



T.C.  
EGE ÜNİVERSİTESİ  
Fen Bilimleri Enstitüsü



# MAKİNE ÖĞRENMESİ DESTEKLİ AKCİĞER GÖRÜNTÜLEME

Yüksek Lisans Tezi

Gülce LEYLEK

Bilgisayar Mühendisliği Ana Bilim Dalı

İzmir  
2023

T.C.  
EGE ÜNİVERSİTESİ  
Fen Bilimleri Enstitüsü

# MAKİNE ÖĞRENMESİ DESTEKLİ AKCİĞER GÖRÜNTÜLEME

Gülce LEYLEK

Tez Danışmanı: Prof. Dr. Nakife Yasemin TOPALOĞLU

İkinci Danışman: Dr. Öğr. Üyesi Ahmet EGESÖY

Bilgisayar Mühendisliği Ana Bilim Dalı  
Bilgisayar Mühendisliği Tezli Yüksek Lisans  
Programı

İzmir  
2023



## EGE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ

### ETİK KURALLARA UYGUNLUK BEYANI

EÜ Lisansüstü Eğitim ve Öğretim Yönetmeliğinin ilgili hükümleri uyarınca Yüksek Lisans Tezi olarak sunduğum “MAKİNE ÖĞRENMESİ DESTEKLİ AKCİĞER GÖRÜNTÜLEME” başlıklı bu tezin kendi çalışmam olduğunu, sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi, tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını, bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı, bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

12 / 11 / 2023

Gülce LEYLEK

**ÖZET****MAKİNE ÖĞRENMESİ DESTEKLİ AKCİĞER GÖRÜNTÜLEME**

LEYLEK, Gülce

Yüksek Lisans Tezi, Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Nakife Yasemin TOPALOĞLU

İkinci Danışman: Dr. Öğr. Üyesi Ahmet EGESÖY

Aralık 2023, 59 sayfa

Bu çalışmada akciğerin bilgisayarlı tomografi görüntülerinden makine öğrenmesi yöntemleri ile güvenilir ve otomatik COVID-19 tespiti hedeflenmiştir. Bilgisayarlı tomografi, yirminci yüzyılın sonlarından bu yana akciğer hastalıklarının tanısında önemli rol oynamaktadır. COVID-19 salgınının yarattığı hayati risk ve ekonomik yük, bu ve benzer hastalıklara karşı yapay zeka teknolojilerinden alınabilecek desteğin önemini göstermiştir. Çalışmada sınıflandırma performansını arttırmak amacıyla görüntüleri gereksiz detaylardan arındıran bölütleme ve görüntü iyileştirme işlemlerine başvurulmuştur. Ayrıca veri yetersizliğine bir çare olarak transfer öğrenme ile ince ayar teknikleri kullanılmıştır. Bu teknikler uygun parametrelerle birlikte kullanıldığında benzer çalışmalardan daha yüksek başarımlar getirmiştir.

Uygulanan tekniklerin başarımlarının yalın bir biçimde karşılaştırılabilmesi için kesit bazında sınıflandırma performansları hesaplanmıştır. Gerçek teşhis başarısı değerlendirmesi için, kesit bilgilerinin birleştirilmesi ile hasta bazında elde edilen başarı oranları tespit edilmiştir. Çalışma sonucunda en yüksek doğruluk oranı, kesit bazında %95,45 ile VGG-16 modeli ile elde edilmiştir. Hasta bazında değerlendirmede ise doğruluk açısından en yüksek başarımlar %98,02 ile ResNet152V2 modeli tarafından, doğruluk ve hassasiyet birlikte değerlendirildiğinde ise %99,52 F-5 skoru ile VGG-16 modeli tarafından elde edilmiştir. Kullanılmış olan model, teknik ve parametrelerin, COVID-19 ve benzer akciğer hastalıklarının tomografi tabanlı otomatik teşhisi açısından güvenilir bir yapay zeka reçetesi sunduğu düşünülmektedir.

**Anahtar sözcükler:** Akciğer Bölütlemesi, COVID-19 Tespiti, Makine Öğrenmesi Yöntemleri, Bilgisayarlı Tomografi



**ABSTRACT****MACHINE LEARNING SUPPORTED LUNG IMAGING**

LEYLEK, Gülce

MSc in Computer Engineering

Thesis Supervisor: Prof. Dr. Nakife Yasemin TOPALOĞLU

Second Supervisor: Assist. Prof. Ahmet EGESÖY

December 2023, 59 pages

The aim of this study is to achieve reliable and automatic detection of COVID-19 from lung computed tomography images using machine learning methods. Computed tomography has been playing an important role in the diagnosis of lung diseases since the late twentieth century. The life-threatening risk and economic burden caused by the COVID-19 pandemic has shown the importance of support from artificial intelligence technologies against this and similar diseases. In this study, segmentation and image enhancement processes are used to remove unnecessary details from images to improve classification performance. In addition, fine-tuning techniques were used with transfer learning as a solution to data insufficiency. When these techniques are used with suitable parameters, they provide higher performance than similar studies.

To make a simple comparison between the performance of the applied techniques, slice-based classification performances were calculated. For real diagnosis success evaluation, patient-based success rates were determined by combining slice-based information. As a result of the study, the highest accuracy rate was obtained by the VGG-16 model with 95,45% in slice-based evaluation. In patient-based evaluation, the highest performance in accuracy was achieved by the ResNet152V2 model with 98,02%, when accuracy and precision were evaluated together, the highest F-5 score performance was achieved by the VGG-16 model with 99,52%. The model, techniques and parameters used are considered to provide a reliable artificial intelligence prescription for tomography-based automated diagnosis of COVID-19 and similar lung diseases.

**Keywords:** Lung Segmentation, COVID-19 Detection, Machine Learning Methods, Computed Tomography.



## ÖNSÖZ

“Makine Öğrenmesi Destekli Akciğer Görüntüleme” başlıklı çalışmada bilgisayarlı tomografi görüntülerinin kesitleri ele alınmıştır. Bu görüntülerin işlenmesi yolu ile makine öğrenmesi temelli bir COVID-19 tespiti ve akciğer bölütlemesi gerçekleştirilmiştir. COVID-19 tespitinde zamanın ne kadar önemli olduğunun pandemi zamanında görülmüş olmasına istinaden, hastalıkların teşhisinde bilgisayar destekli teşhisin önemi bir kez daha gündeme gelmiştir. Teşhislerde destek sağlayacak olan otomatikleştirilmiş sistemlerin, makine öğrenmesi desteği ile az sayıda örnek görüntü ile dahi çok sayıda teşhise destek sağlayabilecek kapasitede olduğu görülmüştür.

Makine öğrenmesi yöntemlerinin araştırılmasının, temel mantığının anlaşılabilir olarak görüntülere ve probleme en uygun yöntemlerin seçilebilmesi aşamalarında; kaynakların, araştırmaların ve yol gösterenlerin önemi bu değerli süreçte tarafımda bir kez daha anlaşılmıştır. Bir probleme yönelik uygun veri seti bulmanın ve uygun veriler ile çalışmanın önemi de aynı şekilde problemin çözümüne yönelik yöntemlerin tespiti aşamasında ışık tutmaktadır.

İZMİR

12/11/2023

Gülce LEYLEK



## İÇİNDEKİLER

	<u>Sayfa</u>
İÇ KAPAK.....	(ii)
KABUL ONAY SAYFASI .....	(iii)
ETİK KURALLARA UYGUNLUK BEYANI.....	(v)
ÖZET .....	(vii)
ABSTRACT.....	(ix)
ÖNSÖZ .....	(xi)
İÇİNDEKİLER DİZİNİ.....	(xiii)
ŞEKİLLER DİZİNİ .....	(xv)
TABLolar DİZİNİ.....	(xvi)
SİMGELER VE KISALTMALAR DİZİNİ .....	(xviii)
<b>1. GİRİŞ.....</b>	<b>1</b>
<b>2. LİTERATÜR .....</b>	<b>3</b>
2.1. Yapay Zeka ile Hastalık Teşhisi.....	3
2.2. Görüntü İşleme.....	5
2.2.1. Görüntü İyileştirme Yöntemleri.....	5
2.2.2. Bölütleme .....	7
2.3. Makine Öğrenmesi .....	8
2.4. Makine Öğrenmesi ve BT Görüntüleri ile COVID-19 Teşhisi Hakkındaki Çalışmalar	9
<b>3. MATERYAL VE METOT .....</b>	<b>12</b>
<b>3.1. Veri Seti.....</b>	<b>17</b>
<b>3.2. Kullanılan Görüntü İşleme Teknikleri.....</b>	<b>20</b>
3.2.1. Kullanılan Görüntü İyileştirme Yöntemleri (CLAHE) .....	20
3.2.2. Kullanılan Bölütleme Yöntemleri.....	21
<b>3.3. Kullanılan Öğrenme Yöntemleri.....</b>	<b>24</b>
<b>4. GELİŞTİRİLEN MODELLER.....</b>	<b>27</b>
<b>4.1. VGG-16 Modeli.....</b>	<b>29</b>
4.1.1. VGG-16 Modeli Bölütlenmemiş Veri Seti .....	29
4.1.2. VGG-16 Modeli Bölütlenen Veri Seti .....	31
<b>4.2. ResNet152V2 Modeli.....</b>	<b>33</b>
4.2.1. ResNet152V2 Modeli Bölütlenmemiş Veri Seti.....	34
4.2.2. ResNet152V2 Modeli Bölütlenen Veri Seti.....	36
<b>4.3. DenseNet-121 Modeli.....</b>	<b>38</b>

**İÇİNDEKİLER (devam)**

<b>4.3.1. DenseNet-121 Modeli Bölütlenmemiş Veri Seti .....</b>	<b>38</b>
<b>4.3.2. DenseNet-121 Modeli Bölütlenen Veri Seti .....</b>	<b>40</b>
<b>4.4. Kullanılan Modellerin Sonuçları.....</b>	<b>42</b>
<b>5. TARTIŞMA ve SONUÇ.....</b>	<b>47</b>
<b>KAYNAKLAR DİZİNİ .....</b>	<b>50</b>
<b>TEŞEKKÜR.....</b>	<b>58</b>
<b>ÖZGEÇMİŞ .....</b>	<b>59</b>



## ŞEKİLLER DİZİNİ

<u>Şekil</u>	<u>Sayfa</u>
3.1. Sistem mimarisi görüntü işleme aşaması aktivite diyagramı.....	13
3.2. Sistem mimarisi bölütleme aşaması aktivite diyagramı.....	14
3.3. Sistem mimarisi model eğitim ve test aşaması aktivite diyagramı .....	15
3.4. Sistem mimarisi veri akış diyagramları.....	16
3.5. Veri setindeki COVID-19 ve normal hasta oranları .....	17
3.6. COVID-19 bulgusu içermeyen sağlıklı akciğer BT görüntü örnekleri .....	18
3.7. COVID-19 bulgusu içeren akciğer BT görüntü örnekleri.....	18
3.8. COVID-19 kesit sayılarının hasta bazında dağılımı .....	19
3.9. Normal kesit sayılarının hasta bazında dağılımı .....	20
3.10. Orijinal ve CLAHE uygulanan görüntü kesitleri .....	21
3.11. Otsu tarafından üretilen maske çıktısı.....	22
3.12. Çevresel görüntülerden temizlenmiş maske çıktısı.....	23
3.13. Akciğer kesitinin maske çıktısı .....	23
3.14. Bölütlenmiş olan sonuç kesit çıktısı.....	24
4.1. Bölütlenmemiş veri seti ince ayar VGG-16 dönem-kayıp ilişkisi .....	30
4.2. Bölütlenen veri seti ince ayar VGG-16 dönem-kayıp ilişkisi .....	32
4.3. Bölütlenmemiş veri seti ince ayar ResNet152V2 dönem-kayıp ilişkisi.....	34

**ŞEKİLLER DİZİNİ (devam)**

- 4.4. Bölütlenen veri seti ince ayar ResNet152V2 dönem-kayıp ilişkisi ..... 36
- 4.5. Bölütlenmemiş veri seti ince ayar DenseNet-121 dönem- kayıp ilişkisi ..... 38
- 4.6. Bölütlenen veri seti ince ayar DenseNet-121 dönem-kayıp ilişkisi ..... 40



## TABLOLAR DİZİNİ

Tablo	Sayfa
2.1. Pandey et al. 2022 çalışması bölütleme-model doğruluk sonuçları.....	10
2.2. Uçkuner 2021 çalışması model doğruluk sonuçları.....	11
4.1. Genel hata matrisi gösterimi .....	29
4.2. VGG-16 bölütlenmemiş veri seti ile kesit bazında hata matrisi .....	30
4.3. VGG-16 bölütlenmemiş veri seti ile kesit bazında sınıflandırma raporu ....	31
4.4. VGG-16 bölütlenmemiş veri seti ile hasta bazında hata matrisi.....	31
4.5. VGG-16 Bölütlenmemiş veri seti ile hasta bazında sınıflandırma raporu ...	31
4.6. VGG-16 bölütlenen veriler ile kesit bazında hata matrisi.....	32
4.7. VGG-16 bölütlenen veri seti ile kesit bazında sınıflandırma raporu .....	33
4.8. VGG-16 bölütlenen veri seti ile hasta bazında hata matrisi.....	33
4.9. VGG-16 bölütlenen veri seti ile hasta bazında sınıflandırma raporu.....	33
4.10. ResNet152V2 bölütlenmemiş veri seti ile kesit bazında hata matrisi.....	35
4.11. ResNet152V2 bölütlenmemiş veri seti ile kesit bazında sınıflandırma raporu.	35
4.12. ResNet152V2 bölütlenmemiş veri seti ile hasta bazında hata matrisi .....	35
4.13. ResNet152V2 bölütlenmemiş veri seti ile hasta bazında sınıflandırma raporu.	36
4.14. ResNet152V2 bölütlenen veri seti ile kesit bazında hata matrisi.....	37

## TABLOLAR DİZİNİ (devam)

<u>Tablo</u>		<u>Sayfa</u>
4.15.	ResNet152V2 bölütlenen veri seti ile kesit bazında sınıflandırma raporu...	37
4.16.	ResNet152V2 bölütlenen veri seti ile hasta bazında hata matrisi .....	37
4.17.	ResNet152V2 bölütlenen veri seti ile hasta bazında sınıflandırma raporu .	38
4.18.	DenseNet-121 bölütlenmemiş veri seti ile kesit bazında hata matrisi .....	39
4.19.	DenseNet-121 bölütlenmemiş veri seti ile kesit bazında sınıflandırma raporu.	39
4.20.	DenseNet-121 bölütlenmemiş veri seti ile hasta bazında hata matrisi.....	39
4.21.	DenseNet-121 bölütlenmemiş veri seti ile hasta bazında sınıflandırma raporu.	40
4.22.	DenseNet-121 bölütlenen veri seti ile kesit bazında hata matrisi .....	41
4.23.	DenseNet-121 bölütlenen veri seti ile kesit bazında sınıflandırma raporu ..	41
4.24.	DenseNet-121 bölütlenen veri seti ile hasta bazında hata matrisi.....	41
4.25.	DenseNet-121 bölütlenen veri seti ile hasta bazında sınıflandırma raporu.	42
4.26.	Bölütlenen ve bölütlenmeyen veri setleri ile kesit bazında model başarımları.	43
4.27.	Bölütlenen ve bölütlenmeyen veri setleri ile hasta bazında model başarımları.	44
4.28.	Karşılaştırılan çalışmanın ve çalışmamızın model başarımları.....	45

**SİMGELER VE KISALTMALAR DİZİNİ****Kısaltmalar**

BT	Bilgisayarlı Tomografi
EKG	Elektrokardiyografi
ESA	Evrişimli Sinir Ağları
BDT	Bilgisayar Destekli Teşhis
DVM	Destek Vektör Makineleri
EYKA	En Yakın Komşu Algoritması
DSA	Derin Sinir Ağları
NB	Naive Bayes
GB	Gaussian Bayes
RA	Rastgele Ağaç
RO	Rastgele Orman
HE	Histogram Eşitleme
CLAHE	Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme

## 1. GİRİŞ

Dünya genelinde pandemiye yol açan COVID-19 hastalığı, ileri safhalarda zatürreye ve çoklu organ yetmezliğine dönüşerek ölümcül olabilmektedir. COVID-19'un teşhis edilmesi polimeraz zincir reaksiyonu (PCR) tekniğinin kullanılmaktadır. PCR tekniğinin yanı sıra bilgisayarlı tomografi (BT) ve X-ray gibi radyolojik göğüs görüntülemesi yöntemleri doğru tanıya katkı sağlamaktadır (Özdemir, vd., 2020). Son yıllarda BT görüntüleri ile doğru ve hızlı teşhis yapılabilmesi için yapay zeka ve makine öğrenmesinin kullanımı yaygınlaşmıştır (Alimadadi et al., 2020). Bu çalışmada, makine öğrenmesi yöntemleri ile akciğer BT görüntülerinden COVID-19 hastalığının tespit edilmesi amaçlanmıştır.

Bilgisayarlı tomografi (BT), görüntüleri birçok hastalığın tespitinde kritik bir rol oynamaktadır. Bir BT çekiminin çok sayıda akciğer kesiti içermesi, bilgisayarlı görüş yöntemlerinin gerekli olduğunu göstermektedir (Sluimer et al., 2006).

Günümüzde, tanı aşamasında radyologlara yardımcı olması hedeflenen otomatik algılama sistemlerine Bilgisayar Destekli Teşhis (BDT) sistemi denmektedir. Tipik olarak, BDT mimarisinin ilk aşamalarından biri radyolojik görüntülerin önemli parçalarının bölütlenmesidir (Özekes vd., 2006). Bölütleme ile otomatik veya yarı otomatik olacak şekilde ilgilenilen alan çıkartılmaktadır. Bu yöntem farklı tıbbi problemlere yönelik çalışmaların öncesinde kullanılmaktadır (Norouzi et al., 2014). Bu gelişmelerden sonra araştırmacılar, hasta verileri üzerinden hastalık teşhis edebilmek için yapay zekâ ve bilgisayar algoritmalarına yönelmişlerdir.

Yapay zekâ; sağlık sistemi içerisinde teşhis, tedavi, halk sağlığı vb. birçok alanda kullanılmaktadır. Yapay zekanın akciğer görüntüleri üzerinde kullanımı özellikle pandemi döneminden itibaren artış göstermiştir. Bu durum, COVID-19 hastalarının hızlı tespitinde yapay zekanın önemini ortaya koymaktadır (Dack et al., 2023). Yapay zekanın bir alt dalı olan makine öğrenmesi, eğitim verilerini kullanarak büyük veri kümeleri üzerinden varyasyonlar tespit edebilir. Bu doğrultuda makine öğrenmesi erken teşhis araştırmaları ve teşhis alanlarında fayda sağlayabilir (Boddu et al., 2022).

Makine öğrenmesi yöntemleri, bilgisayar sistemini tahminleme yapabilecek bir uzman olarak eğitmek için önemli bir rol oynamaktadır. Bu yöntemler eğitim verilerine göre kalıpları çıkarabilen ve ardından verilen test verilerine göre otomatik tahminleme yoluyla işleyebilen yapılardır. Makine öğrenmesi, 1990'lı yıllarda ayrı bir alan olarak incelenmeye başlanmıştır. Günümüzde ise makine öğrenmesi yöntemleri medikal ve daha başka alanlarda olmak üzere sıklıkla kullanılmaktadır (Portugal et al., 2018).

Makine öğrenmesinin araştırma alanlarından biri olan transfer öğrenme, insanların daha önceki tecrübelerinden öğrenerek karşılaşılan başka problemlerin bu tecrübe ile çözümünden faydalanmaktadır. Transfer öğrenme yaklaşımları, Pratt'ın 1993 yılında yaptığı çalışma ile hız kazanmıştır (Fırıldak vd., 2019).

Çalışmamızda, makine öğrenmesi tekniklerinden olan transfer öğrenme ile akciğer BT görüntülerinden COVID-19 tespit edilmesi hedeflenmiştir. Genel yapı; görüntü ön işleme teknikleri, görüntülerin bölütlenmesi ve transfer öğrenme ile belirtilen probleme çözüm bulunmasına yönelik kurulmuştur. COVID-19'un tespiti aşamasında diğer medikal hastalıklarda da olduğu gibi model eğitimi için kısıtlı veri bulunmaktadır. Bu sebeple çalışmamızda, az veri ile dahi yüksek doğruluk elde edebilen transfer öğrenme yöntemi ve ince ayar (fine-tuning) birlikte kullanılmıştır.

Tezin ikinci bölümünde yapay zeka ile hastalık teşhisi, görüntü işleme, makine öğrenmesi ve akciğer BT görüntülerinde makine öğrenmesi ile COVID-19 teşhisi hakkındaki çalışmaların literatür incelemesi yer almaktadır. Üçüncü bölümde tez çalışmamızda kullanılan veri seti, uygulanan görüntü işleme yöntemleri ile bölütleme ve makine öğrenmesi yöntemleri tanıtılmıştır. Dördüncü bölüm, tez kapsamında geliştirilen modelleri içermektedir. Beşinci bölüm, geliştirilen modellerden elde edilen sonuçları karşılaştırmalı olarak irdelemektedir ve yapılabilecek sonraki çalışmaları tartışmaktadır.

## 2. LİTERATÜR

Görüntü işleme, bölütleme ve makine öğrenmesinin bir araştırma alanı olan transfer öğrenme hakkındaki literatür bu bölümde incelenmiştir.

Literatürde akciğer hastalıklarının teşhisi ve akciğer bölütlemesi hedeflenerek çeşitli çalışmalar bulunmaktadır (Abdullah et al.,2019; Hu et al., 2023; Chithra et al., 2018). Bu çalışmalar üzerinde makine öğrenmesi yöntemlerinden faydalanıldığında oldukça yüksek sonuçlar alındığı görülmüştür. Teşhis aşamasında çok farklı yöntemler kullanılsa bile, bölütlemeyle belirlenen problem için, gereksiz alanları görüntülerden temizlemek faydalı bir uygulamadır.

### 2.1. Yapay Zeka ile Hastalık Teşhisi

Makine öğrenmesi ve derin öğrenmeyi kapsayan yapay zeka, hastalık teşhisinde sıklıkla kullanılmaktadır. Özellikle erken teşhis gerektiren hastaların tespit edilmesinde yapay zeka tabanlı tekniklerin kullanılması teşhise hız kazandırmaktadır (Kumar et al., 2022). Erken teşhisin de hastanın tedavisinin başarı ile sonuçlanma olasılığını arttırdığı bilinmektedir. Bu doğrultuda, teşhis sırasında karşılaşılabilecek sorunları en aza indirmek amacıyla yapay zeka ve çeşitli karar destek sistemlerinden yararlanılmaktadır (Lawton et al., 2021).

BDT sistemleri, tıbbi görüntülerde anomali tespitinde radyoloji uzmanlarına ikinci bir bakış açısı olarak görev yapmaktadır. BDT sistemleri, karar vermeyi hızlandırarak desteklemekte ve teşhiste insan hatalarını azaltmaktadır (Özen, 2013). Günümüzde, hastalıkların teşhisini destekleyici, sınıflandırıcı yazılım ve araçlar üzerine çalışmalar artmaktadır. Son yıllarda oldukça başarılı makine öğrenmesi algoritmaları geliştirilmiş ve derin öğrenme algoritmaları ile hata oranı oldukça düşmüştür (Işık, vd., 2015).

Yapay zeka ve makine öğrenmesi; Alzheimer, kanser, tüberküloz, beyin ve damar hastalıkları gibi farklı hastalıkların teşhisinde kullanılmaktadır (Kumar et al., 2022). Murugan et al. 2021 yılında, Alzheimer hastalığının manyetik rezonans görüntüleme (Magnetic Resonance Imaging: MRI) görüntüleri üzerinden tespiti için bir çalışma gerçekleştirmiştir. Çalışmalarında evrişimli sinir ağlarını özelleştirerek DEMNET isminde bir yapı önermişlerdir. Kullanılan açık kaynaklı veriler ile oluşturdukları ağ üzerinde %95,23 doğruluk, %97 eğri altında kalan alan (Area Under the Curve: AUC) sonucu elde etmişlerdir (Murugan et al.,2021).

Akciğer hastalıklarının makine öğrenmesi yöntemleriyle tespiti de literatürde sıklıkla yer almaktadır. Akciğer görüntüleme çıktıları ile akciğer kanser tespiti, akciğer nodül tespiti,

akciğer emboli tespiti ve pnömoni gibi hastalıkların teşhisinde öğrenme yöntemleri kullanılmıştır (Gonem et al., 2020).

Zhang et al. 2019 yılında, akciğer kanseri tespiti ve sınıflandırması için derin evrişimli ağlar ile bir çalışma gerçekleştirmiştir. Çalışmalarında, Lung Imaging Database Consortium isimli veri tabından alınan akciğer BT görüntülerini kullanmışlardır. Çalışmada, AlexNet ve VGG-16 transfer öğrenme yöntemleri kullanılmıştır. AlexNet modeli ile %97,76 sınıflandırma doğruluğu elde etmişlerdir. Kanser türlerinin sınıflandırılması aşamasında ise tüm sınıflarda %90 üzerinde doğruluk elde etmişlerdir (Zhang et al., 2019).

COVID-19, 2019 yılı aralık ayında Çin'de ortaya çıkmış ve kısa süre içerisinde tüm dünyaya yayılarak pandemiye dönüşmüş olan ciddi bir salgın hastalıktır. COVID-19'un değerlendirilmesinde BT görüntülemesi kabul görmektedir (Pontone et al., 2021). BT üzerinde en sık ve erken rastlanan COVID-19 radyolojik bulgusunun, buzlu cam opasitesi olduğu belirtilmiştir (Özdemir, vd., 2020). Hastalığın erken tanısında akciğer grafisinin duyarlılığı %30-60 olarak değişmekte olduğundan, buzlu cam tarzındaki bulguların akciğer grafisinde görülemeyebileceği belirtilmiştir. Bu doğrultuda, uygun durumlar mevcutsa BT değerlendirmesi önerilmektedir (Kömürcüoğlu, 2020).

Dutta et al. tarafından 2021 yılında yapılan çalışmada, akciğer BT görüntüleri üzerinden COVID-19 tespiti hedeflenmiştir. InceptionV3 transfer öğrenme modeli düzenlenerek yeni bir model oluşturulmuştur. Modelin son birkaç katmanı dört özelleştirilmiş katman içeren derin sinir ağları ile değiştirilmiştir. Sonuçlara bakıldığında özelleştirilen modelin InceptionV3'nin aldığı %71 sonucuna kıyasla %84 doğruluk ettiği görülmüştü (Dutta et al., 2021).

Gifani et al. tarafından 2021 yılında yapılan çalışmada, BT görüntüleri üzerinden COVID-19 tespiti hedeflenmiştir. Çalışmalarında açık kaynaklı bir veri seti kullanmıştır. Kullanılan veri seti 349 COVID-19, 397 normal görüntü kesiti içermektedir. Toplamda 15 farklı önceden eğitilmiş transfer öğrenme modeli kullanılmıştır. Hedefe yönelik olarak modeller üzerinde ince ayar sağlanmıştır. Sonrasında topluluk yöntemi uygulanarak tanıma performansının artırılmasını hedeflemişlerdir. Topluluk yönteminde transfer öğrenme modellerinin çoğunluk oylamasına dayalı olarak sonuçlar sağlanmıştır. EfficientNetB0, EfficientNetB3, EfficientNetB5, Xception ve Inception\_resnet\_v2 modellerinin çoğunluk oylaması; %85,7 kesinlik, %85,4 hassasiyet ve %85 doğruluk ile bireysel transfer öğrenme yapılarından daha yüksek sonuç elde etmiştir (Gifani et al., 2021).

## 2.2. Görüntü İşleme

Görüntü işlemenin amacı sınıflandırma veya öznelik çıkarma işlemlerinin uygulanmasından önce görüntülerin kalitesini artırmaktır (Saxena et al., 2016). İki boyutlu görüntüler üzerinde uygulanan görüntü işleme yöntemleri görüntüye uyarlanabilirlik, tekrarlanabilirlik özellikleri sağlamaktadır. Bu özellikler kazandırılırken görüntünün orijinal doğruluğu korunmaktadır. Görüntü işleme teknikleri farklı alt başlıklara ayrılmaktadır ve her biri farklı problemlerin çözümünü hedef almaktadır. Bu alt başlıklar; Görüntü ön işleme, görüntü iyileştirme, görüntü bölütleme, öznelik çıkartma ve son olarak görüntülerin sınıflandırılması olarak temelde verilebilir (Chitradevi et al., 2014).

Akciğer BT ve göğüs röntgen görüntülerinde COVID-19 teşhisi için yeniden boyutlandırma, gürültü azaltma, görüntü üzerindeki ayrıntıları belirginleştirerek bilgileri daha görünür kılmak için görüntü iyileştirme ve temel bir rol oynayan bölütleme, sıklıkla kullanılan ön işleme teknikleridir. Medikal alanda, görüntü üzerindeki verilerin belirginleştirilmesi ve bilginin artırılarak tıbbi görüntüleme uygulamalarında kullanabilmesi için bu yöntemlere sıklıkla başvurulmaktadır (Shyni et al., 2022).

Bir diğer görüntü işleme tekniği olan morfolojik yöntemler, görüntünün özellikleri ve şekli ile ilgilidir. Morfolojik işlemlerin genel amacı görüntülerin temel şekil özelliklerini koruyarak gürültüleri gidermektir. Morfolojik işlemler bölütleme sonrasında kalan kusurları gidermek için de sıkça kullanılmaktadır. Sürecin en temel iki örneği genişletme (dilation) ve aşındırma (erosion) olarak verilmektedir. Genişletme işlemi, ilgili bölgenin genişletilmesinin gerektiği durumlarda kullanılır. Piksel grupları genişlediğinden boşlukların kapatılması gereksinimi içeren durumlarda tercih edilir. Aşındırma ise birleşmiş olan nesnelere birbirinden ayrılması gereksinimi içeren durumlarda tercih edilir (Goyal, 2011).

### 2.2.1. Görüntü İyileştirme Yöntemleri

Görüntü iyileştirme, görüntüdeki bilgilerin algılanmasını geliştirmeyi ve otomatik görüntü işleme teknikleri için daha iyi bir girdi sağlamayı hedefler (Chaudhary et al, 2012). Tıp görüntüleri, uydu görüntüleri vb. farklı alanlardaki görüntüler yüksek gürültü ve zayıf kontrast barındırmaktadır. Görüntü kalitesinin artırılması için gürültünün azaltılması ve kontrastın artırılması önemlidir (Singh et at., 2014).

Çalışmamızda kullandığımız, kontrast sınırlı uyarlanabilir histogram eşitleme, (contrast-limited adaptive histogram equalization: CLAHE) görüntü iyileştirme yöntemlerinden biridir. CLAHE yöntemi ile, azaltılmış gürültü ve artırılmış görüntü kontrastı elde edilir.

Histogram eşitleme, en sık yoğunluk değerlerini etkili bir şekilde yaymak veya görüntünün yoğunluk aralığını genişletmeyi amaçlar. Bu, belirli özelliklerin görünümünü iyileştiren ve özellik çıkarma sırasında daha iyi performans gösteren, yüksek kontrastlı görüntülerle sonuçlanmaktadır. Farklı problemlere yönelik kullanılan standart histogram eşitleme ve CLAHE gibi farklı teknikler bulunmaktadır.

Histogram Eşitleme (HE), piksel değerlerinin dağılımını tüm görüntü boyunca tutarlı olduğunda en iyi şekilde çalışmaktadır. Görüntünün çoğundan belirgin şekilde daha açık veya daha koyu alanlar olduğunda, bu alanlardaki kontrast bu durumda uygun şekilde artırılmayacaktır. Bu durumda kullanılacak en iyi yöntem CLAHE olacaktır. CLAHE, her piksele komşu bir bölgeden türetilen bir dönüştürme işlevi uygulamaktadır. Her pikseli değiştirmek için bir karenin histogramı veya görüntünün pikseli çevreleyen alt bölgesi kullanılmaktadır. Standart histogram eşitlemede kullanılan "genel eşitleme" görüntünün çeşitli bölgelerine yinelemeli olarak uygulanmaktadır (Lawson et al., 2021).

CLAHE algoritması belirtildiği gibi, AHE (adaptif histogram eşitleme) algoritmasına benzer şekilde çalışmaktadır. Aralarındaki tek fark CLAHE'nin kümülatif dağılım fonksiyonunu hesaplamadan önce, büyütme sınırlandırmak için histogramı belirli değerlerde kırpmasıdır. Kullanıcıların değerlerini ayarladığı iki önemli değişken olan klip limiti ve döşeme boyutu, CLAHE yaklaşımının ne kadar iyi performans gösterdiğini belirlemektedir (Siddhartha et al., 2020). Kırpma limiti, histogramdaki gürültünün ne kadarının yumuşatılacağını ve sonuç olarak kontrastın ne kadar iyileştirileceğini kontrol etmektedir. CLAHE, kırpma limiti ile histogramı kırparak amplifikasyonu kısıtlamaktadır. Kırpma limitini aşan histogram, CLAHE aracılığıyla tüm histogram arasında eşit olarak dağıtılmaktadır. CLAHE orijinal bir görüntüyü üst üste binen küçük parçalara bölmektedir. Bu parametreye "döşeme boyutu" adı verilmektedir (Gedik, 2013).

Sonuç olarak CLAHE algoritması kullanılarak görüntü kontrastı artırılabilir ancak CLAHE uygulaması ek gürültüye de neden olabilmektedir (Lawson et al., 2021). Bu sebeple, olası bir gürültüyü azaltmak için amaca yönelik bir gürültü azaltma filtresi kullanılabilir. CLAHE uygulaması görüntü üzerinde kontrastın iyileştirilmesi yanında, küçük detayların ve dokuların üzerinde de iyileştirme sağlamaktadır (Koonsanit et al., 2017). İncelenen görüntü iyileştirme yöntemleri medikal görüntüler üzerinde yüksek önem derecesine sahiptir (Awwalin et al., 2021). Çalışmamız içerisinde CLAHE algoritması, bölütleme aşamasında akciğer sınırlarının ve dokusunun belirginleştirilmesinde önemli bir rol oynamaktadır.

### 2.2.2. Bölütleme

Bölütleme, görüntü işleme alanında en temel ve önemli işlemlerden biridir. Tıbbi görüntüler, organların ve lezyonların piksellerini arka plandan ayırt etmek için bölütlenmektedir. Lezyonların veya organların hacimleri ve şekiller hakkında kritik bilgiler bölütlemeyle elde edilebilir. Hedef organın doğru bölütlenmesi çoğu BDT sisteminin verimli ve etkili çalışmasında kritik rol oynamaktadır (Özekes vd., 2006). Görüntü işlemenin ilk aşamalarından olan bölütleme, özellikle teşhise destek sağlamak amacı ile kullanılan biyomedikal görüntülerde büyük önem taşımaktadır. Bu aşamanın yüksek doğruluk ile tamamlanması sonraki görüntü işleme aşamalarını da etkileyecektir (Pektatlı, 2011).

Bölütleme için geliştirilebilecek, en iyi olarak belirtilebilecek bir teknik yoktur. Seçilen teknikler probleme özel olmalıdır. Görüntü bölütleme teknikleri yoğunluk değerlerine, süreksizlik ve benzerliğe dayanmaktadır. Görüntü bölütleme teknikleri genel yapıda şu şekilde gruplanabilir; Eşikleme, bölge büyütme, kümeleme, kenar tespiti ve model tabanlı yöntemler (Ramesh et al, 2021).

Eşik tabanlı yöntem, gri tonlamalı bir görüntüyü ikili görüntüye dönüştürmek için bir eşik değeri kullanmaktadır. Eşik değeri seçilirken; eşik değerinin üzerinde yoğunlukta bulunan pikseller ön plan, diğer pikseller ise arka plan olarak seçilmektedir. Eşik değerinin seçilmesi için kullanılan bazı algoritmalara örnek olarak Otsu ve *K-means* verilebilir. Eşik tabanlı yöntem, gürültü barındırmayan ve kenarları belirgin olan görüntüler üzerinde en iyi şekilde performans göstermektedir (Ramesh et al, 2021).

Eşik tabanlı yöntem de kendi içerisinde 3 farklı alt sınıfa ayrılmaktadır (Zhu et al., 2007). Bunlar; bütünsel eşikleme, yerel eşikleme ve uyarlamalı eşikleme şeklindedir (Bhargavi et al., 2014). Bölütleme ile ilgili tüm görüntüde bir eşik değeri belirlenerek işlem sağlanıyorsa buna “bütünsel eşikleme”, görüntüde lokal özelliklere göre eşikleme sağlanıyorsa “yerel eşikleme” isimleri verilir. Yerel eşikleme genel eşiklemenin yetersiz kaldığı, çok ayrıntı bulunduran ve sabit bir arka plana sahip olmayan görüntülerde tercih edilmektedir (Özen, 2013). Yerel eşikleme bu kapsamda görüntünün bazı kısımlarında iyi sonuç verebilirken, bazı kısımlarında talep edildiği şekilde sonuç döndürmeyebilir (Norouzi et al., 2014).

Yerel eşikleme yönteminde, verilen görüntü farklı bölümler için kendi içerisinde görüntüyü alt bölümlere ayırır ve sonuçları birleştirerek sunar. Her bir alt görüntü için eşik değeri seçilerek farklı istatistiksel yöntemler kullanılır. Bu istatistiksel yöntemler; ortalama, standart sapma, ortalama ve standart sapma birlikte ve maksimum ve minimumun ortalaması şeklinde olabilir. Yerel eşikleme, bütünsel eşiklemeye kıyasla bir görüntüyü bölümlere ayırmak için daha fazla zamana ihtiyaç duymaktadır. Bu kapsamda eşik değerinin yanlış olarak

seçilmesi hatalı sonuçlara yol açabilmektedir. Alt sınıflarda, eşik değerinin otomatik olarak belirlenebilmesi amacı ile Otsu eşikleme algoritması gibi bazı yöntemler kullanılmaktadır (Norouzi et al., 2014). Otsu eşikleme algoritması, klasik eşikleme ile yeterli ayrım sağlanamadığında yani görüntüde karmaşık bilgiler var ise optimum eşik değerini veren bir algoritmadır (Zhu et al., 2007).

### 2.3. Makine Öğrenmesi

Günümüzde, tıbbi görüntülemenin hastalık tanı ve tedavisinde birçok alanda kullanılması ile klinik görüntüleme alanında bilgiler hızla artmaktadır. Bu doğrultuda, çok büyük miktarlarda verinin işlenebilmesi için algoritmalar ve yöntemler gerekmektedir. Görüntülerden öğrenerek teşhis sağlayabilmek için büyük sayıdaki görüntü örneklerinden öğrenim sağlayacak olan makine öğrenmesi gündeme gelmektedir (Giger et al., 2018). Makine öğrenmesi, ilgili tahmin ve teşhisin sağlanmasında önemi bulunan görüntü özelliklerinin kullanılan makine öğrenmesi algoritması tarafından hesaplanmasıdır (Erickson et al., 2017).

Makine öğrenmesinde yaklaşımlar denetimli ve denetimsiz olmak üzere iki ana kategoriye ayrılmaktadır. Denetimli öğrenme yaklaşımı tahminleme için geri bildirim alarak, etiketlenmiş veri kullanılmaktadır. Denetimli yöntemler sınıflandırma ve regresyon için uygundur. En sık kullanılan algoritmalar k-en yakın komşuluk, destek vektör makineleri, yapay sinir ağları olarak verilebilir. Denetimsiz öğrenme tahminleme için herhangi bir geri bildirim almamaktadır ve etiketli veri gerektirmemektedir. Denetimsiz öğrenme, verilerdeki gizli kalıpları bulmayı hedefler. *K-means* kümeleme algoritması denetimsiz öğrenme algoritmasına örnek olarak verilebilir (Chauhan et al., 2021).

Makine öğrenmesi algoritmaları, mevcut verilerden öğrenerek karmaşık ve büyük veri setleri içerisindeki desenleri hızlı bir şekilde tespit edebildiğinden kanser tanı ve teşhislerinde yaygın olarak kullanılmaktadır. Örneğin; BT taramalarının analiz edilerek akciğer kanseri teşhisinde, göğüs kanseri teşhisinde, deri görüntülerini analiz ederek lezyonların sınıflandırılmasında vb. alanlarda yüksek sayıda veri bulunduğundan algoritma başarımları yüksek sonuçlar verebilmektedir. Makine öğrenmesi ile yapılan çalışmalar bunlarla sınırlı kalmayarak astım, KOAH, mezotelyoma (bir akciğer zarı kanseri) gibi çeşitli akciğer hastalık teşhisleri için de kullanılmıştır (Sevli, 2019).

Derin öğrenme, yapay sinir ağlarını kullanan ve ham verilerin doğrudan işlenmesine imkan veren, makine öğrenmesinin bir alt alanıdır. Bu modeller, katman sayısına ve katman başına birim sayısına bağlı olarak eğitim süresince tahmin edilebilecek milyonlarca parametreye ulaşabilir. Derin öğrenme modelleri, nispeten küçük veri setleri yerine büyük veri kümeleri için daha uygundur. Bunun sebebi ise, küçük veri kümelerinin aşırı uyuma yatkın

olmasıdır. Derin öğrenme, tıbbi görüntüler, radyoloji ve onkoloji alanlarında büyük veri kümelerindeki çok karmaşık ilişkileri tespit edebilmesi sebebiyle sıkça kullanılmıştır (Castiglioni et al., 2021). Sağlık alanında derin öğrenme ile, hastalıkların tanı ve teşhisinin daha hızlı gerçekleştirilebileceği, ameliyatların bir kısmını robotların yapabileceği, hastaya otomatik cevapların sunulabileceği sistemler üzerinde çalışılmaktadır (Keleş, 2018).

Tıp alanında derin öğrenmenin temel zorlukları, modellerinin yüksek başarımlar elde etmesi için gerekli olan eğitim verisini toplama ve etiketleme eksikliğidir. Bu dezavantajın üstesinden gelmek için önceden çok büyük veri kümeleri ile eğitilmiş olan modellerden başka bir deyişle, transfer öğrenmeden yararlanılabilir (Alzubaidi et al., 2020). Transfer öğrenme makine öğrenmesinin bir diğer alt çalışma alanıdır. Önceden eğitilmiş olan benzer görevlere ilişkin bilgilerden yararlanarak, bu bilgileri yeni bir görevde kullanıp bilgi transferi sağlamaktadır. Bu sayede transfer öğrenme, eğitim için yüksek sayıda veri gereksinimi problemine çözüm olmuştur. Buna ek olarak zaman ve donanım kaynaklarından da tasarruf sağlamaktadır (Kim et al., 2022).

Öğrenme transferi, uygun durumlar arasında yapıldığında başarılı olacaktır. Başarımın sağlanmasındaki en önemli faktörler kaynak ve hedef alanlar arasındaki alaka düzeyi ve alanlar arasındaki bilginin problem için faydalı olan kısmının bulunma kapasitesidir (Zhuang et al., 2020).

#### **2.4. Makine Öğrenmesi ve BT Görüntüleri ile COVID-19 Teşhisi Hakkındaki Çalışmalar**

Literatürde akciğer BT görüntülerinden makine öğrenmesi ile COVID-19 teşhisine yönelik çok sayıda çalışma bulunmaktadır.

Skourt et al., görüntü bölütleme için sıkça kullanılan derin öğrenme mimarilerinden olan *U-net*'i kullanarak bir akciğer BT görüntü bölütlemesi önermiştir. Akciğer BT görüntülerinden gereksiz bilgileri silmek ve sadece gerekli alanlara odaklanabilmek için bölütleme gerekli bir adım olduğundan *U-net* ile bir yaklaşım gerçekleştirmişlerdir. Ağ parametreleri olarak *batch* boyut değeri 32, dönem (epoch) değeri 50 olarak belirlenmiştir. Ağ performans değerlendirmesi için *Dice* katsayısı endeksini kullanmışlardır ve sonuç 0.9502 olarak elde edilmiştir (Skourt et al., 2018).

Seum et al. tarafından 2020 yılında, BT görüntüleri üzerinden COVID-19 tespiti için transfer öğrenme ile yapılan çalışmada, 1252 adet COVID-19, 1229 adet normal akciğer BT kesiti içeren açık kaynaklı bir veri seti kullanılmıştır. Akciğer BT görüntülerine *U-Net* ile bölütleme uygulanmasının, modellerin performansına katkısı ölçülmüştür. Çalışma içerisinde en iyi oranları, *U-Net* kullanılan şekilde DenseNet201 modelinde %89,92 doğruluk ve %89,67

F-1 skoru elde edilmiştir. Çalışma kapsamında performanslar değerlendirildiğinde, bölütleme uygulamasının transfer öğrenme modellerinin performansını arttırdığı belirtilmiştir (Seum et al., 2020).

Pandey et al. tarafından 2022 yılında gerçekleştirilen çalışmada, BT görüntüleri üzerinden Otsu bölütleme yöntemi ve transfer öğrenme modelleri kullanılarak COVID-19 teşhisi gerçekleştirilmiştir. Kullanılan transfer öğrenme yöntemleri; VGG-16, ResNet-50 ve MobileNet şeklindedir. Bölütleme sağlanmamış ve sağlanmamış veri seti üzerindeki sonuçlar Tablo 2.1.'de modeller bazında görülmektedir. Sonuçlar karşılaştırıldığında bölütleme sağlanan ve sağlamayan veri setlerinde en yüksek başarı oranını VGG-16 modeli elde etmiştir (Pandey et al., 2022).

	VGG-16	ResNet-50	MobileNet
<b>Bölütlenmeyen Veri Seti Doğruluk (%)</b>	83,18	70,24	72,98
<b>Bölütlenen Veri Seti Doğruluk (%)</b>	99,28	75,08	80,12

Tablo 2.1. Pandey et al. 2022 çalışması bölütleme-model doğruluk sonuçları

Yang et al. 2021 yılında yaptıkları çalışmada, akciğer BT görüntülerinden transfer öğrenme modeli ResNet152V2 ile COVID-19 tespiti gerçekleştirmiştir. Çalışmada açık kaynaklı akciğer BT görüntü verileri kullanılmıştır. Veri dağılımları COVID-19 sınıfı için 1252, normal sınıfı için 1259 adet görüntü kesiti içermektedir. Önerilen model, %95,06 doğruluk, %97,19 kesinlik, %92,81 ve %94,96 hassasiyet değerlerini elde etmiştir (Yang et al., 2021).

Uçkuner vd. 2021 yılındaki çalışmalarında, 3 adet sınıf içeren COVID-19 veri seti transfer öğrenme yöntemi kullanılarak sınıflandırma işlemini gerçekleştirilmişlerdir. Veriler %80 eğitim, %20 test olmak üzere ayrılmıştır. Çalışmada InceptionV3, Xception, ResNet152V2, DenseNet201, InceptionResNetV2 ve VGG19 modelleri tercih edilmiştir. Önceden eğitilmiş modeller kullanılarak oluşturulan sınıflandırıcılar ile eğitim sağlanmıştır. Elde edilen modellerin test verisi için doğruluk oranları Tablo 2.2.'de görülmektedir. Xception ve VGG-19, yüksek doğruluk değerlerine en hızlı ulaşan modellerdir. InceptionResNetV2 ise önerilen diğer 5 modelden daha iyi sonuçlar elde etmiştir (Uçkuner vd., 2021).

	<b>InceptionV3</b>	<b>Xception</b>	<b>InceptionResNetV2</b>	<b>VGG19</b>	<b>ResNet152V2</b>	<b>DenseNet201</b>
<b>Doğruluk (%)</b>	98,6	98,7	99,3	97,8	98,7	98,0

Tablo 2.2. Uçkuner 2021 çalışması model doğruluk sonuçları

Maftuni et al. tarafından 2021 yılında gerçekleştirilen çalışmada derin öğrenme modelleri kullanılarak COVID-19 teşhisi hedeflenmiştir. Çalışmada, 3 farklı etiket kümesinden yüksek çeşitlilik gösteren bir veri seti derlenmiştir. Bu veri seti üzerinde DenseNet-121 ve Residual Attention-92 modellerini topluluk öğrenmesini kullanarak eğitim sağlamışlardır. Eğitim öncesinde görüntülere arka plan kaldırma, akciğer alanını kırpma, görüntü normalleştirme gibi görüntü dönüşümleri uygulanmıştır. Burada meta öğrenici olarak üç katmanlı tam bağlantılı (Fully connected: FC) meta öğrenicinin tek başına kullanılması ve destek vektör makineleri ile kullanılması şeklinde iki farklı kullanım mevcuttur. Çalışma sonuçlarına bakıldığında modellerin tekli kullanımından, topluluk öğrenmesi ile iki modelin birlikte kullanılmasının daha yüksek sonuçlar verdiği görülmüştür. En yüksek sonucu FC ve destek vektör makinelerinin meta öğrenici olarak kullanıldığı topluluk öğrenme modeli ile %95,31 doğruluk oranıyla elde etmişlerdir (Maftuni et al., 2021).

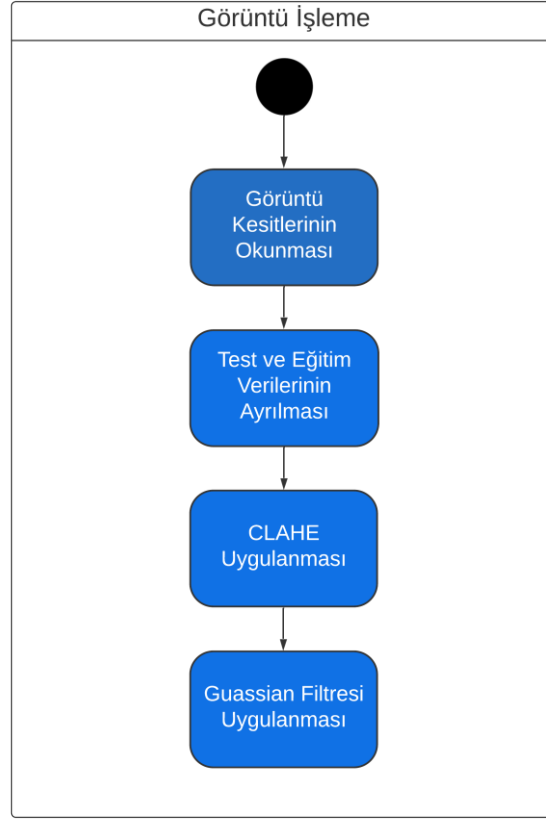
### 3. MATERYAL VE METOT

Çalışma kapsamında Python dili kullanılarak bir makine öğrenmesi modeli geliştirilmiştir. Python programlama dilinin veri işleme, görüntü işleme ve makine öğrenmesi kütüphaneleri açısından zengin olması çalışma açısından önemli görülmüştür. Bu duruma ek olarak Python programlama dilinin veri görselleştirme için de tam teşekküllü özellikler sunması, çalışmanın kodlanması aşamasında tercih sebebi olmuştur (Python, 2023). Geliştirilen makine öğrenmesi modellerinin eğitimi ve testi için Google Colab üzerinde bulunan grafik işlem birimleri (graphics processing unit: GPU) kullanılmıştır (Google Colab, 2023).

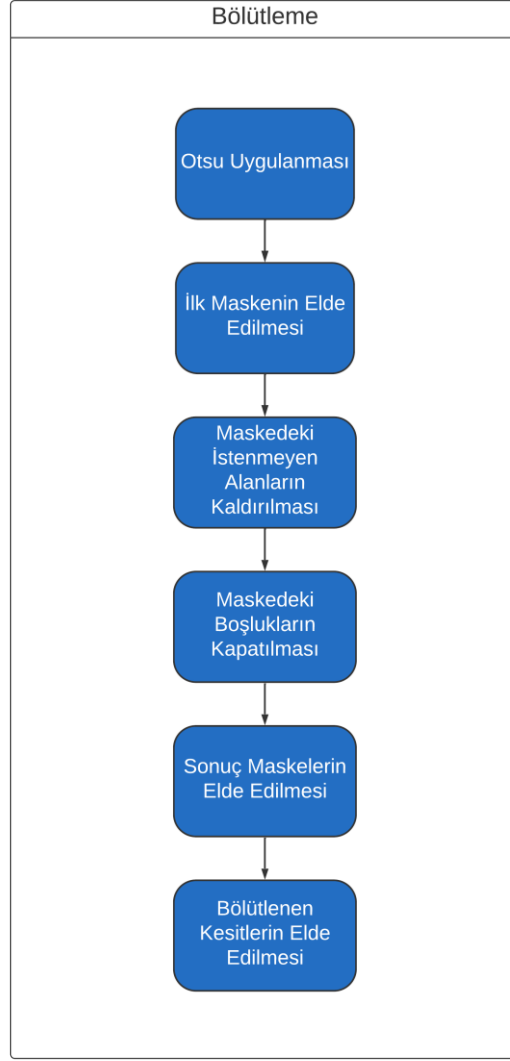
Geliştirilen makine öğrenmesi modelinde, transfer öğrenmenin teşhise destek sağlayacak şekilde kullanılması için akciğer BT görüntülerinden COVID-19 tespitine yönelik açık kaynaklı bir veri setinden faydalanılmıştır (Maftouni et al., 2021). Sistemin genel mimarisi şu aşamalardan oluşmaktadır:

- İlk aşamada görüntü işleme ve iyileştirme yöntemleri görüntülere uygulanmaktadır.
- İkinci aşamada görüntüler maske oluşturularak bölütlenmektedir. Bu aşamanın önemi akciğerin tamamını kapsayacak bir maske oluşturmaktır, bu sayede doğru bir bölütleme işlemi sağlanacaktır. Tüm görüntülere bölütleme işlemi uygulandıktan sonra bölütlenmiş kesitler elde edilmiştir.
- Üçüncü aşamada ise veriler transfer öğrenme modellerine verilerek eğitim sağlanmıştır. Eğitimler sırasında doğrulama veri seti de oluşturulmuştur. Veri arttırımı ve ince ayar yöntemi de kullanılarak veri yetersizliğine çözüm sağlanmıştır. Eğitim sonrasında modellerin testleri hasta bazında ve kesit bazında olacak şekilde gerçekleştirilmiştir. Hasta bazında ayırım sağlanması aşamasında veri setinin meta verileri kullanılmıştır. Üçüncü aşama sonucunda hasta bazında ve kesit bazında başarımler metrikleri elde edilmiştir.

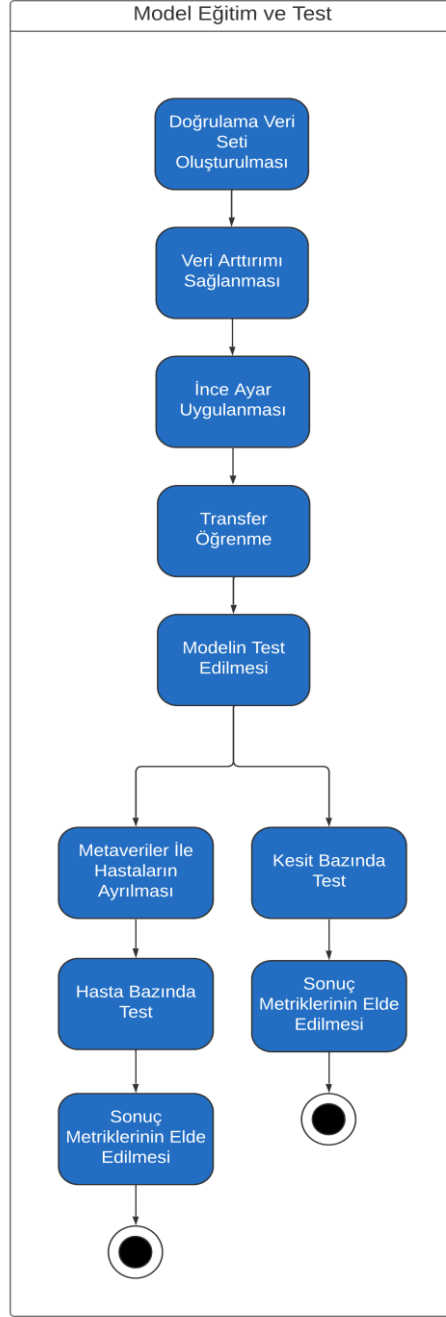
Sistem mimarisi, Birleşik Modelleme Dili (Unified Modelling Language: UML) aktivite diyagramı ve veri akış diyagramı formatlarında çizilmiştir. Diyagramlar; görüntü işleme, bölütleme, model eğitim ve testi olmak üzere 3 temel başlığa ayrılarak çizilmiştir. Sistem mimarisi aktivite diyagramları; Şekil 3.1.'de görüntü işleme aşaması, Şekil 3.2.'de bölütleme aşaması, Şekil 3.3'te model eğitim ve test aşaması olarak gösterilmiştir. Sistem mimarisi veri akış diyagramları ise; Şekil 3.4. (a)'da görüntü işleme aşaması, (b)'de bölütleme aşaması, (c)'de model eğitim ve test aşaması olarak gösterilmiştir.



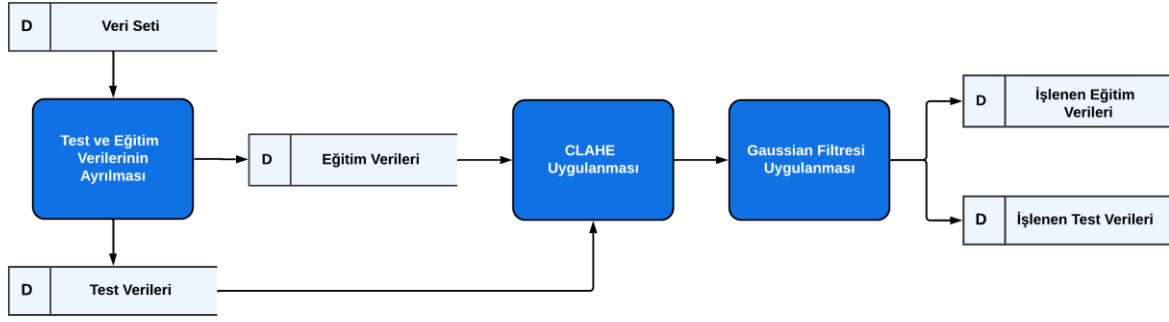
Şekil 3.1. Sistem mimarisi görüntü işleme aşaması aktivite diyagramı




Şekil 3.2. Sistem mimarisi bölütleme aşaması aktivite diyagramı



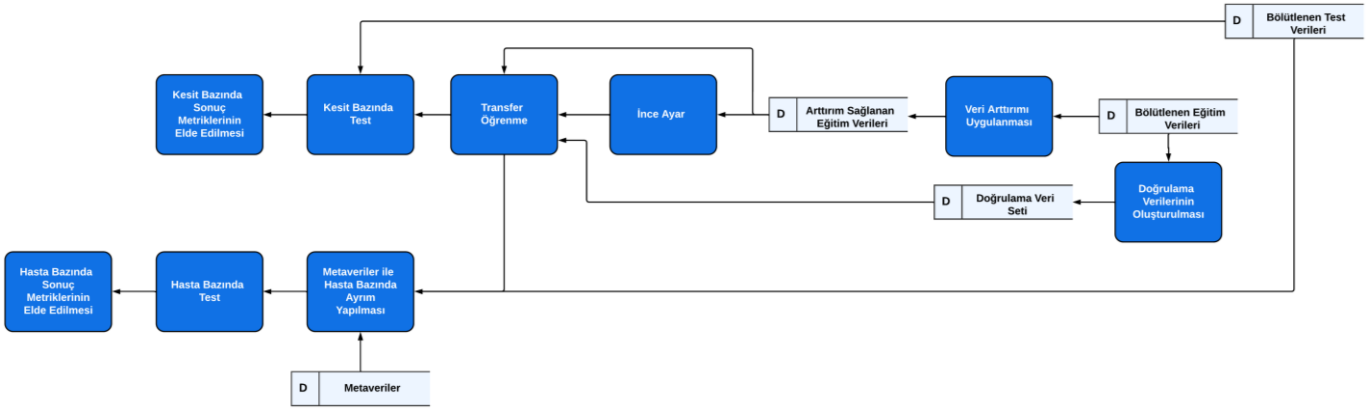
Şekil 3.3. Sistem mimarisi model eğitim ve test aşaması aktivite diyagramı



(a)



(b)




(c)

Şekil 3.4. Sistem mimarisi veri akış diyagramları a) Görüntü işleme aşaması, b) Bölütleme aşaması, c) Model eğitim ve test aşaması

### 3.1. Veri Seti

Çalışmamızda kullanılan veri seti, yedi farklı açık kaynaklı veri setinin derlenmiş bir halidir ve Maftouni et al. tarafından 2021 yılında yapılan çalışmayla sunulmuştur. Bir araya derlenmiş olan veri setlerinin her biri açık kaynaklı olarak COVID-19 literatüründe kullanılmıştır. Veri seti toplum kökenli pnömoni (community-acquired pneumonia: CAP) görüntü verilerini ve metaverisini de içermektedir. Bu veriler çalışmamızın odaklandığı problem kapsamında olmadığı için dahil edilmemiştir. Maftouni et al. tarafından elde edilen veri seti; 466 adet hastadan 7.594 COVID-19 BT kesiti ve 604 hastadan 6.893 normal yani sağlıklı BT kesiti içermektedir. Veri seti içerisinde tekrar eden kesit örnekleri bulunmamaktadır (Maftouni et al., 2021).




Şekil 3.5. Veri setindeki COVID-19 ve normal hasta oranları

COVID-19 ve normal sınıflarına ait kesit sayıları ve oranları Şekil 3.5.'de görülebilmektedir. Veri seti üzerindeki genel dağılıma bakıldığında, sınıfların dengeli olduğu görülmektedir.

Veri seti, görüntülerin metaverilerini de içermektedir. Metaveriler COVID-19 ve normal görüntüler için virgülle ayrılmış değerler (comma sperated values: csv) formatında ayrı şekilde bulunmaktadır. Metaveriler görüntü kesitlerinin; dosya ismi, benzersiz bir hasta numarası, tanı, hasta yaşı, ülke vb. olmak üzere ayrıntılı bilgi içermektedir. Kullanılan veri seti, COVID-19


bulgusu içeren ve içermeyen görüntüleri ayrılmış bir klasör yapısı ile bulundurmaktadır. Görüntüler klasörlerde metaveri içerisinde bulunan görüntü isimleri ile aynı şekilde bulunmaktadır. COVID-19 bulgusu içermeyen yani normal olarak sınıflandırılmış olan kesit örnekleri Şekil 3.6.'da görülmektedir. COVID-19 bulgusunu içeren yani COVID-19 olarak sınıflandırılmış olan kesit örnekleri ise Şekil 3.7.'de görülebilir.



(a)

(b)

Şekil 3.6. COVID-19 bulgusu içermeyen sağlıklı akciğer BT görüntü örnekleri




(a)

(b)

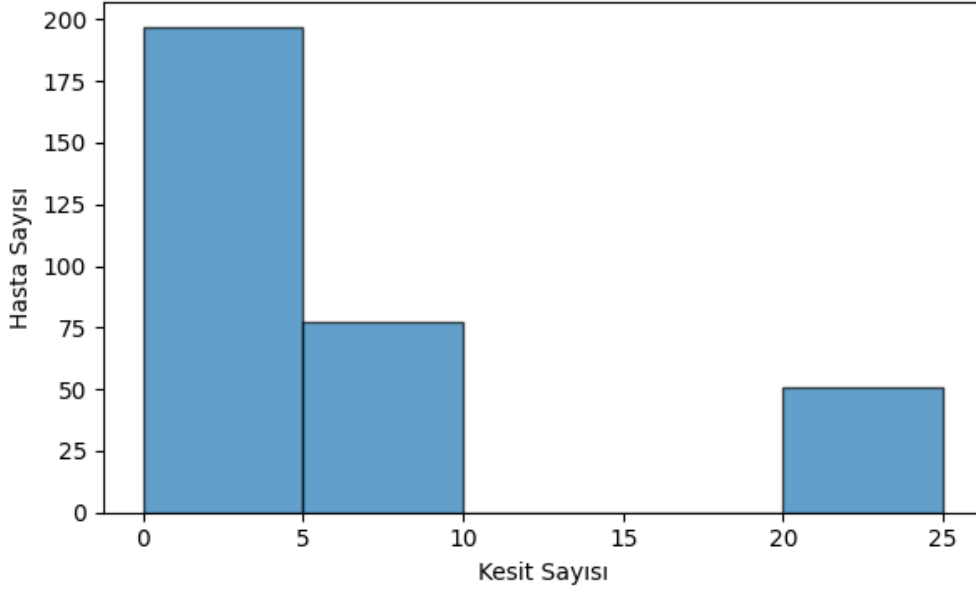
Şekil 3.7. COVID-19 bulgusu içeren akciğer BT görüntü örnekleri

Çalışmamızda kullanılan veri seti, bu çalışma için %70 eğitim, %30 test olarak ayrılmıştır. Verilerin test ve eğitim setleri şeklinde ayrılması sırasında aynı hastaya ait olan kesit görüntülerinin hem eğitim hem de test verisi içerisinde olmamasına dikkat edilmiştir. Aksi takdirde test sonucunu yanıltıcı biçimde etkileyebileceği bilinmektedir.

Metaveri içerisindeki benzersiz hasta numarası, tanı bilgisi ve dosya ismi kolonları test verilerimiz üzerinde hasta bazında ayırım sağlayabilmemize imkan sağlamıştır. Hasta bazında ayırım benzersiz hasta numaraları üzerinden sağlanmıştır. Test veri seti içerisine 3 kesit sayısından az olan hastaların kesitleri test veri setine dahil edilmemiştir. Bunun nedeni, hasta üzerinde yapılan tahminleme sonucunda hasta bazında tahminlemeye katkıda bulunamayacak olmasıdır. Test verilerimizin hasta bazında ayrılmış hali iki sınıf olarak Şekil 3.8. ve 3.9.'da görselleştirilmiştir. COVID-19 hastalarının kesit sayılarının hasta bazında dağılımı Şekil 3.8.'de normal hastalar için hasta bazında dağılım ise Şekil 3.9.'da gösterilmiştir.



Şekil 3.8. COVID-19 kesit sayılarının hasta bazında dağılımı



Şekil 3.9. Normal kesit sayılarının hasta bazında dağılımı

### 3.2. Kullanılan Görüntü İşleme Teknikleri


Transfer öğrenme ile COVID-19 teşhisini hedefleyen çalışmamızda, görüntülerin sınıflandırılmaya uygun hale getirilebilmesi için görüntü işleme yöntemleri kullanılmıştır. Görüntüler, çalışmamız kapsamında format fark etmeksizin (.png veya DICOM olmak üzere) okunabilmekte ve gösterilebilmektedir. Görüntülerin işlenebilmesi için görüntü kesitleri, buldukları dosyalar üzerinden okunarak ilgili dizilerin içerisine sıralı olarak eklenmiştir. Sonrasında görüntü kesitleri görüntülenmek istenilen görüntü numarası ile ekranda gösterilebilir hale gelmiştir.

Görüntüler üzerinde ön işleme yapılarak alanları belirgin hale getirilmektedir. Bu doğrultuda belirginleşen alanlar daha doğru bir bölütleme katkı sağlar. Literatürdeki çalışmalarda, CLAHE uygulamasının bölütleme üzerinde olumlu etkisi olduğu belirtilmektedir (Khomduean et al.,2023).

#### 3.2.1. Kullanılan Görüntü İyileştirme Yöntemleri (CLAHE)

Görüntüler klasörler içerisinden okunduktan sonra ön işleme hazır hale gelmiştir. Bu görüntüler üzerinde ilk olarak görüntüyü iyileştirmek ve kontrastı artırarak detayları ortaya çıkarmak için CLAHE yöntemi uygulanmıştır (Koonsanit et al., 2017). CLAHE, uygulanması aşamasında belirli parametreler almaktadır. CLAHE yönteminin genel çalışma mantığı 2.2.1.'de açıklanmıştır. Çalışmamızda, 8x8 karo boyutu ve 1,5 kırpma limiti parametre olarak kullanılmıştır. CLAHE uygulanması sonrasında olası bir gürültü etkisinin azaltmak için

Gaussian filtresi tekniđi kullanılmıřtır. Őekil 3.10. (a)'da akciđer grnt kesitinin orijinal hali ve (b) zerinde CLAHE uygulanmıř hali grlebilmektedir.



Őekil 3.10. Orijinal ve CLAHE uygulanan grnt kesitleri (a) Orijinal grnt kesiti (b) CLAHE uygulanmıř olan grnt kesiti

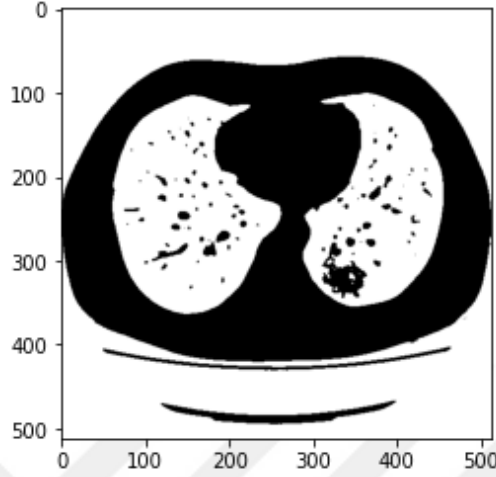
### 3.2.2. Kullanılan Bltleme Yntemleri

Akciđer bltlemesi, akciđer hastalıklarının tanımlanması iin BDT sistemlerinin nemli bir n iřleme adımdır. Bltleme, teřhis edilecek alana odaklanmayı kolaylařtırmakta ve teřhis iin gerekli olmayan alanların ıkarılması ile deđerlendirmenin gvenilirliđini artırmaktadır.

Bu alıřmada eřik bazlı bltleme yntemi kullanılmıřtır. Eřik bazlı yntemlerde grnt zerinde bir veya daha fazla eřik deđerini kullanılmaktadır. rnek olarak Otsu yntemi grntnn n plan/hedef pikselleri ve arka plan pikselleri olarak iki kategoriye blme iin optimal eřik deđerini hesaplar (Essaf et al., 2020). Eřik tabanlı yntem temel yntemlerden biridir ve alıřmada problemin zmlenmesinde faydalı olmuřtur.


Otsu ynteminin temel amacı grnty n ve arka piksellere ayırmaktır. Otsu yntemi kullandığı algoritma ierisinde grntnn n ve arka plan olarak ayrılabilmesi iin ideal eřik deđerini bulmayı hedefler (Bhosle et al., 2023). Bu yntem ile grnt zerinden bltleme

maskesi elde edebilmek için görüntü ön ve arka plana ayrılmıştır. Otsu uygulanmış olan örnek maske çıktısı Şekil 3.11.'de gösterilmiştir.



Şekil 3.11. Otsu tarafından üretilen maske çıktısı


Otsu yöntemiyle bölütlenmiş görüntüde akciğerin etrafında istenmeyen alanlar mevcuttur. Bunlar bilgisayarlı tomografi cihazının kısımlarıdır ve görüntüden temizlenmesi gerekmektedir. Bu kapsamda “clear\_border” adında scikit-image kütüphanesinde bulunan bir Python fonksiyonu yardımı ile bu alanlar görüntü üzerinden kaldırılmıştır. Temizleme işlemi sonrasında akciğer dokusu görüntü üzerinde yalnız bırakılarak bölütlemenin en önemli işlevi sağlanmıştır. Temizlenmiş olan görüntü Şekil 3.12.'de gösterilmiştir. Akciğer dokusu etrafındaki fazlalık alanların temizlenmesi, fazlalık alanların öğrenme yöntemleri üzerinde herhangi bir yanıltıcı etki oluşturmaması için önemlidir.



Şekil 3.12. Çevresel görüntülerden temizlenmiş maske çıktısı


Temizlenen bazı kesitler üzerinde akciğer etrafında kalan istenmeyen kısımlar bulunduğu görülmüştür. Bu sebeple en büyük alanlar tutularak geriye kalan bağlantılı alanlar görüntüden kaldırılmıştır. Görüntüde kalan küçük objeler ise görüntü üzerinden “remove\_small\_objects” adında scikit-image kütüphanesi altında bulunan bir Python fonksiyonuyla silinmiştir. Bu fonksiyonda 1 piksel parametresi kullanılmıştır.

Bu işlemden sonra bir maske oluşturulması için bölütleme yapılan alandaki delikler bir Python fonksiyonu olan “binary\_fill\_holes” ve genişletme yöntemleri kullanılarak kapatılmıştır. Bu işlemler sonucunda akciğerin bölütlenmesi için uygun maske elde edilmiştir. Elde edilmiş olan maske çıktısı Şekil 3.13.’de gösterilmiştir. Maske elde edilirken, akciğerin tüm alanın dahil edilebilmesi COVID-19’un göstermiş olduğu belirtilerin eksiksiz olarak yakalanabilmesi açısından önemlidir.



Şekil 3.13. Akciğer kesitinin maske çıktısı

Maskenin tüm akciğeri kapsayacak biçimde elde edilmesi ile bölütleme tamamlanmıştır. Bu maske kullanılarak, içinde sadece akciğerin bulunduğu görüntüler elde etmek için orijinal görüntü ile basit bir işleme tabi tutulur. Görüntü ile çarpılan beyaz pikseller orijinal görüntüdeki hedef akciğer alanlarını içerecek olup siyah alanlar orijinal görüntüden çıkarılacak alanlardır. Bölütleme işlemi veri seti içerisindeki tüm görüntülere uygulanarak bölütlenmiş veri seti elde edilmiştir. Bölütleme sonucunda elde edilen görüntü kesit örneği Şekil 3.14. içerisinde gösterilmiştir.



Şekil 3.14. Bölütlenmiş olan sonuç kesit çıktısı

Bölütlenmiş ve bölütlenmemiş olan veri setlerinin kullandığımız modeller üzerinden karşılaştırılması da sağlanmıştır. Bu karşılaştırmanın ayrıntıları 5. Sonuçlar bölümünde aktarılmıştır. Bölütlemenin çalışmamızın başarımı üzerindeki olumlu etkisi de bu sonuçlar doğrultusunda görülmüştür.

### 3.3. Kullanılan Öğrenme Yöntemleri

Bu çalışmada az veriyle dahi yüksek sonuçlar veren makine öğrenmesi yöntemlerinden transfer öğrenme tekniğinden yararlanmak gerekmiştir. Yeni bir model oluşturulabilmek ve yüksek doğruluk oranları elde etmek için genellikle büyük veri setleri gerekmektedir. Transfer öğrenme yöntemi kullanılmasının bir sebebi de medikal alanda özel bir probleme ait büyük sayılarda veri bulmanın zorlayıcı olmasıdır. Bu kapsamda modelin baştan öğrenmesi yerine, çok büyük sayıda veriyle eğitilmiş hazır bir ağı probleme yönelik özelleştirmek problemin çözümünde hız ve doğruluk sağlamaktadır.

Çalışmamız kapsamında transfer öğrenme modellerinden VGG-16, ResNet50, DenseNet-121 vb. birçok farklı model doğrudan denenmiştir. Bu modeller, çalışmadaki veri seti üzerinde %60-65 oranı üzerinde başarımları sağlayamamışlardır. Bu oranlar içerisinde en iyi sonucu veren iki algoritma ResNet152V2 ve VGG-16 olmuştur. Sonuçlar incelendiğinde çalışmanın ilk aşamalarında düşük dönem değerleri kullanılmasının da bu sonuçlara sebep olduğu görülmüştür.

Çalışmanın ilerleyen süreçlerinde dönem değerleri arttırımı, bölütleme üzerinde yapılan iyileştirmeler, yeni parametre, yeni model seçimleri ve transfer öğrenmenin etkinliğini arttıran ince ayar yönteminin de modeller üzerine uygulanması ile başarımları arttırılmıştır. Artan başarımları ile çalışmanın COVID-19 teşhisi konusunda yararlılığının gösterilmesi için hasta bazında değerlendirme gerekmektedir. Çalışmamızda hem kesit bazında hem de hasta bazında değerlendirme sonuçları bulunmaktadır. Bu sonuçlar tezin dördüncü bölümünde açıklanmıştır.

Başarımlarının arttırılması için yapılan araştırmalar sonucunda, öğrenme yöntemi üzerinde ince ayar uygulanması kullanılmıştır. İnce ayar tekniğinden transfer öğrenme kapsamında çalışmadaki probleme özgü öğrenilmesi için iyileştirmeler yapılmaktadır. Eğitilmiş ağın evrişim katmanındaki ağırlıkların tamamının aktarımının sağlanması yerine, belirlendiği kısmının yeni ağa aktarılmasıdır. Buna ek olarak yeni ağdan kalan sınıflandırıcı ve evrişim katmalarının güncellenmesi yeni eğitim kümesi kullanılarak yapılmaktadır (Fırıldak vd., 2019).

Makine öğrenmesi çalışmalarında ezberleme (overfitting) olarak adlandırılan durum ile karşılaşılabilir. Bu durum modelin görülmemiş veriler üzerinde iyi bir genelleme yapamamasıdır. Ezberleme sebebi ile model eğitim verileri üzerinde yüksek performans gösterirken test verilerinde zayıf performans sağlamaktadır. Modelin verileri ezberlemesini engellemek için erken durdurma (early-stopping), gürültü azaltma ve eğitim verilerinin arttırımı gibi yöntemler kullanılmaktadır (Ying et al., 2019). Eğitimin erken durdurulması için bekleme (patience) değeri kullanılmaktadır. Bu değer dönem sayısı (epoch) üzerinden kontrol edilmektedir (Burlina et al., 2018). Dönem sayısı, modelin eğitim veri kümesi boyunca kaç kez çalışacağını tanımlayan bir hiper parametre olarak tanımlanmaktadır (Brownlee, 2018).

İnce ayar, problem üzerinde çalışmanın verisi ile eğitilen katmanlar sonucu özelleşen katmanlar elde edilmesini sağlamıştır. Bu işlemde 20 dönem değeri, 7 bekleme (patience) değeri kullanılmıştır. Öğrenme oranı (learning rate) için ise 3 bekleme değeri kullanılmıştır ve bu değer doğrulama kayıp değeri üzerinden kontrol edilmiştir. Bu parametre ince ayar sırasında ezberleme (overfitting) riskinin önüne geçebilmek adına eğitim hızının azaltılmasında kullanılmıştır.

Daha sonra dondurulan katmanlar için ana model serbest bırakıldığında (unfreeze) ağırlıklar güncellenmeye başlamıştır. Ana modelin katmanları serbest bırakıldıktan sonra 100 dönem değeri ile ana model üzerinde eğitim sağlanmıştır. Model içerisinde küme boyutu (batch size) 16 olarak kullanılmıştır. Dönem içerisindeki adım sayıları ise eğitim veri sayısı / küme boyutu olarak kullanılmıştır. Doğrulama adım sayısı da doğrulama veri sayısı / küme boyutu olarak kullanılmıştır. Bu doğrultuda dönem başına 506 adım sayısı kullanılmıştır. Eğitim sürecinde alınan en iyi sonuçların modele kaydedilmesi için “save\_best\_only: true” parametresi geçilmiştir.

Eğitim sırasında aşırı öğrenme (overfitting) olması durumunun önüne geçebilmek için veri çoğaltma (data augmentation) kullanılmıştır. Eğitim veri seti içerisinde %20 oranında doğrulama (validation) veri seti alınarak doğrulama parametreleri de eğitim sırasında takip edilmiştir. Eğitim sırasında belirli bir süre doğrulama kayıp (validation loss) değerinin azalmaması durumunda gereksiz eğitim sağlanmaması ve aşırı öğrenmenin (overfitting) önüne geçilebilmesi adına eğitim erken durdurulabilir. Bu özellik ince ayar kısmında kullanılmıştır. Her model için ince ayar ile elde edilen kayıp-dönem ilişkileri 4. Bölüm 'de tartışılmıştır.

#### 4. GELİŞTİRİLEN MODELLER

COVID-19 tespiti hedeflenen çalışmamızda transfer öğrenme modelleri kullanılmıştır. Probleme yönelik uygun parametre ve yöntemler belirlenerek model yapıları şekillendirilmiştir.

Çalışmanın ilk evrelerinde farklı veri seti ve transfer öğrenme modelleri ile denemeler yapılmıştır. İlk aşamalarda kullanılan veri setinde çok fazla kesit ve çeşitlilik bulunmaması vb. sebeplerden farklı bir veri seti arayışına girilmiştir (Xingyi et al., 2020).

Çalışmamızda kullanılan ve 3.1. Veri seti başlığı altında açıklanan veri seti 7 farklı kaynaktan derlenmiştir. Modelin farklı kaynaklardan veriler içermesi, çalışmayı gerçek dünya özelinde teşhise katkıda bulunulabilmesine bir adım daha yaklaştırmıştır. Veri setinin önceki veri setlerine kıyasla yüksek sayıda veri içermesi, modelin sonuçlarına da katkıda bulunabilecektir.

Literatürde yüksek doğruluk oranları vermiş ve birbirinden farklı yapılarda olan modeller seçilmiştir. Çalışmanın ilk aşamalarında bu seçimler ile testler sağlandığında kullanılabilecek olan modeller hakkında yol göstermiştir. İlk aşamalarda düşük dönem değerleri ile dahi ResNet, VGG, DenseNet modelleri %60-65 oranlarında başarımlar sağlamışlardır. Çalışmanın ilerleyen aşamalarında yapılan araştırmalarda dönem değerleri arttırılmış ve ince ayar kullanılmıştır.

Çalışmamızda kullanılan ResNet152V2, VGG-16 ve DenseNet-121 büyük sayıda veri ile eğitilmiştir ve genel tanıma işlemleri için kapsamlı bilgi içermektedir. Özel problemler için ise modelleri ilgili veri setine uygun hale getirmek için ince ayar yapılması gerekmektedir. İnce ayar kullanılması, önceden büyük görüntü verileri ile eğitilmiş modellerin hedef veriler için özelleştirilmesini sağlamaktadır (Gifani et al., 2021).

Kullanılan tüm modellerde eşit şartlar yaratılması için aynı parametreler kullanılmıştır. En yüksek başarımları elde eden VGG-16 modeli, bölütlenmiş ve bölütlenmemiş veri setleri ile eğitilmiş ve değerlendirilmiştir. Diğer tüm modeller bölütlenmiş veri seti ile eğitilmiş ve test edilmiştir.

Görüntüler modellere verilmeye hazır olduktan sonra, eğitim veri kümesi üzerine veri çoğaltma işlemi yapılmaktadır. Sonrasında temel model ve ağırlıkları yüklenmektedir. İnce ayar işlemi sağlanacağından temel modelin katmanları dondurulmaktadır. 128 nörona sahip bir yoğun katman eklemektedir. Bu katmanda “ReLU” aktivasyon fonksiyonu kullanılmıştır. Bu katman ile önceden eğitilmiş olan modelin özellikleri belirli bir görev için özelleştirilebilmektedir. Aşırı uyumu önleyebilmek adına sönümlenme (dropout) katmanı eklenmiştir. Bu doğrultuda sönümlenme katmanı modelin genelleme yapma yeteneğine de

katkıda bulunmaktadır. İki sınıflı sınıflandırma sağlanacağından, ikili sınıflandırma için uygulanan görülen “sigmoid” aktivasyon fonksiyonu parametresiyle bir çıkış katmanı eklenmiştir.

İnce ayar için bir başka deyişle temel model katmanlarının dondurulduğu aşamada, dönem değeri 20 olarak kullanılmıştır. Erken durdurma içerisinde bulunan bekleme parametre değeri ise 7 olarak geçilmiştir. Erken durdurma içerisinde bulunan bekleme parametresi, modelin aşırı öğrenmesini ve gereksiz eğitimi önleyebilmek açısından önemli görülmektedir. Öğrenme hızı parametresi de doğrulama kayıp parametresini takip edilecek şekilde ayarlanmıştır. Buradaki bekleme parametresi değeri ise 3 olarak kullanılmıştır. Bu işlemler sonucunda dönem değeri-doğruluk ve dönem değeri-kayıp grafikleri elde edilmiştir. Bu grafikler 4.1., 4.2. ve 4.3. bölümlerde verilmiştir.

Modelin temel katmanları serbest bırakıldıktan sonra modelin ağırlıkları eğitim sırasında güncellenmeye başlayacaktır. Modeller 100 dönem değeri ile eğitime tabi tutulmuştur ve doğrulama kayıp değerleri üzerinden takip sağlanmıştır.

Eğitim tamamlandıktan sonra test veri seti benzersiz hasta numaraları ile hasta bazında ayrılmıştır. Bu işlem kesit bazında test verilerinden bağımsız sağlanmıştır. Sonuç olarak hasta bazında ayrılmış olan kesitleri ve tüm kesitleri içeren iki farklı test veri seti elde edilmiştir. Modellerin test sonuç metrikleri ve hata matrisleri her model kapsamında alt başlıklar içerisinde incelenecektir. Hasta bazında test sonuçlarının değerlendirilmesinde, hasta kesitlerinin gerçek etiket değeri ve tahminlenen etiket değerleri karşılaştırılmıştır. Her kesit için bu karşılaştırma sağlanmış olup tahminlenen etiket değeri hangi sınıf için fazla ise hasta o etiket değerine atanmıştır. Bu doğrultuda her hasta için sonuç çıktısı elde edilmiştir.

Hata matrisi genel gösterimi Tablo 4.1.’de sunulduğu şekilde ifade edilmektedir. Hata matrisinde x eksenini üzerinde görüntülerin gerçek değerleri, y eksenini üzerinde tahminlenen değerleri gösterilmektedir. Hata matrisi üzerinde gerçek değeri COVID-19 olup doğru teşhis konulan değerler doğru pozitiflerdir (TP). Gerçek değeri COVID-19 olan fakat normal olarak değerlendirilenler yanlış negatiflerdir (FN). Gerçek değeri normal olup normal olarak değerlendirilenler doğru negatiflerdir (TN). Gerçek değeri normal olup COVID-19 teşhisi konulanlar ise yanlış pozitiflerdir (FP) (Lawton et al., 2021). Bu değerlerin hata matrisi üzerinde soldan sağa doğru sıralaması TN, FP, FN ve TP olarak verilmektedir.

	Tahminlenen Normal	Tahminlenen COVID-19
Gerçek Değer Normal	TN	FP
Gerçek Değer COVID-19	FN	TP

Tablo 4.1. Genel hata matrisi gösterimi


Modellerin başarımları alt başlıklar şeklinde açıklanacaktır, modellerin başarımlarını karşılaştırmaları ise 4.4. bölüm içerisinde gerçekleştirilecektir.

#### 4.1. VGG-16 Modeli

VGG modeli Görsel Geometri Grubu (Visual Geometry Group) tarafından geliştirilen, önceden eğitilmiş bir evrişimli sinir ağıdır (Lee et al., 2020). VGG modeli 2014 yılında ImageNet veri seti üzerinde ikincilik kazanmıştır. Sonrasında görüntü sınıflandırma problemlerinde yaygın olarak kullanılmaya başlanmıştır. VGG-11, VGG-16 ve VGG-19 gibi çeşitleri bulunmaktadır. İsimlendirmelerinin farklılaşmasının sebebi buldukları evrişimli katmanlarının sayısıdır (Yang et al., 2021).

##### 4.1.1. VGG-16 Modeli Bölütlenmemiş Veri Seti

En yüksek başarımların elde edildiği VGG-16 modeli, bölütlenmemiş ve bölütlenmiş veri setleri üzerinden değerlendirilmiştir. Bölütlenmemiş veri setinde, ince ayar için 20 dönem değeri ve 4.başlık altında aktarılan ortak parametreler ile eğitim sağlanmıştır. Modelin ince ayar eğitim sürecinde aldığı dönem-kayıp grafiği Şekil 4.1.'de görülebilmektedir. Eğitim hızı değeri kayıp değerinin düşmemesi doğrultusunda 14. ve 17. dönemlerde düşürülmüştür. Doğrulama kayıp değerinin 18. dönem içerisinde alınan en düşük değerinden daha düşük bir değer almadığı grafikte de görülebilmektedir. Bu doğrultuda 18. dönem değerinden sonra eğitim erken sonlandırılmıştır.



Şekil 4.1. Bölütlenmemiş veri seti ince ayar VGG-16 dönem-kayıp ilişkisi

Temel model katmanları serbest bırakıldıktan sonra 100 dönem değeri ile eğitim tamamlanmıştır. Bu kapsamda testler kesit bazında ve hasta bazında olmak üzere iki farklı şekilde gerçekleştirilmiştir. VGG-16 bölütlenmemiş olan veri seti ile kesit bazında değerlendirmede %94,39 doğruluk oranı elde etmiştir. Kesit bazında test sonuçlarının karışıklık matrisi Tablo 4.2.'de gösterilmiştir. Kesit bazında değerlendirme metriklerini içeren sınıflandırma raporu ise Tablo 4.3.'de gösterilmiştir.

Karışıklık Matrisi	Normal olarak Tahminlenen	COVID-19 olarak Tahminlenen
<b>Gerçek Normal</b>	1898	175
<b>Gerçek COVID-19</b>	46	2234

Tablo 4.2. VGG-16 bölütlenmemiş veri seti ile kesit bazında hata matrisi

Sınıflandırma Metrikleri	Doğruluk	Kesinlik (%)	Hassasiyet (%)	F-1 Skoru (%)	F-2 Skoru (%)	F-5 Skoru (%)	Örnek Sayısı
	94,92	91,56	97,63	94,50	96,35	97,38	4353

Tablo 4.3. VGG-16 bölütlenmemiş veri seti ile kesit bazında sınıflandırma raporu

Hasta bazında sınıflandırma sonucunda elde edilen hata matrisi Tablo 4.4.'de, sınıflandırma raporu ise 4.5.'de gösterilmiştir.

Karışıklık Matrisi	Normal olarak Tahminlenen	COVID-19 olarak Tahminlenen
Gerçek Normal	315	10
Gerçek COVID-19	0	80


Tablo 4.4. VGG-16 bölütlenmemiş veri seti ile hasta bazında hata matrisi

Sınıflandırma Metrikleri	Doğruluk	Kesinlik (%)	Hassasiyet (%)	F-1 Skoru (%)	F-2 Skoru (%)	F-5 Skoru (%)	Örnek Sayısı
	97,53	88,89	100	94,12	97,56	99,52	405

Tablo 4.5. VGG-16 bölütlenmemiş veri seti ile hasta bazında sınıflandırma raporu

#### 4.1.2. VGG-16 Modeli Bölütlenen Veri Seti

En yüksek başarımlar oranını elde etmiş olan VGG-16 modeli diğer tüm modeller gibi bölütlenmiş olan veri seti üzerinde eğitilmiş ve test edilmiştir. İnce ayar eğitimi sırasında öğrenme hızı parametresi ortak olarak seçilen ve 5. Bölüm içerisinde aktarılan bekleme parametresi doğrultusunda 12. ve 15. dönem değerlerinde eğitim hızı düşürülmüştür. İnce ayar için 20 dönem değeri içerisinde, doğrulama kayıp değeri daha fazla düşmediğinden ince ayar eğitimi 16. dönem değerinde durdurulmuştur. Modelin ince ayar eğitim sürecinde aldığı dönem-kayıp grafiği Şekil 4.2.'de görülebilmektedir.



Şekil 4.2. Bölütlenen veri seti ince ayar VGG-16 dönem-kayıp ilişkisi

Temel model katmanları serbest bırakıldıktan sonra 100 dönem değeri ile eğitim tamamlanmıştır. Bu doğrultuda testler kesit bazında ve hasta bazında olmak üzere iki farklı şekilde gerçekleştirilmiştir. VGG-16 bölütlenmiş olan veri seti ile kesit bazında değerlendirmede %95.45 doğruluk oranı elde etmiştir. Kesit bazında test sonuçlarının karışıklık matrisi Tablo 4.6.'de gösterilmiştir. Kesit bazında değerlendirme metriklerini içeren sınıflandırma raporu ise Tablo 4.7.'de gösterilmiştir.

Karışıklık Matrisi	Normal olarak Tahminlenen	COVID-19 olarak Tahminlenen
Gerçek Normal	1955	118
Gerçek COVID-19	80	2200

Tablo 4.6. VGG-16 bölütlenen veriler ile kesit bazında hata matrisi

<b>Sonuç Metrikleri</b>	<b>Doğruluk</b>	<b>Kesinlik (%)</b>	<b>Hassasiyet (%)</b>	<b>F-1 Skoru (%)</b>	<b>F-2 Skoru (%)</b>	<b>F-5 Skoru (%)</b>	<b>Örnek Sayısı</b>
	95,45	94,31	96,07	95,18	95,71	96,01	4353

Tablo 4.7. VGG-16 bölütlenen veri seti ile kesit bazında sınıflandırma raporu

Gerçek bir teşhis sağlanabilmesi için gerçekleştirilen hasta bazında değerlendirme sonuçları Tablo 4.8.'de hata matrisi olarak, Tablo 4.9.'de sınıflandırma raporu olarak gösterilmiştir.

<b>Karışıklık Matrisi</b>	<b>Normal olarak Tahminlenen</b>	<b>COVID-19 olarak Tahminlenen</b>
<b>Gerçek Normal</b>	315	10
<b>Gerçek COVID-19</b>	0	80

Tablo 4.8. VGG-16 bölütlenen veri seti ile hasta bazında hata matrisi

<b>Sonuç Metrikleri</b>	<b>Doğruluk</b>	<b>Kesinlik (%)</b>	<b>Hassasiyet (%)</b>	<b>F-1 Skoru (%)</b>	<b>F-2 Skoru (%)</b>	<b>F-5 Skoru (%)</b>	<b>Örnek Sayısı</b>
	97,53	88,89	100	94,12	97,56	99,52	405

Tablo 4.9. VGG-16 bölütlenen veri seti ile hasta bazında sınıflandırma raporu


## 4.2. ResNet152V2 Modeli

Artık ağlar (Residual network) olarak da bilinen sinir ağının eğitimi ImageNet verileri ile sağlanmıştır. Temel yapısı, önerilen ağa daha önceki ağ düzeylerinden bazı çıktılarını koruyan etkili bir bağlantı kanalı sağlamaktadır. Katmanın, sinir ağının sadece önceki ağdan elde edilmiş olan çıktının artık değerini öğrenmesi gerektiğini göstermektedir. Orijinal (V1)'den farklı olarak V2'de ağırlık katmanlarından sonra yığın normalleştirme (batch normalization) kullanılmaktadır. ResNet152V2 152 katmanlı bir sinir ağıdır (Elshennawy et al, 2020). Yığın

normalleştirmesi ağ daha kararlı hale gelmekte ve yüksek oranlarda eğitim sağlanabilmektedir (Thakkar et al., 2018).

#### 4.2.1. ResNet152V2 Modeli Bölütlenmemiş Veri Seti

İnce ayar eğitimi sırasında öğrenme hızı parametresi ortak olarak geçilen ve 5. Bölüm içerisinde aktarılan bekleme parametresi doğrultusunda 20. dönem değerinde eğitim hızı düşürülmüştür. Eğitimin erken durdurulmadığı bir modeldir. Modelin ince ayar eğitim sürecinde aldığı dönem-kayıp grafiği Şekil 4.3.'de görülebilmektedir.



Şekil 4.3. Bölütlenmemiş veri seti ince ayar ResNet152V2 dönem-kayıp ilişkisi

Temel model katmanları serbest bırakıldıktan sonra 100 dönem değeri ile eğitim tamamlanmıştır. Bu kapsamda testler kesit bazında ve hasta bazında olmak üzere iki farklı şekilde yapılmıştır. ResNet152V2 üzerinde bölütlenmiş olan veri seti ile kesit bazında değerlendirmede %94.76 doğruluk oranı elde etmiştir. Kesit bazında test sonuçlarının karışıklık matrisi Tablo 4.10.'de gösterilmiştir. Kesit bazında değerlendirme metriklerini içeren sınıflandırma raporu ise Tablo 4.11.'de gösterilmiştir.

<b>Karışıklık Matrisi</b>	<b>Normal olarak Tahminlenen</b>	<b>COVID-19 olarak Tahminlenen</b>
<b>Gerçek Normal</b>	1600	473
<b>Gerçek COVID-19</b>	25	2255

Tablo 4.10. ResNet152V2 bölütlenmemiş veri seti ile kesit bazında hata matrisi

<b>Sonuç Metrikleri</b>	<b>Doğruluk</b>	<b>Kesinlik (%)</b>	<b>Hassasiyet (%)</b>	<b>F-1 Skoru (%)</b>	<b>F-2 Skoru (%)</b>	<b>F-5 Skoru (%)</b>	<b>Örnek Sayısı</b>
	88,56	82,66	98,90	90,06	95,16	98,15	4353

Tablo 4.11. ResNet152V2 bölütlenmemiş veri seti ile kesit bazında sınıflandırma raporu

Hasta kesitlerinin benzersiz hasta numaraları ile ayrılması sonrasında modelin hasta bazında sonuç metrikleri elde edilmiştir. Hasta bazında elde edilen hata matrisi sonuçları Tablo 4.12.'de, sınıflandırma raporu ise Tablo 4.13.'de görülebilmektedir.

<b>Karışıklık Matrisi</b>	<b>Normal olarak Tahminlenen</b>	<b>COVID-19 olarak Tahminlenen</b>
<b>Gerçek Normal</b>	256	69
<b>Gerçek COVID-19</b>	0	80

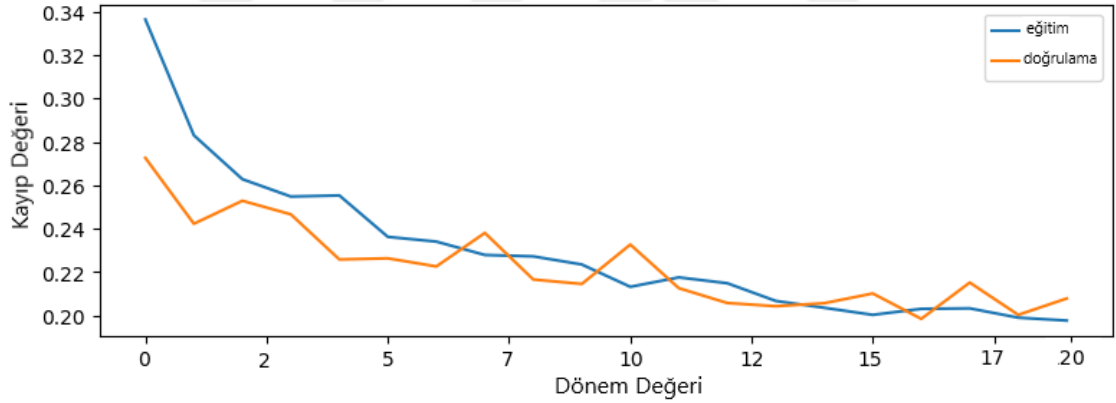
Tablo 4.12. ResNet152V2 bölütlenmemiş veri seti ile hasta bazında hata matrisi

Sonuç Metrikleri	Doğruluk	Kesinlik (%)	Hassasiyet (%)	F-1 Skoru (%)	F-2 Skoru (%)	F-5 Skoru (%)	Örnek Sayısı
	82,96	53,69	100	69,87	85,28	96,78	405

Tablo 4.13. ResNet152V2 bölütlenmemiş veri seti ile hasta bazında sınıflandırma raporu

#### 4.2.2. ResNet152V2 Modeli Bölütlenen Veri Seti

İkinci en yüksek başarımlarını elde etmiş olan ResNet152V2 modeli diğer tüm modeller gibi bölütlenmiş olan veri seti üzerinde eğitilmiş ve test edilmiştir. İnce ayar eğitimi sırasında öğrenme hızı parametresi ortak olarak geçilen ve 5. Bölüm içerisinde aktarılan bekleme parametresi doğrultusunda 20. dönem değerinde eğitim hızı düşürülmüştür. Eğitimin erken durdurulmadığı bir modeldir. Modelin ince ayar eğitim sürecinde aldığı dönem- kayıp grafiği Şekil 4.4. üzerinde görülebilmektedir.



Şekil 4.4. Bölütlenen veri seti ince ayar ResNet152V2 dönem-kayıp ilişkisi

Temel model katmanları serbest bırakıldıktan sonra 100 dönem değeri ile eğitim tamamlanmıştır. Bu kapsamda ResNet152V2 ile elde edilen kesit bazında test sonuçlarının karışıklık matrisi Tablo 4.14.'de gösterilmiştir. Kesit bazında değerlendirme metriklerini içeren sınıflandırma raporu ise Tablo 4.15.'de gösterilmiştir.

<b>Karışıklık Matrisi</b>	<b>Normal olarak Tahminlenen</b>	<b>COVID-19 olarak Tahminlenen</b>
<b>Gerçek Normal</b>	2020	53
<b>Gerçek COVID-19</b>	184	2096

Tablo 4.14. ResNet152V2 bölütlenen veri seti ile kesit bazında hata matrisi

<b>Sonuç Metrikleri</b>	<b>Doğruluk</b>	<b>Kesinlik (%)</b>	<b>Hassasiyet (%)</b>	<b>F-1 Skoru (%)</b>	<b>F-2 Skoru (%)</b>	<b>F-5 Skoru (%)</b>	<b>Örnek Sayısı</b>
	94,56	97,44	91,93	94,46	92,98	92,13	4353

Tablo 4.15. ResNet152V2 bölütlenen veri seti ile kesit bazında sınıflandırma raporu

Hasta kesitlerinin benzersiz hasta numaraları ile ayrılması sonrasında modelin hasta bazında sonuç metrikleri elde edilmiştir. Hasta bazında elde edilen hata matrisi sonuçları Tablo 4.16.'de, sınıflandırma raporu ise Tablo 4.17.'de görülebilmektedir.

<b>Karışıklık Matrisi</b>	<b>Normal olarak Tahminlenen</b>	<b>COVID-19 olarak Tahminlenen</b>
<b>Gerçek Normal</b>	319	6
<b>Gerçek COVID-19</b>	2	78

Tablo 4.16. ResNet152V2 bölütlenen veri seti ile hasta bazında hata matrisi

Sonuç Metrikleri	Doğruluk	Kesinlik (%)	Hassasiyet (%)	F-1 Skoru (%)	F-2 Skoru (%)	F-5 Skoru (%)	Örnek Sayısı
	98,02	92,86	97,50	95,12	96,53	97,31	405


Tablo 4.17. ResNet152V2 bölütlenen veri seti ile hasta bazında sınıflandırma raporu

### 4.3. DenseNet-121 Modeli

Dense Convolutional Network (DenseNet) ImageNet üzerinde önceden eğitilmiş bir evrişimli sinir ağıdır (Gozes at al., 2019). Çalışmamızda kullanılan DenseNet mimarisi 121 katmandan oluşmaktadır. DenseNet yapısı ResNet ile aynı temel fikre dayanmaktadır. DenseNet farklı olarak önceki ve sonraki tüm katmanlar arasında yoğun bağlantılar kurmaktadır. Bu sayede DenseNet daha az hesaplama maliyeti sağlamaktadır (Yang et al., 2021).

#### 4.3.1. DenseNet-121 Modeli Bölütlenmemiş Veri Seti

Bölütlenmemiş olan veri setinde, DenseNet-121 ile ince ayar için 20 dönem değeri ve 4.başlık altında aktarılan ortak parametrelerle eğitim sağlanmıştır. Modelin ince ayar eğitim sürecinde aldığı dönem- doğruluk ve dönem- kayıp grafikleri sırasıyla Şekil 4.2. (a) ve (b)'de görülebilmektedir. Eğitim hızı değeri kayıp değerinin düşmemesi doğrultusunda 16. dönem değerlerinde düşürülmüştür. İnce ayar sırasında 20 dönem değerini de tamamlamıştır, başka bir deyişle erken durdurma sağlanmamıştır. DenseNet-121 modelinin ince ayar eğitim sürecinde dönem- kayıp grafiği Şekil 4.5.'de görülebilmektedir.



Şekil 4.5. Bölütlenmemiş veri seti ince ayar DenseNet-121 dönem- kayıp ilişkisi

Bölütlenmemiş veriler ile sağlanan testler sonucunda elde edilen kesit bazında hata matrisi Tablo 4.18.'de, sınıflandırma raporu ise Tablo 4.19.'de verilmiştir.

<b>Karışıklık Matrisi</b>	<b>Normal olarak Tahminlenen</b>	<b>COVID-19 olarak Tahminlenen</b>
<b>Gerçek Normal</b>	1642	431
<b>Gerçek COVID-19</b>	150	2130

Tablo 4.18. DenseNet-121 bölütlenmemiş veri seti ile kesit bazında hata matrisi

<b>Sonuç Metrikleri</b>	<b>Doğruluk</b>	<b>Kesinlik (%)</b>	<b>Hassasiyet (%)</b>	<b>F-1 Skoru (%)</b>	<b>F-2 Skoru (%)</b>	<b>F-5 Skoru (%)</b>	<b>Örnek Sayısı</b>
	86,65	79,21	83,17	88,00	82,34	83,01	4353

Tablo 4.19. DenseNet-121 bölütlenmemiş veri seti ile kesit bazında sınıflandırma raporu

Hasta kesitlerinin benzersiz hasta numaraları ile ayrılması sonrasında modelin hasta bazında sonuç metrikleri elde edilmiştir. Elde edilen sonuç metriklerin hata matrisi Tablo 4.20.'de, sınıflandırma raporu Tablo 4.21.'de verilmiştir.

<b>Karışıklık Matrisi</b>	<b>Normal olarak Tahminlenen</b>	<b>COVID-19 olarak Tahminlenen</b>
<b>Gerçek Normal</b>	267	58
<b>Gerçek COVID-19</b>	0	80

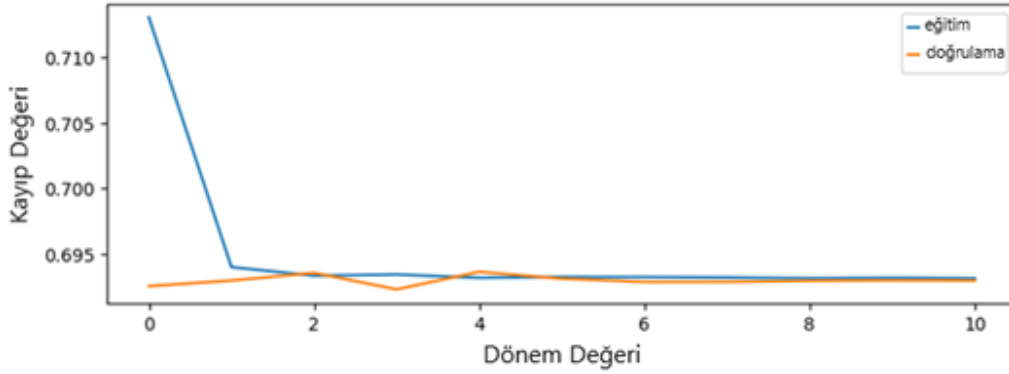
Tablo 4.20. DenseNet-121 bölütlenmemiş veri seti ile hasta bazında hata matrisi

Sonuç Metrikleri	Doğruluk	Kesinlik (%)	Hassasiyet (%)	F-1 Skoru (%)	F-2 Skoru (%)	F-5 Skoru (%)	Örnek Sayısı
	85,68	57,97	100	73,39	87,65	97,28	405

Tablo 4.21. DenseNet-121 bölütlenmemiş veri seti ile hasta bazında sınıflandırma raporu

#### 4.3.2. DenseNet-121 Modeli Bölütlenen Veri Seti

DenseNet-121 çalışmamız kapsamında diğer modellere kıyasla en düşük doğruluk başarımlarını alan modeldir. Bu model de diğer tüm modeller ile aynı şekilde bölütlenmiş olan veri seti üzerinde eğitilmiş ve test edilmiştir. İnce ayar eğitimi sırasında öğrenme hızı parametresi ortak olarak kullanılan bekleme parametresi doğrultusunda 7. Ve 10. dönem değerlerinde öğrenme hızı düşürülmüştür. Eğitim doğrulama kayıp değerinin bekleme değeri sınırları içerisinde düşmemesi kaynaklı ince ayar eğitiminde erken durdurma sağlanmıştır. Erken durdurma 11. Dönem değerinde gerçekleşmiştir. Modelin ince ayar eğitim sürecinde aldığı dönem- kayıp grafiği Şekil 4.6.'de görülebilmektedir.



Şekil 4.6. Bölütlenen veri seti ince ayar DenseNet-121 dönem-kayıp ilişkisi

Temel model katmanları serbest bırakıldıktan sonra 100 dönem değeri ile eğitim tamamlanmıştır. Bu kapsamda testler kesit bazında ve hasta bazında olmak üzere iki farklı şekilde sağlanmıştır. Kesit bazında test sonuçlarının karışıklık matrisi Tablo 4.22.'de

gösterilmiştir. Kesit bazında değerlendirme metriklerini içeren sınıflandırma raporu ise Tablo 4.23.'de gösterilmiştir.

Karışıklık Matrisi	Normal olarak Tahminlenen	COVID-19 olarak Tahminlenen
Gerçek Normal	1824	249
Gerçek COVID-19	74	2206

Tablo 4.22. DenseNet-121 bölütlenen veri seti ile kesit bazında hata matrisi

Sonuç Metrikleri	Doğruluk	Kesinlik (%)	Hassasiyet (%)	F-1 Skoru (%)	F-2 Skoru (%)	F-5 Skoru (%)	Örnek Sayısı
	92,58	87,99	96,10	91,87	94,36	95,76	4353

Tablo 4.23. DenseNet-121 bölütlenen veri seti ile kesit bazında sınıflandırma raporu

Hasta kesitlerinin benzersiz hasta numaraları ile ayrılması sonrasında modelin hasta bazında sonuç metrikleri elde edilmiştir. Elde edilen sonuç metrikleri Tablo 4.24. ve sınıflandırma raporu Tablo 4.25.'de gösterilmiştir.

Karışıklık Matrisi	Normal olarak Tahminlenen	COVID-19 olarak Tahminlenen
Gerçek Normal	293	32
Gerçek COVID-19	0	80

Tablo 4.24. DenseNet-121 bölütlenen veri seti ile hasta bazında hata matrisi

Sonuç Metrikleri	Doğruluk	Kesinlik (%)	Hassasiyet (%)	F-1 Skoru (%)	F-2 Skoru (%)	F-5 Skoru (%)	Örnek Sayısı
	92,10	71,43	100	83,33	92,59	98,48	405

Tablo 4.25. DenseNet-121 bölütlenen veri seti ile hasta bazında sınıflandırma raporu

#### 4.4. Kullanılan Modellerin Sonuçları

Test aşamasında iki farklı yaklaşım kullanılarak modeller test verileri üzerinden değerlendirilmiştir. Modeller test verileri üzerinde ilk yaklaşımda kesit bazında sonuçlar ile değerlendirilmiştir. Fakat gerçek hayatta bir teşhis aşamasında kesit bazında değil hasta bazında değerlendirmeye ihtiyaç duyulduğundan ikinci yaklaşımda hasta bazında değerlendirme sağlanmıştır. Çalışmamızın sonuçları; doğruluk, kesinlik, hassasiyet ve seçilen “ $\beta$ ” parametreleri ile F $\beta$  skorları üzerinden irdelenmiştir.

Problemimizin temelinde doğru pozitiflerin sınıflandırılması yüksek öneme sahiptir. Değerlendirme metrikleri bu doğrultuda irdelenmiştir. Doğru pozitiflerin, doğru pozitif ve yanlış negatiflerin toplamına oranı olan hassasiyet (recall) problemimizde önem taşımaktadır. Doğru pozitif değerler doğru sınıflandırılan COVID-19 değerlerini, yanlış negatifler ise normal olarak sınıflandırılan COVID-19 değerleri göstermektedir. Bu kapsamda, sınıflandırma sürecinde hassasiyet değerinin 1’e ulaşması veya yaklaşması COVID-19 teşhisi için gerekmektedir (Alakus vd., 2020).

F $\beta$  skoru da çalışmamızda hesaplanmıştır. F $\beta$  skoru kesinlik ve hassasiyet değerlerinin harmonik ortalamasıdır (Aggarwal et al., 2022). Burada “ $\beta$ ” parametresi, hassasiyetin kesinlik değerinden kaç kat önemli olduğunu belirtmektedir (Boulorani et al., 2021). F $\beta$  skoru içerisinde “ $\beta$ ” değeri çalışmamızda 1,2 ve 5 olarak kullanılmıştır. F $\beta$  skoru 10 değeri için de hesaplandığında, kesinlik değerine çok fazla yaklaştığından çalışma sonuçlarına dahil edilmemiştir.

Bölütlenmiş ve bölütlenmemiş veri seti ile modellerin sonuçları başarımları metrikleri üzerinden kesit bazında Tablo 4.26.’de ve hasta bazında Tablo 4.27.’de olmak üzere gösterilmiştir.

<b>Model</b>	<b>Doğruluk (%)</b>	<b>Kesinlik (%)</b>	<b>Hassasiyet (%)</b>	<b>F-1 Skoru (%)</b>	<b>F-2 Skoru (%)</b>	<b>F-5 Skoru (%)</b>
<b>Bölütlenmemiş Veri Seti ile VGG-16</b>	94,92	91,56	97,63	94,50	96,35	97,38
<b>Bölütlenen Veri Seti ile VGG-16</b>	95,45	94,31	96,07	95,18	95,71	96,01
<b>Bölütlenmemiş Veri Seti ile ResNet152V2</b>	88,56	82,66	98,90	90,06	95,16	98,15
<b>Bölütlenen Veri Seti ile ResNet152V2</b>	94,56	97,44	91,93	94,46	92,98	92,13
<b>Bölütlenmemiş Veri Seti ile DenseNet-121</b>	86,65	79,21	83,17	88,00	82,34	83,01
<b>Bölütlenen Veri Seti ile DenseNet-121</b>	92,58	87,99	96,10	91,87	94,36	95,76

Tablo 4.26. Bölütlenen ve bölütlenmeyen veri setleri ile kesit bazında model başarımları

Kesit bazında bölütlenen ve bölütlenmeyen veri setleri üzerinden başarımlarına bakıldığında bölütlemenin kesit bazında başarımları arttırdığı modeller üzerinde görülmüştür. Kesit bazında en yüksek sonuçları VGG-16 modeli elde etmiştir.

<b>Model</b>	<b>Doğruluk (%)</b>	<b>Kesinlik (%)</b>	<b>Hassasiyet (%)</b>	<b>F-1 Skoru (%)</b>	<b>F-2 Skoru (%)</b>	<b>F-5 Skoru (%)</b>
<b>Bölütlenmemiş Veri Seti ile VGG-16</b>	97,53	88,89	100	94,12	97,56	99,52
<b>Bölütlenen Veri Seti ile VGG-16</b>	97,53	88,89	100	94,12	97,56	99,52
<b>Bölütlenmemiş Veri Seti ile ResNet152V2</b>	82,96	53,69	100	69,87	85,28	96,78
<b>Bölütlenen Veri Seti ile ResNet152V2</b>	98,02	92,86	97,50	95,12	96,53	97,31
<b>Bölütlenmemiş Veri Seti ile DenseNet-121</b>	85,68	57,97	100	73,39	87,65	97,28
<b>Bölütlenen Veri Seti ile DenseNet-121</b>	92,10	74,43	100	83,33	92,59	98,48

Tablo 4.27. Bölütlenen ve bölütlenmeyen veri setleri ile hasta bazında model başarımları

Hasta bazında bölütlenen ve bölütlenmeyen veri setleri üzerinden başarımlarına bakıldığında bölütlemenin hasta bazında başarımlarını arttırdığı modeller üzerinde de görülmüştür. En yüksek sonucu VGG-16 modeli elde etmiştir. Burada VGG-16'nın bölütlenen ve bölütlenmeyen veri setinde ile eşit sonucu vermesinin model başarımının yakın olmasından kaynaklandığı düşünülmektedir. Diğer modellerin bölütlenen ve bölütlenmeyen hasta bazında sonuçlarına bakıldığında bölütlemenin başarımlarını arttırdığı görülmüştür.

Hasta bazında sınıflandırmada, modeller üzerinde hassasiyet değerinin kesinlik değerine kıyasla yüksek sonuçlar elde ettiği görülmüştür. Bu durum COVID-19 sınıfına ait hastaların, hasta bazında kesit sayısının fazla olmasından kaynaklandığı düşünülmektedir. Hassasiyetin yüksek olması ile COVID-19 tespitinin daha doğru şekilde yapılacaktır.

Maftouni et al.'un 2021 yılındaki çalışmalarından elde edilen sonuç metrikleri çalışmamızdan elde edilen sonuç metrikleri ile karşılaştırılarak tablo halinde verilmiştir (Maftouni et al., 2021). Belirtilen çalışma içerisinde F-2, F-5 skorları mevcut olmadığından bizim çalışmamız ile karşılaştırılabilmesi için bu skor değerleri tarafımızca hesaplanmıştır. Çalışmadan elde edilmiş olan ve tarafımızca hesaplanan sonuç metrikleri, çalışmamızın sonuçlarıyla birlikte Tablo 4.28.'de gösterilmiştir.

<b>Model</b>	<b>Doğruluk (%)</b>	<b>Kesinlik (%)</b>	<b>Hassasiyet (%)</b>	<b>F-1 Skoru (%)</b>	<b>F-2 Skoru (%)</b>	<b>F-5 Skoru (%)</b>
<b>DenseNet-121</b>	92,57	94,42	87,55	90,85	88,84	87,79
<b>Residual Attention-92</b>	91,76	90,47	90,99	90,73	90,88	90,96
<b>FC ile Önerilen Topluluk Modeli</b>	95,07	98,32	89,84	93,89	91,41	90,13
<b>FC + DVM ile Önerilen Topluluk Modeli</b>	95,31	97,93	90,80	94,23	91,50	91,05
<b>Çalışmamızda Kullanılan VGG-16</b>	97,53	88,89	100	94,12	97,56	99,52
<b>Çalışmamızda Kullanılan ResNet152V2</b>	98,02	92,86	97,50	95,12	96,53	97,31
<b>Çalışmamızda Kullanılan DenseNet-121</b>	92,10	71,43	100	83,33	92,59	98,48

Tablo 4.28. Karşılaştırılan çalışmanın ve çalışmamızın model başarımları

Maftouni et al. tarafından 2021 yılında gerçekleştirilen çalışmanın başarımları, çalışmamızın bölütlenmiş veri setinden hasta bazında alınan sonuçları ile karşılaştırılmıştır (Maftouni et al., 2021). Bunun sebebi, karşılaştırılan çalışmada da sonuçların hasta bazında alındığının belirtilmesidir. Önerilen iki yöntem ile çalışmamızın karşılaştırılmasında modellerimizden VGG-16 ve ResNet152V2 modelleri genel anlamda daha üstün başarımlar sağlamıştır. DenseNet-121 modeli ise hassasiyet ve F-5 skorlarında karşılaştırılan çalışmadan daha iyi başarımlar elde etmiştir.



## 5. TARTIŞMA ve SONUÇ

Çalışmamız içerisinde COVID-19 için hayat kurtaran, hızlı ve güvenilir bir yapay zeka çözümü sunulmaktadır. Akciğer BT görüntüleri üzerinden COVID-19 teşhisinin hızlandırılması ile hayati risklerin ve ekonomik yüklerin en aza indirilebilmesi için yapay zekanın desteği çalışmamızda kullanılmıştır.

Yapay zeka destekli sunulan çalışmamızda, bölütleme için en temel yöntemlerden biri olan Otsu eşikleme yöntemi kullanılmıştır. Otu eşikleme yöntemi, diğer uygun ön işleme teknikleri ile akciğer bölütlemesi için tüm problemlerin üstesinden gelmiştir. Bölütleme, görüntüler üzerindeki gürültüleri azaltarak hedef alana odaklanabilmesini sağlamıştır. Sonuçlar bölütlenen ve bölütlenmeyen görüntüler üzerinden hasta bazında ve kesit bazında olacak şekilde değerlendirilmiştir. Gerçek hayatta kullanılacak bir teşhis reçetesi sunulabilmesi için hasta bazında değerlendirme kullanılmıştır. Kesit bazında değerlendirme ise bölütlemenin ve diğer işlemlerin model başarımlarına tüm test verileri üzerinden bakılabilmesi için kullanılmıştır.

Hassasiyet, COVID-19 tespiti için en önemli değerlendirme metriklerdendir ve karşılaştırılan çalışmalarda bu durum tarafımızca ön planda tutulmuştur. Bu doğrultuda kullanılan F $\beta$  metriği ile hassasiyetin kesinlikten kaç kat daha önemli olacağı seçilmektedir. F $\beta$  ile sonuçların değerlendirilmesinde, doğru pozitiflerin doğru şekilde sınıflandırılması odak noktası seçilerek teşhis gerçekleştirilmiştir.

Bölütleme yapılan ve yapılmayan veri setleri üzerinde başarımlar karşılaştırılmıştır ve bölütleme ile başarımlar oranlarında anlamlı bir artış sağlanmıştır. VGG-16 modelinde ise hasta bazında değerlendirmede başarımların değişmediği fakat kesit bazında modelin başarımlarının arttığı görülmüştür. Bunun sebebinin modelin kesit bazında başarımlarının da oldukça yakın olmasından kaynaklandığı görülmektedir. ResNet152V2 modelinde hasta bazında bölütlenmemiş ve bölütlenen başarımlar karşılaştırıldığında sırasıyla; F-1 skoru %69,87'den %95,12'ye, F-2 skorunun %85,28'den %96,53'e ve F-5 skorunun %96,78'den %97,31'e yükseldiği görülmüştür. Doğruluk oranı da %82,96'dan %98,02'ye yükselmiştir. DenseNet-121 modelinde ise hasta bazında bölütlenmemiş ve bölütlenmiş verilerin başarımlarını karşılaştırıldığında; F-1 skoru %73,39'dan %83,33'e, F-2 skoru %87,65'ten %92,59'a, F-5 skoru %97,28'den %98,48'e yükselmiştir. Doğruluk oranı da %85,68'den %92,10'a yükselmiştir.

Medikal görüntülerin sıfırdan bir ağı eğitmek için yeterli sayıda veri içermemesi sebebi ile transfer öğrenme yöntemine başvurulmuştur. Farklı transfer öğrenme yöntemleri ile de yüksek başarımlar sağlanamaması üzerine, sorunun modellerden kaynaklanmadığı görülmüştür.

Bu kapsamda ađın, alıřmamızın verileri ile zelleřtirilmesi gerektiđi grlmřtr ve modeller zerinde ince ayar yntemi kullanılmıřtır. alıřmada kullanılan veriler ile eđitilen katmanlar sonucunda problem iin zelleřen katmanlar elde edilmiřtir. İnce ayarın modeller zerinde kullanılması ve arttırılan dnem deđerleri ile bařarımlar %60-65 civarlarından %90 zerine ıkarılmıřtır. Denenmiř yntemlerden en iyi sonucu veren modellerin ResNet152V2 ve VGG-16 olduđu grlmřtr. Hasta bazında bltlenen veriler ile en nemli bařarım sonularından bazıları; VGG-16 modeli %97,53 dođruluk ve %94,12 F-1 skoru, ResNet152V2 modeli %98,02 dođruluk ve %95,12 F-1 skoru, DenseNet-121 modeli %92,10 dođruluk ve %83,33 F-1 skoru řeklinde dir.

Maftouni et al.'un alıřması ile alıřmamızın sonularının karřılařtırılabilmesi iin sonu metriklerinde bulunmayan F-2 ve F-5 skorları tarafımızca hesaplanmıřtır (Maftouni et al., 2021). alıřmamızda kullanılan VGG-16 ve ResNet152V2 modellerinin genel bařarım ve Fβ metriklerine bakıldıđında, karřılařtırılan alıřmadan daha iyi bařarım sađladıđı grlmřtr. DenseNet-121 modelinin de hassasiyet, F-2 ve F-5 skorlarında karřılařtırılan alıřmadan daha iyi sonular elde ettiđi grlmřtr.

Seum et al. alıřmalarında %86,80 hassasiyet, %92,74 kesinlik, %89.67 F-1 skoru ve %89.92 dođruluk elde edilmiřtir (Seum et al., 2020). F-2 ve F-5 skorları tarafımızca hesaplanmış olup sırasıyla; 87,98 ve 87,01 řeklinde dir. alıřmamızdan ResNet152V2 modelinde alınan %95,12 F-1, %96,53 F-2 ve %97,31 F-5 skorları ile karřılařtırılan alıřmadan daha iyi sonular elde edildiđi aıka grlmřtr.

Yang et al. alıřmalarında ResNet152V2 modeli ile %95,06 dođruluk, %94,96 hassasiyet, %92,81 F-1 skoru ve %97,19 kesinlik elde edilmiřtir (Yang et al., 2021). Karřılařtırılan alıřmanın tarafımızca hesaplanan F-2 ve F-5 skorları sırasıyla; %95,39 ve %95,04 řeklinde dir. alıřmamız ise bltleme sađlanan hasta bazında ResNet152V2 modeli ile %98,02 dođruluk, %97,50 hassasiyet, %95,12 F-1, %96,53 F-2 ve %97,31 F-5 skorları ile stn sonular elde etmiřtir.

COVID-19'un makine đrenmesi destekli teřhisi sayesinde kazanılan hız ve dođruluk ile erken teřhis kolaylařacaktır. Bu kapsamda COVID-19 ilerlemeden tedavi edilecek ve erken teřhis ile hayat kurtarılacaktır. Kesit bazında deđerlendirme ise, yapay zeka alanındaki arařtırmalar ve analizler tarafında kullanılarak COVID-19 ve diđer akciđer hastalıklarının teřhisi iin oluřturulacak yapılara katkıda bulunacaktır.

Gelecek çalışmalarımızda, topluluk modeli kullanılarak elde edilen sonuçlar üzerindeki başarımların ölçülmesi ilk sıralarda yer almaktadır. Topluluk modelinin kullanılmasında bu alanda yapılan en güncel çalışmaların incelenmesi planlanmıştır. Bu sayede uygun ve güncel veri setlerinin çalışmamızda kullanılmış olan veri setine eklenmesiyle veri setinin büyütülmesi de planlanmaktadır. Bir diğer planlanan çalışma ise segmentasyonun uygun yapay zeka öğrenme yöntemleri kullanılarak otomatikleştirilmesidir. 3 boyutlu akciğer BT görüntüleri üzerinden farklı akciğer hastalıklarının teşhisi üzerinde çalışmalar yapılması da çalışma kapsamının genişletilmesi dahilinde planlanmaktadır.



## KAYNAKLAR DİZİNİ

- Abdullah, Mohd Firdaus., et al.**, 2019, "A comparative study of image segmentation technique applied for lung cancer detection. *9th IEEE International Conference on Control System, Computing and Engineering (ICCSCE)*. IEEE.
- Abuzaghleh, O., Barkana, B. D., and Faezipour, M.**, 2015, **Noninvasive** real-time automated skin lesion analysis system for melanoma early detection and prevention. *IEEE journal of translational engineering in health and medicine*, 3. 1-12s.
- Alakus, Talha Burak., and Ibrahim Turkoglu.**, 2020, Comparison of deep learning approaches to predict COVID-19 infection. *Chaos, Solitons & Fractals*, 140s.
- Alimadadi, Ahmad., et al.** Artificial intelligence and machine learning to fight COVID-19. *Physiological genomics* 52.4 (2020): 200-202.
- Alzubaidi, Laith., et al.**, 2020, Towards a better understanding of transfer learning for medical imaging: a case study. *Applied Sciences* 10.13s.
- Awwalin, A. R., Setiawati, E., and Anam, C.**, 2021, Implementasi Metode Contrast Limited Adaptive Histogram Equalization dan Laplacian of Gaussian Filter Untuk Peningkatan Kontras Citra CT. *Berkala Fisika*, vol. 24, no. 1, pp. 35-43p.
- Bhargavi, K., and S. Jyothi.**, 2014, A survey on threshold based segmentation technique in image processing." *International Journal of Innovative Research and Development*. 3.12 234-239p.
- Bhosle, Sanket, et al.**, 2023, Comparative Analysis Between Different Lung Segmentation Techniques, *ITM Web of Conferences. Vol. 56. EDP Sciences*.
- Boddu, Raja Sarath Kumar, et al.**, 2022, Analyzing the impact of machine learning and artificial intelligence and its effect on management of lung cancer detection in covid-19 pandemic. *Materials Today: Proceedings*, (56), 2213-2216s.
- Bolourani, Siavash., et al.**, 2021, A machine learning prediction model of respiratory failure within 48 hours of patient admission for COVID-19: model development and validation. *Journal of medical Internet research* 23.2p.
- Brownlee, Jason.**, 2018, What is the Difference Between a Batch and an Epoch in a Neural Network", *Machine Learning Mastery* 20.
- Bozkurt, F.**, 2021, Derin Öğrenme Tekniklerini Kullanarak Akciğer X-Ray Görüntülerinden COVID-19 Tespiti. *Avrupa Bilim ve Teknoloji Dergisi*, (24), 149-156s.

## KAYNAKLAR DİZİNİ (devam)

- Budak, Ü.**, 2019, SegNet Mimarisi ile Bilgisayarlı Tomografi Görüntülerinden Karaciğer Bölgesinin Bölütlenmesi. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 31(1), 215-222p.
- Burlina, Phillippe, et al.**, 2018, Utility of deep learning methods for referability classification of age-related macular degeneration. *JAMA ophthalmology* 136.11 1305-1307p.
- Büyüköze, S. ve Dereli, E.**, 2019, Dijital Sağlık Uygulamalarında Yapay Zeka. VI. Uluslararası Bilimsel ve Mesleki Çalışmalar Kongresi-Fen ve Sağlık, 07-10s.
- Castiglioni, Isabella., et al.**, 2021, AI applications to medical images: From machine learning to deep learning. *Physica Medica* 83,9-24p.
- Chaudhary, Anita., and Sonit Sukhraj Singh.**, 2012, Lung cancer detection on CT images by using image processing. *International Conference on Computing Sciences*. IEEE.
- Chauhan, Tannu., et al.**, 2021, Supervised and unsupervised machine learning based review on diabetes care. *2021 7th International Conference on Advanced Computing and Communication Systems (ICACCS)*. Vol. 1. IEEE.
- Chithra, A. S., and Renjen Roy RU.**, 2018, Otsu's Adaptive Thresholding Based Segmentation for Detection of Lung Nodules in CT Image. *2018 2nd International Conference on Trends in Electronics and Informatics (ICOEI)*. IEEE.
- Chitradevi, B., and Srimathi, P.**, 2014, An overview on image processing techniques. *International Journal of Innovative Research in Computer and Communication Engineering*, 2(11), 6466-6472p.
- Cömert, S. Ş., ve Kıral, N.**, 2020, COVID-19 Pnömonisinin Radyolojik Bulguları. Southern Clinics of Istanbul Eurasia.
- Çevik, K., ve Dandıl, E.**, 2019, Classification of lung nodules using convolutional neural networks on CT Images. In *2nd International Turkish World Engineering and Science Congress*, 27-35p.
- Dack, Ethan, et al.**, 2023, Artificial Intelligence and Interstitial Lung Disease: Diagnosis and Prognosis, *Investigative radiology*, (10), 1097s.
- Dutta, Pramit., Tanny Roy., and Nafisa Anjum.**, 2021, COVID-19 detection using transfer learning with convolutional neural network. *2021 2nd International Conference on Robotics, Electrical and Signal Processing Techniques (ICREST)*. IEEE.

## KAYNAKLAR DİZİNİ (devam)

- Elshennawy, Nada M., and Dina M. Ibrahim.,** 2020, Deep-pneumonia framework using deep learning models based on chest X-ray images. *Diagnostics* 10.9, 649p.
- Erickson, Bradley J., et al.,** 2017, Machine learning for medical imaging. *Radiographics* 37.2, 505-515p.
- Essaf, Firdaous., et al.,** 2020, An improved lung parenchyma segmentation using the maximum inter-class variance method (OTSU). *Proceedings of the 2020 6th International Conference on Computing and Artificial Intelligence.*
- Fan, D. P., Zhou, T., Ji, G. P., Zhou, Y., Chen, G., Fu, H., ... and Shao, L.,** 2020, Inf- net: Automatic covid-19 lung infection segmentation from ct images. *IEEE Transactions on Medical Imaging*, 39(8), 2626-2637s.
- Fırıldak, K., ve Talu, M. F.,** 2019, Evrişimsel sinir ağlarında kullanılan transfer öğrenme yaklaşımlarının incelenmesi. *Computer Science.* 4.(2), 88-95s.
- Gedik, N.,** 2013, Bilgisayar destekli teşhis sistemi ile mamografi görüntülerinin sınıflandırılması (Doctoral dissertation), Karadeniz Teknik Üniversitesi.
- Gifani, Parisa., Ahmad Shalbaf., and Majid Vafaezadeh.,** 2021, Automated detection of COVID-19 using ensemble of transfer learning with deep convolutional neural network based on CT scans. *International journal of computer assisted radiology and surgery* 16, 115-123p.
- Giger, Maryellen L.,** 2018, Machine learning in medical imaging. *Journal of the American College of Radiology* 15.3, 512-520p.
- Google Colab,** “Google Colaboratory”<https://colab.google/>
- Gonem, Sherif., et al.,** 2020, Applications of artificial intelligence and machine learning in respiratory medicine. *Thorax* 75.8, 695-701p.
- Goyal, M.,** 2011, Morphological image processing. *IJCST*, 2(4), 59s.
- Gozes, Ophir., and Hayit Greenspan.,** 2019, Deep feature learning from a hospital-scale chest x-ray dataset with application to TB detection on a small-scale dataset. *2019 41st annual international conference of the ieee engineering in medicine and biology society (embc).* IEEE.
- Hu, Anmei., et al.,** 2023, Support vector machine model based on OTSU segmentation algorithm in diagnosing bronchiectasis with chronic airway infections. *Journal of Radiation Research and Applied Sciences* 16.1.

## KAYNAKLAR DİZİNİ (devam)

- Işık, Ü., Güven, A., ve Büyükoğlan, H.**, 2015, Yapay Sinir Ağları ile Kronik Obstrüktif Akciğer Hastalığının Sınıflandırılması, Chronic Obstructive Pulmonary Disease Classification with Artificial Neural Networks. *Tıp Teknolojileri Ulusal Kongresi*, 189-192s.
- Keleş, A.**, 2018, **Derin** Öğrenme ve Sağlık Alanındaki Uygulamaları, *Electronic Turkish Studies*, 13s(21).
- Khomduean, P., Phaudomcharoen, P., Boonchu, T., Taetragool, U., Chamchoy, K., Wimolsiri, N., ... & Tweatsani, N.**, 2023, Segmentation of Lung Lobes and Lesions in Chest CT for the Classification of COVID-19 Severity.
- Kim, Hee E., et al.**, 2022, Transfer learning for medical image classification: a literature review. *BMC medical imaging* 22.1, 69p.
- Koonsanit, Kitti, et al.**, 2017, Image enhancement on digital x-ray images using N-CLAHE. *10th Biomedical engineering international conference (BMEICON)*, (2), IEEE.
- Kömürcüoğlu, Berna.**, 2020, COVID-19'un Klinik ve Laboratuvar Bulguları. *Göğüs Hastalıkları Uzmanlarının Bilmesi Gerekenler*, 28p.
- Kumar, Yogesh., et al.**, 2022, Artificial intelligence in disease diagnosis: a systematic literature review, synthesizing framework and future research agenda. *Journal of ambient intelligence and humanized computing*, 1-28p.
- Lawton, S., and Viriri, S.**, 2021, Detection of COVID-19 from CT lung scans using transfer learning. *Computational Intelligence and Neuroscience*.
- Lee, Ki-Sun., et al.**, 2020, Evaluation of scalability and degree of fine-tuning of deep convolutional neural networks for COVID-19 screening on chest X-ray images using explainable deep-learning algorithm. *Journal of personalized medicine* 10.4, 213p.
- Maftouni, M., Law, A.C, Shen, B., Zhou, Y., Yazdi, N., and Kong, Z.J.**, 2021, "A Robust Ensemble-Deep Learning Model for COVID-19 Diagnosis based on an Integrated CT Scan Images Database," *Proceedings of the 2021 Industrial and Systems Engineering Conference, Virtual Conference*.
- Murugan, Suriya., et al.**, 2021, DEMNET: a deep learning model for early diagnosis of Alzheimer diseases and dementia from MR images. *Ieee Access* 9. 90319-90329p.
- Narin, A., ve Isler, Y.**, 2021, Detection of new coronavirus disease from chest x-ray images using pre-trained convolutional neural networks. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 36(4), 2095-2107p.

## KAYNAKLAR DİZİNİ (devam)

- Norouzi, A., Rahim, M. S. M., Altameem, A., Saba, T., Rad, A. E., Rehman, A., and Uddin, M.**, 2014, **Medical** image segmentation methods, algorithms, and applications. *IETE Technical Review*, 31(3), 199-213s.
- Özdemir, M., Taydaş, O., ve ÖZTÜRK, M. H.**, 2020, COVID-19 Enfeksiyonunda Toraks Bilgisayarlı Tomografi Bulguları. *Journal of Biotechnology and Strategic Health Research*, 4, 91-96s.
- Özdemir, Z., ve Keleş, H. Y.**, 2021, Covid-19 Detection in Chest X-ray Images with Deep Learning. In *2021 29th Signal Processing and Communications Applications Conference (SIU)* (pp. 1-4). IEEE.
- Özekes, S., ve Çamurcu, A. Y.**, 2006, Şablon eşleme yöntemi kullanılarak mamogramlardaki ve akciğer BT'lerindeki anormalliklerin bilgisayar destekli tespiti: bir derleme çalışması.
- Özen, Y.**, 2013, Akciğer BT görüntülerinin bölütlenmesi ve değerlendirilmesi. Diss. Karadeniz Teknik Üniversitesi, 2013.
- Pandey, Sanat Kumar., Ashish Kumar Bhandari., and Himanshu Singh.**, 2022, A transfer learning based deep learning model to diagnose COVID-19 CT scan images. *Health and Technology* 12.4, 845-865p.
- Pektatlı, Yasemin.**, 2011, Sayısal Görüntü İşlemede Paralel Bölütleme, *Elektrik-Elektronik Mühendisliği Anabilim Dalı*.
- Pontone, Gianluca., et al.**, 2021, Role of computed tomography in COVID-19. *Journal of cardiovascular computed tomography* 15.1, 27-36p.
- Portugal, I., Alencar, P., and Cowan, D.**, 2018, The use of machine learning algorithms in recommender systems: A systematic review. *Expert Systems with Applications*, 97, 205-227s.
- Python**, "Python Documentation", <https://docs.python.org/3/>
- Ramesh, K. K. D., et al.**, 2021, A review of medical image segmentation algorithms. *EAI Endorsed Transactions on Pervasive Health and Technology* 7.27.
- Sevli, O.**, 2019, Göğüs Kanseri Teşhisinde Farklı Makine Öğrenmesi Tekniklerinin Performans Karşılaştırması. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 176-185s.

## KAYNAKLAR DİZİNİ (devam)

- dos Santos, J. C. M., Carrijo, G. A., de Fátima dos Santos Cardoso, C., Ferreira, J. C., Sousa, P. M., and Patrocínio, A. C.**, 2019, Fundus image quality enhancement for blood vessel detection via a neural network using CLAHE and Wiener filter. *Research on Biomedical Engineering*, 36, 107-119s.
- Saxena, S., Sharma, S., and Sharma, N.**, 2016, Research Article Parallel Image Processing Techniques, Benefits and Limitations. *Research Journal of Applied Sciences, Engineering and Technology*, 12(2), 223-238p.
- Seum, Ashek., et al.**, 2020, A comparative study of cnn transfer learning classification algorithms with segmentation for COVID-19 detection from CT scan images. *2020 11th International Conference on Electrical and Computer Engineering (ICECE), IEEE*.
- Singh, Gursharn., and Anand Mittal.**, 2014, Various image enhancement techniques-a critical review. *International Journal of Innovation and Scientific Research* 10.2, 267-274p.
- Shojaii, R., Alirezaie, J., and Babyn, P.**, 2005, Automatic lung segmentation in CT images using watershed transform. *In IEEE International Conference on Image Processing 2005 (Vol. 2, pp. II-1270)*.
- Shyni, H. M., and Chitra, E.**, 2022, A comparative study of X-ray and CT images in COVID-19 detection using image processing and deep learning techniques. *Computer Methods and Programs in Biomedicine Update*, 2, 100054.
- Siddhartha, M., ve Santra, A.**, 2020, COVIDLite: A depth-wise separable deep neural network with white balance and CLAHE for detection of COVID-19. *arXiv preprint arXiv:2006.13873*.
- Skourt, B. A., El Hassani, A., ve Majda, A.**, 2018, Lung CT image segmentation using deep neural networks. *Procedia Computer Science*, 127, 109-113p.
- Sluimer, I., Schilham, A., Prokop, M., & Van Ginneken, B.**, 2006, Computer analysis of computed tomography scans of the lung: a survey. *IEEE transactions on medical imaging*, 25(4), 385-405p.

## KAYNAKLAR DİZİNİ (devam)

- Thakkar, Vignesh., Suman Tewary., and Chandan Chakraborty.,** 2018, Batch Normalization in Convolutional Neural Networks—A comparative study with CIFAR-10 data. *2018 fifth international conference on emerging applications of information technology (EAIT)*, IEEE.
- Toğaçar, M., Ergen, B., ve Sertkaya, M. E.,** 2019, Zatürre Hastalığının Derin Öğrenme Modeli ile Tespiti. *Firat University Journal of Engineering*, 31.
- Tuba, A. D. A. R., Elif KILIÇ DELİCE.,** *A Literature Review On The Use Of Machine Learning Algorithms In Health.*
- Türkdamar, M. U., Taşyürek, M., ve Öztürk, C.,** 2022, X-Ray Filmlerinden Transfer Öğrenmeli Faster R-CNN Derin Öğrenme ile Zatürre Tespiti . *IV. International Turkish World Congress on Science and Engineering* 61-71p. Niğde, Turkey
- Uçkuner, M., ve Hamza, E. R. O. L.,** 2021, COVID-19 veri seti kullanarak ön-eğitilmiş modellerin sınıflandırma performanslarının karşılaştırılması. *Bilgisayar Bilimleri ve Teknolojileri Dergisi*, 2(2), 43-50p.
- Xingyi, Yang., et al.,** 2020, Covid-ct-dataset: a ct image dataset about covid-19. *arXiv preprint arXiv:2003.13865.*
- Yang, Lin., and Dimas Lima.,** 2021, Covid-19 Recognition by Chest CT and Deep Learning." *EAI Endorsed Transactions on e-Learning* 7.23, e3-e3.
- Yang, Yuan., et al.,** 2021, A comparative analysis of eleven neural networks architectures for small datasets of lung images of COVID-19 patients toward improved clinical decisions." *Computers in Biology and Medicine* 139: 104887.
- Ying, Xue.,** 2019, "An overview of overfitting and its solutions." *Journal of physics: Conference series*. Vol. 1168. IOP Publishing.
- Zhang, Chao., et al.,** 2019, Toward an expert level of lung cancer detection and classification using a deep convolutional neural network. *The oncologist* 24.9: 1159-1165p.
- Zheng, B., Leader III, J. K., Maitz, G. S., Chapman, B. E., Fuhrman, C. R., Rogers, R. M., ... ve Gur, D.,** 2003, A simple method for automated lung segmentation in X-ray CT images. *Medical Imaging 2003: Image Processing*. Vol. 5032. *International Society for Optics and Photonics.*

**KAYNAKLAR DİZİNİ (devam)**

**Zhuang, F., Qi, Z., Duan, K., Xi, D., Zhu, Y., Zhu, H., ... and He, Q.,** 2020, A comprehensive survey on transfer learning. *Proceedings of the IEEE*, 109(1), 43-76s.

**Zhu, S., Xia, X., Zhang, Q., and Belloulata., K,** 2007, An image segmentation algorithm in image processing based on threshold segmentation. In *2007 third international IEEE conference on signal-image technologies and internet-based system*. IEEE. 673-678p.



**TEŐEKKÜR**

Bu alıŐma sűresince bana gerekli tűm desteęi saęlayan, tűm sűre boyunca alıŐmalarıma ve araŐtırmalarımı yol gűsteren, deęerli bilgi birikimleri ile ıŐık tutan ok deęerli tez danıŐman hocam Sayın Prof. Dr. Nakife Yasemin TOPALOęLU'na ve ok deęerli ikinci danıŐman hocam Sayın Dr. Őgr. Őyesi Ahmet EGESoy'a sonsuz teŐekkűrlerimi ve saygılarımı sunarım.

12 / 11 / 2023

Gűlce LEYLEK

## ÖZGEÇMİŞ

Gülce LEYLEK, lise öğrenimini Narlıdere Cahide Ahmet Dalyanoğlu Anadolu Lisesi'nde sayısal bölümünde tamamlamıştır. Lisans eğitimini Manisa Celal Bayar Üniversitesi Computer Engineering bölümünde %100 İngilizce olarak tamamlamıştır. 2019 yılında Anadolu Üniversitesi İkinci Üniversite programı kapsamında Web Tasarımı ve Kodlama öğrenimine başlamış olup, 2023 yılında bu bölümü tamamlamıştır. 2020 yılında ise Ege Üniversitesi'nde Bilgisayar Mühendisliği Yüksek Lisans programına başvurarak, yüksek lisans eğitimine başlamıştır. Ana dili Türkçe olmakla birlikte, İngilizce dilinde Upper-Intermediate seviyesinde bulunmaktadır. Buna ek olarak lise eğitimi sırasında Almanca eğitimi de almıştır.

Programlama alanında C ile eğitimine başlamış olup bugüne kadar JAVA, C#, HTML, CSS, Matlab, Kali Linux, Python, Node.js, Oracle SQL, PHP ve Angular ile çalışmalarda bulunmuştur. Geliştirme ortamlarından ise Eclipse, Visual Studio, Unity, Android Studio, Postman, Jupyter, Spyder ortamlarında çalışmalar sağlamıştır. Lisans eğitiminde iki adet staj yapmıştır. Donanım stajını Devlet Hava Meydanları İşletmesi'nde 2017 Temmuz ve ağustos ayları arasında tamamlamıştır. Bu stajı sırasında Sivil Havacılık Güvenliği, Güvenlik Bilinci eğitimine katılımı sağlamış olup katılım sertifikası bulunmaktadır. Yazılım stajını ise İzmir Büyükşehir Belediyesi Bilgi İşlem Departmanı'nda Yazılım Geliştirme Servisi'nde tamamlamıştır. Bu yazılım stajı sırasında C# ve Microsoft Access Database ile bir masaüstü uygulaması geliştirmiştir. Lisans eğitimi sırasında katılım sağladığı diğer etkinliklerden ise; SoftTech Ar-Ge Merkezi "Teoriden Pratiğe Yazılım Teknolojileri ve Süreçleri" katılım sertifikası ve Bilişimde Kariyer Zirvesi katılım sertifikaları bulunmaktadır.

Günümüzde, 2021 yılından beri Kentkart'ta Sistem Mühendisliği Departmanı'nda Sistem Mühendisi pozisyonunda çalışma hayatını sürdürmektedir.