasındaki katmanlardır. Gizli katmanlar olarakta adlandırılırlar. Girdilerin matematiksel hesaplamalarının yapıldığı katmanlardır. Çıkış katmanı öğrenme işleminin gerçekleştiği, sonuçların hesaplandığı katmandır. Şekil 2.10’da yapay sinir ağı katmanları gösterilmiştir.



Şekil 2.10: Yapay sinir ağı katmanları.

Yapay sinir ağıları biyolojik sinir sisteminden esinlenen hesaplamalı analitik araçlardır. Veri işleme ve bilgi temsili için paralel hesaplamalar yapabilen ve nöron olarak adlandırılan yüksek düzeyde birbirine bağlı bilgisayar işlemcilerinden oluşan ağlardan oluşurlar. Geçmiş örneklerden öğrenme, doğrusal olmayan verileri analiz etme, kesin olmayan bilgilerle başa çıkma ve modelin bağımsız verilere uygulanmasını sağlayan genelleme yetenekleri, onları tıp alanında çok çekici bir analitik araç haline getirmiştir.

Yapay sinir ağıları halihazırda çok çeşitli uygulama alanları bulmuştur. Görüntüleri doğru bir şekilde sınıflandırma ve tanıma yetenekleri, araştırmacıları onları birçok klinik problemin çözümünde uygulamaya çekmiştir. Birçok klinik durumda teşhis, tedavi ve sonucun tahmin edilmesinin birçok klinik, biyolojik ve patolojik değişkenin karmaşık etkileşimine bağlı olduğunu fark ettiğimizde, bu değişkenler arasındaki karmaşık ilişkileri kullanabilen yapay sinir ağıları gibi analitik araçlara olan ihtiyaç artmaktadır [21].

## **2.7. Derin Öğrenme**

Derin öğrenme insanların öğrenme sürecini taklit ederek, sinir hücreleri ve hücreler arasındaki öğrenme bağlantısını yapay olarak oluşturarak makinelerle insan beyninin öğrenme işlemine benzer şekilde öğretmeyi hedefler. Makine öğrenimi alanının bir alt dalı olan derin öğrenme işlemi esnasında, veriler birbirini takip eden katmanlarda işlenir. Son yıllarda, derin öğrenme teknikleri, medikal görüntü işleme dahil olmak üzere birçok alanda etkileyici performans göstermeye devam etmektedir. Tıbbi veri setleriyle çalışma alanında, derin öğrenme yaygın olarak kullanılan yöntemdir. Röntgen Cihazı, MRI ve Bilgisayarlı Tomografi gibi tıbbi görüntüleme yöntemlerinden sağlanan görüntü ve sinyal verileri, çeşitli derin öğrenme mimarileri kullanılarak analiz edilebilir. Bu analizler sayesinde cilt kanseri, meme kanseri, beyin tümörü gibi hastalıkların tespiti ve teşhisi mümkün hale gelmiştir. Derin öğrenme yöntemleri, medikal görüntü işlemede önemli bir alan olmuştur [22].

Derin öğrenme alanında yapılan ilk çalışmalar Yann LeCun tarafından üretilip 1998'de yayınlanan LeNet modelidir. Yapay sinir ağıları eğitim sırasında yüksek bellek ve hesaplamalara ihtiyaç duymaktadır. Yapay sinir ağlarının bu ihtiyaçları ilk geliştirildiği zamanlar öğrenme konusunda yavaş çalışmalarına neden olmuştur. Derin öğrenme alanında ilk defa 2012 yılında nesne tanımlama alanındaki bir yarışma olan ILSVRC (ImageNet Large Scale Visual Recognition Challenge) yarışmasında Krizhevsky ve

ekibinin ortaya çıkardığı evrişimli sinir ağlarını kullanmaları ve bu modelin elde ettiği başarı sayesinde derin öğrenme alanında büyük ilerleme sağlanmıştır. Gün geçtikçe derin öğrenme alanında başarılı sonuçlar alınmaktadır ve bu başarı oranı daha da yükselmektedir. İnsan hayatında teknoloji ilerledikçe ve dijitalleşme arttıkça veri birikimi oluşmakta, yükselen veri miktarları derin öğrenmeye büyük kaynaklar sağlamaktadır. Ayrıca ilerleyen teknoloji ile birlikte bu verilerin işlenmesini sağlayan hesaplama araçlarının gelişmesi, CPU yerine GPU'ların kullanılmasıyla derin öğrenme çalışmaları daha hızlı ilerleyebilmektedir. [47].

### **2.7.1. Derin öğrenme katmanları**


Derin öğrenme modelleri katmanlardan meydana gelir ve her katmanın kendine has görevi vardır. Modelin mimarisindeki bu katmanlar, önceki katmanlardan bilgi alır ve sonraki katmanlara aktarırlar.

#### **2.7.1.1. Giriş katmanı**

Giriş katmanı adından da anlaşıldığı gibi evrişimli sinir ağının ilk katmanıdır. Görüntüler filtreler aracılığıyla ön işlem gerçekleştirilir. Ham girdi görüntüsüne ek olarak kenarlar ve gradyanlar gibi ek bilgileri ağa iletebilen yapıdır. Görüntü işleme katmanı olarak da adlandırılmaktadır [26].

#### **2.7.1.2. Evrişim (konvolüsyon) katmanı**


Evrişim katmanı, yeni görüntüler üretmek için özellik haritaları adı verilen bir dizi görüntülerin oluşturulduğu katmandır. Bu katman evrişimli sinir ağının temelini oluşturur. Özellik haritaları, orijinal görüntünün özgün özelliklerini vurgulamak için tasarlanmıştır. Evrişim katmanı, diğer sinir ağı katmanlarından büyük ölçüde farklı bir şekilde işler. Bu katmanda filtreler tüm görüntü üzerinde matrisler halinde dolaştırılmaktadır ve yeni öznetelik haritaları çıkartılmaktadır. Bu katman, bağlantı ağırlıkları veya ağırlık toplamı kullanmadan, görüntüleri dönüştüren filtrelerden oluşur. Bu filtreler evrişim filtreleri olarak adlandırılır ve görüntü üzerinde ölçeklendirme işlemlerini gerçekleştirir. Filtreleme boyutu, farklı derin öğrenme modellerine bağlı olarak değişebilir [22]. Şekil 2.11'de evrişim katmanı gösterilmiştir.



Şekil 2.11: Evrişim katmanı [23].

### 2.7.1.3. Aktivasyon katmanı

Aktivasyon fonksiyonlarının uygulandığı katmandır. Bu katmanda negatif görüntü değerleri sıfıra, pozitif görüntü değerlerinin kendi değerlerine eşitlenmesi sağlanır [24]. Şekil 2.12’de Aktivasyon fonksiyonu matematiksel denklemini ve grafiği gösterilmiştir.




Şekil 2.12: Aktivasyon fonksiyonu [25].

### 2.7.1.4. Havuzlama (pooling) katmanı

Havuzlama katmanı, görüntünün boyutunu küçültülmesini, görüntüden hangi piksellerin seçileceğini ve temsili değer nasıl ayarlanacağını belirlemek için kullanılır. Piksellerin ortalaması veya maksimum değeri, temsili değer olarak kullanılır. Ortalama ve

maksimum havuzlama yöntemleri, havuzlama işlemlerinde en yaygın kullanılan yöntemlerdir. Maksimum havuzlama yönteminde en yüksek değer alınırken, ortalama havuzlama yönteminde piksellerin ortalama değeri alınır. [22]. Şekil 2.13'te havuzlama katmanı gösterilmiştir.



Şekil 2.13: Havuzlama katmanı [21].

#### 2.7.1.5. Normalizasyon katmanı

Normalizasyon katmanı diğer katmanlardan gelen verileri düzenlemek için kullanılır. Normalizasyon katmanı ağırlık verileri daha düzenli bir hale getirmesini sağlayarak yapay sinir ağının performansını yükseltmesini sağlar.

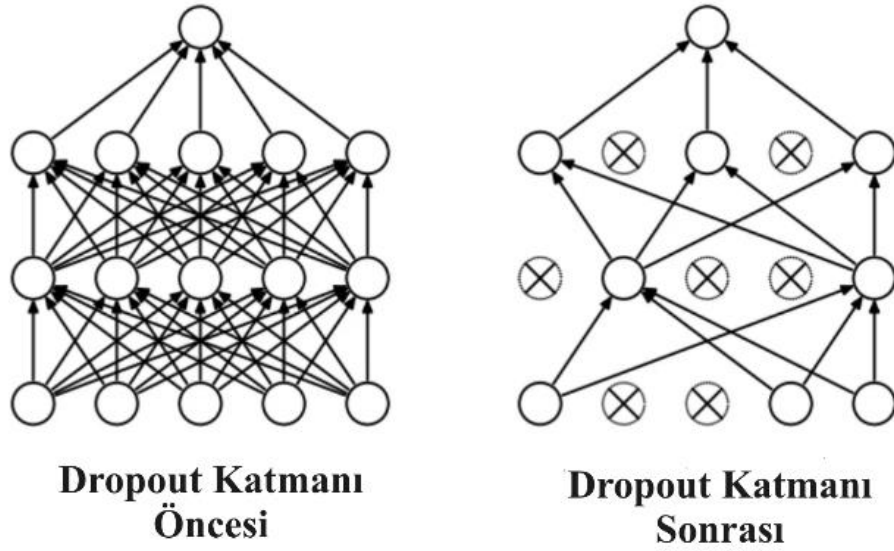
#### 2.7.1.6. Tam bağlı katman

Tam bağlı katman kendisinden önceki katmanlardan iletilen verilerin tek boyutlu matris haline dönüştürüldüğü, sonuçları optimize etmeye çalışan katmandır. Geri yayılım algoritması ile ağırlıkların güncellendiği ve öğrenmenin optimize edilmeye çalışıldığı katmandır. [27].

#### 2.7.1.7. Seyreltme (dropout) katmanı

Seyreltme katmanı yapay sinir ağının yapısındaki bazı düğümleri kaldırarak yapıyı seyreltme işlemini yapar. Yapay sinir ağının ezberlemesine engel olmasını sağlayan

katmandır. Bu katman, ağıın ezber yapan nöronlarını belirli bir oranda ortadan kaldırarak çalışır [28]. Şekil 2.14'te Dropout katmanı gösterilmiştir.



Şekil 2.14. Dropout katmanı [29].

#### 2.7.1.8. Softmax katmanı

Derin öğrenme modelleri, sınıflar arasında olasılıksal değer üretimi gerçekleştirir. Her sınıfa atanan olasılıklar ondalık değerlerdir ve toplamaları her zaman 1 olmalıdır.

#### 2.7.1.9. Sınıflandırma katmanı

Derin öğrenme modellerinde genellikle sınıflandırma katmanı softmax katmanından sonra yer alır. Bu katmanın çıktı değeri, oluşturulan sınıf sayısıdır [26].

#### 2.7.2. Derin öğrenme mimari yapıları

Derin öğrenme modellerinin kendine has mimari yapıları bulunur. En çok kullanılan derin öğrenme mimari yapıları hakkında genel bilgiler aşağıda verilmiştir.



### **2.7.2.1. Evrişimli sinir ağıları**

Derin öğrenmenin en temel mimarisi olan evrişimli sinir ağıları görüntü işleme ve ses işleme uygulamalarında kullanılan, verileri matris formatında filtreler ile işleyen sinir ağılarıdır. Biyomedikal alanında özellikle görüntü işlemede sıkça bu yöntem kullanılmaktadır. Yapısında temel olarak evrişim katmanı, tam bağlı katman ve havuzlama katmanı bulunur. Girdi olarak görüntüler öncelikle bilgisayar tarafından işlenebilmesi için uygun şekilde matris formatına dönüştürülür. Her bir matristeki farklılıklar tespit edilerek hangi görüntünün hangi etikete uygun olduğu belirlenir. Etiketler sayesinde bu bilgileri kullanarak gelecekteki görüntüler için varsayımlarda bulunur. 2012 yılında ImageNet yarışmasından sonra evrişimli sinir ağıları popüler hale gelmiştir ve birçok alanda geliştirmeye ve kullanılmaya başlanmıştır.

### **2.7.2.2. Tekrarlayan sinir ağı**

Bir dizide yer alan ve aynı görevi gerçekleştiren her bir öğrenin, bir önceki çıktıya göre yerine getirmesi gereken göre “yinelenen” olarak adlandırılır. Öğeler arası bir döngü oluşturulmuş yapay sinir ağı sınıflarından biridir. Ek sınıf ve bilgi gereksinimine ihtiyaç duymadan bir önceki çıktıdaki verileri kullanarak gelecekteki veri dizinlerini tahmin etmektedir. Özellikle ses ve metin gibi verilerde çok etkili şekilde kullanılmaktadır ancak uzun ve ardışık dizilerde eğitmek biraz daha zordur.

### **2.7.2.3. Derin inanç ağı**

Genellikle görüntü tanıma ve üretme konularında kullanılan bu mimari oldukça karmaşık üretken bir sinir ağı olarak bilinmektedir. Gizli değişkenlerin katmanlarından olasılıksal bir model oluşturmaktadır.

### **2.7.2.4. Oto-kodlayıcılar**

İleri beslemeli sinir ağı olan bu mimarinin amacı veri setinin boyutunu indirgemektir. Girdi verisinin en iyi özelliklerinin öğrenerek indirgenmiş bir yapı üzerinde çalışmaktadır.

### **2.7.2.5. Derin nöron ağlar**

Derin nöron ağlar denetimli ve denetimsiz ön eğitim tekniği kullanılarak başlatılırlar. Derin nöron ağlar birçok gizli katmana sahiptir.

### **2.7.2.6. Boltzmann makineleri**

Boltzmann makineleri iç temsilleri öğrenebilen ilk sinir ağlarından biri olarak bilinirler. Hopfield ağlarının stokastik üretken karşılığı olarak kabul edilmektedirler.

### **2.7.2.7. Kısıtlı boltzmann makinesi**

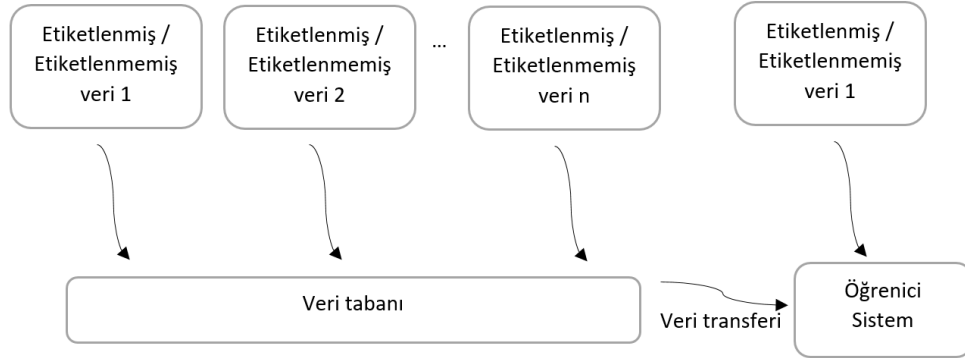
Kısıtlı boltzmann makinesi girdi olarak gösterilen veri setinin üzerindeki olasılıkların dağılımını öğrenebilen bir ağıdır. Görünür ve gizli katmanları arasında simetrik bağlantılar bulunur [22].

## **2.8. Öğrenme Aktarımı (Transfer Learning)**

Derin öğrenme alanındaki son gelişmeler, görüntü işleme, sayısal veri analizi ve tahminleri, doğal dil işleme ve ses tanıma gibi farklı alanlarda çeşitli kullanımlar ve uygulamalar sunmaktadır. Ancak derin öğrenme, zorlu eğitim süreçleri ve kapsamlı eğitim verisi gereksinimi gibi maliyetlerle birlikte karşımıza çıkmaktadır. Öğrenme aktarımı, öğrenme maliyetlerini azaltmak için başka bir öğrenmeden ve veri kümesinden elde edilen bilginin kullanılmasıyla ilgilidir. İnsanlar günlük yaşantılarında öğrendikleri bilgileri kullanarak yeni durumlara aktarır ve yeni durumu öğrenmesi kolaylaşır. Öğrenme aktarımı makine öğrenmesi yöntemlerinin de aynı şekilde problemi çözerken elde edilen bilginin, başka bir problem ile karşılaşıldığında o bilginin kullanılmasıdır. Örneğin, COVID-19 pandemisinin başlangıcında ve hatta bir yıl içinde, bir derin öğrenme modelini eğitmek için yeterli göğüs röntgeni verisi sağlamak hala zordu, ancak transfer öğrenmesi kullanıldığında, yapay zeka sınırlı bir eğitim seti ile hastalığı çok yüksek bir doğrulukla tespit etmeyi başarmıştır. Öğrenme aktarımı araştırma alanı, derin öğrenme modellerinin kapsamlı veriye bağımlılık ve eğitim maliyetleri gibi sınırlamalarını ele alma motivasyonu nedeniyle gelişmektedir. Ana fikir, kaynak verilerden elde edilen bilginin hedef veriler üzerindeki eğitim sürecinde kullanılmasıdır. Öğrenme aktarımının amacı yapay zekayı gerçeğe bir adım daha yaklaştıran sürekli öğrenmeyi başarmaktır. Öğrenme aktarımı mevcut algoritmaların

daha kısa zamanda, daha az veri ile daha yüksek performans elde edebilmesi için kullanılan bir tekniktir.

Şekil 2.15'te öğrenme aktarımı algoritması gösterilmiştir.



Şekil 2.15. Öğrenme aktarımı algoritması [58].

## 2.9. Literatür Araştırması

Literatürdeki araştırmalar incelendiğinde, derin öğrenme ile X-Ray görüntülerini kullanarak yapılan uygulamalarda evrişimli sinir ağı tabanlı modellerin kullanıldığı görülmektedir. Evrişimli sinir ağları, hastalık tespiti alanında umut verici sonuçlar sunmuştur. Özellikle önceden eğitilmiş evrişimli sinir ağı modellerinin, COVID-19'un teşhis edilmesinde başarılı sonuçlar verdiği gözlemlenmektedir. Yapılan çalışmalarda, derin öğrenme modelleri ve sonuçları üzerine detaylı incelemeler yapılmıştır.

Öztürk ve arkadaşlarının çalışmasında COVID-19 pandemisi ve derin öğrenme hakkında bilgiler vermiştir. Ortalama yaşları 55 olan 82 erkek 43 kadından elde edilen 125 adet COVID-19, 500 adet normal ve 500 adet pnömoni teşhisi konmuş göğüs röntgen görüntüleri kullanılmıştır. Sıfırdan bir sistem geliştirmek yerine, daha önce başarısı kanıtlanmış, nesne tespiti için tasarlanmış son teknoloji mimariye sahip Darknet mimarisinden ilham alınarak, DarkNet temelli DarkCovidNet modeli sunulmuştur. DarkNet modeli hakkında bilgiler verilmiştir. Yeni sunulan bu modelde, DarkNet mimarisine kıyasla daha az katman ve filtre kullanılmıştır. DarkCovidNet modeli 100 epoch değeri ile eğitilmiştir. Bu modelde 17 katman uygulanmış, doğruluk, kesinlik, duyarlılık ve F1 puanı sonuçları analiz edilmiştir. DarkCovidNet modeli COVID-19 ve

normal vakaları ayırt etmek üzere 2 sınıflı, COVID-19, pnömoni ve normal vakaları ayırt etmek üzere 3 sınıflı iki adet sınıflandırma çalışması yapılmıştır. DarkCovidNet modeli ikili sınıflandırmada %98,09 üçlü sınıflandırmada %87,02 doğruluk oranı elde etmiştir. Çalışmanın sonuçları hakkında bir uzman radyoloğun analizine yer verilmiştir. Uzman Radyolog modelin COVID-19 vakalarını tespit etmede çok başarılı olduğundan, ikili sınıflandırmada olağanüstü başarılı olduğundan, üçlü sınıflandırmada ise sistemin bazı COVID-19 vakalarını pnömoni vakalarından ayırt etmede biraz zorlandığından, bu durumun kabul edilebileceğinden, sistemin COVID-19 vakalarını belirlemede kullanılabileceğinden bahsetmiştir. Çalışmada sınırlı sayıda veri olmasının çalışmayı sınırladığı etmenlerden olduğundan, veri miktarı yükseldikçe başarı oranının yükseleceğinden bahsedilmiştir. Bu modelin hastanelerde kullanılarak hekimlerin iş yükünü hafifleteceğini ve kısa sürede vaka tespiti için çok faydalı olabileceği sonucuna varılmıştır [3].

Ouchicha ve arkadaşlarının çalışmasında göğüs röntgeni görüntülerini kullanarak COVID-19 enfeksiyonunu normal ve pnömoni vakalarından ayırıp sınıflandırmak için evrişimli sinir ağı modeli olan CVDNet modeli sunulmuştur. Önerilen mimaride farklı çekirdek boyutlarında iki paralel katman kullanılarak oluşturulmuştur. Çalışmada CVDNet yapısı ve katmanları hakkında bilgiler verilmiştir. Bu model, Kaggle'ın COVID-19 Radyografi veritabanından elde edilen 219 COVID-19, 1341 normal ve 1345 pnömoni teşhisli göğüs röntgeni görüntüsü içeren kamuya açık bir veri kümesi üzerinde eğitilmiştir. Bu veri setinin %70'i eğitim, %10'u doğrulama ve %20'si test için kullanılmıştır. Eğitim 20 epoch değeri ile tamamlanmıştır ve modelin doğruluk, kesinlik, duyarlılık ve F1 puanı sonuçları analiz edilmiştir. CVDNet'in COVID-19'u tespit etmek için ortalama %97,20'lik bir doğruluk ve üç sınıflı sınıflandırma için ortalama %96,69'luk bir doğruluk elde ettiği gözlemlenmiştir. Önerilen modelin COVID-19 vakalarını sınıflandırmada üstün ve umut verici bir performans sergilediği gözlemlenmiş, radyologlara COVID-19 teşhisinde yardımcı olabilecek etkili bir model olduğu sonucuna varılmıştır [4].

İsmail ve Şengür yaptıkları çalışmada CVDNet modelini sunmuştur. Toplam 180 COVID-19 ve 200 normal göğüs röntgeni görüntüleri kamuya açık üç farklı kaynaktan toplanmıştır. Göğüs röntgeni görüntülerinin etiketlenmesi uzman doktorlar tarafından gerçekleştirilmiştir. Çalışmanın %75'i eğitim kalan %25'i ise önerilen yöntemi test

etmek için kullanılmıştır. Ayrıca, sınıflandırma amacıyla Gauss, Doğrusal, Kübik ve Kuadratik olmak üzere dört kernel fonksiyonu ile DVM (Destek Vektör Makinesi) sınıflandırıcı yöntemi kullanılmıştır. Çalışmada Destek Vektör Makinesi sınıflandırıcısı hakkında bilgi verilmiştir. Çalışmanın deneylerinde VGG16, VGG19, ResNet18, ResNet50 ve ResNet101 olmak üzere önceden eğitilmiş beş evrişimli sinirağı modeli kullanılmıştır. Görüntüler evrişimli sinir ağı modelleriyle uyumlu olabilmesi için başlangıçta 224×224 piksel olarak yeniden boyutlandırılmıştır. Derin öğrenme MATLAB yazılımı ile gerçekleştirilmiştir. ResNet50 modelinin %92,6 VGG16 modelinin %89,8 ortal ResNet101 modelinin %89,5 VGG19 modelinin %88,1 ve ResNet18 modelinin %87,4 ortalama doğruluk puanları elde ettiği gözlemlenmiştir. Sonuçlar çekirdek fonksiyonları açısından incelendiğinde, en iyi ortalama doğruluk skorunun %90,3 ile Kübik çekirdek fonksiyonu tarafından üretildiği görülmektedir. İkinci en iyi ortalama doğruluk skoru %89,5 ile Doğrusal çekirdek tabanlı DVM sınıflandırıcı tarafından üretilmiştir. Kuadratik çekirdek ve Gauss çekirdeğine dayalı DVM sınıflandırıcıları aynı %89,1 doğruluk skorlarını üretmiştir. CVDNet'in COVID-19'u tespit etmek için ortalama %97,20'lik bir doğruluk ve üç sınıflı sınıflandırma (COVID-19, normal ve pnömoni) için ortalama %96,69'luk bir doğruluk oranı elde ettiği ve COVID-19 vakalarını sınıflandırmada umut verici bir performans sergilediği gözlemlenmiştir [31].

Hemdan ve arkadaşları çalışmasında evrişimli sinir ağlarının X-ray görüntü sınıflandırmasında tüberküloz taramasında ve tomografi görüntülerinde mediastinal lenf düğümleri gibi yaygın göğüs hastalıklarını teşhis etmede başarılı olduklarını belirtmiş, ve bu derin öğrenme tekniklerin COVID-19'u da teşhis edebileceğini düşünüp COVIDX-Net modelini sunmuştur. COVIDX-Net modeli önceden eğitilmiş Xception, VGG19, MobileNetV2, ResNet201, DenseNet201, ResnetV2, InceptionV3, InceptionResNetV2 modellerini içermektedir. Kullandıkları veri seti 25 adet COVID-19 teşhis edilen, 50 adet normal göğüs röntgen görüntüsü içermektedir. Bu çalışmada negatif ve pozitif COVID-19 vakalarını sınıflandırmak için kullanılan X-ray görüntülerinin kamuya açık veri seti Dr. Joseph Cohen ve Dr. Adrian Rosebrock2 tarafından sağlanmıştır. Tüm X-ray görüntüleri tek bir veri kümesinde toplanmış ve derin öğrenme işlem hattında daha fazla işlemeye uygun olması için 224 x 224 piksel sabit boyutta ölçeklendirilmek üzere yüklenmiştir. Veri setinin %80'i eğitim %20'si test için kullanılmıştır. Eğitim 50 epoch değeri ile tamamlanmıştır ve modelin doğruluk,

kesinlik, duyarlılık ve F1 puanı sonuçları analiz edilmiştir. Test edilen tüm modeller arasında VGG19 ve DenseNet201 modelleri en iyi doğruluk değerlerine %91 ile ulaşırken InceptionV3 modelinin doğruluğu %50 ile en başarısız sonucu vermiştir [32].

Narin ve arkadaşlarının çalışmasında COVID-19 hakkında bilgi verilmiş, hastanelerde sınırlı test olduğundan ve sebeple alternatif teşhis yöntemi olarak otomatik teşhis sisteminin geliştirilmesi gerektiğinden bahsedilmiştir. Çalışmada derin öğrenme hakkında bilgi verilmiş, derin öğrenmenin tıbbi veri setleriyle olan çalışmalarda başarılı sonuçlar verdiğiinden bahsedilmiştir. Derin öğrenmenin katmanları ve çalışmada kullanılan derin öğrenme modelleri hakkında bilgi verilmiş. Derin öğrenme programlaması Phyton programlama dili ile Google Colab sunucusunda uygulanmıştır. Dr. Joseph Paul Cohen ve arkadaşlarının paylaştığı 341 adet COVID-19 teşhisi konmuş röntgen görüntüsü, Kaggle “Chest X-Ray Images” veri tabanından 2800 adet normal, 2772 adet bakteriyel pnömoni, 1493 adet viral pnömoni kullanılan veri setlerinin %80’i eğitim %20’si test olarak kullanılmıştır. İterasyon 30, batch size 3 olarak uygulanmıştır ve modelin doğruluk, kesinlik, duyarlılık ve F1 puanı sonuçları analiz edilmiştir. Modeller COVID-19-normal, COVID-19-viral pnömoni ve COVID-19-bakteriyel pnömoni olmak üzere 3 farklı sınıfta eğitilmiştir. Karışıklık Matrisi ile sonuçlar değerlendirilmiştir Yapılan test sonucunda en başarılı modelin üç sınıfta ortalama %98.4 doğruluk ile Resnet50 olduğu belirtilmiştir [33].

Uçar ve Korkmaz yaptıkları çalışmada COVID-19 hastalığının tespit edilmesinde kullanılan PCR testi yönteminin dezavantajlarından bahsedilmiş, bu konuda yapay zeka temelli derin öğrenme yöntemlerinin kullanılmasının büyük fayda sağlayacağından bahsedilmiştir. Çalışmada SqueezeNet derin öğrenme modeli deaylı şekilde anlatılmış. Bayes optimizasyonu hakkında bilgi verilmiş ve Bayes optimizasyonlu SqueezeNet derin öğrenme modeli temelli COVIDiagnosis-Net modeli geliştirilmiştir. Veri seti 4290 pnömoni, 1583 normal, 76 COVID-19 vakası içermektedir. Bu veri setinin %80 i eğitim, %10’u validasyon, %10’u test için kullanılmıştır. Model COVID-19, normal ve pnömoni sonuçlarını veren 3 sınıflı olacak şekilde tasarlanmıştır. Derin öğrenme MATLAB üzerinde programlanmıştır. Yapılan testlerin sonuçları karışıklık matrisi analizi ile değerlendirilmiştir ve modelin doğruluk, kesinlik, duyarlılık ve F1 puanı sonuçları analiz edilmiştir. İlk test sonuçlarında ortalama doğruluk oranı %76,37 değerinde sonuçlanırken, Bayes optimizasyonu yapıldıktan sonra ortalama doğruluk

oranı %98,26'ya ulaşarak, Bayes optimizasyonunun ne kadar faydalı olduğunu ortaya koymaktadır. COVID-19 teşhisinde bu modelin oldukça başarılı sonuçlar ortaya koyduğu belirtilmiştir [34].

Panwar ve arkadaşlarının çalışmasında X-ray görüntülerini kullanarak COVID19 hastalarını tespit etmek için nCOVnet modelini önerilmiştir. Evrişimli sinir ağı tabanlı nCOVnet modelinin mimarisi hakkında detaylı bilgiler verilmiştir. Çalışmada kullanılan veri seti 142 COVID-19 teşhis edilen, 142 normal göğüs röntgen görüntüsü içermektedir. Veri setindeki görüntülerin boyutları farklı olduğundan hepsi 240x240 piksele dönüştürülmüştür. Veri setinin %70'i eğitim, %30'u test olarak kullanılmıştır. Elde edilen sonuçların karışıklık matrisi ve ROC analizi yapılmıştır. Eğitim 80 epoch değeri ile tamamlanmıştır ve modelin doğruluk, kesinlik, duyarlılık ve F1 puanı sonuçları analiz edilmiştir. nCOVnet modelinin COVID-19 vakası tahmin oranının %97,97 oranında başarılı şekilde gerçekleştiğinden bahsedilmiştir. Bu tahmin süresinin 5 saniyenin altında gerçekleştiğinden, 4-10 saat süren RT-PCR testine göre çok daha avantajlı olduğundan bahsedilmiştir [35].

Sethy ve Behara yaptıkları çalışmada (2020) X-Ray görüntüleri ile COVID-19 vakalarını tespit etmek için DenseNet201, GoogleNet, Inceptionresnetv2, Inceptionv3, Resnet18, Resnet101, Resnet 50, VGG19 ve VGG16 modelleri ile çalışmıştır. COVID-19 X-ışını görüntüleri, Montreal Üniversitesi'nde doktora sonrası araştırmacı olan Dr. Joseph Cohen tarafından paylaşılan GitHub deposundan toplanan 127 adet COVID-19, 127 adet normal ve 127 adet pnömoni teşhisi konulan göğüs röntgen görüntülerini içermektedir. Veri setinin %80'i eğitim %20'si test olarak kullanılmıştır. Çalışmada Destek Vektör Makinesi sınıflandırıcısı kullanılmıştır. Çalışma sonunda modelin doğruluk, kesinlik, duyarlılık ve F1 puanı sonuçları analiz edilmiştir. Çalışmada AlexNet %94.86, DenseNet201 %93.86, GoogleNet %91.73, InceptionResnetV2 %91.13, InceptionV3 %90.26, MobileNetV2 %94.46, ResNet18 %94.26, XceptionNet %93.00, ResNet101 %93.53, ShuffleNet %65.26, VGG16 %94.20, VGG19 %94.13, ResNet50 %95.33 doğruluk oranına ulaşmıştır. Sonuçlara göre ResNet50 modelinin en yüksek sınıflandırma doğruluğuna ulaştığı tespit edilmiştir. Bu yöntemin dezavantajının, hastanın kritik bir durumda olması ve X-Ray taramasına katılamaması olduğu belirtilmiştir [36].

Bozkurt'un yaptığı çalışmasında göğüs röntgeni görüntüleri ile tüberküloz, pnömoni ve fitik gibi çeşitli akciğer hastalıklarının teşhisinde kullanıldığından COVID-19 teşhisinde de kullanılabileceğinden bahsedilmiştir. COVID-19'un pnömoni ile benzer özelliklerde olduğundan ve karıştırılmaması gerektiğinden bahsedilmiştir. Çalışmada X-Ray görüntüleri ile COVID-19, pnömoni ve normal olarak sınıflandırılan 11 adet derin öğrenme modeli hakkında detaylı bilgiler verilmiş, eğitilen bu modellerin performansları değerlendirilmiş ve karşılaştırılmıştır. Çalışmada veri seti olarak Kaggle'dan sağlanan 1200 COVID-19, 1341 adet normal, 1345 pnömoni, teşhisli X-Ray görüntüleri kullanılmıştır. Kullanılan veri setinin %70'i eğitim, %10'u doğrulama, %20'si test olarak kullanılmıştır. Eğitim 50 epoch değeri ile tamamlanmıştır ve modelin doğruluk, kesinlik, duyarlılık ve F1 puanı değerlendirilmiş ve ROC analizi yapılmıştır. Çalışma sonucunda Sığ-Tam Bağlı Ağ Modeli %90,62, Derin-Tam Bağlı Ağ Modeli %92,03, Sığ-Evrişimli Ağ Modeli %94,73, Derin-Evrişimli Ağ Modeli %96,02, Alexnet modeli %95,76, VGG16 modeli %95,76, VGG19 modeli %95,50, Resnet50 modeli %93,32, InceptionV3 modeli %93,70, Xception modeli %95,50, DenseNet121 modeli %97,17 doğruluk oranı elde etmiştir. En yüksek başarı oranı DenseNet121 modeli %97,17 doğruluk oranı elde edilmiştir. DenseNet121 modelinin diğer modellere göre daha iyi performans gösterdiği gözlemlenmiştir. DenseNet121 modelinin 50 epoch için eğitim/test doğruluk ve eğitim/test kayıp grafikleri verilmiştir. Hem test hem de eğitim doğruluk eğrileri, epoch sayısı arttıkça yükselen bir başarı göstermiştir. Önerilen modelin başarılı olduğu ve COVID-19 tespit edebilmek için kullanılabileceği sonucuna ulaşılmıştır [37].

Pandit ve arkadaşlarının çalışmasında COVID-19 vakalarının teşhisi için amacıyla VGG-16 derin öğrenme modelini kullanmıştır. Çalışmada transfer learning ve VGG-16 mimarisinin detaylarından bahsedilmiştir. Kaggle'dan sağlanan veri seti 224 adet COVID-19, 504 adet normal ve 700 adet pnömoni teşhisi konulan göğüs röntgen görüntülerini içermektedir. Bu veri setinin %70'i eğitim %30'u test olarak 25 epoch değeri ile eğitilmiştir. Model COVID-19 ve sağlıklı ile COVID-19, sağlıklı ve pnömoni teşhisli olmak üzere iki ayrı şekilde eğitilmiştir. Eğitim 25 epoch değeri ile tamamlanmıştır ve modelin doğruluk, kesinlik, duyarlılık ve F1 puanı sonuçları analiz edilmiştir. Modelin ikili (COVID-19 ve normal) sınıflandırmada %96, üçlü (COVID-19, normal ve pnömoni) sınıflandırmada %92,5 başarı oranı elde edildiği gözlemlenmiştir. Çalışmanın sonuçları başka çalışmaların sonuçları ile kıyaslanmıştır.



Bu çalışmanın, sağlık çalışanlarının zamanında daha iyi tespit ederek ve hastalığın varlığını tarayarak COVID-19 hastalarını tedavi etmelerine yardımcı olabilecek bir yöntem olduğundan bahsedilmiştir [38].

Horry ve arkadaşlarının çalışmasında en sık kullanılan üç tıbbi görüntüleme yöntemi olan X-Ray, Ultrason ve Bilgisayarlı Tomografi görüntüleri kullanılarak, derin öğrenme modelleri geliştirilmiştir. Çalışmada VGG16, VGG19, Resnet50-V2, Inception V3, Xception, Inceptionresnet V2, Nasnetlarge, Densenet121 mimarilerinden bahsedilmiştir. Görüntüler kamuya açık kaynaklardan toplanmıştır. Veri setinde 115 COVID-19, 322 pnömoni, 60361 normal teşhisli X-Ray görüntüleri, 349 COVID-19 ve 397 normal teşhisli Bilgisayarlı Tomografi görüntüleri, 654 COVID-19, 277 pnömoni ve 172 normal teşhisli Ultrason görüntüleri bulunmaktadır. Her bir görüntüleme yöntemi ile ayrı ayrı derin öğrenme modelleri üzerinde çalışılmıştır. Veri setlerinin %80'i eğitim, %20'si test amaçlı kullanılmıştır. Bu modeller 5 kez 100 epoch değeri ile eğitilmiştir ve modelin doğruluk, kesinlik, duyarlılık ve F1 puanı sonuçları analiz edilmiştir. Genel olarak sonuçlar analiz edildiğinde en başarılı modelin ultrason görüntüleri ile eğitilen VGG-19 modeli olduğu ve bu modelin teşhis amaçlı başarılı şekilde kullanılabilmesinden bahsedilmiştir. Derin öğrenme modellerinin ultrason görüntü moduyla son derece iyi performans gösterdiğini gözlemlenmiştir. Röntgen ve Ultrason makineleri gibi kolaylıkla bulunabilen ve taşınabilir tıbbi görüntüleme ekipmanlarından COVID-19'u teşhis edebilme yeteneğinin hastalığın teşhisinde ve yayılmasını önlenmesinde önemli faydalar sağlayabileceğinden bahsedilmiştir [39].

Yapılan çalışmalarda veri setlerinin halka açık olarak yayınlanan Kaggle kaynaklı olduğu gözlemlenmektedir. Çalışmaların hepsinde COVID-19 pandemisi ve derin öğrenme modelleri hakkında detaylı bilgiler verilmiştir. Çalışmalarda evrişimli sinir ağları kullanılmıştır. Bazı çalışmalarda daha önceden kullanılmış olan derin öğrenme modelleri geliştirilerek COVID-19 teşhisi için model geliştirilmiştir. Öztürk ve arkadaşları [3] DarkNet modelini temel alarak DarkCovidNet modelini, Uçar ve Korkmaz [34] SqueezeNet modelini temel alarak COVIDiagnosis-Net modelini geliştirmiştir. İsmail ve Şengür [31] ile Sethy ve Behara [36] diğerlerinden farklı olarak DVM (Destek Vektör Makinesi) sınıflandırıcı kullanmıştır. Bazı çalışmalarda (İsmail ve Şengür [31], Bozkurt [37], Panwar ve arkadaşları [35]) ROC analizi yapılmıştır. Yapılan çalışmaların hepsinde karışıklık matrisi, doğruluk, kesinlik,

duyarlılık ve F1 puanı sonuçları analiz edilmiştir. Geliştirilen modellerin hepsinde karışıklık matrisi analizi yapılmıştır. Modellerin eğitimi genel olarak 50-100 epoch değeri aralığında tamamlanmıştır. Horry ve arkadaşları [31] diğerlerinden farklı olarak ultrason görüntüleri ile de derin öğrenme modelleri geliştirmiştir ve bu modeller çok başarılı sonuçlar vermiştir. Bu tez çalışması ultrason görüntülerinin de COVID-19 tespitinde etkin rol oynayabileceğini göstermiştir. Genel olarak bütün çalışmalarda COVID-19 teşhisi için başarılı sonuçlar veren modeller geliştirilmiş ve bu modellerin salgının yayılımının önlenmesinde çok faydalı olabilecekleri, sağlık sistemine çok önemli katkılar sağlayabilecekleri belirtilmiştir.



## BÖLÜM 3. MATERYAL VE YÖNTEM

Bu çalışmada, X-Ray görüntüleri ile derin öğrenme metotları kullanılarak COVID-19 vakalarının tespiti amaçlanmıştır. Evrişimli sinir ağır tabanlı CNN, VGG19, Xception, Alexnet ve Resnet50 derin öğrenme modelleri ile COVID-19, Normal ve Pnömoni sınıfları arasında doğru sınıflandırmalar yapılması amaçlanmıştır.













### 3.1. Veri Seti

Derin öğrenme yöntemlerinde en önemli unsurlardan biri veri setidir. Doğru seçilen veri seti ile yapılan çalışmalar çok daha başarılı sonuçlar vermektedir. Derin öğrenme uygulamalarının başarı sonucu veri seti miktarı ve kalitesiyle doğru orantılıdır. Bu tez çalışmasında derin öğrenme uygulaması için Joseph Paul Cohen ve ekibi ile Core COVID-Net Team ekibinin kamuya açık kaynaklardan toplayıp derledikleri ve sundukları “Chest X-Ray” veri seti kullanılmıştır. Derin öğrenme uygulamaları yüksek miktarda veri gerektirmektedir. Çalışmada 576 adet COVID-19 pozitif, 1583 adet normal ve 4273 adet pnömoni teşhisi olan toplamda 6432 adet adet göğüs röntgen görüntüsü içeren veri seti kullanılmıştır [40]. COVID-19 vakalarını tespit edebilmek için derin öğrenme kullanılan bu çalışmada programlama Google Colaboratory ortamında gerçekleştirilmiştir. Google Colabrotary derin öğrenme projeleri üzerinde çalışmaya imkan sunan, tamamen bulut tabanlı bir programlama ortamıdır. Google Colabrotary sunduğu özellikler sayesinde bu veri seti ile çalışmaya imkan sağlamaktadır. Tablo 3.1’de veri seti özeti, tablo 3.2’de veri setinden örnek görüntüler bulunmaktadır.

Tablo 3.1: Veri seti.

Veri Seti	COVID-19	Normal	Pnömoni	Toplam
Test	116	317	855	1288
Eğitim	460	1266	3418	5144
Toplam	576	1583	4273	6432

Tablo 3.2: Veri setinde bulunan sınıflara ait X-Ray görüntü örnekleri

COVID-19	NORMAL	PNÖMONİ
		
		
		
		

### **3.2. Derin Öğrenme Uygulamasında Kullanılan Programlama Dili**

COVID-19 vakalarını tespit edebilmek için derin öğrenme kullanılan bu çalışmada, yapay zeka ve derin öğrenme yöntemlerinde en yaygın kullanılan programlama dili Python kullanılmıştır. Python açık kaynaklı, basit söz dizilimlerine sahip bir programlama dilidir. Python, okunaklı ve anlaşılır bir dil olduğu için, derin öğrenme algoritmalarının kodlarını yazmak ve anlamak kolaydır. Python dili için, TensorFlow, Keras, PyTorch gibi hazırlanmış kütüphaneler mevcuttur. Bu kütüphaneler, derin öğrenme modellerinin eğitilmesi ve test edilmesi için gereken işlemleri kolaylaştırmaktadır.

### **3.3. Derin Öğrenme Uygulamalarında Kullanılan Programlama Kütüphaneleri**

Derin öğrenme uygulamalarının yapılabilmesi için Python dilinde yazılan çeşitli kütüphaneler kullanılmaktadır.

Keras, TensorFlow ve Theano için kullanılan bir arayüz sağlar. Francois Chollet tarafından geliştirilmiştir. Keras, optimize edilmiş gelişmiş algoritmaları destekler ve aynı zamanda normalleştirme rutinleri ve çeşitli aktivasyon fonksiyonlarıyla birlikte en iyi seçenekleri sunar. Her ne kadar TensorFlow ve Theano tarafından desteklense de, bu iki kütüphane arka planda farklı boyutlarda giriş verileri kullanır. Bu nedenle, Keras'ın her iki kütüphaneyle de uyumlu çalışabilmesi için dikkatlice tasarlanması gerekmektedir [41].

Tensorflow Google araştırmacıları olarak bilinen “Google Brain” ekibi tarafından 2011 yılında geliştirilen bir derin öğrenme kütüphanesidir. Bu öncü grup, ilk olarak DistBelief makine öğrenme sistemini oluşturmuştur. DistBelief, öğretmensiz öğrenme, dil çevirisi, görüntü sınıflandırması, nesne tespiti ve sınıflandırması, ses tanıma ve takviyeli öğrenme gibi birçok alanda kullanılmıştır. Zamanla, makine öğrenimini çok daha verimli hale getirmek amacıyla TensorFlow adında ikinci nesil bir derin öğrenme kütüphanesi geliştirilmiştir. Bu kütüphane, veri akış grafikleri olarak adlandırılan bir dizi hesaplamadan oluşan bir yapıya sahiptir. Bu veri akış grafikleri, düğümlerin durumunu koruma, güncelleme, dallanma ve döngü kontrolü gibi işlemleri gerçekleştirerek veri akışı tabanlı hesaplamaları sağlar. Her bir düğüm, işlemi temsil eder ve 0 veya daha fazla girişe, 0 veya daha fazla çıkışa sahiptir. TensorFlow, açık

kaynaklı bir kütüphaneye sahip olup geniş bir kullanım alanına yönelik olarak tasarlanmıştır. Mobil cihazlar, tabletler, telefonlar, büyük ölçekli dağıtık sistemler ve GPU kartları gibi çeşitli hesaplama cihazlarında kullanılabilir

Numpy, açık kaynaklı ve numerik bir kütüphanedir. Python programlama dilinde diziler ve matrislerle çalışmayı kolaylaştırır. Matematiksel işlemleri verimli bir şekilde gerçekleştirir ve giriş verilerinin işlenmesi öncesinde hazırlık yapar.

Pandas veri analizini hızlandırmak amacıyla kullanılan, açık kaynaklı Python dilinde yazılmış olan kütüphanesidir. Verileri işleyerek sisteme uygun bir formata dönüştürme işlemlerini gerçekleştirir.


Matplotlib sistem verilerinin görselleştirilmesini, iki ve üç boyutlu çizimlerin yapılmasını sağlayan Python kütüphanesidir [42].

### **3.4. Çalışmada Kullanılan Derin Öğrenme Modelleri**

Bu tez çalışmasında X-Ray görüntüleri ile COVID-19 vakalarını tespit edebilen model geliştirmek için evrişimli sinir ağları tabanlı 5 adet derin öğrenme modeli kullanılmıştır.

#### **3.4.1. CNN modeli**


Görüntü sınıflandırma işlemleri için kullanılan bir derin sinir ağı mimarisidir. Giriş olarak verilen görüntüler, bilgisayar tarafından tanınması ve işlenebilmesi için uygun bir formata dönüştürülür. Bu dönüşüm sürecinde, görüntüler matris formatına çevrilir. Sistem, matrislerdeki farklılıkları analiz eder ve görüntüleri sınıflandırılmasını sağlar. Eğitim aşamasında, farklılıkların etiket üzerindeki etkisini öğrenir ve bu bilgiyi kullanarak yeni görüntüler için tahminlerde bulunur. Evrişimli sinir ağları, görüntü işleme uygulamalarında başarılı sonuçlar elde etmiştir. Biyomedikal alanda yapılan görüntü işleme çalışmalarında Evrişimli Sinir Ağları oldukça sık kullanılmaktadır [22]. Yapısında farklı işlevlerde birçok katman bulunur. Bu katmanlar birbirlerini takip edecek şekilde dizilip Evrişimli Sinir Ağlarını oluşturur. Bu yapının ilk katmanlarında öznitelik çıkarım işlemleri, son katmanlarında ise sınıflandırma işlemleri gerçekleştirilir [48]. Şekil 3.6. CNN model mimarisi gösterilmiştir.



Şekil 3.6: CNN model mimarisi [49].

### 3.4.2. Alexnet modeli


Alex Krizhevsky tarafından geliştirilmiştir. Yapısında giriş katmanı, 5 konvolüsyon katmanı, 7 ReLU katmanı, 3 havuzlama katmanı, 2 seyreltme katmanı, 3 tam bağlı katman, 2 normalizasyon katmanı, softmax katmanı ve çıkış katmanı olmak üzere 25 adet katmandan oluşmaktadır. Imagenet yarışmasında %83,6 doğruluk oranı elde ederek derin öğrenmenin popüler hale gelmesinde büyük katkı sağlamıştır [50]. Şekil 3.7. Alexnet modeli gösterilmiştir.



Şekil 3.7: Alexnet model mimarisi [51].

### 3.4.3. VGG19 modeli

CNN derinliğini arttırarak sınıflandırma sonucunun iyileşmesi amacıyla Visual Geometry Group tarafından geliştirilmiş 19 katmanlı modeldir. Adındaki 19 bu katmanların sayısı dolayısıyla verilmiştir. VGG19 modeli yaklaşık 144 milyon parameter içermektedir. Bu modeled parameter sayısını azaltmak için tüm katmanlarda 3x3'lük küçük filtreler kullanılmıştır. VGG19 modeli Imagenet yarışmasında bir milyondan fazla görüntü üzerinde eğitilmiştir ve %92,7 doğruluk oranı ederek başarılı performans sergilemiştir [52]. Şekil 3.8. VGG19 model mimarisi gösterilmiştir.




Şekil 3.8: VGG19 model mimarisi. [52]

### 3.4.4. Resnet50 modeli

Resnet50 modeli 50 adet katmana sahip olduğu için bu ism almıştır. Yapısında sırasıyla 1x1 evrişim katmanı, 3x3 evrişim katmanı ve 1x1'lik evrişim katmanları bulunur. Parametre sayıları düşürülerek hesaplama yükü hafifletilmiş, modelin hata payının büyük oranda azaltılması sağlanmıştır. Resnet50 modeli evrişimli sinir ağındaki performans düşmesi sorununu çözmek odaklı ortaya çıkmıştır [53]. Şekil 3.8. Resnet50 model mimarisi gösterilmiştir.

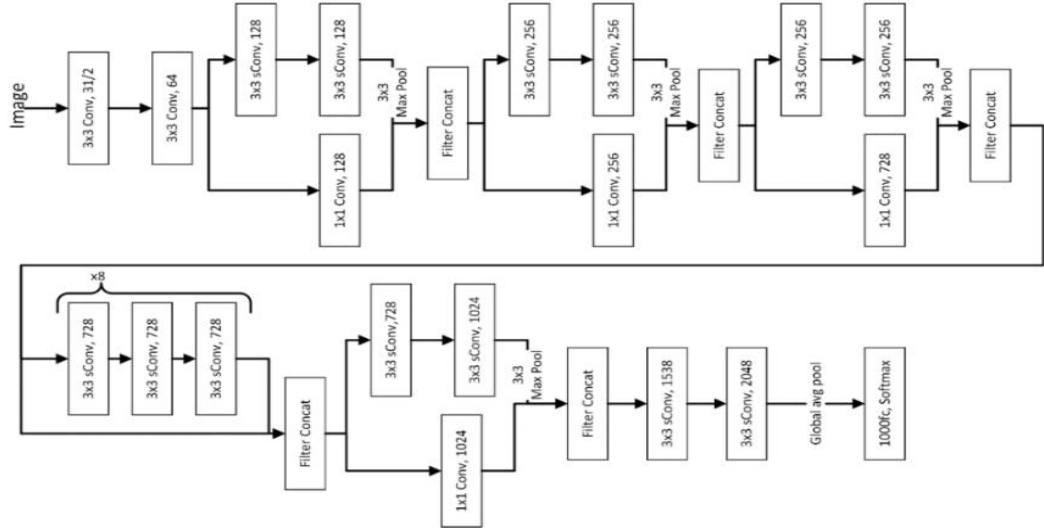




Şekil 3.9: Resnet50 model mimarisini [53].

### 3.4.5. Xception modeli

Inception mimari tabanlı olduğundan, "Extreme Inception" anlamına gelen Xception olarak adlandırılmıştır. Yapısında 71 adet katman mevcuttur. Xception modelinde önemli ölçüde işlem maliyetini azaltabilen derinlemesine ayrılabilir evrişim uygulanmıştır [54]. Şekil 3.10. Xception model mimarisini gösterilmiştir.



Şekil 3.10: Xception model mimarisini [55].

## 3.5. Derin Öğrenmede Kullanılan Hiperparametreler

Hiperparametreler, bir yapay sinir ağının veya makine öğrenme modelinin yapısını ve eğitim sürecini belirleyen parametrelerdir. Bu parametreler, eğitim öncesi ayarlanır ve modelin performansını etkiler. Hiperparametrelerin doğru bir şekilde ayarlanması, modelin eğitimini optimize etme ve genel performansını artırma açısından önemlidir.

### **3.5.1. Veri seti boyutu**

Veri seti miktarı yükseldikçe, öğrenme oranı yükselmektedir. Bu sebeple veri seti boyutu önemli bir parametredir. Miktar ve nitelik olarak yetersiz veri, öğrenmenin zayıf olmasına sebep olmaktadır. Bununla birlikte, yalnızca veri setinin büyüklüğü yeterli değildir, çeşitlilik de büyük önem taşır. Veri setinin çeşitliliği arttıkça, modelin performansı da artar.

### **3.5.2. Öğrenme oranı**

Öğrenme oranı parametresi, hız ve başarı oranı açısından büyük öneme sahiptir. Doğru öğrenme oranını seçmek kritiktir ve rastgele tahminler veya deneme yanılmalar yerine, modelin etkili bir şekilde öğrenebileceği bir öğrenme oranı belirlemek önemlidir.

### **3.5.3. Epoch (döngü) sayısı**

Eğitim sürecinde tüm eğitim verilerinin modele kaç kez sunulduğunu, modelin eğitiminin kaç döngüde tamamlandığını ifade eder. Model için doğru epoch sayısı, uygun bir uyum seviyesine ulaşmak için önemlidir. Düşük epoch sayısı, yetersiz uyum seviyesine neden olabilir. Modelin doğru şekilde eğitilebilmesi için optimum epoch sayısı ile eğitilmesi gerekir.

### **3.5.4. Batch size**

Modelin eğitimi esnasında aynı anda kaç adet verinin işleneceğini ifade eden veridir. Veri setinin alt kümeleri üzerinde eğitim yapmak, verilerin tamamının eğitilmesine nazaran daha hızlı etkileyen bir parametredir. Batch boyutu yüksek olduğunda, tek bir seferde işlenecek veri miktarı artar ve modelin ayrıntılara olan dikkati azalır. Batch boyutu çok düşük olduğunda detaylı inceleme artar ve bu durum eğitim sürecinin uzamasına sebep olur.

## **3.6. Model Değerlendirme Metrikleri**

Modellerin performanslarını değerlendirmede yaygın olarak kullanılan metriklerden biri performans ölçümleridir. Bu çalışmada sınıflandırma performansını belirlemek için

karışıklık matrisi sonuçlarından elde edilen doğruluk, kesinlik, duyarlılık ve F1 Puanı olmak üzere dört adet ölçüt kullanılmıştır. Modelin performans başarısı bu ölçütlerin sonuçlarının yüksekliği ile doğru orantılı olarak değişir. Tıbbi görüntüleme sistemlerine yönelik çalışmalarda bu değerlendirme metrikleri sıklıkla kullanılır. Bu çalışmada bu ölçütlerden faydalanılmıştır.

Derin öğrenme sonuçları analiz edilirken, sınıflandırma sonuçlarına göre doğru pozitif (TP), doğru negatif (TN), yanlış pozitif (FP) ve yanlış negatif (FN) olmak üzere dört farklı parametre kullanılır. TP gerçekte pozitif olup, modelin pozitif olarak tahmin ettiği veri miktarıdır. TN gerçekte negatif olup, modelin negatif olarak tahmin ettiği veri miktarıdır. FP gerçekte negatif olup, modelin pozitif olarak tahmin ettiği veri miktarıdır. FN gerçekte pozitif olup, modelin negatif olarak tahmin ettiği veri miktarıdır.

Doğruluk derin öğrenme sınıflandırıcıları için en önemli ölçüt olup, doğru olarak değerlendirilen örneklerin sayısını gösterir. Bu ölçüt, doğru pozitiflerin ve doğru negatiflerin toplamına bölünen karışıklık matrisi bileşenlerinin toplam değerlerinden oluşur. 3.1 numaralı denklemde doğruluğun matematiksel formülü gösterilmiştir.

$$\text{Doğruluk} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.1.)$$

Kesinlik derin öğrenme modellerinde doğru pozitifleri doğru olarak tahmin etme performansını analiz eder. Bu ölçüt, doğru pozitif ve yanlış pozitiflere bölünen doğru pozitiflerin sonucu ile bulunur. 3.2 numaralı denklemde kesinliğin matematiksel formülü gösterilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (3.2.)$$

Duyarlılık derin öğrenme modellerindeki doğru tanımlanmış pozitiflerin doğru pozitifler içindeki oranını ifade eder. Bu ölçüt, doğru pozitif ve yanlış negatiflere bölünen doğru pozitiflerin sonucu ile bulunur. 3.3 numaralı denklemde duyarlılığın matematiksel formülü gösterilmiştir.

$$Duyarluluk = \frac{TP}{TP+FN} \quad (3.3)$$

Derin öğrenme modellerinde F1 Puanı duyarlılık ve kesinlik arasındaki hassas dengeyi bulma amacını taşır. Duyarlılık ve kesinlik sonuçlarının harmonik ortalaması alınarak elde edilir. 3.4 numaralı denklemde F1 puanının matematiksel formülü gösterilmiştir.

$$F1 Puanı = \frac{2*Kesinlik*Duyarluluk}{Kesinlik+Duyarluluk} \quad (3.4)$$

Karışıklık matrisi, sınıflandırma probleminde elde edilen tahmin sonuçlarının özetini sunan bir araçtır. Derin öğrenmeyle gerçekleştirilen birçok sınıflandırma sistemi, performanslarını değerlendirmek için karışıklık matrisini kullanır. Bu matris, sınıflandırıcı tarafından yapılan hataların yanı sıra sistemdeki hata türleri hakkında da bilgi sağlar. Karışıklık matrisi, beklenen dört farklı sonuca dayanarak, sistemin sınıflandırma tahminlerini ve hata türlerini genel bir bakış açısıyla sunar [56].

Tablo 3.3: Karışıklık matrisi.

	<b>Tahmin Edilen Pozitif</b>	<b>Tahmin Edilen Negatif</b>
<b>Gerçek Pozitif</b>	Doğru Pozitif (TP)	Yanlış Negatif (FN)
<b>Gerçek Negatif</b>	Yanlış Pozitif (FP)	Doğru Negatif (TN)

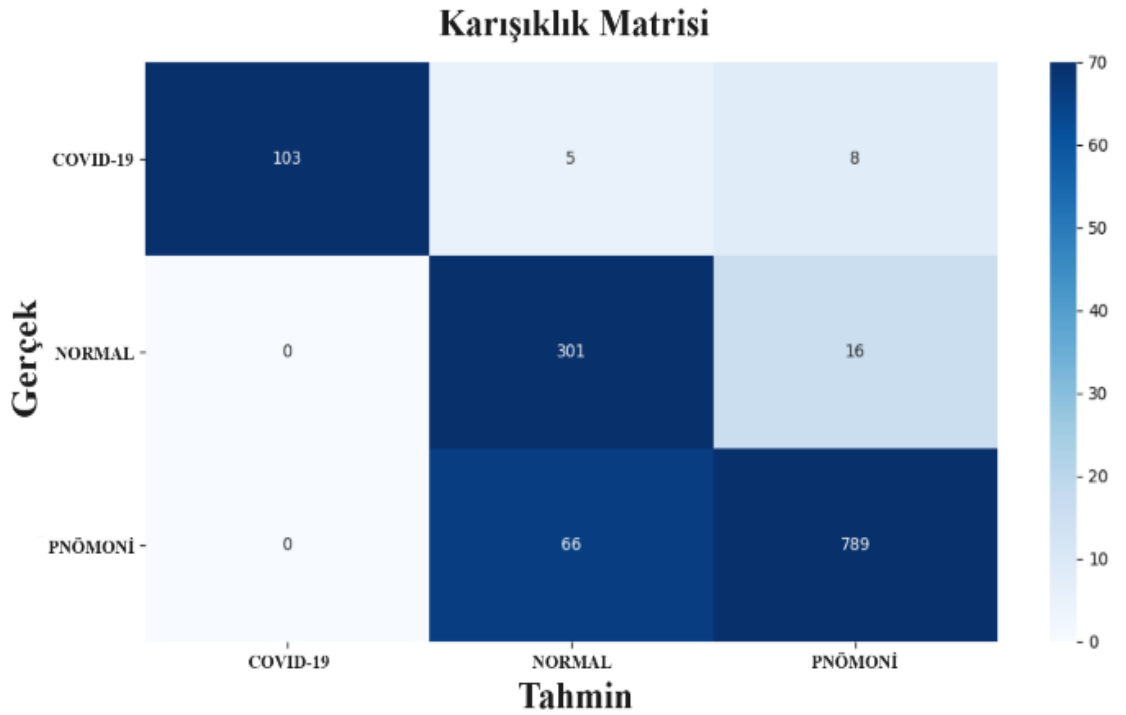
## **BÖLÜM 4. SONUÇLAR VE ÖNERİLER**

Medikal teşhis alanlarında yapay zeka tekniklerinin kullanımı önemli ölçüde artmıştır. Bu alanda derin öğrenme modellerine dayanan birçok çalışma yapılmış ve yeni modeller geliştirilmiştir. Yapılan çalışmalarda, COVID-19 pozitif vakalarını COVID-19 negatif vakalardan ayırt etmek yaygın olarak çalışılmıştır. Ancak, COVID-19 pozitif vakaları diğer akciğer hastalıklarından ayırt etmek büyük önem taşımaktadır. COVID-19 hastalığı ile pnömoni hastalığı benzer semptomlara sahip olmalarından dolayı teşhis edilirken birbirleri ile karıştırılmakta ve yanlış tedavi uygulanmasına sebep olabilmektedir. Bu nedenle bu çalışmada X-Ray görüntüleri kullanılarak COVID-19, pnömoni ve normal durumlar arasında çoklu sınıflandırma yapmak için yaygın olarak kullanılan derin öğrenme yöntemleriyle çalışılmıştır. COVID-19 virüsü negatif olarak bulunan sonuçlar normal adı altında sınıflandırılmıştır. Çalışmada göğüs X-Ray görüntüleri ile COVID-19 vakalarının tespit etmek ve sonuçları sınıflandırmak için CNN, VGG19, Xception, ResNet50 ve Alexnet derin öğrenme modelleri kullanılarak derin öğrenme uygulanmış ve ortaya çıkan sonuçlar analiz edilmiştir. Derin öğrenme modelleri COVID-19 enfekte olan, normal ve pnömoni teşhisli üç sınıfta sonuç verecek şekilde eğitilmiştir. Bu çalışmada 460 adet COVID-19, 1266 adet normal, 3418 adet pnömoni teşhisi konmuş göğüs X-ray görüntüleri derin öğrenme modelleri ile eğitilmiş, 116 adet COVID-19, 317 adet normal, 855 adet pnömoni teşhisi konmuş göğüs X-ray görüntüleri test edilmiştir. Çalışma sonucu ortaya çıkan derin öğrenme modellerinin karışıklık matrisi ve ROC eğrisi ile birlikte doğruluk, duyarlılık, kesinlik ve F1 Puanı oranları gösterilmiştir.

### **4.1. CNN Modeli Sonuçları**

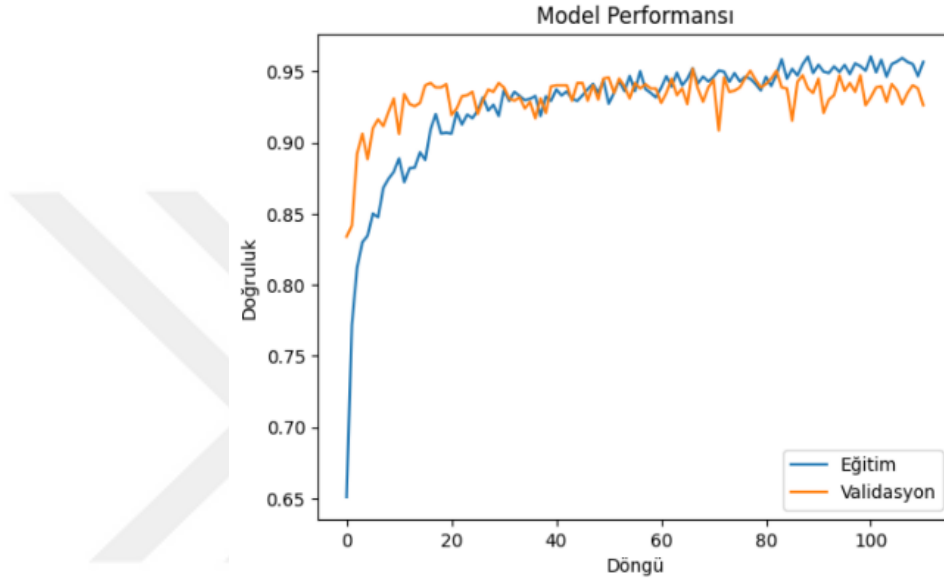
CNN modelinin eğitiminde 116 adet COVID-19 görüntüsü, 317 adet normal teşhisli görüntü, 855 adet pnömoni teşhisli görüntü kullanılmıştır. Sınıflandırma amacıyla

tasarlanan CNN modeli 111 epoch değeri ile eğitilmiştir. Batch size 16 olarak ayarlanıp her bir döngüde veri setinden 16 adet görüntü işlenmiştir. Modelin eğitim tamamlandığında şekil 4.1’de gösterilen karışıklık matrisi sonuçlarına göre matematiksel hesaplamalar yapıldığında, 116 adet COVID-19 teşhisli görüntünün 103 tanesi COVID-19, 5 tanesi normal, 8 tanesi pnömoni olarak tahmin edilmiştir. CNN modelinin COVID-19 teşhisli görüntüleri doğru tahmin etme oranı %88,79 olarak tamamlanmıştır. 317 adet normal teşhisli görüntünün 301 tanesi normal, 16 tanesi pnömoni teşhisli olarak tahmin edilip, hiçbir görüntü COVID-19 teşhisli olarak tahmin edilmemiştir. CNN modelinin normal teşhisli görüntüleri doğru tahmin etme oranı %94,95 olarak tamamlanmıştır. 855 adet pnömoni teşhisli görüntünün 789 tanesi pnömoni, 66 tanesi normal teşhisli olarak tahmin edilip, hiçbir görüntü COVID-19 teşhisli olarak tahmin edilmemiştir. CNN modelinin pnömoni teşhisli görüntüleri doğru tahmin etme oranı %92,62 olarak tamamlanmıştır. CNN modeli ile ortalama %92,62 doğruluk oranı elde edilmiştir. Sonuçlar arasında dikkat çeken bir detay COVID-19 teşhisi olmayan hiçbir görüntüde COVID-19 tahmininde bulunmamış olmasıdır. COVID-19 vakalarını tahmin etmede daha başarılı olmakla birlikte genel olarak başarılı sonuçlar elde etmiştir.



Şekil 4.1: CNN modeli karışıklık matrisi.

Şekil 4.2’de gösterilen CNN modeli ROC eğrisi grafiğine göre modelin test görüntülerinin eğitimi ilk 10 döngüde %85-90 aralığında seyredip 20. döngüden sonra %90-95 aralığında kararlı seyretmiş ve başarılı sonuçlar vermiştir. Grafiğe göre validasyon eğrisinin altında kalan alanın, karışıklık matrisindeki hesaplamalar sonucu ortaya çıkan ortalama %92,62 olarak çıkan sonuca benzer oranda olduğu görülmektedir.



Şekil 4.2: CNN modeli ROC eğrisi.

Tablo 4.1’de görüldüğü gibi CNN modeli COVID-19 vakalarında %100 kesinlik, %89 duyarlılık, %94 F1 Puanı, normal vakalarda %81 kesinlik, %95 duyarlılık, %87 F1 Puanı, pnömoni vakalarında %97 kesinlik, %92 duyarlılık, %95 F1 Puanı elde etmiştir.

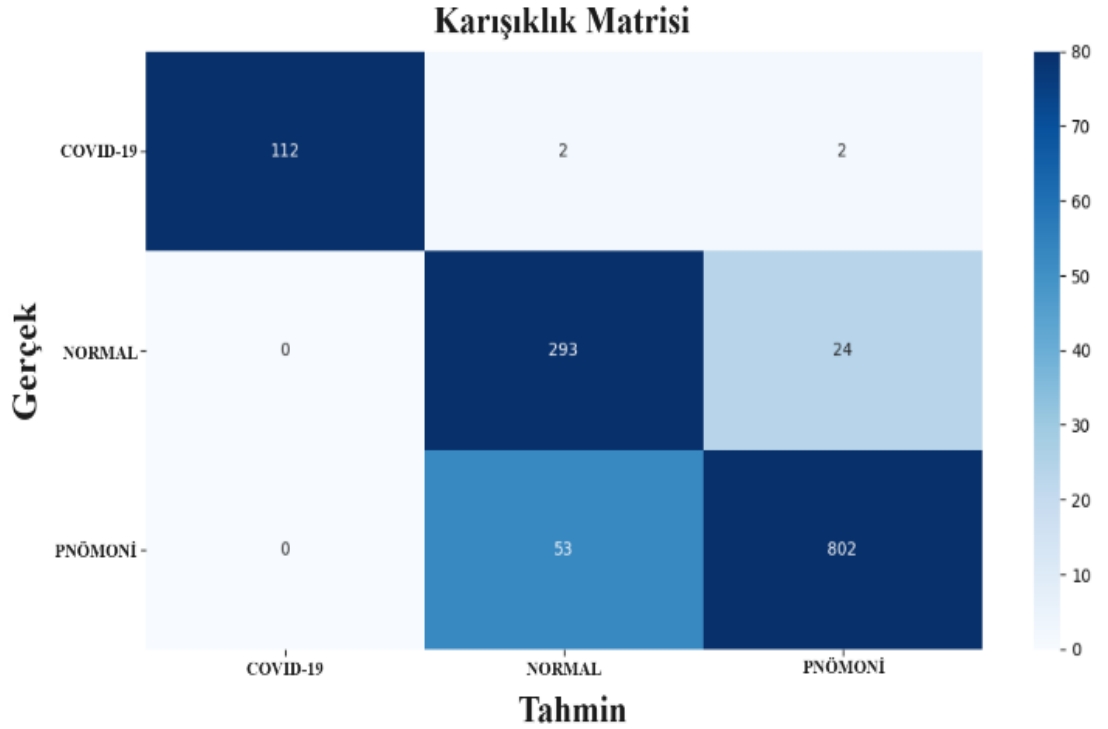
Tablo 4.1: CNN modeli performans değerlendirme.

Performans	Kesinlik	Duyarlılık	F1 Puanı
<b>COVID-19</b>	1.00	0.89	0.94
<b>Normal</b>	0.81	0.95	0.87
<b>Pnömoni</b>	0.97	0.92	0.95

#### 4.2. VGG19 Modeli Sonuçları

VGG19 modelinin eğitiminde 116 adet COVID-19 görüntüsü, 317 adet normal teşhisli görüntü, 855 adet pnömoni teşhisli görüntü eğitilmiştir. Sınıflandırma amacıyla

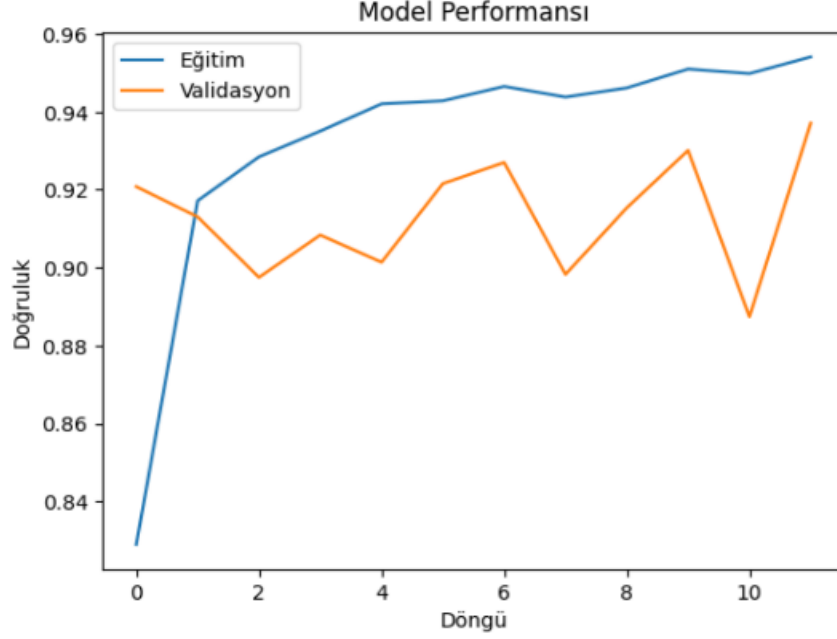
tasarlanan VGG19 modeli 12 epoch değeri ile eğitilmiştir. Batch size 16 olarak ayarlanıp her bir döngüde veri setinden 16 adet görüntü işlenmiştir. Modelin eğitimi eğitimi tamamlandığında şekil 4.3'te gösterilen karışıklık matrisi sonuçlarına göre matematiksel hesaplamalar yapıldığında, 116 adet COVID-19 teşhisli görüntünün 112 tanesi COVID-19, 2 tanesi normal, 2 tanesi pnömoni olarak tahmin edilmiştir. VGG19 modelinin COVID-19 teşhisli görüntüleri doğru tahmin etme oranı %95,55 olarak tamamlanmıştır. 317 adet normal teşhisli görüntünün 293 tanesi normal, 24 tanesi pnömoni teşhisli olarak tahmin edilip, hiçbir görüntü COVID-19 teşhisli olarak tahmin edilmemiştir. VGG19 modelinin normal teşhisli görüntüleri doğru tahmin etme oranı %92,42 olarak tamamlanmıştır. 855 adet pnömoni teşhisli görüntünün 802 tanesi pnömoni, 53 tanesi normal teşhisli olarak tahmin edilip, hiçbir görüntü COVID-19 teşhisli olarak tahmin edilmemiştir. VGG19 modelinin pnömoni teşhisli görüntüleri doğru tahmin etme oranı %93,71 olarak tamamlanmıştır. VGG19 modeli ile ortalama %93,71 doğruluk oranı elde edilmiştir. COVID-19 teşhisli görüntüleri tahmin etme oranı %95,55 ile oldukça başarılı sonuç vermiştir. Sonuçlar arasında bir diğer dikkat çeken bir detay COVID-19 teşhisi olmayan hiçbir görüntüde COVID-19 tahmininde bulunmamış olmasıdır. VGG19 modeli ortalama doğruluk oranı en başarılı sonucu veren model olmuştur.



Şekil 4.3: VGG19 modeli karışıklık matrisi.



Şekil 4.4'te gösterilen VGG19 modeli ROC eğrisi grafiğine göre modelin test görüntülerinin eğitimi başlangıçtan itibaren 10 döngü boyunca %90-95 aralığında kararlı seyretmiş ve başarılı sonuçlar vermiştir. Grafiğe göre validasyon eğrisinin altında kalan alanın, karışıklık matrisindeki hesaplamalar sonucu ortaya çıkan ortalama %93,71 olarak çıkan sonuca benzer oranda olduğu görülmektedir.



Şekil 4.4: VGG19 modeli ROC eğrisi.

Tablo 4.2'de görüldüğü gibi VGG19 modeli COVID-19 vakalarında %100 kesinlik, %84 duyarlılık, %97 F1 Puanı, normal vakalarda %84 kesinlik, %92 duyarlılık, %88 F1 Puanı, pnömoni vakalarında %97 kesinlik, %94 duyarlılık, %95 F1 Puanı elde etmiştir.


Tablo 4.2: VGG19 modeli performans değerlendirilmesi.

Performans	Kesinlik	Duyarlılık	F1 Puanı
<b>COVID-19</b>	1.00	0.97	0.98
<b>Normal</b>	0.84	0.92	0.88
<b>Pnömoni</b>	0.97	0.94	0.95

### 4.3. Xception Modeli Sonuçları


Xception modelinin eğitiminde 116 adet COVID-19 görüntüsü, 317 adet normal teşhisli görüntü, 855 adet pnömoni teşhisli görüntü eğitilmiştir. Sınıflandırma amacıyla

tasarlanan Xception modeli 10 epoch değeri ile eğitilmiştir. Batch size 32 olarak ayarlanıp her bir döngüde veri setinden 32 adet görüntü işlenmiştir. Modelin eğitimi eğitimi tamamlandığında şekil 4.5'te gösterilen karışıklık matrisi sonuçlarına göre matematiksel hesaplamalar yapıldığında 116 adet COVID-19 teşhisli görüntünün 101 tanesi COVID-19, 7 tanesi normal, 8 tanesi pnömoni olarak tahmin edilmiştir. Xception modelinin COVID-19 teşhisli görüntüleri doğru tahmin etme oranı %87,06 olarak tamamlanmıştır. 317 adet normal teşhisli görüntünün 311 tanesi normal, 6 tanesi pnömoni teşhisli olarak tahmin edilip, hiçbir görüntü COVID-19 teşhisli olarak tahmin edilmemiştir. Xception modelinin normal teşhisli görüntüleri doğru tahmin etme oranı %98,11 olarak tamamlanmıştır. 855 adet pnömoni teşhisli görüntünün 694 tanesi pnömoni, 161 tanesi normal teşhisli olarak tahmin edilip, hiçbir görüntü COVID-19 teşhisli olarak tahmin edilmemiştir. Xception modelinin pnömoni teşhisli görüntüleri doğru tahmin etme oranı %81,17 olarak tamamlanmıştır. VGG19 modeli ile %85,86 doğruluk oranı elde edilmiştir. Xception modeli CNN ve VGG19 modellerinden sonra en başarılı sonucu veren model olmuştur. Xception modeli normal teşhisli görüntüleri %98,11 oranında doğru tahmin ederek bu sınıflandırmada en başarılı model olmuştur.



Şekil 4.5: Xception modeli karışıklık matrisi.

Şekil 4.6’da gösterilen Xception modeli ROC eğrisi grafiğine göre modelin test görüntülerinin eğitimi ilk 5 döngü boyunca başarılı ilerleyip, altıncı döngüde zayıflasa da kalan döngülerde çok daha başarılı sonuçlar vermiştir. Grafiğe göre validasyon eğrisinin altında kalan alanın, karışıklık matrisindeki hesaplamalar sonucu ortaya çıkan ortalama %85,86 olarak çıkan sonuca benzer oranda olduğu görülmektedir.



Şekil 4.6: Xception modeli ROC eğrisi.

Tablo 4.3’te görüldüğü gibi Xception modeli, COVID-19 vakalarında %100 kesinlik, %87 duyarlılık, %93 F1 Puanı, normal vakalarda %65 kesinlik, %98 duyarlılık, %78 F1 Puanı, Pnömoni vakalarında %98 kesinlik, %81 duyarlılık, %87 F1 Puanı elde etmiştir.


Tablo 4.3: Xception modeli performans değerlendirilmesi.

Performans	Kesinlik	Duyarlılık	F1 Puanı
<b>COVID-19</b>	1.00	0.87	0.93
<b>Normal</b>	0.65	0.98	0.78
<b>Pnömoni</b>	0.98	0.81	0.89

#### 4.4. Alexnet Modeli Sonuçları


Alexnet modelinin eğitiminde 116 adet COVID-19 görüntüsü, 317 adet normal teşhisli görüntü, 855 adet pnömoni teşhisli görüntü eğitilmiştir. Sınıflandırma amacıyla tasarlanan Alexnet modeli 100 epoch değeri ile eğitilmiştir. Batch size 32 olarak

ayarlanıp her bir döngüde veri setinden 32 adet görüntü işlenmiştir. Modelin eğitimi eğitimi tamamlandığında şekil 4.7’de gösterilen karışıklık matrisi sonuçlarına göre matematiksel hesaplamalar yapıldığında, 116 adet COVID-19 teşhisli görüntünün 12 tanesi COVID-19, 26 tanesi normal, 78 tanesi pnömoni olarak tahmin edilmiştir. Alexnet modelinin COVID-19 teşhisli görüntüleri doğru tahmin etme oranı %10,34 olarak tamamlanmıştır. 317 adet normal teşhisli görüntünün 75 tanesi normal, 211 tanesi pnömoni, 31 tanesi COVID-19 olarak tahmin edilmiştir. Alexnet modelinin normal teşhisli görüntüleri doğru tahmin etme oranı %23,66 olarak tamamlanmıştır. 855 adet pnömoni teşhisli görüntünün 576 tanesi pnömoni, 207 tanesi normal 72 tanesi COVID-19 olarak tahmin edilmiştir. Alexnet modelinin pnömoni teşhisli görüntüleri doğru tahmin etme oranı %67,37 olarak tamamlanmıştır. Alexnet modeli ile %51,48 doğruluk oranı elde edilmiştir. Alexnet modeli diğer modellere göre oldukça düşük doğruluk oranları sunarak Resnet50 modeli ile birlikte başarısız model olarak dikkat çekmiştir.



Şekil 4.7: Alexnet modeli karışıklık matrisi.

Şekil 4.8’de gösterilen Alexnet modeli ROC eğrisi grafiğine göre modelin test görüntülerinin ilk 20 döngü boyunca başarısız olduğu, eğitimin 50. döngüsünden sonra ideal değerlere ulaştığı anlaşılmaktadır. Grafiğe göre validasyon eğrisinin altında kalan alanın, karışıklık matrisindeki hesaplamalar sonucu ortaya çıkan ortalama %51,58 olarak çıkan sonuca benzer oranda olduğu görülmektedir.



Şekil 4.8: Alexnet modeli ROC eğrisi.

Tablo 4.4’te görüldüğü gibi Alexnet modeli, COVID-19 vakalarında %10 kesinlik, %10 duyarlılık, %10 F1 Puanı, normal vakalarda %24 kesinlik, %24 duyarlılık, %24 F1 Puanı, pnömoni vakalarında %67 kesinlik, %67 duyarlılık, %67 F1 Puanı elde etmiştir.


Tablo 4.4: Alexnet modeli performans değerlendirmesi.

Performans	Kesinlik	Duyarlılık	F1 Puanı
<b>COVID-19</b>	0.10	0.10	0.10
<b>Normal</b>	0.24	0.24	0.24
<b>Pnömoni</b>	0.67	0.67	0.67

#### 4.5. Resnet50 Modeli Sonuçları

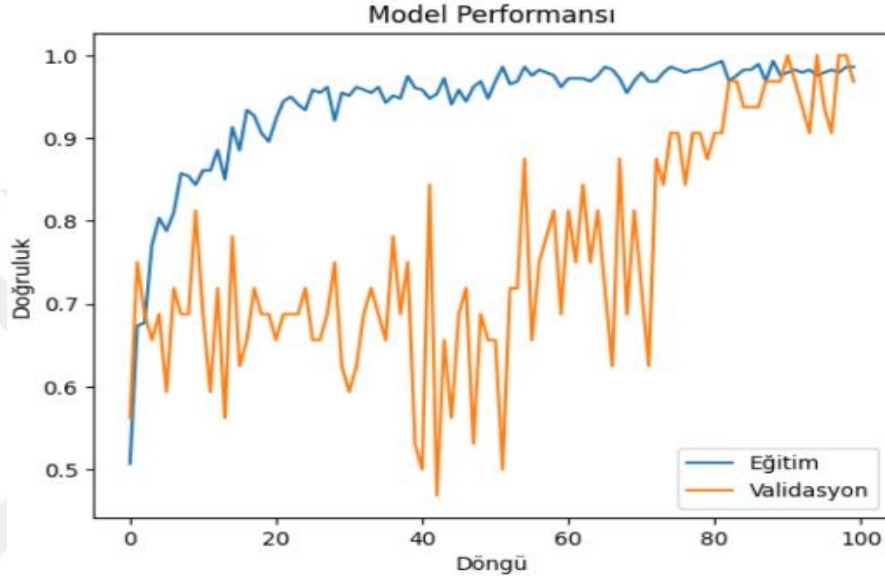
Resnet50 modelinin eğitiminde 116 adet COVID-19 görüntüsü, 317 adet normal teşhisli görüntü, 855 adet pnömoni teşhisli görüntü eğitilmiştir. Sınıflandırma amacıyla tasarlanan Resnet50 modeli 100 epoch değeri ile eğitilmiştir. Batch size 32 olarak

ayarlanıp her bir döngüde veri setinden 32 adet görüntü işlenmiştir. Modelin eğitimi eğitimi tamamlandığında şekil 4.8’de gösterilen karışıklık matrisi sonuçlarına göre matematiksel hesaplamalar yapıldığında, 116 adet COVID-19 teşhisli görüntünün 13 tanesi COVID-19, 31 tanesi normal, 72 tanesi pnömoni olarak tahmin edilmiştir. Resnet50 modelinin COVID-19 teşhisli görüntüleri doğru tahmin etme oranı %11,20 olarak tamamlanmıştır. 317 adet normal teşhisli görüntünün 80 tanesi normal, 204 tanesi pnömoni, 33 tanesi COVID-19 olarak tahmin edilmiştir. Resnet50 modelinin normal teşhisli görüntüleri doğru tahmin etme oranı %25,23 olarak tamamlanmıştır. 855 adet pnömoni teşhisli görüntünün 578 tanesi pnömoni, 210 tanesi normal 67 tanesi COVID-19 olarak tahmin edilmiştir. Resnet50 modelinin pnömoni teşhisli görüntüleri doğru tahmin etme oranı %52,10 olarak tamamlanmıştır. Resnet50 modeli ile %52,10 doğruluk oranı elde edilmiştir. Resnet50 modeli diğer modellere göre oldukça düşük doğruluk oranları sunarak Alexnet modeli ile birlikte başarısız model olarak dikkat çekmiştir.



Şekil 4.9: Resnet50 modeli karışıklık matrisi.

Şekil 4.10'da gösterilen Resnet50 modeli ROC eğrisi grafiğine göre modelin test görüntülerinin eğitimi modelin performansı ile benzer başlasa da, sonrasında 80. döngüye kadar modelden negatif ayrılmış, 80. döngüden sonra test görüntüleri başarılı sonuçlar vermeye başlamıştır. Grafiğe göre validasyon eğrisinin altında kalan alanın, karışıklık matrisindeki hesaplamalar sonucu ortaya çıkan ortalama %52,10 doğruluk oranına olarak çıkan sonuca benzer oranda olduğu görülmektedir.



Şekil 4.10: Resnet50 modeli ROC eğrisi.

Tablo 4.5'de görüldüğü gibi Resnet50 modeli, COVID-19 vakalarında %12 kesinlik, %11 duyarlılık, %11 F1 Puanı , normal vakalarda %25 kesinlik, %25 duyarlılık, %25 F1 Puanı, pnömoni vakalarında %68 kesinlik, %68 duyarlılık, %68 F1 Puanı elde etmiştir.

Tablo 4.5: Resnet50 modeli performans değerlendirilmesi.

Performans	Kesinlik	Duyarlılık	F1 Puanı
<b>COVID-19</b>	0.12	0.11	0.11
<b>Normal</b>	0.25	0.25	0.25
<b>Pnömoni</b>	0.68	0.68	0.68

#### 4.6. Sonuçların Değerlendirmesi ve Öneriler

Bu tez çalışmasında, tüm dünyada insanların hayatını son derece olumsuz etkileyen, milyonlarca insanın ölümüne sebep olan, çok ağır sosyal ve ekonomik problemlere yol açan COVID-19 pandemisine yol açan koronavirüs hakkında, bu salgının önüne geçebilmek için teşhis yöntemi olarak kullanılan röntgen görüntülerinde kullanılan X-ışınları hakkında, bu alanda daha verimli teşhis yöntemleri sunabilecek olan yapay sinir ağları ve derin öğrenme hakkında bilgiler verilmiştir. Derin öğrenme mimarileri hakkında bilgiler verilmiş, derin öğrenmenin temel mimarisi olan evrişimli sinir ağlarının yapısı, içerisinde gerçekleştirilen işlemler anlatılmıştır. Derin öğrenmenin en önemli avantajlarından birisi, model tasarımı konusunda bir sınırı olmaması, daima gelişime açık olmasıdır. Derin öğrenmenin uygulandığı alanlara bakıldığında zaman, birçok alanda çok iyi başarılar elde ettiği görülmektedir. Günümüzdeki teknolojinin ilerleyiş hızı ve depolanan veri miktarının daima yükselişi göz önüne alındığında, derin öğrenmenin gün geçtikçe daha başarılı sonuçlar elde edeceği anlaşılmaktadır. Derin öğrenmenin dezavantajları olan bol miktarda veri gerektirmesi ve donanımsal kaynakların getirdiği sınırlamalar, teknolojinin gelişmesi ve imkanların artması ile günden güne azalacaktır.

Bu çalışmada COVID-19 vakalarının tespitinde, derin öğrenme mimarilerinden başarılı sonuçlar verdiği bilinen evrişimli sinir ağlarının 5 farklı modelinin eğitilmesi ile farklı sonuçlar elde edilmiştir. Tüm modellerin sonuçları incelendiğinde başarı sırasına göre VGG19 modeli %93,71 CNN modeli %92,62 Xception modeli %85,86 Resnet50 modeli %52,10 Alexnet modeli %51,48 doğruluk oranı elde etmiştir. Sonuçlar incelendiğinde pnömoni vakalarının doğru sonuç verme oranının, COVID-19 ve normal vakalara göre daha yüksek olduğu anlaşılmaktadır. Bu durumun sebebinin eğitilen veri setindeki pnömoni içeren X-Ray görüntülerinin diğerlerinden daha fazla sayıda olduğu anlaşılmaktadır. COVID-19 ve normal teşhisli olan göğüs X-Ray veri miktarlarının yükseltildiği eğitimlerde bu parametreler için de daha başarılı sonuçlar elde edilebileceği anlaşılmaktadır. Bu durum derin öğrenme uygulamalarında kullanılan veri setinin önemini ortaya koymaktadır.



Derin öğrenme mimarilerinin her zaman gelişmeye açık olması sayesinde hastalık teşhisi için farklı derin öğrenme mimariler geliştirilerek, eğitilen veri miktarı yükseltilecek daha yüksek performans elde edilebileceği anlaşılmaktadır. Derin öğrenme alanında yapılacak olan yeni çalışmalarda yeni modeller geliştirilerek, çok daha başarılı sonuçlar elde edilebileceği, COVID-19 ve benzeri hastalıkların tespiti alanında büyük katkılar sağlayabileceği anlaşılmaktadır.



## KAYNAKLAR

- [1] Li, X., Geng, M., Peng, Y., Meng, L. ve Lu, S. (2020). Molecular immune pathogenesis and diagnosis of COVID-19. *Journal of Pharmaceutical Analysis*, 10, 102-108.
- [2] Singhal, T. (2020). A review of Coronavirus Disease-2019 (COVID-19). *The Indian Journal of Pediatrics*, 87, 281–286.
- [3] Ozturk, T., Talo, M., Yildirim, E. A., Baloglu, U. B., Yildirim, O. ve Acharya, U. R. (2020). Automated detection of COVID-19 cases using deep neural networks with X-ray images. *Computers in Biology and Medicine*, 121.
- [4] Ouchicha, C., Ammor, O. ve Mekkassi, M. (2020). CVDNet: A novel deep learning architecture for detection of coronavirus (Covid-19) from chest X-ray images. *Chaos, Solitons and Fractals*, 140.
- [5] Lalmuanawma S, Hussain J, Chhakchhuak L. (2020). Applications of machine learning and artificial intelligence for Covid-19 (SARS-CoV-2) pandemic: A review. *Chaos Solitons Fractals*, 139:110059.
- [6] Caobelli, F. (2020). Artificial intelligence in medical imaging: Game over for radiologists?, *European Journal of Radiology*, 126, 108940
- [7] Elektrik Rehberiniz. (2022, 6 Şubat). X ışınları nedir? özellikleri kullanım alanları. (<https://www.elektrikrehberiniz.com/elektrik/x-isinlari-nedir-126994/>)
- [8] Özada, Ç. (2017, 9 Ekim). Nükleer tıp nedir. <https://www.muhendisbeyinler.net/nukleer-tip-nedir/>
- [9] Zhou Y, Yang Y, Huang J, Jiang S, Du L. Advances in MERS-CoV Vaccines and Therapeutics Based on the Receptor-Binding Domain. *Viruses*. 2019 Jan 14;11(1).
- [10] (Balzarini vd., 2006; Haagmans vd., 2016; Lai vd., 2020; Meyer vd., 2014; Wu vd., 2020).
- [11] 2023. TC Sağlık Bakanlığı COVID-19 Bilgilendirme Platformu. COVID-19 Nedir?. <https://covid19.saglik.gov.tr/TR-66300/covid-19-nedir->.
- [12] Lifemed. (2020, 28 Nisan). Koronavirüs Nedir? Belirtileri Nelerdir?. <https://www.lifemed.com.tr/blog/koronavirus-nedir-belirtileri-nelerdir/>.
- [13] T.C. Sağlık Bakanlığı (2020, Aralık 7), COVID-19 (SARS-CoV-2 Enfeksiyonu) <https://covid19.saglik.gov.tr/Eklenti/39551/0/covid-19rehberigenelbilgilerepidemiyojivetanipdf.pdf>.

- [14] Centers for Disease Control and Prevention. (2022, 15 Temmuz). Specimen collection. <https://www.cdc.gov/coronavirus/2019-ncov/lab/guidelines-clinical-specimens.html>
- [15] Ceylan, E. (2023, 8 Mart). Zatürre (pnömoni) nedir? Zatürre belirtileri ve tedavisi. <https://www.medicalpark.com.tr/zaturre-nedir-belirtileri-ve-tedavileri-nelerdir/hg-152#:~:text=Pn%C3%B6moni%20halk%20aras%C4%B1daki%20bilinen%20tabiriyle,ki%C5%9Filere%20do%C4%9Frudan%20bula%C5%9Fma%20riski%20vard%C4%B1r.>
- [16] Zatürre (Pnömoni) <https://sevgihastaneleri.com/saglik-rehberi/zaturre-pnomoni/>.
- [17] Turing, A. M., (1950). The word problem in semi-groups with cancellation. *Annals of Mathematics*, 491-505.
- [18] Machine. A. (2017, Temmuz 31). The artificial use of the term “Intelligence”, <https://becominghuman.ai/the-artificial-use-of-the-term-intelligence-c82878447dfd>
- [19] Kim, P. (2017). Matlab deep learning: With machine learning, neural networks and artificial intelligence. *Apress*, 151 p, Seoul, Korea.
- [20] Chandra. L. A. (2018, Temmuz 24). McCulloch-Pitts Neuron — mankind’s first mathematical Model of a biological neuron <https://towardsdatascience.com/mcculloch-pitts-model-5fdf65ac5dd1>
- [21] Scherer, D., Müller, A., and Behnke, S. (2010) Evaluation of pooling operations in convolutional architectures for object recognition, In International conference on artificial neural networks, Springer, Berlin, Heidelberg, 92-101. doi: 10.1007/978-3-642-15825-4\_10
- [22] Deng, L. ve Yu, D. (2014). Deep learning: methods and applications. *Foundations and Trends in Signal Processing*, 7(3–4), 197-387.
- [23] Doğan, F., Türkoğlu, İ. (2019). Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme, *DÜMF Mühendislik Dergisi* 10:2, 409-445
- [24] Agarap, A. F. (2018). Deep learning using rectified linear units (relu). *arXiv Preprint arXiv:1803.08375*, 1-8,
- [25] Jarrett, K., Kavukcuoglu, K., & LeCun, Y. (2009). What is the best multi-stage architecture for object recognition?. In *Computer Vision, 2009 IEEE 12th International Conference*, 2146-2153
- [26] Cireşan, D. C., Meier, U., Gambardella, L. M., & Schmidhuber, J., (2011). Convolutional neural network committees for handwritten character classification. *2011 International Conference on Document Analysis and Recognition, IEEE, Beijing, China*.
- [27] Lin, M., Chen, Q. and Yan, S., (2013). Network in network. *arXiv preprint arXiv:1312.4400*.
- [28] Avenash, R., Viswanath, P. (2019). In *Proceedings of the 14th International Joint Conference on Computer Vision, Imaging and Computer Graphics Theory and Applications VISIGRAPP*, 413-420.

- [29] Srivastava, Nitish, et al. "Dropout: a simple way to prevent neural networks from overfitting", JMLR 2014
- [30] Ismael, A. M. ve Şengür, A. (2021). Deep learning approaches for COVID-19 detection based on chest X-ray images. *Expert Systems with Applications*, 164, 6.
- [31] Jarrett, K., Kavukcuoglu, K., & LeCun, Y. (2009). What is the best multi-stage architecture for object recognition?. In *Computer Vision, 2009 IEEE 12th International Conference*, 2146-2153.
- [32] Hemdan, E. E. D., Shouman, M. A. ve Karar, M. E. (2020). Covidx-net: A framework of deep learning classifiers to diagnose COVID-19 in X-ray images. *arXiv Preprint arXiv:2003.11055*, 1-14
- [33] Narin, A., Kaya, C. ve Pamuk, Z. (2021). Automatic detection of coronavirus disease (COVID-19) using X-ray images and deep convolutional neural networks. *Pattern Anal Applications*, 24, 1207–1220..
- [34] Ucar, F. and Korkmaz, D., (2020). COVIDiagnosis-Net: Deep Bayes-SqueezeNet based diagnosis of the coronavirus disease 2019 (COVID-19) from X-ray images. *Medical Hypotheses*, 140, 109761.
- [35] Panwar, H., Gupta, P. K., Siddiqui, M. K., Morales-Menendez, R. and Singh, V., (2020b). Application of deep learning for fast detection of COVID-19 in X-Rays using nCOVnet. *Chaos, Solitons and Fractals*, 138, 109944
- [36] Sethy, P. K., Behera, S. K., Ratha, P. K. and Biswas, P., (2020). Detection of coronavirus disease (COVID-19) based on deep features and support vector machine. *Preprints*
- [37] Bozkurt, F., Köse C. and Sarı, A., (2018). An inverse approach for automatic segmentation of carotid and vertebral arteries in CTA. *Expert Systems with Applications*, 93, pp. 358- 375
- [38] Pandit, M. K., Banday, S. A., Naaz, R. and Chishti, M. A., (2020). Automatic detection of COVID-19 from chest radiographs using deep learning. *Radiography*, 27(2), 483-489.
- [39] Horry, M. J., Paul, M., Ulhaq, A., Pradhan, B., Saha, M. and Shukla, N., (2020). X-Ray image based COVID-19 detection using pre-trained deep learning models. *Engineering Engrxiv Archive*, 1.
- [40] Patel, P., (2020), Chest X-ray (Covid-19 & Pneumonia) <https://www.kaggle.com/datasets/prashant268/chest-xray-covid19-pneumonia>.
- [41] Chollet, F. (2016). Xception: Deep learning with depthwise separable convolutions. *arXiv preprint*.
- [42] Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., ... & Ghemawat, S. (2016). Tensorflow: Large-scale machine learning on heterogeneous distributed systems. *arXiv preprint arXiv:1603.04467*. [43] Turing, A. M., (1950). The word problem in semi-groups with cancellation. *Annals of Mathematics*, 491-505.

- [44] Ekici, H., (2020, Mart 23), Tahribatsız malzeme muayenesi – radyografi, <http://ekcmetallurgy.org/Haber/1021/TAHRIBATSIZ-MALZEME-MUAYENESI---RADYOGRAFI-.html>
- [45] Kim, P. (2017). Matlab deep learning: With machine learning, neural networks and artificial intelligence. Apress, 151 p, Seoul, Korea.
- [46] Yiğit, R. and Haldenbilen, S., (2021), Kısa Zamanlı Trafik Tahmini ile Devre Süresi Optimizasyonu ve Gecikme Analizi, Teknik Dergi, 627, 11102.
- [47] Özkan, İ. N. İ. K., & Ülker, E. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri. Gaziosmanpaşa Bilimsel Araştırma Dergisi, 6(3), 85-104.
- [48] Tabian I., Fu H., and Khodaei Z., (2019), A convolutional neural network for impact detection and characterization of complex composite structures, Sensors, 19, 4933..
- [49] Horry, M. J., Paul, M., Ulhaq, A., Pradhan, B., Saha, M. and Shukla, N., (2020). X-Ray image based COVID-19 detection using pre-trained deep learning models. Engineering Engrxiv Archive, 1.
- [50] Kızrak, A., (2018). Konu: Derine Daha Derine: Evrişimli Sinir Ağları, Bilgisayarlı görü neden gerekli?. Erişim Adresi: <https://medium.com/deep-learning-turkiye/deri%CC%87nedaha-deri%CC%87ne-evri%20C5%9Fimli-sinir-a%20C4%9Flar%C4%B1-2813a2c8b2a>.
- [51] Krizhevsky, A., Sutskever, I. and Hinton, G.E., (2012). Imagenet classification with deep convolutional neural net works, Adv. Neural Inf. Process. Syst., 1097–1105.
- [52] Zheng, Y., Yang, C. and Merkulov, A. (2018) Breast cancer screening using convolutional neural network and follow-up digital mammography, in Proc. SPIE San Francisco 10669, Computational Imaging III, doi: 10.1117/12.2304564.
- [53] Talo, M. (2019). Convolutional neural networks for multi-class histopathology image classification. arXiv Preprint arXiv:1903.10035, 1-16..
- [54] Chollet, F., (2017). Xception: Deep learning with depthwise separable convolutions. Proceedings of the IEEE conference on computer vision and pattern recognition, 1251- 1258.
- [55] Srinivasan, K. et al., (2021). Performance comparison of deep CNN models for detecting driver’s distraction, Computers, Materials & Continua, vol. 68, no. 3, pp. 4109–4124.
- [56] Hossin, M. and Sulaiman, M.N. (2015) A review on evaluation metrics for data classification evaluations, International Journal of Data Mining & Knowledge Management Process, 5(2), 1-11. doi: 10.5121/ijdkp.2015.5201.
- [57] Hao, Z. Huaicheng Y., Congzhi H., Mengling W., (2016), Guaranteed Cost Filtering for Discrete-time Multi-layer Neural Networks with Time-varying Delays and Unideal Measurements, Proceedings of the IEEE International Conference on Information and Automation, Ningbo, Çin, 12-15 Ağustos 2016.

[58] Koçer, B. (2012). Transfer öğrenmede yeni yaklaşımlar. Selçuk Üniversitesi, Yayınlanmış doktora tezi, Konya.

