



**DERİN ÖĞRENME KULLANARAK TIBBİ  
GÖRÜNTÜLERDE COVID-19 VE ZATÜRRE  
TESPİTİ**

**2023  
YÜKSEK LİSANS TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ**

**İrem KURA**

**Tez Danışmanı  
Dr. Öğr. Üyesi Nesrin AYDIN ATASOY**

**DERİN ÖĞRENME KULLANARAK TIBBİ GÖRÜNTÜLERDE COVID-19  
VE ZATÜRRE TESPİTİ**

**İrem KURA**

**Tez Danışmanı  
Dr. Öğr. Üyesi Nesrin AYDIN ATASOY**

**T.C.  
Karabük Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalında  
Yüksek Lisans Tezi  
Olarak Hazırlanmıştır**

**KARABÜK  
Eylül 2023**

İrem KURA tarafından hazırlanan “DERİN ÖĞRENME KULLANARAK TIBBİ GÖRÜNTÜLERDE COVID-19 VE ZATÜRRE TESPİTİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Nesrin AYDIN ATASOY .....  
Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 14/09/2023

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Başkan : Dr. Öğr. Üyesi Nesrin AYDIN ATASOY ( KBÜ)	.....
Üye : Dr. Öğr. Üyesi Ferhat ATASOY ( KBÜ)	.....
Üye : Dr. Öğr. Üyesi Emel SOYLU (SAMÜ)	.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile Yüksek Lisans derecesini onaylamıştır.

Doç. Dr. Zeynep ÖZCAN .....  
Lisansüstü Eğitim Enstitüsü Müdürü

*“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”*

İrem KURA

## **ÖZET**

**Yüksek Lisans Tezi**

### **DERİN ÖĞRENME KULLANARAK TIBBİ GÖRÜNTÜLERDE COVID-19 VE ZATÜRRE TESPİTİ**

**İrem KURA**

**Karabük Üniversitesi**

**Lisansüstü Eğitim Enstitüsü**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı:**

**Dr. Öğr. Üyesi Nesrin AYDIN ATASOY**

**Eylül 2023, 48 sayfa**

Covid-19 virüsü dünya çapında bir pandemi olarak yayıldı. Bilim insanları bu sorunları azaltmak ve çözüm bulmak için büyük çaba sarf ettiler. Tespit için kullanılan Ters Transkripsiyon-Polimeraz Zincir Reaksiyonu (RT-PCR) testinin başarı oranı düşük olması ve testi temin etmek için gereken süre nedeniyle, derin öğrenme modelleri, hastalığın teşhisinde yardımcı tespit yöntemi olarak birçok alanda başarıyla kullanılmış ve X-Işını, akciğer röntgeni görüntülerinde enfekte ve normal bireyleri belirlemek için kullanılmıştır. Covid-19 semptomları zatürreye benzediği için hastalığın tespiti için birçok derin öğrenme modeli önerilmiştir. Bu çalışmada dört farklı genel veri seti kullanılarak hem X-Işını hem de BT görüntüleri üzerinde Covid-19 ve pnömoni hastalığı tespiti yapılmaktadır. Hastalıkların tespiti için sade ve güçlü bir Evrişimsel Sinir Ağı modelinin kullanılması amaçlanmaktadır. Modelin veri seti özelliklerinden bağımsız olarak başarılı bir sınıflandırma gerçekleştirdiğini göstermek için X-Işını ve BT görüntülerine RGB, HSV ve CIE

LAB renk uzayı dönüşümleri uygulanmıştır. Röntgen görüntülerinde ikili sınıflandırma (Covid-19-zatürre) doğruluk oranı %98.7, %98.4. BT görüntülerinde ikili sınıflandırma (Covid-19- zatürre) doğruluk oranı %97,6, %99,4'tür. Hassasiyet, Kesinlik, Spesifiklik, F1 Değeri ve Ortalama Kare Hatası metrikleri her model için hesaplanır. Ayrıca modelin başarı oranı 5 kat çapraz doğrulama ile kanıtlanmıştır.

**Anahtar Sözcükler :** Evrişimli sinir ağı, Covid-19 tespiti, BT göğüs görüntüleri, Zatürre tespiti, X-Işını göğüs görüntüleri

**Bilim Kodu** : 92431

## **ABSTRACT**

**M. Sc. Thesis**

### **DETECTION OF COVID-19 AND PNEUMONIA IN MEDICAL IMAGES USING DEEP LEARNING**

**İrem KURA**

**Karabük University  
Institute of Graduate Programs  
Department of Computer Engineering**

**Thesis Advisor:**

**Assist. Prof. Dr. Nesrin AYDIN ATASOY**

**September 2023, 48 pages**

The Covid-19 virus has spread as a worldwide pandemic. Scientists have made great efforts to reduce these problems and find solutions. Due to the low success rate of the Reverse Transcription-Polymerase Chain Reaction (RT-PCR) test used for detection and the time required to provide the test, deep learning models have been successfully used in many areas as an auxiliary detection method in the diagnosis of the disease, and X-Ray is used in lung X-ray images. used to identify infected and normal individuals. Because Covid-19 symptoms are similar to pneumonia, many deep learning models have been proposed for the detection of the disease. In this study, Covid-19 and pneumonia disease detection is performed on both X-ray and CT images using four different general data sets. It is aimed to use a simple and powerful Convolutional Neural Network model for the detection of diseases. RGB, HSV and CIE LAB color space transformations are applied to X-ray and CT images to show that the model performs successful classification regardless of data set

properties. Binary classification (Covid-19-pneumonia) accuracy rate in X-ray images is 98.7%, 98.4%. Binary classification (Covid-19-pneumonia) accuracy rate in CT images is 97.6%, 99.4%. Precision, Recall, Specificity, F1score, and Mean Squared Error metrics are calculated for each model. In addition, the success rate of the model has been proven by 5-fold cross validation.

**Keyword** : Convolutional neural network, Covid-19 detection, CT chest image, Pneumonia detection, X-ray chest image.

**Science Code** : 92431



## TEŐEKKÜR

Yüksek lisans çalışmamın her aşamasında bana yardımcı olan ve desteklerini esirgemeyen danışman hocam Dr. Öğr. Üyesi Nesrin AYDIN ATASOY'a sonsuz teşekkürlerimi sunarım.

Sevgili aileme manevi, maddi hiçbir yardımı esirgmeden yanımda oldukları için tüm kalbimle teşekkür ederim.

Meslektaşım İsmail ÇELEBİ'ye sağlamış olduğu donanımsal destekleri için teşekkür ederim.

## İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER .....	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ .....	xiii
KISALTMALAR DİZİNİ.....	xiv
BÖLÜM 1 .....	1
GİRİŞ .....	1
BÖLÜM 2 .....	3
TIBBİ GÖRÜNTÜLERİN SINIFLANDIRILMASI.....	3
2.1. ÇALIŞMANIN KATKILARI .....	3
2.2. LİTERATÜR ÇALIŞMASI.....	3
BÖLÜM 3 .....	7
HASTALIKLAR, TIBBİ GÖRÜNTÜLER VE DERİN ÖĞRENME.....	7
3.1. TIBBİ GÖRÜNTÜLER .....	7
3.1.1. Röntgen (X-IŞINI).....	7
3.1.2. Bilgisayarlı Tomografi (BT).....	8
3.2. PANDEMİK HASTALIKLAR.....	9
3.2.1. Zatürre.....	9
3.2.2. Covid-19 .....	9
3.3. DERİN ÖĞRENME .....	10
3.3.1. Evrişimli Sinir Ağı.....	10
3.3.1.1. Aktivasyon Fonksiyonları.....	11

	<b><u>Sayfa</u></b>
3.3.1.1.a. ReLU .....	11
3.3.1.1.b. LeakyRelu .....	12
3.3.1.1.c. Sigmoid.....	13
3.3.1.2. Optimizasyon Fonskiyonları.....	14
3.3.1.2.a. Adagrad (Adaptif Gradyan Algoritması).....	15
3.3.1.2.b. Adam (Adaptif Moment Tahmini) .....	15
3.3.1.2.c. RMSprop (Kök Ortalama Kare Yayılımı).....	15
3.3.1.3. Kayıp Fonskiyonları.....	16
3.3.1.3.a. Ortalama Kare Hatası .....	16
3.3.1.4. Havuzlama .....	17
3.3.1.4.a. Maksimum Havuzlama.....	17
3.3.1.4. Atma Fonskiyonu.....	17
3.3.2. Çalışmada Kullanılan Kütüphaneler.....	18
3.3.2.1. TensorFlow .....	18
3.3.2.2. Pandas .....	18
3.3.2.3. Numpy.....	18
3.3.2.4. OpenCV .....	18
3.3.2.5. Matplotlib.....	19
3.3.2.6. Glob.....	19
3.3.2.7. Keras .....	19
3.3.2.8. Scikit-Learn.....	19
3.3.3. Metrikler .....	19
3.3.3.1. Karmaşıklık Matrisi .....	20
3.3.3.2. Doğruluk .....	20
3.3.3.3. F1 Değeri .....	20
3.3.3.4. Kesinlik .....	20
3.3.3.5. Hassasiyet .....	21
3.3.3.6. Özgüllük.....	21
3.3.3.7. Ortalama Kare Hatası.....	21
3.3.4. K Katlı Çapraz Doğrulama .....	21
BÖLÜM 4 .....	22

TIBBİ GÖRÜNTÜLERE DERİN ÖĞRENME YÖNTEMİ İLE TESPİTİ İÇİN	
UYGULANMA .....	22
4.1. VERİ SETİ .....	23
4.1.1. Renk Uzayları .....	24
4.1.1.1. Ton-Doygunluk-Değer .....	25
4.1.1.2. Mavi-Yeşil-Kırmızı.....	26
4.1.1.3. CIE 1976 LAB .....	26
4.1.1.4. Kırmızı-Yeşil-Mavi.....	26
4.2. VERİ SETİNİN HAZIRLANMASI.....	26
4.2.1. Veri Artırma.....	27
4.3. GÜÇLÜ EVRİŞİMLİ SİNİR AĞI MODELİ.....	29
BÖLÜM 5 .....	33
DENEYSEL ÇALIŞMALAR .....	33
5.1. MODELİN DEĞERLENDİRİLMESİ .....	36
BÖLÜM 6 .....	39
SONUÇLAR .....	39
KAYNAKLAR .....	42
ÖZGEÇMİŞ .....	48

## ŞEKİLLER DİZİNİ

	<b><u>Sayfa</u></b>
Şekil 3. 1. Röntgen .....	8
Şekil 3. 2. BT .....	8
Şekil 3. 3. Zatürre .....	10
Şekil 3. 4. Covid-19 .....	10
Şekil 3. 5. Aktivasyon fonksiyonu .....	11
Şekil 3. 6. ReLU fonksiyonu .....	12
Şekil 3. 7. LeakyReLU fonksiyonu .....	12
Şekil 3. 8. Sigmoid fonksiyonu .....	13
Şekil 3. 9. Gradyan inişi optimizasyon algoritması .....	14
Şekil 3. 10. Maksimum havuzlama .....	17
Şekil 3. 11. Atma fonksiyonu [47] .....	17
Şekil 4. 1. Çalışmanın genel şeması .....	22
Şekil 4. 2. Veri artırma yöntemi uygulanmış görüntü verileri .....	28
Şekil 4. 3. Önerilen modelin mimari tasarımı .....	29
Şekil 4. 4. Her bir veri seti grubu için rgb-hsv-cie lab-rgb renk uzay dönüşümleri yapılmış örnek giriş verileri. ....	30
Şekil 5. 1. BT verileri için doğrulama ve eğitim başarı-kayıp grafiği .....	36
Şekil 5. 2. Her veriseti için 5 katlı çapraz doğrulanma için karmaşıklık matrisi .....	37

## ÇİZELGELER DİZİNİ

### Sayfa

Çizelge 3. 1. Aktivasyon fonksiyonlarının karşılaştırmalar sonuçları x-ışını-1 veri seti baz alarak yapılmıştır. ....	13
Çizelge 3. 2 Optimizasyon fonksiyonlarının karşılaştırmalar sonuçları x-ışını-1 veri seti baz alarak yapılmıştır. ....	16
Çizelge 4. 1. Veri seti görüntü miktarı.....	24
Çizelge 4. 2. Veriseti içinde veri artırma .....	27
Çizelge 4. 3. Önerilen CNN model katmanları .....	31
Çizelge 5. 1. X-Işını-1 veri seti için renk uzaylarının kıyaslanması .....	34
Çizelge 5. 2. X-Işını-2 veri seti için renk uzaylarının kıyaslanması .....	34
Çizelge 5. 3. BT-1 veri seti için renk uzaylarının kıyaslanması .....	35
Çizelge 5. 4. BT-2 veri seti için renk uzaylarının kıyaslanması .....	35
Çizelge 5. 5. Tüm veri gruplarında uygulanan 5 katlı çapraz doğrulama için ortalama performans sonuçları.....	37
Çizelge 6. 1. Literatürde bulunan referans çalışmalar.....	40
Çizelge 6. 2. Literatürde bulunan referans çalışmalar.....	41

## KISALTMALAR DİZİNİ

### KISALTMALAR

RT-PCT	: Ters Transkripsiyon-Polimeraz Zincir Reaksiyonu
CNN	: Evrişimsel Sinir Ağları
BT	: Bilgisayarlı Tomografi
X-Işını	: Röntgen
MSE	: Ortalama Kare Hata
OpenCV	: Açık Kaynak Bilgisayarla Görü Kitaplığı
HSV	: Ton Doygunluk Değer
RGB	: Kırmızı-Yeşil-Mavi
SGD	: Stokastik Gradyan İnişi

## BÖLÜM 1

### GİRİŞ

2019 yılının sonlarında dünya, salgın bir hastalık olarak Covid-19 ile karşılaşmıştır. Covid-19 virüsü, 2019 yılında şiddetli akut solunum yolu sendromunun (SARS) yeni bir türü olarak ortaya çıkmıştır. Covid-19 virüsü yüksek enfeksiyon etkisiyle insanlar arasında hızlı bir şekilde yayılmıştır. Dünya genelinde koronavirüse yakalandığı tespit edilen 298,096,535 kişiden 5,481,668 kişi hayatını kaybetmiştir. [1] Covid-19 virüsünün belirtileri zatürre hastalığı belirtilerine benzediği için sıklıkla karıştırılmaktadır. Zatürre hastalığının belirtileri; göğüs ağrısı, nefes darlığı ve öksürüktür. Zatürre hastalığı, akciğer loblarının iltihaplanmasıyla hastaya solunum zorluğu yaşatan ve geç teşhis edildiğinde ölümlerle sonuçlanan bir hastalıktır. [2] Göğüs hastalıkları uzmanları tarafından akciğer tıbbi görüntülerinin ve solunum testlerinin incelenmesi ile teşhis edilmektedir. Bu hastalığın erken teşhis edilmesi hastanın hayatını kurtarmaktadır.

Covid-19 virüsünün tespitinde zatürre gibi tıbbi görüntüler kullanılmasına rağmen ilk olarak Revers Transkriptaz- Polimeraz Zincir Reaksiyonu (RT-PCR) testi kabul edilmektedir [3]. Bu test yönteminin başarı oranının yüksek olmaması, test sonucu için zamanın gerekli olması, test kiti temini ve test kitlerinin her hastanede değerlendirilememesi gibi sebepler araştırmacıları farklı tespit çalışmalarına yöneltmiştir. Milyonlarca kişinin ölümüne sebep olan bu salgın hastalığı tanımak ve tedavi etmek için çeşitli çalışmalar gerçekleştirilmektedir. Teknolojide yaşanan gelişmeler de bu çalışmalara büyük katkı sağlamaktadır. Bilim insanları, doktorlara Covid-19 ve zatürre hastalığı teşhis ve tedavi sürecinde destek olmak için çeşitli derin öğrenme modelleri önermektedirler. [4]–[9] Bu çalışmalarda görüldüğü gibi hastanelerde halen kullanılan X-Işını ve Bilgisayarlı Tomografi (BT) gibi görüntüleme teknikleri akciğer hastalıklarının teşhisinde tamamlayıcı bir role sahiptir ve riskli bir durumda tedavi yönteminin belirlenmesine yardımcı olan tanı



yöntemleridir. X-ışını görüntüleme, siyah beyaz bir görüntü oluşturmak için çok küçük dozlarda iyonlaştırıcı radyasyon kullanır. BT, vücudun içindeki alanların ayrıntılı resimlerini veya taramalarını oluşturmak için özel x-ışını ışınları kullanan bir görüntüleme yöntemidir. BT tekniği, vücudun ilgili bölgelerini X-ışını görüntüleme tekniğinden daha detaylı tarayarak detaylı ve katmanlı bir resim oluşturur. X-ışını ve BT görüntülerin hızlı tanı ortaya çıkarması, X-ışını ve BT görüntüler arasındaki özellik farkları, farklı marka görüntüleme cihazlarının farklı görüntü özelliğinde görüntü oluşturması gibi durumlar bu çalışmanın motivasyonunu oluşturmaktadır. Bu çalışmada, 4 farklı veri seti kullanılarak farklı görüntüleme teknikleri ve farklı renk uzaylarında elde edilen göğüs radyoloji görüntülerinin tek bir derin öğrenme modeli ile doğru sınıflandırılması hedeflenmiştir. Bu nedenle görüntü tabanlı uygulamalarda başarılı sonuçlar veren [10]–[13] derin öğrenme modeli Evrişimli Sinir Ağı (CNN) tercih edilmiştir. Önerilen bu gürbüz modelin başarısı hem X-ışını hem BT göğüs radyoloji görüntülerin RGB, HSV ve CIE LAB renk uzaylarında olması durumunda bile yüksek başarı oranı ile Covid-19 ve zatürre hastalığı olarak sınıflandırılması şeklinde gösterilmektedir. Böylece, RT-PCR testinin sonuçlanması için gereken zamanı hastalara kazandıran, test için harcanan maliyeti düşüren, veri seti farklılıklarından bağımsız gürbüz bir model ile düşük maliyetli bir uzman sistem önerilmektedir.

## BÖLÜM 2

### TIBBİ GÖRÜNTÜLERİN SINIFLANDIRILMASI

#### 2.1. ÇALIŞMANIN KATKILARI

Önerilen yaklaşım ile hastanelerde bulunan farklı tıbbi görüntüleme cihazlarına uygun tek bir gürbüz model önerilmektedir.

Önerilen model, farklı görüntü özelliklerine sahip hasta X-Işını ve BT göğüs radyoloji görüntülerini Covid-19 ve zatürre hastalığı olarak başarılı bir şekilde sınıflandırabilmektedir. Hastanın çok, doktorun az olduğu bölgelerde teşhis için yardımcı uzman sistem olarak kullanılabilir.

CNN mimarisinin güçlü yönleri kullanılarak farklı renk uzaylarındaki veriler üzerinde tek bir ağ mimarisi ile sınıflandırma gerçekleştirilmektedir. Böylece, görüntüleme cihazı değişse bile önerilen mimariye göre model başarılı bir şekilde sınıflandırma yapabilecektir.

#### 2.2. LİTERATÜR ÇALIŞMASI

Günümüzde, derin öğrenme modelleri birçok alanda faydalı bir şekilde kullanılmaktadır. Derin öğrenme algoritmaları; yüz tanıma sistemleri, sağlık sektörü [14], ses tanıma çalışmaları[15], otonom sistemler, görüntü işleme[16], tahmin uygulamaları[17], doğal dil işleme, metin ve karakter tanıma çalışmaları[11], savunma ve güvenlik, nesne tanıma, sınıflandırma[18] gibi birçok alanda kullanılmaktadır. Çünkü derin öğrenme modelleri çok fazla veri girişi ile ayırt edici özellikleri öğrenebildiği için başarılı sonuçlar ortaya çıkarmaktadır.

Polsinelli ve ekibi[8], Covid-19 hastalığını tespit etmek için Zhao ve ekibi[19] dataset and the Italian dataset[20] BT göğüs görüntülerini kullanarak modifiye edilmiş bir SqueezeNet modeli önermektedirler. İki farklı veri setinde 2000' e yakın görüntü ile Matlab Tools ile bir çalışma gerçekleştirmişlerdir. Modifiye edilen model, eğitim aşamasında özellikleri daha iyi oluşturduğu için yalın SqueezeNet' e göre daha iyi performans göstermektedir. Hiperparametreler, Bayesian yaklaşım kullanarak belirlenmektedir. CNN tabanlı modifiye model ile 85,03% doğruluk oranı elde edilmiştir ve sınıflandırma süresi yeterli derecede azdır. Bu çalışmada, CNN modelin sınırlı donanım kaynaklarıyla bile görüntü analiz etme yeteneğine sahip olduğu görülmektedir.

Nayak ve ekibi[9], Covid-19 hastalığını erken teşhis etmek için X-Işını göğüs görüntüleri kullanarak derin öğrenme tabanlı bir yaklaşım önermektedirler. CNN mimarisine dayanan AlexNet, VGG-16, GoogleNet, MobileNet-V2, SqueezeNet, ResNet-34, ResNet-50 and Inception-V3 derin öğrenme modelleri arasından en iyi modeli bulmak için batch size, learning rate, number of epochs, and type of optimizers parametrelerini değiştirmişlerdir. Böylece Covid-19 ya da normal şekilde sınıflandırma yapan otomatik bir sistem gerçekleştirmeyi hedeflemektedirler. 286 adet görüntü eğitim için, 120 adet görüntü test için kullanılmıştır. Bu modeller arasından ResNet-34 98,33% doğruluk oranı ile en iyi performansı göstermiştir. Fakat derin öğrenme modellerinin sınıflandırma başarısına göre bu çalışmanın veri seti yeteri kadar büyük değildir. Bu nedenle seçilen modellerin başarı oranları birbirine çok yakındır.

Karim ve ekibi[21] Covid-19 hastalığı tespiti için bilgisayar destekli bir tanı sistemi önermektedirler. CNN ile Ant Lion Optimizasyon algoritması and Softmax, Destek Vektör Makinesi (SVM), K-En Yakın Komşular (KNN) ve Karar Ağaçları, Çok Sınıflı Naive Bayes Sınıflandırıcı birleştirerek akciğer X-Işını görüntülerini hasta ve normal olarak sınıflandırmaktadırlar. Çalışmanın amacı CNN ile uyumlu en iyi sınıflandırma algoritmasını belirlemektir. Önerilen modelin performansını değerlendirmek için iyi bilinen veri setini kullanmışlardır[22], [23]. Veri yeniden boyutlandırma ve özellik çıkarma için AlexNet, özellik seçimi için Ant Lion Optimizasyon Algoritması ve sınıflandırma için en iyi model olan Bayes Naive

sınıflandırıcısını kullanmışlardır. Önerilen modelin doğruluğu, kesinliği ve F1 puanı sırasıyla %98.31, %100 ve %98.25'tir.

Thakur and Kumar. [24]X-Işını ve BT görüntüler kullanarak farklı CNN modeller ile ikili ve çoklu sınıflandırma gerçekleştirmişlerdir. İkili sınıflandırma için Covid-19 ve normal; çoklu sınıflandırma için Covid-19, normal ve zatürre şeklinde sınıflandırma gerçekleştirmişlerdir.

İkili sınıflandırma doğruluk oranı 99.64%, çoklu sınıflandırma doğruluk oranı 98.28% olarak elde etmişlerdir. Her iki model için optimizasyon metodu olarak SGD ve öğrenme olarak değeri olarak 0.02 kullanmışlardır. Yazarlar, orijinal giriş veri setini ilk ön işleme adımında grayscale görüntüye çevirdiklerini belirtmişlerdir. Fakat, X-Işını ve BT görüntüler oluşturulma şekline göre grayscale'dir[25], [26]. Çalışmada, orijinal veri seti özellikleri ve bu dönüşümün sebebi belirtilmemiştir.

Rahimzadeh ve ekibi [27] BT görüntülerden Covid-19 hastalığını tespit etmek için bilgisayar tabanlı bir tanı sistemi önermektedirler. 282 normal hasta, 95 Covid-19 hastanın; 15589 Covid-19 görseli, 48260 normal görsel BT veri seti kullanmışlardır. Zaman ve hatalı tespit işlemini azaltmak için ilk olarak BT görüntülerinde enfekte olan bölgeleri Grad-Cam algoritması kullanarak tespit etmişlerdir. ResNet50V2, Xception ve önerdikleri model ile Covid-19 hastalığı tespiti için ikili sınıflandırma gerçekleştirmişlerdir. Önerdikleri model 98.49% doğruluk oranı ile en iyi sınıflandırmayı gerçekleştirmiştir.

Islam ve ekibi [5] Covid-19 hastalığını tespit etmek için X-Işını görüntüler kullanarak CNN ve LSTM modelleri birleştirerek bir model önermektedirler. 1525 adet Covid-19, normal ve pneumonia olarak dengeli bir X-Işını veri seti kullanmışlardır. Bu çalışmada derin öznitelik çıkarımı için CNN, çıkarılan özniteliği kullanarak sınıflandırma için LSTM kullanılmaktadır. Önerilen model akciğer X-Işını görüntülerini Covid-19, zatürre ve normal olarak sınıflandırılmaktadır. Önerilen modelde Doğruluk, AUC, Özgüllük, Hassasiyet, F1 değerleri sırayla 99.4%, 99.9%, 99.2%, 99.3%, 98.9%'dir. Bu çalışmada CNN'in başarısının LSTM ile daha da artırıldığı görülmektedir.

Serener ve ekibi [6] Covid-19, mycoplasma pneumonia ve typical viral pneumonia hastalıklarının tanı zorluğunu azaltmayı amaçlamaktadırlar. Yedi farklı mimari ResNet-50, ResNet-18, MobileNet-V2, VGG, SqueezeNet, AlexNet, DenseNet-121 ile ikili classification gerçekleştirmişlerdir. En iyi performans sonuçlarını ResNet-18 ve MobileNet-v2 modelleri göstermiştir. Verisetini 325 orijinal, 1005 arttırılmış 224x224 boyutuna sahip BT göğüs görüntüsü oluşturmaktadır. Bu derin öğrenme

modellerinin sınıflandırma başarısı Mycoplasma Pneumonia ve Covid-19 tespiti için en yüksek doğruluk oranı 89.0%, Mikroplazma Zatürre ve Typical Viral Zatürre tespiti için en yüksek doğruluk 76.0%'dır. Çalışma literatürdeki diğer çalışmalara göre yeterli başarıyı elde edememiştir. Veri seti çok fazla oranda artırma ve model eğitiminin yeterli olmaması model başarısı büyük oranda etkilemektedir.

Literatürde görüldüğü gibi X-Işını ve BT akciğer görüntüleri kullanılarak küçük ve büyük veri setleri ile CNN modele dayalı birçok çalışma başarılı bir şekilde gerçekleştirilmiştir. Hatta birkaç model birleştirilerek başarılı sınıflandırma modellerin başarısı artırılmaktadır. Bu çalışmada, yalın ama güçlü bir CNN model oluşturulmuştur ve Farklı renk uzaylarındaki hem X-Işını hem BT göğüs radyoloji görüntüleri Covid-19 ya da zatürre olarak sınıflandırılmıştır.

## BÖLÜM 3

### HASTALIKLAR, TIBBİ GÖRÜNTÜLER VE DERİN ÖĞRENME

Özellikle akciğer hastalıkları gibi solunum yoluyla bulaşan pandemik hastalıkların tanı, takip ve tedavi süreçlerinde kullanılan tıbbi görüntüleme teknikleri bu süreçlerde önemli rol oynamaktadır. Covid-19 pandemisi sırasında, radyolojik görüntüleme teknikleri, hastalığın teşhisi, takibi ve sonrasında oluşan hasarların izlenmesi için göğüs uzmanları tarafından kullanılmıştır.

#### 3.1. TIBBİ GÖRÜNTÜLER

Tıbbi görüntüleme teknikleri göğüs hastalıkları uzmanları için önemli bir yer teşhis de önemli bir yere sahiptir. Türkiye Cumhuriyetinde bulunan devlet hastanelerinde X-Işını ve BT görüntüleme cihazlarına erişim mümkündür.

##### 3.1.1. Röntgen (X-IŞINI)


X-Işını görüntüleri, x ışınlarının vücuttaki hava ve gaz, yumuşak doku, yağ doku, kemik içerisinden geçerken doku tarafından tutulmasına göre renklendirme yapılarak oluşturulmaktadır. Akciğer gibi hava içeren oluşumlarda ışının yoğunluğu düşük olduğundan akciğer dokusu siyah görünmektedir. Aynı kalınlıkta olan kemik ve yumuşak dokular daha beyaz görünmektedir. [28]



Şekil 3. 1. Röntgen

### 3.1.2. Bilgisayarlı Tomografi (BT)

Bilgisayarlı Tomografi (BT) yöntemi, bir hastanın vücudundaki belirli alanların enine kesit görüntülerini oluşturmak için birden fazla açıdan ve konumlardan alınan röntgen verilerini birleştirilerek oluşturulan tıbbi bir görüntüleme yöntemidir. Görüntülenmesi istenilen alanı dijital dilimlere ayırır. Hekimlerin kemikler, dokular ve organlardaki sorunları belirlemek için insan vücudunu görmelerini sağlar. [29] BT görüntülerde, Hounsfield cetveline göre dokular beyaz, siyah ve gri olarak renklendirilmektedir. Gri tonlama, her bir piksel değerinin bir miktar ışığı temsil eden yoğunluk bilgisini oluşturmaktadır. [28]



Şekil 3. 2. BT

## **3.2. PANDEMİK HASTALIKLAR**

Geçmişten bugüne kadar, doktorlar bir çok salgın hastalıkla mücadele etmişlerdir. Pandemik hastalıklar, küresel ölçekte yayılan ve insan sağlığında ciddi boyutlarda hasar bırakan hastalıklardır. Bu tür hastalıklar genellikle virüs ve bakteriden kaynaklanmakta ve kısa zamanda yayılması engellenmezse ölümlerle sonuçlanmaktadır. Tarihte en çok ölümlerle sonuçlanan dünya çapındaki en büyük pandemik hastalıklar veba ve çiçek hastalığı olarak bilinmektedir. Günümüzde bilim dünyasındaki ilerleme ile hızlı bir şekilde koruyucu aşı üretilmiştir. Göğüs uzmanları tarafından sürdürülen tanı, takip ve tedavi süreçleri zamanla daha etkili bir hale gelmiştir.


### **3.2.1. Zatürre**

Zatürre bir veya her iki akciğeri etkileyen bir enfeksiyondur. Akciğerlerin hava keselerinin veya alveollerinin sıvı veya irinle dolmasına neden olur. Bakteriler, virüsler veya mantarlar zatürreye neden olabilir. Semptomlar arasında ateş, öksürük, balgam üretimi, nefes darlığı, göğüs ağrısı ve halsizlik gibi belirtiler yer alır. Semptomlar hafif ya da ağır görünebilir. [2], [30] Göğüs hastalıkları uzmanları tarafından teşhis edilen bu hastalık da, göğüs radyoloji görüntüleri, solunum testleri ve fiziki muayene yapılmaktadır.


### **3.2.2. Covid-19**

COVID-19, insanları enfekte eden ve solunum yolu yoluyla yayılan bir virüstür. Hastalığın nedeni SARS-CoV-2 virüsüdür ve ilk olarak 2019 yılında Çin'de ortaya çıkmıştır. COVID-19, dünya genelinde hızla yayılmış ve 11 Mart 2020'de Dünya Sağlık Örgütü tarafından bir pandemi olarak ilan edilmiştir. COVID-19 semptomları arasında ateş, öksürük, nefes darlığı, kas ağrıları, yorgunluk, boğaz ağrısı ve baş ağrısı yer alır. COVID-19 tanısı, semptomlar, tıbbi görüntüleme teknikleri, solunum yolu örnekleri ve antikor testleri gibi faktörler göz önünde bulundurularak konulur. Tedavi, semptomların şiddetine ve kişinin sağlık durumuna bağlı olarak farklılık gösterir. [31]





Şekil 3. 3. Zatürre



Şekil 3. 4. Covid-19


### 3.3. DERİN ÖĞRENME

Derin öğrenme, yapay sinir ağları gibi birçok katman içeren öğrenme modelini ifade eder. Bu model, makine öğrenmesi algoritmaları tarafından öğrenilen bir dizi temsil ve işleme katmanından oluşur. Bu katmanlar, belirli veri kümeleri üzerinde yapılan işlemler sonucunda, verinin daha yüksek seviyeli özelliklerini öğrenmek için tasarlanmıştır.

#### 3.3.1. Evrişimli Sinir Ağı

Görsel verileri sınıflandırma da başarılı bir derin öğrenme modelidir. Evrişim ve havuzlama katmanı içeren bir ağ yapısıdır. Evrişim katmanları, giriş görüntü verilerindeki özellikleri çıkarmak için filtreler kullanarak görüntüyü işler. Havuzlama katmanı ise giriş verisinin boyutunu indirger. CNN modelleri, sınıflandırma problemleri, nesne tespiti, görüntü segmentasyonu ve benzer görsel işleme problemlerinde de kullanılmaktadır. [43]

### 3.3.1.1. Aktivasyon Fonksiyonları



Şekil 3. 5. Aktivasyon fonksiyonu


Aktivasyon fonksiyonları, sinir ağlarındaki her bir nöronun çıktısını hesaplamak için kullanılan, matematiksel işlevlerdir. Bu fonksiyonlar, nöronun toplam girdileri üzerinde bir eşik değeri belirler.

Gerçek dünya karmaşık verilerinde ve sonuçlar doğrusal olmayacağı için aktivasyon fonksiyonları ile geri yayılım algoritmaları türevlemleri ile ağırlıkları güncelleyerek hataları indirmek için kullanılmaktadır.[44], [45]

#### 3.3.1.1.a. ReLU

Giriş değeri sıfırdan küçük olanları sıfır olarak kabul ederken, sıfırdan büyük olan değerlerin tamamını geçirgen hale getirir. Bu özellik sayesinde, ReLU hem hesaplama açısından hızlı hem de etkili bir şekilde ağırların derinleştirilmesine olanak tanır.

$$f(x) = \max(0, x)$$




Şekil 3. 6. ReLU fonksiyonu

### 3.3.1.1.b. LeakyRelu

LeakyReLU, sıfırdan küçük girişler için belirli bir eğimi (genellikle 0.01 olarak ayarlanır) kabul eder ve bu şekilde sıfır olmayan bir çıkış üretir.

$$f(x) = \{x, x \geq 0; ax, x < 0\}$$




Şekil 3. 7. LeakyReLU fonksiyonu

### 3.3.1.1.c. Sigmoid

Sigmoid fonksiyonu, çıkış değeri olarak 0-1 aralığına sıkıştırılan bir fonksiyondur. İkili sınıflandırma problemlerinde kullanılır. Ancak, derin ağlarda kullanıldığında, sifıra yakın veya sifıra eşit girişler için türevi sıfır olma eğilimi gösterir.

$$f(x) = \frac{1}{1 + e^{-x}}$$



Şekil 3. 8. Sigmoid fonksiyonu


Çizelge 3. 1. Aktivasyon fonksiyonlarının karşılaştırmalar sonuçları x-ışını-1 veri seti baz alarak yapılmıştır.

<b>Sade Veri</b>				
	Tanh	Relu	LeakyRelu	
	0.9385	0.9029	0.9112	Doğruluk
Adagrad	0.944	0.8854	0.901	Doğrulama Doğruluğu
	0.9701	0.9763	0.971	Doğruluk
Adam	0.9792	0.9844	0.9792	Doğrulama Doğruluğu
	0.9612	0.9733	0.9694	Doğruluk
RMSProp	0.9779	0.9844	0.9818	Doğrulama Doğruluğu
<b>Sade Veri</b>				
	Tanh	Relu	LeakyRelu	
	4.5508	4.616	4.5999	Kayıp
Adagrad	4.5595	4.6223	4.5951	Doğrulama Kaybı
	0.1507	0.1098	0.138	Kayıp
Adam	0.1257	0.092	0.1268	Doğrulama Kaybı
	0.1659	0.116	0.1429	Kayıp
RMSProp	0.1317	0.0818	0.1216	Doğrulama Kaybı

### 3.3.1.2. Optimizasyon Fonksiyonları

Optimizasyon algoritmaları, modelin parametrelerini optimize etmek için kullanılır. Bu algoritmalar, modelin kaybı fonksiyonunun minimize edilmesini hedefler. Bu amaçla, algoritmalar mevcut parametrelerin kayıp fonksiyonunun gradyanını hesaplarlar ve bu gradyan bilgisini kullanarak parametreleri güncellerler.

Optimizasyon algoritmaları, derin öğrenme gibi karmaşık yapay zeka sistemlerinin başarısını artırmak için önemlidir. Bu algoritmaların kullanımı, model eğitiminde daha hızlı ve daha doğru sonuçlar elde edilmesine yardımcı olabilir. RMSprop, Adam, Adagrad gibi optimizasyon algoritmaları, gradient descent yöntemlerinin geliştirilmiş versiyonlarıdır. Bu algoritmalar, gradient descent yöntemlerinin düşüşü yavaşlatan bir dezavantajını ortadan kaldırmaya çalışır: aşırı öğrenme. Bu algoritmalar, özellikle derin öğrenme modellerinde aşırı öğrenmeyi önlemek için yaygın bir şekilde kullanılır. [46]



Şekil 3. 9. Gradyan inişi optimizasyon algoritması

Gradyan İnişi, temel optimizasyon algoritmasıdır. Bir çok optimizasyon algoritması bu algoritmanın negative yanlarını geliştirerek türetilmiştir. Gradient descent, bir fonksiyonun minimum (veya maksimum) noktasına iteratif bir şekilde yaklaşarak bu noktayı bulmaya çalışır. Temel mantığı, bir fonksiyonun eğiminin en dik olduğu noktada minimuma ya da maksimuma ulaşmaktır. Çalışma adımları mantığına göre ilk olarak; başlangıç noktası belirlenir. Fonksiyonun eğimi olarak gradyanı hesaplanır. Gradyan ile öğrenme oranı kullanılarak yeni nokta hesaplanır. Hesaplanan nokta yeni başlangıç noktası olur. Bu döngü kullanılarak minimuma yaklaşmaya çalışılır.

### **3.3.1.2.a. Adagrad (Adaptif Gradyan Algoritması)**

Adagrad, gradientin tüm değerlerinin karelerinin toplamının karekökünü hesaplar ve bu sayıya göre gradienti günceller. Adagrad, daha az sık kullanılan özelliklere daha fazla vurgu yapar, böylece bu özelliklerin ağırlıkları daha fazla güncellenir. Bu algoritma, nadir özelliklere sahip veri kümeleri için iyi performans gösterir.

### **3.3.1.2.b. Adam (Adaptif Moment Tahmini)**

Bu algoritma, RMSprop ve momentum yöntemlerini birleştirir. Adam, RMSprop ile benzer şekilde gradientin karelerinin ortalamasını hesaplar ancak ayrıca gradient momentumunu da hesaplar. Böylece, Adam yöntemi, gradientin hem büyüklüğünü hem de yönünü dikkate alarak güncelleme yapar. Bu sayede, yüksek varyanslı ve düşük varyanslı gradyanlar için optimize edilmiş bir algoritma olur.

### **3.3.1.2.c. RMSprop (Kök Ortalama Kare Yayılımı)**

Gradientin karelerinin ortalamasını hesaplar ve gradientin güncellenmesinde kullanır. Bu sayede, yüksek varyanslı gradyanlar azaltılır ve düşüş hızı artar. RMSprop, özellikle doğrusal olmayan çıkışlara sahip modellerde iyi performans gösterir.

Çizelge 3. 2. Optimizasyon fonksiyonlarının karşılaştırmalar sonuçları X-ışını-1 veri seti baz alarak yapılmıştır.

<b>Sade Veri</b>				
	Tanh	Relu	LeakyRelu	
	0.9385	0.9029	0.9112	Doğruluk
Adagrad	0.944	0.8854	0.901	Doğrulama Doğruluğu
	0.9701	0.9763	0.971	Doğruluk
Adam	0.9792	0.9844	0.9792	Doğrulama Doğruluğu
	0.9612	0.9733	0.9694	Doğruluk
RMSProp	0.9779	0.9844	0.9818	Doğrulama Doğruluğu

<b>Sade Veri</b>				
	Tanh	Relu	LeakyRelu	
	4.5508	4.616	4.5999	Kayıp
Adagrad	4.5595	4.6223	4.5951	Doğrulama Kaybı
	0.1507	0.1098	0.138	Kayıp
Adam	0.1257	0.092	0.1268	Doğrulama Kaybı
	0.1659	0.116	0.1429	Kayıp
RMSProp	0.1317	0.0818	0.1216	Doğrulama Kaybı

### 3.3.1.3. Kayıp Fonksiyonları

Belirli bir algoritmanın verilen verileri ne kadar iyi modellediğini değerlendirme yöntemidir. Tahminler gerçek sonuçlardan uzaklaşırsa, kayıp fonksiyonu değeri de artar.

#### 3.3.1.3.a. Ortalama Kare Hatası


Ortalama Kare Hatası, bir regresyon probleminde gerçek değerlerle tahmin edilen değerler arasındaki farkın karesinin ortalamasını hesaplayan bir hata ölçüsüdür. MSE, aşağıdaki gibi matematiksel olarak yazılabilir:

$$MSE = \left(\frac{1}{n}\right) * \sum_{i=1}^n [y_i - \bar{y}]^2$$

### 3.3.1.4. Havuzlama

Havuzlama katmanları, boyut indirgeme yaparak hesaplama zamanını azaltır ve ağırlık aşırı öğrenmeyi engeller.[43]

#### 3.3.1.4.a. Maksimum Havuzlama



Şekil 3. 10. Maksimum havuzlama

Maksimum Havuzlama, bir önceki katmandan gelen özellik haritasının boyutunu azaltmak için kullanılan bir pooling yöntemidir. Maksimum Havuzlama işlemi, her birim boyutu önceden tanımlanmış bir pencere boyutu ile kaydırılır ve pencerenin maksimum değeri alınarak yeni bir özellik haritası oluşturulur.

### 3.3.1.4. Atma Fonksiyonu

SRIVASTAVA, HINTON, KRIZHEVSKY, SUTSKEVER AND SALAKHUTDINOV




Figure 1: Dropout Neural Net Model. **Left:** A standard neural net with 2 hidden layers. **Right:** An example of a thinned net produced by applying dropout to the network on the left. Crossed units have been dropped.

Şekil 3. 11. Atma fonksiyonu [47]



Çok sayıda parametreye sahip derin sinir ağıları, çok güçlü makine öğrenimi sistemleridir. Ancak bu tür ağlarda aşırı öğrenme olarak adlandırılabilen ciddi bir sorundur. Büyük ağların kullanımı da yavaştır, bu da test zamanında birçok farklı büyük sinir ağının tahminlerini birleştirerek “aşırı öğrenme” ile başa çıkmayı zorlaştırır. Atma yöntemi, bu sorunu ele almak için bir tekniktir. [47]

### **3.3.2. Çalışmada Kullanılan Kütüphaneler**

Python dilinde kütüphaneler önemli bir rol oynamaktadır. Kütüphaneler python dilinin işlevlerine erişim sağlamaktadır. [48]

#### **3.3.2.1. TensorFlow**

Üst düzey hesaplamalar için kullanılan açık kaynaklı bir kütüphanedir. Ayrıca makine öğrenimi ve derin öğrenme algoritmalarında da kullanılır. Çok sayıda tensör işlemi içerir.

#### **3.3.2.2. Pandas**

Özellikle veri için önemli bir kütüphanedir. Esnek üst düzey veri yapıları ve çeşitli analiz araçları sağlayan açık kaynaklı bir makine öğrenimi kütüphanesidir. Veri analizini, veri manipülasyonunu ve verilerin temizlenmesini kolaylaştırır.

#### **3.3.2.3. Numpy**

Numpy kütüphanesi, büyük matrisleri ve çok boyutlu verileri destekleyen popüler bir makine öğrenimi kütüphanesidir. Kolay hesaplamalar için yerleşik matematiksel işlevlerden oluşur.

#### **3.3.2.4. OpenCV**

Açık kaynaklı bir bilgisayarla görme ve makine öğrenimi yazılım kütüphanesidir. OpenCV, bilgisayarlı görü uygulamaları için ortak bir altyapı sağlamak ve ticari ürünlerde makine algısının kullanımını hızlandırmak amacıyla kurulmuştur. Apache 2 lisanslı bir ürün olan OpenCV, işletmelerin kodu kullanmasını ve değiştirmesini kolaylaştırır. [49]

### **3.3.2.5. Matplotlib**

Histogram ve grafik gibi sayısal verilerin çizilmesini sağlayan yazılım kütüphanesidir. 2D ve 3D grafikler, histogramlar, scatter plotlar ve çizgi grafikler gibi farklı grafik türlerini oluşturmak için kullanılabilir.

### **3.3.2.6. Glob**

Belirtilen kurallar ile eşleşen dosya veya dizinleri aramak için kullanılan bir kütüphanedir. Bu kütüphane, bir dizindeki dosyaların adlarını veya uzantılarını belirleyerek bir dizi dosyayı topluca işlemek için kullanılabilir. Özellikle büyük dosya gruplarını toplu halde okuma veya işleme için kullanılır. [50]

### **3.3.2.7. Keras**

Python dilinde hazırlanmış ve TensorFlow üzerinde çalışan bir derin öğrenme API'sidir. [51]

### **3.3.2.8. Scikit-Learn**

Doğrusal regresyon, sınıflandırma, kümeleme gibi çeşitli denetimli ve denetimsiz algoritmaları destekler.

## **3.3.3. Metrikler**

### 3.3.3.1. Karmaşıklık Matrisi

Karmaşıklık matrisi, sınıflandırma modelinin performansını değerlendirmek için kullanılan bir matristir. Modelin gerçekleştirilen sınıflandırmada doğru ve yanlış tahminlerin adedini gösteren tablodur.

Karmaşıklık matrisinde 4 değer vardır. Doğru pozitif (TP), Yanlış pozitif (FP), Doğru negatif (TN), Yanlış negatif (FN).

Karmaşıklık matrisi, modelin doğruluğu, hassasiyetini, özgürlüğünü ve F1 değerini hesaplamak için kullanılır.

### 3.3.3.2. Doğruluk

Modelin doğru sınıflandırdığı verinin, tüm verinin oranını gösterir.

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}$$

### 3.3.3.3. F1 Değeri

Doğruluk ve kesinlik (precision) metriklerinin harmonik ortalamasıdır. Doğru pozitif tahminlerin yanı sıra yanlış negatif tahminlere de dikkat eder.

$$F1 = \frac{2 * P * R}{P + R}$$

### 3.3.3.4. Kesinlik

Sınıflandırılan pozitif örneklerin gerçek pozitifler içindeki oranını ifade eder. Yanlış pozitiflerin azaltılması için önemlidir.

$$P = \frac{TP}{TP + FP}$$

### 3.3.3.5. Hassasiyet

Gerçek pozitif örneklerin sınıflandırılan pozitifler içindeki oranını ifade eder. Yanlış negatiflerin azaltılması için önemlidir.

$$R = \frac{TP}{TP + FN}$$

### 3.3.3.6. Özgüllük

Bir sınıflandırma modelinin, gerçek negatif örneklerin ne kadarının doğru bir şekilde tanımladığını ifade eden bir metriktir.

$$S = \frac{TN}{TN + FP}$$

### 3.3.3.7. Ortalama Kare Hatası

Tahmin edilen ve gerçek değerler arasındaki farkların karesinin ortalamasıdır. Regresyon problemlerinde sıklıkla kullanılır.

$$MSE = \left(\frac{1}{n}\right) * \sum_{i=1}^n [y_i - \bar{y}]^2$$

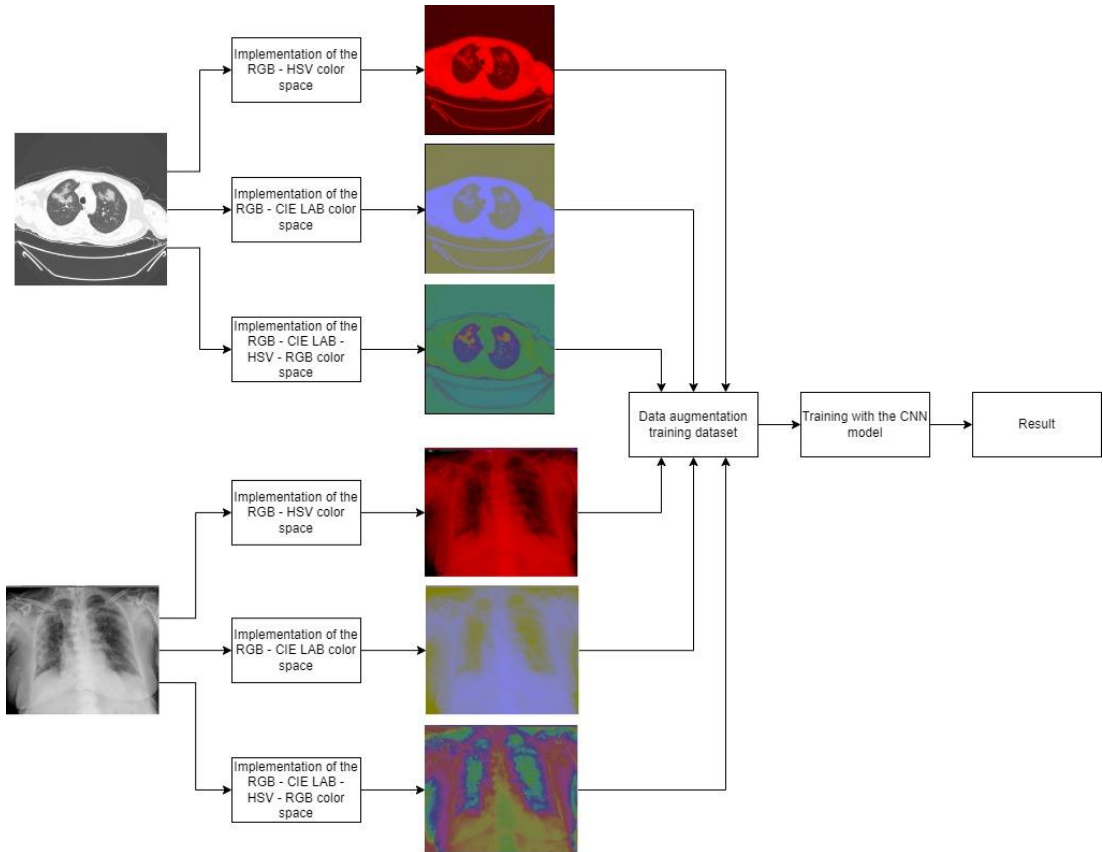
### 3.3.4. K Katlı Çapraz Doğrulama

Çalışmanın performansını değerlendirmek için kullanılmaktadır. Bu yöntem, veri setini k eşit parçaya ayırmakta ve k senaryo oluşturmaktadır. Her senaryo da k-1 miktarı modelin eğitimi için kullanılmaktadır ve 1 parça doğrulama için kullanılmaktadır. Modelin performansını değerlendirmek için elde edilen k tane doğruluk değerinin ortalaması alınır.

## BÖLÜM 4

### TIBBİ GÖRÜNTÜLERE DERİN ÖĞRENME YÖNTEMİ İLE TESPİTİ İÇİN UYGULANMA

Bu çalışmada X-Işını ve BT göğüs radyoloji görüntüleri kullanılarak Covid-19 ve zatürre hastalığı sınıflandırması gerçekleştirilmektedir. Bu çalışma için python programlama dili ve Anaconda IDE'sinde Spyder tümleşik geliştirme ortamı kullanılmıştır. Spyder ortamı, bilimsel hesaplamalar ve veri bilimcileri için kullanışlı bir ortamdır. Bu çalışmanın genel akışı Şekil 5'de gösterilmiştir. [32]



Şekil 4. 1. Çalışmanın genel şeması

#### 4.1. VERİ SETİ

Veri seti, çeşitli görüntüleme cihazlarından alınmış, farklı ışık yapısı ve farklı boyutlara sahiptir. Bu çalışmada 4 farklı göğüs radyoloji veri setleri kullanılmıştır. Farklı boyutlarda olan veri setleri, grayscale X-Işını ve BT görüntüleri içeren 4 farklı göğüs radyoloji veri seti ile gerçekleştirilmiştir. Veri setlerindeki Covid-19 ve zatürre hastalığı görüntü sayıları Çizelge 1’de görülmektedir. BT-1 verisi Kaggle ortamında Alexandria Higher Institute of Engineering and Technology kurumundan Öğretmen asistanı tarafından paylaşılmıştır. BT-2 verisi için Tao Yan’ın “Automatic distinction between COVID-19 and common pneumonia using multi-scale convolutional neural network on chest BT scans” makalesinde kullanılan veriler ve çalışmasının geliştirilmesi amacıyla Mendeley Data platformunda paylaşılan veriler kullanılmıştır. Bu çalışmada hassasiyet, özgüllük, doğruluk ve AUC değerlerini 3 farklı CNN modeli ile kıyaslayarak 99.5, 95.6, 97.7, 0.962 sonuçlarını almıştır. X-Işını-1 Kaggle’den temin edilmiştir. X-Işını-2 verisi, Kaggle’da bulunan verisetlerinin birleşmesinden oluşmaktadır. İlk veri “Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning” Kermany, D. Ve ekip arkadaşlarının yapmış olduğu çalışmadan alınmıştır. İkinci veri Montreal Üniversitesi araştırma ekibi Joseph Paul Cohen tarafından paylaşılmıştır. Üçüncü veri Kaggle ortamında bulunmaktadır ve Covid-19 veriseti ödülünü Kaggle komitesinden almıştır. Bu veriseti iki farklı makalede kullanılmıştır. Bu makaleler Rahman T. Ve ekibi tarafından gerçekleştirilen “Exploring the effect of image enhancement techniques on COVID-19 detection using chest X-ray images” ve Chowdhury M. E. H. Tarafından gerçekleştirilen “Can AI Help in Screening Viral and COVID-19 Pneumonia?” çalışmalarıdır.

Çizelge 4. 1. Veri seti görüntü miktarı

Görüntü Veri Türü	Covid-19 Görüntü Sayısı	Zatürre Görüntü Sayısı
X-Işını-1[33]	576	4273
X-Işını-2[34]	980	4239
BT-1[35]	2035	3390
BT-2[36], [37]	41841	2700

X-Işını görüntüleri, x ışınlarının vücuttaki hava ve gaz, yumuşak doku, yağ doku, kemik içerisinden geçerken doku tarafından tutulmasına göre renklendirme yapılarak oluşturulmaktadır. Akciğer gibi hava içeren oluşumlarda ışının yoğunluğu düşük olduğundan akciğer dokusu siyah görünmektedir. Aynı kalınlıkta olan kemik ve yumuşak dokular daha beyaz görünmektedir. BT görüntülerde, Hounsfield cetveline göre dokular beyaz, siyah ve gri olarak renklendirilmektedir. Gri tonlama, her bir piksel değerinin bir miktar ışığı temsil eden yoğunluk bilgisini oluşturmaktadır. Bu nedenle giriş verileri grayscale görüntülerdir. Göğüs hastalıklarının teşhisinde X-Işını ve BT görüntüleri yaygın bir şekilde kullanılmasına rağmen X-Işını görüntülerde lezyon saptanabilirlik düzeyi BT görüntülere göre daha düşüktür[28]. Çünkü BT görüntülerde, vücudun ince kesitler halinde görüntülenir ve dokuların x-ışını tutma oranları doğrudan ölçülebilmektedir. Fakat her sağlık kuruluşunda BT görüntü cihazı bulunmayabilir. Bunun için bu çalışmada aynı model kullanılarak hem X-Işını hem de BT radyoloji görüntülerinde sınıflandırma gerçekleştirilmiştir.

#### 4.1.1. Renk Uzayları

Renk uzayları, genellikle bir ya da birden fazla renk bileşeninden oluşmaktadır ve matematiksel 3 boyutlu koordinat sistemleri kullanılarak tanımlanır [38]. Renkli görüntülerin dijital temsili, her bir pikselin renk yoğunluğu değerlerinin saklanmasıyla gerçekleştirilir. Bu yoğunluk değerleri genellikle, bileşenleri büyük ölçüde uygulanan renk uzayına bağlı olan üç boyutlu vektörlerle tanımlanır. [39]

#### 4.1.1.1. Ton-Doygunluk-Değer

“H” Hue (Ton), “S” Saturation (Doygunluk), “V” Value (Değer) bileşenlerinden oluşan bir renk uzayıdır. HSV renk uzayı, renkleri daha doğal bir şekilde tanımlamak için kullanılır. H değeri, renk tonunu belirtir. S değeri, rengin yoğunluğunu belirtir. V değeri, rengin parlaklığını belirtir. [38] Renk tonu, 0 ila 360 derece aralığında değişen bir renk skalasını temsil eder. Ancak bu skalada renk geçişi, kırmızıdan başlayarak sarıya, yeşile, cam göbeğine, maviye mora ve siyaha doğru gerçekleşir. [40] HSV renk modeli, özellikle bilgisayar grafiklerinde sıkça kullanılır ve renkleri anlamak için sezgisel bir yaklaşım sunar. Ton, doygunluk ve değer bileşenleri, renkleri tanımlamak ve ayırt etmek için kullanılır. Renk tonu, ışıklandırma ve kamera açısındaki değişikliklere bağlı olarak değişmezken, RGB koordinatları kolayca aşağıdaki formül kullanılarak HSV koordinatlarına dönüştürülebilir. [39]

$$R' = \frac{R}{255}, G' = \frac{G}{255}, B' = \frac{B}{255}$$
$$C_{max} = \max(R', G', B')$$
$$C_{min} = \min(R', G', B')$$
$$\Delta = C_{max} - C_{min}$$

Ton Hesaplaması:

$$H = 0^\circ, \Delta = 0$$
$$H = 60^\circ \times \left( \frac{G' - B'}{\Delta} \bmod 6 \right), C_{max} = R'$$
$$H = 60^\circ \times \left( \frac{B' - R'}{\Delta} + 2 \right), C_{max} = G'$$
$$H = 60^\circ \times \left( \frac{R' - G'}{\Delta} + 4 \right), C_{max} = B'$$

Doygunluk hesaplaması:

$$S = 0^\circ, C_{max} = 0$$
$$S = \frac{\Delta}{C_{max}}, C_{max} \neq 0$$

Değer hesaplaması:

$$V = C_{max}$$



#### **4.1.1.2. Mavi-Yeşil-Kırmızı**

Mavi, yeşil ve kırmızı renk bileşenlerini içeren bir renk uzayıdır. BGR, özellikle OpenCV kütüphanesi gibi bazı görüntü işleme kütüphanelerinde kullanılır. [38] OpenCV, BGR resim formatını kullanır. Bu nedenle, cv2.imread() kullanarak bir görüntüyü okuduğumuzda, varsayılan olarak BGR biçiminde yorumlar. [41], [42]

#### **4.1.1.3. CIE 1976 LAB**

CIE LAB, renklerin insan gözünde nasıl algılandığını modelleyen bir renk uzayıdır. CIE LAB, renklerin farklılık değerlerini hesaplamak ve renklerin uyumluluğunu belirlemek için kullanılır. CIE, renk ve aydınlatma bilimleri alanında dünya çapında bir otorite olan bir organizasyondur. L bileşeni, renkli ışığın parlaklığını belirtir. A ve B bileşenleri, renklerin yeşil-kırmızı ve mavi-sarı bileşenlerini belirtir. [38]

#### **4.1.1.4. Kırmızı-Yeşil-Mavi**

Kırmızı, yeşil ve mavi renk bileşenlerini içeren bir renk uzayıdır. RGB, dijital görüntüleme, kameralar, monitörler ve diğer dijital cihazlar için standart bir renk uzayıdır. [38] Renkli kameralar, tarayıcılar ve ekranlar çoğunlukla doğrudan RGB sinyal girişi ve çıkışı ile sağlandığından, bu renk alanı temeldir ve gerekirse diğer renk alanlarına dönüştürülür. Aydınlatma yoğunluğunun etkisini ortadan kaldırmak için renk,  $r + g + b = 1$  gibi iki boyutlu bir diyagramda çizilebilir. [39]

## **4.2. VERİ SETİNİN HAZIRLANMASI**

X-Işını1 veri setinde verilerin orijinal boyutlarının bir bölümü 1982x1482, 2000x2000, 2563x1148, 951x727, 907x689 şeklindedir. X-Işını2 röntgen veri setinde verilerin orijinal boyutlarının bir bölümü 256x256, 331x331, 1980x2004, 1024x1024, 416x341 şeklindedir. BT1 veri setinde verilerin original boyutu 512x512'dur. BT2 veri setinde, Covid-19 hastalarına ait görüntülerin orijinal boyutu 512x512, zatürre hastalarına ait görüntülerin orijinal boyutu 380x380'dir. Veri

setlerindeki görüntü boyutu farklı olduğu için ilk ön işleme adımı olarak tüm grayscale görüntüler 150x150 olarak yeniden boyutlandırılmıştır.

#### 4.2.1. Veri Artırma

Bir modeli eğitirken veri çeşitliliğini artırarak modelin öğrenmesini sağlamak için Data Augmentation yapılmaktadır. Üretilen veriler, Keras derin öğrenme kütüphanesinde, Görsel Veri Üretme sınıfı kullanılarak elde edilir. Veri artırma yöntemi ikinci ön işleme adımı olarak tüm görüntü verilerine; dönme aralığı, yeniden ölçeklendirme, kesme aralığı, yakınlaştırma aralığı, yatay çevirme, genişlik kaydırma aralığı, yükseklik kaydırma aralığı yöntemleri ile uygulanmıştır. [52]

Çizelge 4. 2. Veriseti içinde veri artırma

Veri	Eğitim Verisi	Arttırılmış Eğitim Verisi
X-Işımı1	3879	3904
X-Işımı2	4173	4224
BT-1	4340	4352
BT-2	35438	35456

**Döndürme Aralığı:** Rastgele döndürme açısı derecesi aralığıdır. Şekil 13’de a. maddede örnek veri mevcuttur.

**Ölçeklendirme:** Görüntü verilerini ölçeklendirme faktörüdür. Şekil 13’de b. maddede örnek veri mevcuttur.


**Kaydırma Aralığı:** Rastgele kaydırma açısı derecesi aralığıdır. Şekil 13’de c. maddede örnek veri mevcuttur.

**Yakınlaşma Aralığı:** Rastgele yakınlaştırma aralığıdır. Şekil 13’de d. maddede örnek veri mevcuttur.


**Yatay Çevirme:** Görüntüyü yatay düzlemde simetriği alınarak çevirme işlemidir. Şekil 13’de f. maddede örnek veri mevcuttur.

**Genişlik Kaydırma Aralığı:** Görüntüyü yatay ekseninde kaydırma aralığıdır. Şekil 13’de e. maddede örnek veri mevcuttur.


**Yükseklik Kaydırma Aralığı e:** Görüntüyü dikey ekseninde kaydırma aralığıdır Şekil 13'de g. maddede örnek veri mevcuttur.




a. Döndürme Uygulanmış Veri



b. Ölçeklendirme Uygulanmış Veri




c. Kaydırma Uygulanmış Veri



d. Yakınlaştırma Uygulanmış Veri



e. Yatay Ekseninde Kaydırma Uygulanmış Veri



f. Simetriği Uygulanmış Veri

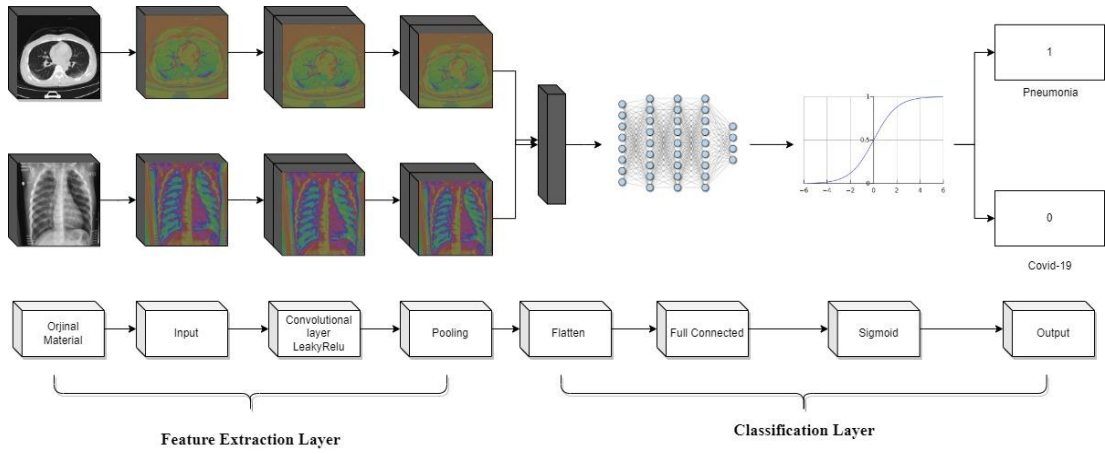


g. Dikey Ekseninde Kaydırma Uygulanmış Veri

Şekil 4. 2. Veri artırma yöntemi uygulanmış görüntü verileri

### 4.3. GÜÇLÜ EVRİŞİMLİ SİNİR AĞI MODELİ

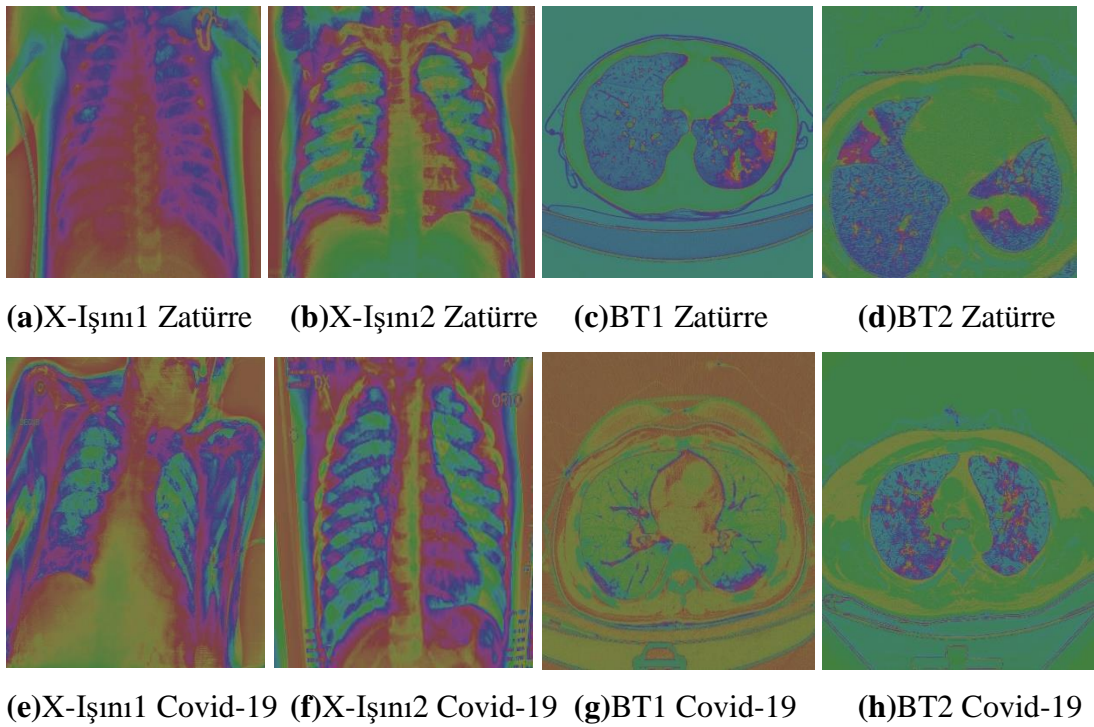
Derin öğrenme, farklı problemlerde başarıyla kullanılmıştır [53], [54]. CNN, en popüler derin öğrenme modellerinden biridir. CNN mimarisi, evrişim, havuzlama ve tam bağlı katman olarak üç parçan oluşur [55]. Katmanlı yapısıyla özünü tespit ederek daha başarılı sonuçlar ortaya koyuyor. Bu nedenle, hastalıklı göğüs radyolojisi görüntülerini sınıflandırabilmek için sağlam CNN modeli tercih edilmiştir. Şekil 16. te bu bulgu kullanılan modelin genel yapısında görülmektedir.



Şekil 4. 3. Önerilen modelin mimari tasarımı

Görüntülerdeki renk çeşitliliğinin fazla olması renkleri standart bir şekilde gruplama ihtiyacını ortaya çıkardığı için renk uzayı kavramı ortaya çıkmıştır. Renk uzayları renkleri tanımlamak için kullanılan matematiksel modellerdir. Renk uzayları, cihaz bağımlı ve cihaz bağımsız olarak sınıflandırılmaktadır[56] . Modelin sınıflandırma başarısını incelemek için orijinal görüntüler üzerinde cihaz bağımlı RGB ve HSV renk uzayı ile cihaz bağımsız CIE LAB renk uzayı dönüşümleri gerçekleştirilmiştir. Çünkü X-Işını ve BT görüntü özellikleri cihazın modeline göre değişiklik gösterebilir. Bu nedenle, bu çalışmada cihaz özelliği ve renk uzayı değişse bile başarılı sınıflandırma yapan bir model gerçekleştirilmektedir. Her bir veri seti RGB-HSV, RGB-CIE LAB ve RGB-HSV-CIE LAB-RGB renk uzaylarına dönüştürülmüştür. Orijinal grayscale veri seti görüntüleri ilk önce RGB renk uzayına dönüştürülmüştür. Çünkü grayscale görüntü, [0, 255] aralığında piksel değerlerine sahip tek kanallı görüntülerdir ve sadece bir RGB görüntüsünün gri tonlamalı

temsilidir. Bu nedenle sadece iki olası değere sahip siyah-beyaz [0, 255] ikili görüntülerden farklıdır. RGB dönüşüm, HSV renk uzayında Hue, Saturation ve Value (Brightness, Lightness) değerlerinin temsilini ve CIE LAB renk uzayında L\*(for perceptual lightness), a\* and b\*(for the four unique colors of human vision: red, green, blue and yellow) değerlerinin temsilini kolaylaştırmaktadır. Renk uzayı dönüşüm işlemi boyutlandırmadan sonra yapılan diğer ön işleme adımdır. Yeni oluşturulan bu veriler modelin giriş veri setini oluşturmaktadır. Şekil 17’de renk uzay dönüşümleri yapılmış giriş verileri görülmektedir.



Şekil 4. 4. Her bir veri seti grubu için rgb-hsv-cie lab-rgb renk uzay dönüşümleri yapılmış örnek giriş verileri.

Boyutlandırma ve renk uzayı dönüşümleri ile veri ön işleme adımları tamamlanarak giriş veri seti hazır hale getirilmiştir. 4 farklı veri seti için kullanılan güçlü modelin mimari detayları Şekil 16’da görülmektedir.

Çizelge 4. 3. Önerilen CNN model katmanları

Katman	Filtre Boyutu	Filtre Sayısı	Çıkış Şekli	Eğitilecek Sayısı	Parametre
Giriş	-	64	150 x 150 x 3	0	
Evrişim	3 x 3	32	148 x 148 x 32	896	
Leaky relu	-	-	148 x 148 x 32	0	
Maksimum Havuzlama	2 x 2	-	74 x 74 x 32	0	
Atma	-	-	74 x 74 x 32	0	
Evrişim	3 x 3	64	72 x 72 x 64	18496	
Leaky relu	-	-	72 x 72 x 64	0	
Maksimum Havuzlama	2 x 2	-	36 x 36 x 64	0	
Evrişim	3 x 3	64	34 x 34 x 128	73856	
Leaky relu	-	-	34 x 34 x 128	0	
Maksimum Havuzlama	2 x 2	-	17 x 17 x 128	0	
Evrişim	3 x 3	128	15 x 15 x 128	147584	
Leaky relu	-	-	15 x 15 x 128	0	
Maksimum Havuzlama	2 x 2	-	7 x 7 x 128	0	
Düzleştirme			6272	0	
Yoğunluk	-	-	256	1605888	
Relu	-	-	256	0	
Atma	-	-	256	0	
Yoğunluk	-	-	2	514	
Sigmoid	-	-	2	0	

Toplam Parametre: 1847314

Bu çalışmada önerilen model 4 veri seti grubu için ayrı ayrı uygulanmıştır. Önerilen modelin evrişim katmanı boyutu 64, 64, 128, 128, 256 olarak belirlenmiştir ve bilgi kaybına yol açmaması için 3x3 gibi küçük boyutlu bir kernel kullanılmıştır. Kernelde bulunan veriler için filtreleme yöntemi olarak Maksimum Havuzlama yöntemi tercih edilmiştir. Çok katmanlı yapay sinir ağlarında doğrusal olmayan dönüşüm işlemler

için aktivasyon fonksiyonları kullanılmaktadır. Bu aktivasyon fonksiyonları, gizli katmanlarda geri türev alınabilmesi için gizli katmanların çıktısını normalize etmektedir. Bu çalışmada negatif değerlerde türevin sıfır olmasını engellemek için aktivasyon fonksiyonu LeakyRelu ve optimizasyon fonksiyonu olarak Adam tercih edilmiştir. Çünkü, Adaptif algoritmalar öğrenme hızını kendisi öğrenmektedir ve dinamikdir. Öğrenme hızı modelin öğrenme performansını etkilediği için bu hiperparametrenin seçimi çok önemlidir. Ayrıca, modeli doğru zamanda durdurabilmek için erken durdurma kullanılmıştır. Tam bağlı katmanlarda belli eşik değerinin altındaki düğümlerin seyreltilmesi başarıyı arttırdığı için önerilen modelin bağlantı katmanında atma yöntemi değeri 0,4 olarak seçilmiştir. Model verileri Covid- 19 ve zatürre olarak ikili sınıflandırdığı için çıkışta Sigmoid fonksiyonu tercih edilmiştir.

## BÖLÜM 5

### DENEYSEL ÇALIŞMALAR

Modelin tasarlandığı bilgisayar ve kütüphane bilgileri şu şekildedir: Intel Core i5-11600K 3.90 GHz CPU ve Nvidia Geforce Gtx 1060 6GB Ekran Kartı, Spyder, Tenserflow, Keras, Numpy, Pandas, Matplotlib. Renk uzayları arasındaki dönüşüm için OpenCV kütüphanesi kullanılmıştır.

4 veriseti için yapılan bu çalışmada renk uzaylarının etkisini belirlemek ve hangi renk uzayının kullanılacağına karar vermek için her veri seti SADE, RGB-HSV, RGB- CIE LAB, RGB- CIE LAB- HSV- RGB olarak gruplandırılarak eğitim yapılmıştır. Eğitim başarısı, eğitim kaybı, doğrulama başarısı, doğrulama kaybı, f1 skoru, epoch başına çalışma süresi ve korelasyon haritası ile tablo oluşturularak değerlendirilmiştir. Bu değerlendirme sonucunda verilere RGB- CIE LAB- HSV- RGB uygulanarak çalışma devam edilmiştir.



Çizelge 5. 1. X-Işını-1 veri seti için renk uzaylarının kıyaslanması

<b>X - Işını 1</b>						
	Eğitim Doğruluğu	Eğitim Kaybı	Doğrulama Doğruluğu	Doğruluk Kaybı	F1 Değeri	Çalışma Zamanı
Sade	0.9803	0.1131	0.9906	0.0878	0.99472	56s
RGB - HSV	0.982	0.0952	0.9885	0.0781	0.99345	52s
RGB- CIE LAB	0.9782	0.118	0.9812	0.101	0.98874	55s
RGB-HSV-CIE LAB-RGB	0.9827	0.0948	0.9823	0.0884	0.98878	55s

<b>Sade</b>			<b>RGB - HSV</b>		
	Covid-19	Zatürre		Covid-19	Zatürre
Covid-19	114	8	Covid-19	125	4
Zatürre	1	847	Zatürre	7	834

<b>RGB- CIE LAB</b>			<b>RGB-HSV-CIE LAB-RGB</b>		
	Covid-19	Zatürre		Covid-19	Zatürre
Covid-19	117	12	Covid-19	114	15
Zatürre	7	834	Zatürre	4	837

Çizelge 5. 2. X-Işını-2 Veri seti için renk uzaylarının kıyaslanması

<b>X - Işını 2</b>						
	Eğitim Doğruluğu	Eğitim Kaybı	Doğrulama Doğruluğu	Doğruluk Kaybı	F1 Değeri	Çalışma Zamanı
Sade	0.9759	0.1265	0.9893	0.0771	0.9928	39s
RGB - HSV	0.9732	0.1284	0.9912	0.088	0.99418	51s
RGB- CIE LAB	0.9737	0.1345	0.9854	0.0968	0.98603	50s
RGB-HSV-CIE LAB-RGB	0.9781	0.1214	0.9893	0.0859	0.9936	53s

<b>Sade</b>			<b>RGB - HSV</b>		
	Covid-19	Zatürre		Covid-19	Zatürre
Covid-19	205	10	Covid-19	180	7
Zatürre	2	827	Zatürre	3	854

<b>RGB- CIE LAB</b>			<b>RGB-HSV-CIE LAB-RGB</b>		
	Covid-19	Zatürre		Covid-19	Zatürre
Covid-19	173	14	Covid-19	179	8
Zatürre	10	847	Zatürre	3	854

Çizelge 5. 3. BT-1 Veri seti için renk uzaylarının kıyaslanması

<b>BT-1</b>						
	Eğitim Doğruluğu	Eğitim Kaybı	Doğrulama Doğruluğu	Doğruluk Kaybı	F1 Değeri	Çalışma Zamanı
Sade	0.9614	0.1697	0.9902	0.117	0.99237	25s
RGB - HSV	0.9539	0.2112	0.9766	0.1341	0.98204	24s
RGB- CIE LAB	0.9516	0.221	0.9795	0.171	0.96086	22s
RGB-HSV-CIE LAB-RGB	0.9808	0.1312	0.998	0.0921	0.98425	24s

<b>Sade</b>			<b>RGB - HSV</b>		
	Covid-19	Zatürre		Covid-19	Zatürre
Covid-19	425	1	Covid-19	405	4
Zatürre	5	650	Zatürre	20	659

<b>RGB- CIE LAB</b>			<b>RGB-HSV-CIE LAB-RGB</b>		
	Covid-19	Zatürre		Covid-19	Zatürre
Covid-19	408	1	Covid-19	408	1
Zatürre	50	626	Zatürre	20	656

Çizelge 5. 4. BT-2 Veri seti için renk uzaylarının kıyaslanması

<b>BT-2</b>						
	Eğitim Doğruluğu	Eğitim Kaybı	Doğrulama Doğruluğu	Doğruluk Kaybı	F1 Değeri	Çalışma Zamanı
Sade	0.9903	0.0973	0.9819	0.0717	0.84713	225s
RGB - HSV	0.9949	0.0452	0.999	0.0343	0.88541	200s
RGB- CIE LAB	0.9807	0.1	0.9896	0.0717	0.90684	187s
RGB-HSV-CIE LAB-RGB	0.9827	0.1049	0.9937	0.0776	0.93613	193s

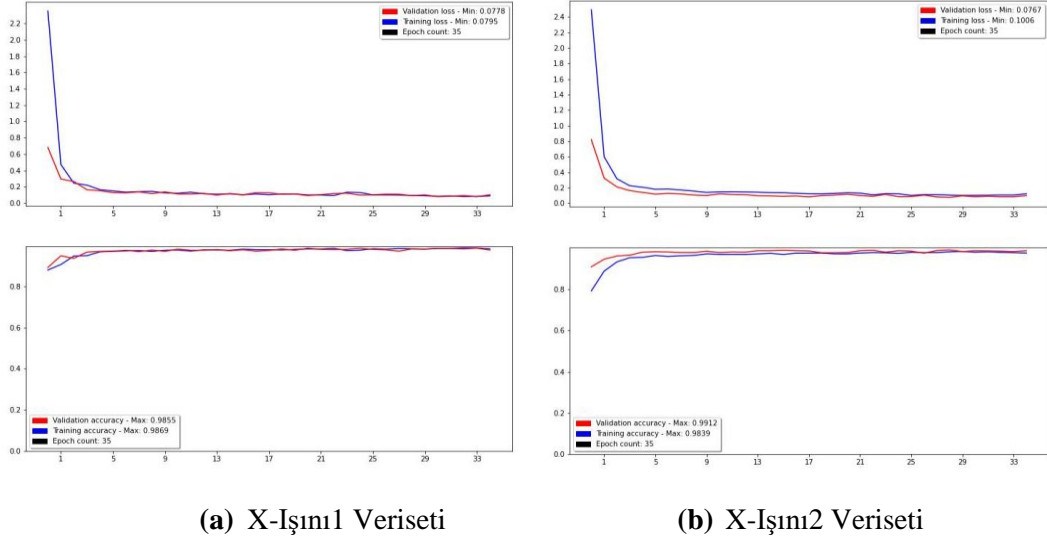
<b>Sade</b>			<b>RGB - HSV</b>		
	Covid-19	Zatürre		Covid-19	Zatürre
Covid-19	8268	35	Covid-19	8291	1
Zatürre	122	435	Zatürre	116	452

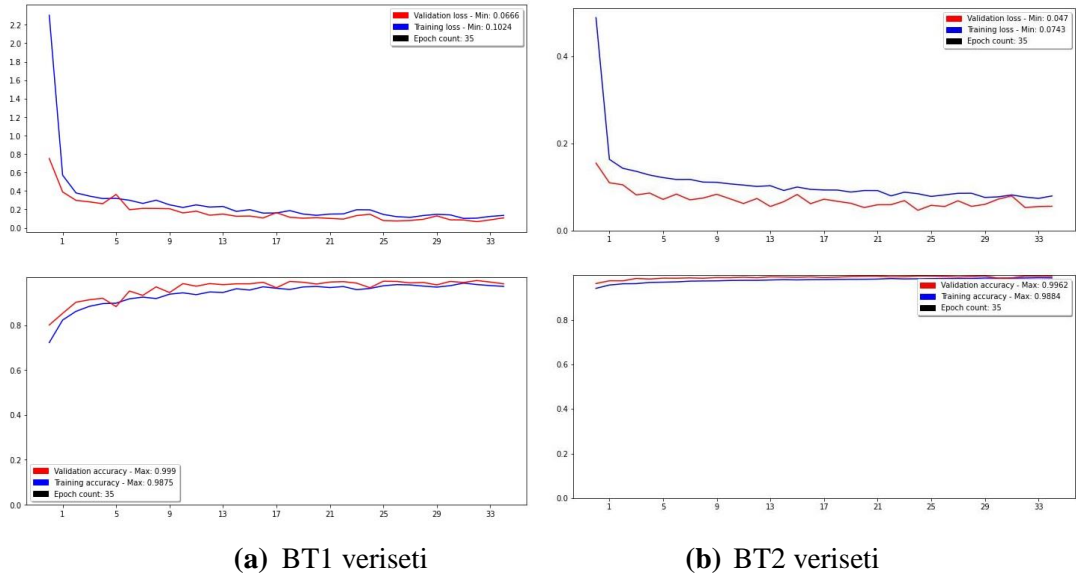
<b>RGB- CIE LAB</b>			<b>RGB-HSV-CIE LAB-RGB</b>		
	Covid-19	Zatürre		Covid-19	Zatürre
Covid-19	8285	7	Covid-19	8277	15
Zatürre	91	477	Zatürre	55	513

## 5.1. MODELİN DEĞERLENDİRİLMESİ

X-Işım1, X-Işım2, BT1 ve BT2 veri setleri %80 eğitim, %20 doğrulama veri seti olarak belirlenmiştir. Şekil 5.1.'de modelin 35 dönem için doğruluk ve kayıp değerlerinin grafiklerini göstermektedir.



Şekil 1. X-Işım verileri için doğrulama ve eğitim başarı-kayıp grafiği



Şekil 5. 1. BT verileri için doğrulama ve eğitim başarı-kayıp grafiği

K-katlı çapraz doğrulama, modelin yüksek performansının rastgele olup olmadığını görmemizi sağlar. Bu yöntem hem aşırı öğrenme sorunu yaşayıp yaşamadığımızı hem de modelin kalitesini gösterir. Oluşturulan modelin geçerliliğini artırmak için 5 katlı çapraz doğrulama yöntemi kullanılır ve onun bir veri seti için Şekil 18 ve Şekil 19’da görülen karışıklık matrisleri ortaya çıkar. Şekil 18 ve Şekil 19’da görüldüğü gibi önerilen model BT1 veri setinde yanlış sınıflandırılan Covid-19 örnek sayısının zatürreye göre daha fazla olduğu görülmektedir. Bunun sebebi, BT görüntünün ‘X-Işını’ e göre tek zayıf yanı görüntülerinin kesit olması nedeniyle anatomik bütünlüğünün olmamasıdır.

		Average X-Ray1		Average X-Ray2	
		Covid-19	Pneumonia	Covid-19	Pneumonia
Actual	Covid-19	106	10	183	13
	Pneumonia	3	852	3	844
		Predict		Predict	

		Average CT1		Average CT2	
		Covid-19	Pneumonia	Covid-19	Pneumonia
Actual	Covid-19	405	2	8309	11
	Pneumonia	24	654	39	501
		Predict		Predict	

Şekil 5. 2. Her veri seti için 5 katlı çapraz doğrulanma için karmaşıklık matrisi

Çizelge 5. 5. Tüm veri gruplarında uygulanan 5 katlı çapraz doğrulama için ortalama performans sonuçları

	Başarı	F1 Değeri	P	R	S	MSE
<b>X-Işını1</b>	0,987	0,993	0,972	0,914	0,996	0,013
<b>X-Işını2</b>	0,984	0,99	0,984	0,934	0,996	0,016
<b>BT1</b>	0,976	0,98	0,944	0,995	0,965	0,024
<b>BT2</b>	0,994	0,953	0,995	0,999	0,928	0,006

Çizelge 3 incelendiğın de en yüksek kayıp değeri BT1 veri setinde gözlemlenmiştir. Eğer Şekil 17.’deki görüntü incelenirse, renk uzak dönüşümü sonrasında görüntüde

belirgin bir şekilde bozulma olduđu grlmektedir. Bu hem orijinal BT grntnn kesitler halinde oluřturulmasından kaynaklı anatomi bozukluđu hem de grayscale grntnn başka renk uzayına dnřtrlmesinden kaynaklıdır. Ama Çizelge 3.'n btnne bakıldığında başarılı sonuçlar elde edildiđi grlmektedir.

## BÖLÜM 6

### SONUÇLAR

Son dönemde geniş çaplı fizyolojik ve psikolojik hasarlar bırakan Covid-19 hastalığının düşük maliyetli, hızlı tespit edilmesi, hastanın ve çevresinde bulunan insanların sağlığı için önem arz etmektedir. Devlet hastanelerinde PCR testi sonucu birkaç saat ile bir gün arasında açıklanmaktadır. Hasta bireylere sonuç ulaşana kadar farklı bireylerle girdikleri temas yayılımı arttırmaktadır. Hızlı tespit ile yayılım hızını azaltmak için, hastanelerde göğüs görüntüleme yöntemleri tedavi yöntemi olarak tercih edilmektedir.

Bu çalışmada, CNN ağına, farklı renk uzaylarındaki hem BT hem de X-Işını görüntülerine uygun olacak şekilde, bir model oluşturulmuştur. Böylece medikal görüntü özelliğinden ve renk uzayından bağımsız bir şekilde hızlı ve başarı oranı yüksek bir model elde edilmiştir. X-Işını ve BT göğüs radyoloji görüntüleri RGB, RGB – HSV ve RGB – HSV –CIE LAB – RGB renk uzaylarına dönüştürülmüştür. Böylece radyoloji cihazı markalarına göre görüntü özellikleri değişse bile model giriş veriseti özelliklerinden minimum seviyede etkilenecektir. Farklı renk uzaylarına dönüştürülen giriş verileri ile Covid-19 ve zatürre hastalığı başarılı bir şekilde tespit edilmiştir. Böylece radyoloji uzmanının eksik-yetersiz olduğu sağlık kuruluşlarında bilgisayar tabanlı uzman sistem olarak tercih edilebilir. Çalışmanın başarısı sonraki çalışmanın motivasyonunu oluşturmaktadır. CNN tabanlı transfer learning algoritması ile mobil uygulama gerçekleştirilmesi hedeflenmektedir. Böylece başarılı sınıflandırma yapan kullanıcı dostu bir sistem oluşturulacaktır.

Önerilen model ile literatürdeki diğer çalışmaların karşılaştırması Tablo 11’de gösterilmiştir. Literatürde önerilen modele en çok benzeyen, renk uzayı ile çalışma yapan Uçar ve ekibi ile yapılan karşılaştırma Tablo 12’de gösterilmiştir. Tabloda gösterildiği üzere önerilen modelin başarı oranı daha yüksektir.

Çizelge 6. 1. Literatürde bulunan referans çalışmalar

Referanslar	Yöntem	Veri Seti	
Togacar ve ekibi [2]	AlexNet	X-Işını	İkili sınıflandırma (Zatürre ve Sağlıklı): 94%
Nayak ve ekibi [9]	ResNet-50, ResNet-34, MobileNet-v2, VGG-16, SqueezeNet, AlexNet, Inception-V3, GoogleNet	X-Işını	İkili sınıflandırma (Covid-19 ve Sağlıklı): 98%
Haque ve ekibi [7]	ResNet-50, InceptionV3, Inception-ResNetV2	X-Işını	İkili sınıflandırma (Covid-19 ve Sağlıklı): 97%
Islam ve ekibi [5]	CNN-LSTM	X-Işını	Çoklu sınıflandırma (Covid-19, Zatürre ve Sağlıklı): 99.4%
Rahimzadeh ve ekibi [27]	Xception ResNet50V2	BT	İkili sınıflandırma (Covid-19 ve Sağlıklı): 98.49%
Öztürk ve ekibi [57]	DarkNet	X-Işını	İkili sınıflandırma (Covid-19 ve Sağlıklı): 98.08% Çoklu sınıflandırma (Covid-19, Zatürre ve Sağlıklı): 87.02%
Thakur ve Kumar[58]	CNN	X-Işını BT	İkili sınıflandırma (Covid-19 ve Sağlıklı): 99.64% Çoklu sınıflandırma (Covid-19, Zatürre ve Sağlıklı): 98.28%
Önerilen Model	CNN	X-Işını1 X-Işını2 BT1 BT2	İkili sınıflandırma X-Işını (Covid-19 ve Zatürre): 98.7%, 98.4% İkili sınıflandırma BT (Covid-19 ve Zatürre): 97.6%, 99.4%

Çizelge 6. 2. Literatürde bulunan referans çalışmalar

<b>Veri İsmi</b>	<b>Başarı</b>	<b>F1Değeri(n)</b>	<b>Kesinlik(n)</b>	<b>Hassasiyet(n)</b>	<b>Spesifiklik(n)</b>
X-Işını1	0,987	0,993	0,972	0,914	0,996
X-Işını2	0,984	0,99	0,984	0,934	0,996
BT1	0,976	0,98	0,944	0,995	0,965
BT2	0,994	0,953	0,995	0,999	0,928
Uçar ve ekibi X-Işını[59]	0,924	0,8879	0,888	0,889	0,943



## KAYNAKLAR

1. “COVID Live - Coronavirus Statistics - Worldometer.” <https://www.worldometers.info/coronavirus/> (accessed Jan. 07, 2022).
2. M. Toğaçar, B. Ergen, and M. E. Sertkaya, “Zatürre Hastalığının Derin Öğrenme Modeli ile Tespiti,” *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, vol. 31, no. 1, pp. 223–230, 2019, [Online]. Available: <https://dergipark.org.tr/tr/pub/fumbd/498364>
3. T. Yan, P. K. Wong, H. Ren, H. Wang, J. Wang, and Y. Li, “Automatic distinction between COVID-19 and common pneumonia using multi-scale convolutional neural network on chest CT scans,” *Chaos Solitons Fractals*, vol. 140, p. 110153, 2020, doi: <https://doi.org/10.1016/j.chaos.2020.110153>.
4. M. Mishra, V. Parashar, and R. Shimpi, “Development and evaluation of an AI System for early detection of Covid-19 pneumonia using X-ray (Student Consortium),” *Proceedings - 2020 IEEE 6th International Conference on Multimedia Big Data, BigMM 2020*, pp. 292–296, 2020, doi: [10.1109/BigMM50055.2020.00051](https://doi.org/10.1109/BigMM50055.2020.00051).
5. M. Z. Islam, M. M. Islam, and A. Asraf, “A combined deep CNN-LSTM network for the detection of novel coronavirus (COVID-19) using X-ray images,” *Inform Med Unlocked*, vol. 20, p. 100412, 2020, doi: <https://doi.org/10.1016/j.imu.2020.100412>.
6. A. Serener and S. Serte, “Deep learning for mycoplasma pneumonia discrimination from pneumonias like COVID-19,” *4th International Symposium on Multidisciplinary Studies and Innovative Technologies, ISMSIT 2020 - Proceedings*, pp. 1–5, 2020, doi: [10.1109/ISMSIT50672.2020.9254561](https://doi.org/10.1109/ISMSIT50672.2020.9254561).
7. K. Foysal Haque, F. Farhan Haque, L. Gandy, and A. Abdelgawad, “Automatic Detection of COVID-19 from Chest X-ray Images with Convolutional Neural Networks,” *Proceedings - 2020 International Conference on Computing, Electronics and Communications Engineering, iCCECE 2020*, pp. 125–130, 2020, doi: [10.1109/iCCECE49321.2020.9231235](https://doi.org/10.1109/iCCECE49321.2020.9231235).
8. M. Polsinelli, L. Cinque, and G. Placidi, “A light CNN for detecting COVID-19 from CT scans of the chest,” *Pattern Recognit Lett*, vol. 140, pp. 95–100, 2020, doi: [10.1016/j.patrec.2020.10.001](https://doi.org/10.1016/j.patrec.2020.10.001).
9. S. R. Nayak, D. R. Nayak, U. Sinha, V. Arora, and R. B. Pachori, “Application of deep learning techniques for detection of COVID-19 cases using chest X-ray

- images: A comprehensive study,” *Biomedical Signal Processing and Control*, vol. 64, 2021. doi: 10.1016/j.bspc.2020.102365.
10. A. Tasdelen and B. Sen, “A hybrid CNN-LSTM model for pre-miRNA classification,” *Scientific Reports* 2021 11:1, vol. 11, no. 1, pp. 1–9, Jul. 2021, doi: 10.1038/s41598-021-93656-0.
  11. E. Somuncu and N. A. Atasoy, “Evrışimli tekrarlayan sinir ađı ile metin g3r3nt3leri 3zerinde karakter tanıma uygulaması gerekleřtirilmesi,” *Gazi 3niversitesi M3hendislik Mimarlık Fak3ltesi Dergisi*, vol. 37, no. 1, pp. 17–28, Nov. 2021, doi: 10.17341/GAZIMMFD.866552.
  12. A. Banerjee, A. Sarkar, S. Roy, P. K. Singh, and R. Sarkar, “COVID-19 chest X-ray detection through blending ensemble of CNN snapshots,” *Biomed Signal Process Control*, vol. 78, p. 104000, Sep. 2022, doi: 10.1016/J.BSPC.2022.104000.
  13. G. Gilanie et al., “Coronavirus (COVID-19) detection from chest radiology images using convolutional neural networks,” *Biomed Signal Process Control*, vol. 66, p. 102490, Apr. 2021, doi: 10.1016/J.BSPC.2021.102490.
  14. A. Kaya, A. S. Keceli, and A. B. Can, “Examination of various classification strategies in classification of lung nodule characteristics,” *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 34, no. 2, pp. 709–725, 2019, doi: 10.17341/gazimmfd.416530.
  15. F. Atasoy and S. Eltanashi, “A Proposed Speaker Recognition Model Using Optimized Feed Forward Neural Network And Hybrid Time-Mel Speech Feature,” *International Conference on Advanced Technologiess, Computer Engineering and Science (ICATCES 2020)*, pp. 130–140, Jun. 2020, Accessed: Jan. 10, 2023. [Online]. Available: <https://www.researchgate.net/publication/343636003>
  16. O. Yıldız, “Melanoma detection from dermoscopy images with deep learning methods: A comprehensive study,” *JOURNAL OF THE FACULTY OF ENGINEERING AND ARCHITECTURE OF GAZI UNIVERSITY*, vol. 34, no. 4, pp. 2241–2260, 2019, doi: 10.17341/GAZIMMFD.435217.
  17. Atasoy F., “Thyroid Disorder Prediction Using Advance Deep Learning Paradigms | Request PDF.” [https://www.researchgate.net/publication/350192636\\_Thyroid\\_Disorder\\_Prediction\\_Using\\_Advance\\_Deep\\_Learning\\_Paradigms](https://www.researchgate.net/publication/350192636_Thyroid_Disorder_Prediction_Using_Advance_Deep_Learning_Paradigms) (accessed Apr. 18, 2022).
  18. İ. A. Metin and B. Karasulu, “A novel dataset of human daily activities: Its benchmarking results for classification performance via using deep learning techniques,” *Journal of the Faculty of Engineering and Architecture of Gazi University*, vol. 36, no. 2, pp. 759–777, 2021, doi: 10.17341/gazimmfd.772849.

19. X. Yang, U. San Diego, U. San Diego Jinyu Zhao, U. San Diego Yichen Zhang, U. San Diego Shanghang Zhang, and P. Xie, "COVID-CT-Dataset: A CT Image Dataset about COVID-19", Accessed: Jan. 10, 2023. [Online]. Available: <https://www.medrxiv.org/>
20. "COVID-19 DATABASE - SIRM." <https://sirm.org/category/senza-categoria/covid-19/> (accessed May 15, 2023).
21. A. M. Karim, H. Kaya, V. Alcan, B. Sen, and I. A. Hadimlioglu, "New Optimized Deep Learning Application for COVID-19 Detection in Chest X-ray Images," *Symmetry* 2022, Vol. 14, Page 1003, vol. 14, no. 5, p. 1003, May 2022, doi: 10.3390/SYM14051003.
22. "[2003.11597] COVID-19 Image Data Collection." <https://arxiv.org/abs/2003.11597> (accessed May 15, 2023).
23. "COVID-19 Radiography Database | Kaggle." <https://www.kaggle.com/datasets/tawsifurrahman/covid19-radiography-database> (accessed May 15, 2023).
24. S. Thakur and A. Kumar, "X-ray and CT-scan-based automated detection and classification of covid-19 using convolutional neural networks (CNN)," *Biomed Signal Process Control*, vol. 69, Aug. 2021, doi: 10.1016/J.BSPC.2021.102920.
25. "CT scan - Wikipedia." [https://en.wikipedia.org/wiki/CT\\_scan](https://en.wikipedia.org/wiki/CT_scan) (accessed May 15, 2023).
26. "X-ray - Wikipedia." <https://en.wikipedia.org/wiki/X-ray> (accessed May 15, 2023).
27. M. Rahimzadeh, A. Attar, and S. M. Sakhaei, "A fully automated deep learning-based network for detecting COVID-19 from a new and large lung CT scan dataset," *Biomed Signal Process Control*, vol. 68, p. 102588, Jul. 2021, doi: 10.1016/J.BSPC.2021.102588.
28. E. Doğan, C. Gürsoy, Ö. O. Tapan, C. Elibol, T. Togan, and S. Demirbilek, "HEALTH SCIENCES MEDICINE The comparison of chest X-ray and CT visibility according to size and lesion types in the patients with COVID-19," *J Health Sci Med*, vol. 5, no. 4, pp. 1151–1155, 2022, doi: 10.32322/jhsm.1100231.
29. H. C. Turkcetin, A. , Bayrakci, "T.c. isparta uygul amali bilimler üniversitesi lisansüstü eğitim enstitüsü," 2019.
30. "Pnömoni - Zatürre Nedir? | NHLBI, NIH." <https://www.nhlbi.nih.gov/health/pneumonia> (accessed May 08, 2023).
31. M. M. Speth, T. Singer-Cornelius, M. Oberle, I. Gengler, S. J. Brockmeier, and A. R. Sedaghat, "Olfactory Dysfunction and Sinonasal Symptomatology in COVID-19: Prevalence, Severity, Timing, and Associated Characteristics,"

Otolaryngology - Head and Neck Surgery (United States), vol. 163, no. 1, pp. 114–120, Jul. 2020, doi: 10.1177/0194599820929185.

32. N. MÜHÜR DAROĞLU and Department, “ANKARA YILDIRIM BEYAZIT UNIVERSITY GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES TEXT CLASSIFICATION BASED ON ORGANIZATIONAL DATA USING MACHINE LEARNING M . Sc . Thesis by Ahmed Enis ERKAYA Department of Computer Engineering TEXT CLASSIFICATION BASED ON,” 2019.
33. “Chest X-ray (Covid-19 & Pneumonia) | Kaggle.” <https://www.kaggle.com/datasets/prashant268/chest-xray-covid19-pneumonia> (accessed Apr. 13, 2023).
34. “Pneumonia & COVID-19 Image Dataset | Kaggle.” <https://www.kaggle.com/gibi13/pneumonia-covid19-image-dataset> (accessed Jan. 07, 2022).
35. “COVID-19&Normal&Pneumonia\_CT\_Images | Kaggle.” <https://www.kaggle.com/anaselmasry/covid19normalpneumonia-ct-images> (accessed Jan. 07, 2022).
36. T. Yan, “COVID-19 and common pneumonia chest CT dataset (412 common pneumonia CT scans),” vol. 1, 2020, doi: 10.17632/YGVGKDBMVT.1.
37. T. Yan, “COVID-19 and common pneumonia chest CT dataset (416 COVID-19 positive CT scans ),” vol. 2, 2020, doi: 10.17632/3Y55VGCKG6.2.
38. “Image technology colour management-Architecture, profile format, and data structure,” 2004, Accessed: May 11, 2023. [Online]. Available: <http://www.color.org>
39. S. Sergyán, “Color Content-based Image Classification.”
40. H. Chakravorty, “To Detection of Fish Disease using Augmented Reality and Image Processing,” Advances in Image and Video Processing, vol. 7, no. 6, Jun. 2020, doi: 10.14738/aivp.76.7503.
41. “Convert BGR and RGB with Python and OpenCV.”
42. “BGR ve RGB’yi Python – OpenCV ile dönüştürün.”
43. A. Géron, “Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow,” 2019. [https://www.knowledgeisle.com/wp-content/uploads/2019/12/2-Aur%C3%A9lien-G%C3%A9ron-Hands-On-Machine-Learning-with-Scikit-Learn-Keras-and-Tensorflow\\_-Concepts-Tools-and-Techniques-to-Build-Intelligent-Systems-O%E2%80%99Reilly-Media-2019.pdf](https://www.knowledgeisle.com/wp-content/uploads/2019/12/2-Aur%C3%A9lien-G%C3%A9ron-Hands-On-Machine-Learning-with-Scikit-Learn-Keras-and-Tensorflow_-Concepts-Tools-and-Techniques-to-Build-Intelligent-Systems-O%E2%80%99Reilly-Media-2019.pdf) (accessed May 15, 2023).

44. A. Uygulanmasi et al., “Derin Öğrenmede Kullanılan Optimizasyon,” 2020.
45. S. Sharma, S. Sharma, and A. Athaiya, “□ACTIVATION FUNCTIONS IN NEURAL NETWORKS,” *International Journal of Engineering Applied Sciences and Technology*, vol. 4, pp. 310–316, 2020, Accessed: May 11, 2023. [Online]. Available: <http://www.ijeast.com>
46. S. Ruder, “An overview of gradient descent optimization algorithms \*”, Accessed: May 11, 2023. [Online]. Available: <http://caffe.berkeleyvision.org/tutorial/solver.html>
47. N. Srivastava, G. Hinton, A. Krizhevsky, and R. Salakhutdinov, “Dropout: A Simple Way to Prevent Neural Networks from Overfitting,” *Journal of Machine Learning Research*, vol. 15, pp. 1929–1958, 2014.
48. “Python’daki Kitaplıklar - GeeksforGeeks.” <https://www.geeksforgeeks.org/libraries-in-python/> (accessed May 11, 2023).
49. “Hakkında - OpenCV.” <https://opencv.org/about/> (accessed May 11, 2023).
50. “11.7. glob — Unix stili yol adı kalıbı genişletme — Python 3.7.0a2 belgeleri.” <https://python.readthedocs.io/en/latest/library/glob.html> (accessed May 11, 2023).
51. “About Keras.” <https://keras.io/about/> (accessed May 11, 2023).
52. “How to Configure Image Data Augmentation in Keras - MachineLearningMastery.com.” <https://machinelearningmastery.com/how-to-configure-image-data-augmentation-when-training-deep-learning-neural-networks/> (accessed May 14, 2023).
53. Y. Steiniger, D. Kraus, and T. Meisen, “Survey paper Survey on deep learning based computer vision for sonar imagery,” *Eng Appl Artif Intell*, vol. 114, p. 105157, 2022, doi: 10.1016/j.engappai.2022.105157.
54. F. Liu, D. Chen, J. Zhou, and F. Xu, “A review of driver fatigue detection and its advances on the use of RGB-D camera and deep learning,” *Eng Appl Artif Intell*, vol. 116, p. 105399, Nov. 2022, doi: 10.1016/J.ENGAPPAL.2022.105399.
55. Y. Lecun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553. Nature Publishing Group, pp. 436–444, May 27, 2015. doi: 10.1038/nature14539.
56. R. Bello-Cerezo, F. Bianconi, A. Fernández, E. González, and F. Di Maria, “Experimental comparison of color spaces for material classification,” *J Electron Imaging*, vol. 25, no. 6, p. 061406, Jun. 2016, doi: 10.1117/1.JEI.25.6.061406.
57. T. Ozturk, M. Talo, E. A. Yildirim, U. B. Baloglu, O. Yildirim, and U. Rajendra Acharya, “Automated detection of COVID-19 cases using deep neural

networks with X-ray images,” *Comput Biol Med*, vol. 121, p. 103792, Jun. 2020, doi: 10.1016/J.COMPBIOMED.2020.103792.

58. S. Thakur and A. Kumar, “X-ray and CT-scan-based automated detection and classification of covid-19 using convolutional neural networks (CNN),” *Biomed Signal Process Control*, vol. 69, p. 102920, Aug. 2021, doi: 10.1016/J.BSPC.2021.102920.
59. E. Uçar, Ü. Atila, M. Uçar, and K. Akyol, “Automated detection of Covid-19 disease using deep fused features from chest radiography images,” *Biomed Signal Process Control*, vol. 69, p. 102862, Aug. 2021, doi: 10.1016/J.BSPC.2021.102862.

## ÖZGEÇMİŞ

İrem KURA lise öğrenimini İstanbul’da Zühtü Kurtulmuş Anadolu Lise’sinden 2015 yılında mezun oldu. 2015 yılında lisans eğitimi için Karabük Üniversitesi Bilgisayar Mühendisliği Bölümü’nde öğrenimine başlayarak 2020 yılında mezun oldu. 2020 yılında Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı altında sürdürmektedir. 2023 yılında “2nd International E-Conference On Mathematical And Statistical Sciences: A Selcuk Meeting”de tezden üretilmiş “Classification of Color Spaces in Various Combinations Using Deep Learning Models” isimli bildiri sunumu gerçekleştirilmiştir.