



**T.C.**  
**NECMETTİN ERBAKAN**  
**ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**



**COVID-19 TANILI BİLGİSAYARLI  
TOMOGRAFİ GÖRÜNTÜLERİNDE  
AKCİĞER VE PNÖMONİ BÖLGELERİNİN  
FARKLI SENARYOLARDA SEMANTİK  
SEGMENTASYONU**

**Hüseyin Emre ALEMDAROĞLU**

**YÜKSEK LİSANS TEZİ**

**Biyomedikal Mühendisliği Anabilim Dalı**

**Temmuz-2022**  
**KONYA**  
**Her Hakkı Saklıdır**

## ÖZET

### YÜKSEK LİSANS TEZİ

# COVID-19 TANILI BİLGİSAYARLI TOMOGRAFİ GÖRÜNTÜLERİNDE AKCİĞER VE PNÖMONİ BÖLGELERİNİN FARKLI SENARYOLARDA SEMANTİK SEGMENTASYONU

Hüseyin Emre ALEMDAROĞLU

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü  
Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Muhammet Üsame ÖZİÇ

2022, 102 Sayfa

Jüri

Dr. Öğr. Üyesi Muhammet Üsame ÖZİÇ

Dr. Öğr. Üyesi Hasan KOYUNCU

Dr. Öğr. Üyesi Sabri ALTUNKAYA

Çin'in Vuhan kentinde ortaya çıkan COVID-19 hastalığı tüm dünyaya hızlı bir şekilde yayılarak, ülkeleri sosyolojik ve ekonomik olarak ciddi anlamda etkilemiştir. Hastalık tat ve koku duyusunun kaybedilmesi, kuru öksürük ve akciğerlerde pnömoni ile kendini göstermektedir. Hastalığın teşhisi burundan alınan sürüntünün PCR testine verilmesi ve bilgisayarlı tomografi görüntülerinin incelenmesi ile gerçekleştirilmektedir. Ancak PCR testlerinin yanlış negatif değerlerinin çok fazla olması teşhis sürecini yanlış yönlendirebilmektedir. Bilgisayarlı tomografi görüntülerinde buzlanma şeklinde pnömonin görülmesi teşhis sürecini hızlandırmaktadır. Bu tez çalışmasında, ZENODO veri seti kullanılarak COVID-19 bilgisayarlı tomografi görüntülerinde farklı senaryolarda semantik segmentasyon işlemi gerçekleştirilmiştir. Veri setinde bulunan maske görüntülerinde ön işlemler gerçekleştirilerek sekiz farklı senaryo için akciğer ve pnömoni bölgelerinin maskeleri türetilmiştir. DeepLabV3+ semantik segmentasyon modeline ResNet-18, ResNet-50, MobileNet-v2, Xception, Inception-ResNet-v2 entegre edilerek sekiz farklı maske için kırk deneme yapılmıştır. Sonuçlar doğruluk, jaccard (IoU), küresel doğruluk, ortalama doğruluk, ortalama IoU, ağırlıklı IoU, ortalama BF(F1) puanı performans kriterleri ile değerlendirilmiştir. Çalışma sonucunda akciğer ve pnömoni bölgelerinin farklı kombinasyonlarda oluşan maskelerinin semantik segmentasyona etkisi tartışılmıştır. Bilgisayarlı tomografi görüntülerinde akciğer ve pnömoni bölgelerinin DeepLabV3+ ile semantik segmentasyonun etkili ve başarılı sonuçlar verdiği gözlemlenmiştir.

**Anahtar Kelimeler:** COVID19, DeepLabV3+, Derin öğrenme, Pnömoni, Semantik segmentasyon, Yapay zeka.

## ABSTRACT

### MS THESIS

# SEMANTIC SEGMENTATION OF LUNG AND PNEUMONIA REGIONS IN DIFFERENT SCENARIOS ON COVID-19 DIAGNOSED COMPUTER TOMOGRAPHIC IMAGES

Hüseyin Emre ALEMDAROĞLU

THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF  
NECMETTİN ERBAKAN UNIVERSITY  
THE DEGREE OF MASTER OF SCIENCE  
IN BIOMEDICAL ENGINEERING

Advisor: Assist. Prof. Dr. Muhammet Üsame ÖZİÇ

2022, 102 Pages

Jury

Assist. Prof. Dr. Muhammet Üsame ÖZİÇ

Assist. Prof. Dr. Hasan KOYUNCU

Assist. Prof. Dr. Sabri ALTUNKAYA

The COVID-19 disease, which emerged in Wuhan, China, spread rapidly all over the world and seriously affected countries sociologically and economically. The disease manifests itself with loss of sense of taste and smell, dry cough and pneumonia in the lungs. The diagnosis of the disease is made by giving the swab taken from the nose to the PCR test and examining the computed tomography images. However, too many false negative values of PCR tests can mislead the diagnostic process. Observation of pneumonia in the form of icing on computed tomography images accelerates the diagnostic process. In this thesis, semantic segmentation was performed in different scenarios on COVID-19 computed tomography images using the ZENODO data set. Masks of the lung and pneumonia regions were derived for eight different scenarios by preprocessing the mask images in the dataset. Forty attempts were made for eight different masks by integrating ResNet-18, ResNet-50, MobileNet-v2, Xception, Inception-ResNet-v2 into the DeepLabV3+ semantic segmentation model. The results were evaluated with the performance criteria of accuracy, jaccard (IoU), global accuracy, average accuracy, average IoU, weighted IoU, average BF(F1) score. As a result of the study, the effect of masks formed in different combinations of lung and pneumonia regions on semantic segmentation is discussed. It has been observed that semantic segmentation of lung and pneumonia regions with DeepLabV3+ gives effective and successful results in computed tomography images.

**Keywords:** Artificial intelligence, COVID-19, Deep learning, DeepLabv3+, Pneumonia, Semantic segmentation

## ÖNSÖZ

Bu tez çalışmasında verdiği eğitim, yönlendirme ve öncü yaklaşımlarıyla desteğini esirgemeyen danışmanım Dr. Öğretim Üyesi Muhammet Üsâme Öziç'e ve desteklerini hiç esirgemeyen kıymetli annem, babam ve kardeşime teşekkürlerimi iletirim.

Hüseyin Emre ALEMDAROĞLU  
KONYA-2022

# İÇİNDEKİLER

<b>ÖZET .....</b>	<b>v</b>
<b>ABSTRACT.....</b>	<b>vi</b>
<b>ÖNSÖZ .....</b>	<b>vii</b>
<b>İÇİNDEKİLER.....</b>	<b>viii</b>
<b>SİMGELER VE KISALTMALAR.....</b>	<b>x</b>
<b>ŞEKİLLER LİSTESİ .....</b>	<b>xi</b>
<b>ÇİZELGELER LİSTESİ .....</b>	<b>xv</b>
<b>1. GİRİŞ.....</b>	<b>1</b>
1.1. Tezin Amacı ve Önemi .....	2
1.2. Tezin Organizasyonu .....	3
<b>2. KAYNAK ARAŞTIRMASI.....</b>	<b>4</b>
<b>3. MATERYAL VE YÖNTEM.....</b>	<b>12</b>
3.1. COVID-19 .....	12
3.2. Bilgisayarlı Tomografi.....	14
3.3. Veri Kümesi .....	16
3.4. Ön İşleme.....	18
3.5. Veri Arttırma.....	22
3.6. DeepLabV3+ ile Semantik Segmentasyon .....	23
3.7. Sınıfların Ağırlıklandırılması.....	28
3.8. Hiper Parametreler .....	28
3.9. Performans Kriterleri .....	30
<b>4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....</b>	<b>33</b>
4.1. Eşit Etiket Değerli Akciğerlerin Semantik Segmentasyon Sonuçları.....	33
4.2. İki Farklı Etiket Değerli Akciğerlerin Semantik Segmentasyon Sonuçları.....	40
4.3. Eşit Etiket Değerli Pnömoni Semantik Segmentasyon Sonuçları .....	48
4.4. Farklı Etiket Değerli Pnömoni Semantik Segmentasyon Sonuçları .....	55
4.5. Eşit Etiket Değerli Akciğer ve Pnömoni Semantik Segmentasyon Sonuçları.....	63
4.6. Eşit Etiket Akciğer ve Farklı Etiket Pnömoni Semantik Segmentasyon Sonuçları .....	70
4.7. Farklı Etiket Akciğer ve Eşit Etiket Pnömoni Semantik Segmentasyon Sonuçları .....	78
4.8. Farklı Etiket Akciğer ve Farklı Etiket Pnömoni Semantik Segmentasyon Sonuçları .....	86

<b>5. SONUÇLAR VE ÖNERİLER .....</b>	<b>95</b>
5.1 Sonuçlar .....	95
5.2 Öneriler .....	98
<b>6. KAYNAKLAR .....</b>	<b>100</b>

## SİMGELER VE KISALTMALAR

### Simgeler

### Kısaltmalar

BT	: Bilgisayarlı Tomografi
CNN	: Convolutional Neural Networks
COVID-19	: Yeni Koronavirüs Hastalığı
CXR	: Chest X-Ray
DAM	: Decoder Attention Module
D2A	: Decoder Two-fold Attention
ESA	: Evrimsel Sinir Ağı
GAM	: Gate Attention Modüle
GPU	: Graphics Processing Unit
Grad-CAM	: Gradient Weighted Class Activation Mapping
IoU	: Intersection over Union
LIME	: Yerel yorumlanabilir model-agnostik açıklamalar
MATLAB	: Matrix Laboratory
MSD	: Küçük hücreli akciğer kanseri
NIFTI	: Neuroimaging Informatics Technology Initiative
NSCLC	: Non Small Cell Lung Cancer
PNG	: Portable Network Graphics
PPV	: Pozitive Predicted Value
RAB	: Artık dikkat bloğu
RAM	: Random Access Memory
ROC	: Receiver Operating Characteristic
RLP	: Regional Level Precision
RLR	: Regional Level Recall
RT-PCR	: Polymerase Chain Reaction
VA	: Volume Accuracy
2B	: İki Boyutlu
3B	: Üç Boyutlu

## ŞEKİLLER LİSTESİ

<b>Şekil 3.1.</b> Veri setinde kullanılan COVID-19 pnömonili bir hastanın akciğer BT görüntüsünden bir kesit (Yang, 2020) .....	12
<b>Şekil 3.2.</b> Bilgisayarlı Tomografi cihazı (Alkan, 2018) .....	14
<b>Şekil 3.3.</b> Helikal BT çalışma prensibi (MEB, 2011).....	15
<b>Şekil 3.4.</b> Hounsfield skalası (MEB, 2011) .....	15
<b>Şekil 3.5.</b> Veri kümesinin alındığı zenodo web sayfasının ekran görüntüsü (Ma Jun, 2020) .....	16
<b>Şekil 3.6.</b> MRIcro programı kullanılarak açılan NIfTI formatındaki 3B BT görüntüsü	17
<b>Şekil 3.7.</b> (a) Akciğer bölgelerinin eşit piksel etiket değerine sahip olduğu maske görüntüsünden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü .....	19
<b>Şekil 3.8.</b> (a) Akciğer bölgelerinin farklı piksel etiket değerine sahip maske görüntüsünden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü .....	20
<b>Şekil 3.9.</b> (a) Pnömoni bölgelerinin eşit piksel etiket değerine sahip maske görüntüsünden bir kesit, (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü .....	20
<b>Şekil 3.10.</b> (a) Pnömoni bölgelerinin farklı piksel etiket değerine sahip maske görüntüsünden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü .....	20
<b>Şekil 3.11.</b> (a) Akciğer ve pnömoni bölgelerinin eşit piksel etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü.....	21
<b>Şekil 3.12.</b> (a) Akciğer bölgelerinin eşit pnömoni bölgelerinin farklı piksel etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü .....	21
<b>Şekil 3.13.</b> (a) Akciğerler bölgelerinin farklı pnömoni bölgelerinin eşit piksel etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü .....	21
<b>Şekil 3.14.</b> (a) Akciğerler ve pnömoni bölgelerinin farklı piksel etiket değerlerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü .....	22
<b>Şekil 3.15.</b> Bir sokak görüntüsü ve görüntüde bulunan yol (road), kaldırım (sidewalk), bina (building), çit (fence), direk (pole), bitki (vegetation), araç (vehicle) ve etiketsiz (unlabel) bölgelerinin anlamsal bölütleme sonucu elde edilen renk haritası (Jeong ve ark., 2018).....	24
<b>Şekil 3.16.</b> Bisiklet süren üç kişinin bisiklet (bicycle), insan (person) ve arka plan (background) sınıfları olarak semantik segmentasyonu (Jordan, 2018).....	24
<b>Şekil 3.17.</b> DeepLabv3+ mimarisi .....	25
<b>Şekil 3.18.</b> Kodlayıcı ve kod çözücü yapısı.....	25
<b>Şekil 3.19.</b> Deeplabv3+ modeline ResNet-18'in entegrasyonu için MATLAB kod bloğu .....	27
<b>Şekil 3.20.</b> Deeplabv3+ modeline ResNet-50'nin entegrasyonu için MATLAB kod bloğu .....	27
<b>Şekil 3.21.</b> Deeplabv3+ modeline MobileNet-v2'in entegrasyonu için MATLAB kod bloğu .....	27
<b>Şekil 3.22.</b> Deeplabv3+ modeline Xception'in entegrasyonu için MATLAB kod bloğu .....	27

<b>Şekil 3.23.</b> Deeplabv3+ modeline Inception-ResNet-v2'in entegrasyonu için MATLAB kod bloğu .....	27
<b>Şekil 3.24.</b> Sonuçların kesin referans ile örtüşme durumu .....	30
<b>Şekil 4.1.</b> Sınıfların piksel frekans grafiği .....	33
<b>Şekil 4.2.</b> ResNet-18 için eğitim doğruluk ve kayıp grafiği .....	34
<b>Şekil 4.3.</b> ResNet-50 için eğitim doğruluk ve kayıp grafiği .....	35
<b>Şekil 4.4.</b> MobileNet-v2 için eğitim doğruluk ve kayıp grafiği .....	35
<b>Şekil 4.5.</b> Xception için eğitim doğruluk ve kayıp fonksiyonu .....	36
<b>Şekil 4.6.</b> Inception-ResNet-v2 için eğitim doğruluk ve kayıp fonksiyonu .....	36
<b>Şekil 4.7.</b> (a) Akciğerlerin eşit etiket değerine sahip olduğu 60 numaralı maske (b) Orijinal görüntü ile maskenin üst üste çakıştırılması ile oluşan görüntü.....	38
<b>Şekil 4.8.</b> ResNet-18 için semantik segmentasyon.....	38
<b>Şekil 4.9.</b> ResNet-50 için semantik segmentasyon.....	38
<b>Şekil 4.10.</b> MobileNet-v2 için semantik segmentasyon .....	39
<b>Şekil 4.11.</b> Xception için semantik segmentasyon .....	39
<b>Şekil 4.12.</b> InceptionResNet-v2 için semantik segmentasyon.....	39
<b>Şekil 4.13.</b> Sınıfların piksel frekans grafiği.....	41
<b>Şekil 4.14.</b> ResNet-18 için eğitim doğruluk ve kayıp grafiği.....	42
<b>Şekil 4.15.</b> ResNet-50 için eğitim doğruluk ve kayıp grafiği.....	42
<b>Şekil 4.16.</b> MobileNet-v2 için eğitim doğruluk ve kayıp grafiği .....	43
<b>Şekil 4.17.</b> Xception için eğitim doğruluk ve kayıp grafiği .....	43
<b>Şekil 4.18.</b> Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği .....	44
<b>Şekil 4.19.</b> (a) Akciğerlerin farklı etiket değerine sahip olduğu 60 numaralı maske (b) Orijinal görüntü ile maskenin üst üste çakıştırılması ile oluşan görüntü.....	45
<b>Şekil 4.20.</b> ResNet-18 için semantik segmentasyon.....	46
<b>Şekil 4.21.</b> ResNet-50 için semantik segmentasyon işlemi .....	46
<b>Şekil 4.22.</b> MobileNet-v2 için semantik segmentasyon işlemi .....	46
<b>Şekil 4.23.</b> Xception için semantik segmentasyon .....	47
<b>Şekil 4.24.</b> Inception-ResNet-v2 için semantik segmentasyon .....	47
<b>Şekil 4.25.</b> Sınıfların piksel frekans grafiği.....	48
<b>Şekil 4.26.</b> ResNet-18 için eğitim doğruluk ve kayıp grafiği.....	49
<b>Şekil 4.27.</b> ResNet-50 için eğitim doğruluk ve kayıp grafiği.....	50
<b>Şekil 4.28.</b> MobileNet-v2 için eğitim doğruluk ve kayıp grafiği .....	50
<b>Şekil 4.29.</b> Xception için eğitim doğruluk ve kayıp grafiği .....	51
<b>Şekil 4.30.</b> Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği .....	51
<b>Şekil 4.31.</b> (a) Pnömoninin eşit etiket değerine sahip olduğu 60 numaralı maske (b) Orijinal görüntü ile maskenin üst üste çakıştırılması ile oluşan görüntü.....	53
<b>Şekil 4.32.</b> ResNet-18 için semantik segmentasyon.....	53
<b>Şekil 4.33.</b> ResNet-50 için semantik segmentasyon.....	53
<b>Şekil 4.34.</b> MobileNet-v2 için semantik segmentasyon .....	54
<b>Şekil 4.35.</b> Xception için semantik segmentasyon .....	54
<b>Şekil 4.36.</b> Inception-ResNet-v2 için semantik segmentasyon .....	54
<b>Şekil 4.37.</b> Sınıfların piksel frekans grafiği.....	56
<b>Şekil 4.38.</b> ResNet-18 için eğitim doğruluk ve kayıp grafiği.....	57
<b>Şekil 4.39.</b> ResNet-50 için eğitim doğruluk ve kayıp grafiği.....	57
<b>Şekil 4.40.</b> MobileNet-v2 için eğitim doğruluk ve kayıp grafiği .....	58
<b>Şekil 4.41.</b> Xception için eğitim doğruluk ve kayıp grafiği .....	58
<b>Şekil 4.42.</b> Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği .....	59
<b>Şekil 4.43.</b> (a) Pnömoni bölgesi farklı etiket değerine sahip maske görüntüsünden bir kesit (b) Orijinal görüntü üzerine maskenin üst üste çakıştırılması ile oluşan görüntü..	60

Şekil 4.44. ResNet-18 için semantik segmentasyon.....	61
Şekil 4.45. ResNet-50 için semantik segmentasyon.....	61
Şekil 4.46. MobileNet-v2 için semantik segmentasyon .....	61
Şekil 4.47. Xception için semantik segmentasyon .....	62
Şekil 4.48. Inception-ResNet-v2 için semantik segmentasyon .....	62
Şekil 4.49. Sınıfların piksel frekans grafiği.....	63
Şekil 4.50. ResNet-18 için eğitim doğruluk ve kayıp grafiği.....	64
Şekil 4.51. ResNet-50 için eğitim doğruluk ve kayıp grafiği.....	65
Şekil 4.52. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği .....	65
Şekil 4.53. Xception için eğitim doğruluk ve kayıp grafiği .....	66
Şekil 4.54. Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği .....	66
Şekil 4.55. (a) Akciğerlerin ve pnömoni bölgelerinin eşit etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü üzerine maskenin üst üste çakıştırılması ile oluşan görüntü .....	68
Şekil 4.56. ResNet-18 için semantik segmentasyon.....	68
Şekil 4.57. ResNet-50 için semantik segmentasyon.....	68
Şekil 4.58. MobileNet-v2 için semantik segmentasyon .....	69
Şekil 4.59. Xception için semantik segmentasyon .....	69
Şekil 4.60. Inception-ResNet-v2 için semantik segmentasyon .....	69
Şekil 4.61. Sınıfların piksel frekans grafiği.....	71
Şekil 4.62. ResNet-18 için eğitim doğruluk ve kayıp grafiği.....	72
Şekil 4.63. ResNet-50 için eğitim doğruluk ve kayıp grafiği.....	72
Şekil 4.64. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği .....	73
Şekil 4.65. Xception için eğitim doğruluk ve kayıp grafiği .....	73
Şekil 4.66. Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği .....	74
Şekil 4.67. (a) Akciğerin eşit pnömoni bölgelerinin farklı etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü üzerine maskenin getirilmesi ile oluşan görüntü.....	75
Şekil 4.68. ResNet-18 için semantik segmentasyon.....	76
Şekil 4.69. ResNet-50 için semantik segmentasyon.....	76
Şekil 4.70. MobileNet-v2 için semantik segmentasyon .....	76
Şekil 4.71. Xception için semantik segmentasyon .....	77
Şekil 4.72. Inception-ResNet-v2 için semantik segmentasyon .....	77
Şekil 4.73. Sınıfların piksel frekans grafiği.....	79
Şekil 4.74. ResNet-18 için eğitim doğruluk ve kayıp grafiği.....	80
Şekil 4.75. ResNet-50 için eğitim doğruluk ve kayıp grafiği.....	80
Şekil 4.76. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği .....	81
Şekil 4.77. Xception için eğitim doğruluk ve kayıp grafiği .....	81
Şekil 4.78. Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği .....	82
Şekil 4.79. (a) Akciğerlerin farklı pnömoni bölgelerinin eşit etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü üzerine maskenin getirilmesi ile oluşan görüntü .....	83
Şekil 4.80. ResNet-18 için semantik segmentasyon.....	84
Şekil 4.81. ResNet-50 için semantik segmentasyon.....	84
Şekil 4.82. MobileNet-v2 için semantik segmentasyon .....	84
Şekil 4.83. Xception için semantik segmentasyon .....	85
Şekil 4.84. Inception-ResNet-v2 için semantik segmentasyon .....	85
Şekil 4.85. Sınıfların piksel frekans grafiği.....	87
Şekil 4.86. ResNet-18 için eğitim doğruluk ve kayıp grafiği.....	88
Şekil 4.87. ResNet-50 için eğitim doğruluk ve kayıp grafiği.....	88

<b>Şekil 4.88.</b> MobileNet-v2 için eğitim doğruluk ve kayıp grafiği .....	89
<b>Şekil 4.89.</b> Xception için eğitim doğruluk ve kayıp grafiği .....	89
<b>Şekil 4.90.</b> Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği .....	90
<b>Şekil 4.91.</b> (a) Akciğerlerin ve pnömoni bölgelerinin farklı etiket değerlerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü üzerine maskenin getirilmesi ile oluşan görüntü .....	92
<b>Şekil 4.92.</b> ResNet-18 için semantik segmentasyon.....	92
<b>Şekil 4.93.</b> ResNet-50 için semantik segmentasyon.....	92
<b>Şekil 4.94.</b> MobileNet-v2 için semantik segmentasyon .....	93
<b>Şekil 4.95.</b> Xception için semantik segmentasyon .....	93
<b>Şekil 4.96.</b> Inception-ResNet-v2 için semantik segmentasyon .....	93

## ÇİZELGELER LİSTESİ

<b>Çizelge 3.1.</b> 3B BT görüntülerinde kullanılan kesit aralıkları.....	18
<b>Çizelge 3.2.</b> Maske gruplarının sınıf etiket değerleri .....	19
<b>Çizelge 3.3.</b> Derin öğrenme modellerinde eğitim için kullanılan hiper parametreler ....	29
<b>Çizelge 4.1.</b> Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları.....	33
<b>Çizelge 4.2.</b> Akciğerlerin eşit etiket değerine sahip olduğu segmentasyon sonuçları....	37
<b>Çizelge 4.3.</b> Akciğer ve arka plan sınıflarının ayrı şekilde segmentasyon işlem sonuçları .....	37
<b>Çizelge 4.4.</b> Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları.....	40
<b>Çizelge 4.5.</b> Akciğerlerin farklı etiket değerine sahip olduğu segmentasyon sonuçları.	44
<b>Çizelge 4.6.</b> Sağ akciğer, sol akciğer ve arka plan sınıflarının segmentasyon sonuçları	45
<b>Çizelge 4.7.</b> Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları.....	48
<b>Çizelge 4.8.</b> Pnömonili bölgenin eşit etiket değerine sahip olduğu segmentasyon sonuçları.....	52
<b>Çizelge 4.9.</b> Pnömonili bölge ve arka plan sınıflarının segmentasyon sonuçları .....	52
<b>Çizelge 4.10.</b> Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları.....	55
<b>Çizelge 4.11.</b> Pnömonili bölgelerin farklı etiket değerine sahip olduğu segmentasyon sonuçları.....	59
<b>Çizelge 4.12.</b> Sağ pnömoni, sol pnömoni ve arka plan gruplarının segmentasyon sonuçları.....	60
<b>Çizelge 4.13.</b> Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları.....	63
<b>Çizelge 4.14.</b> Akciğer ve pnömonili bölgelerin kendi içlerinde eşit etiket değerine sahip olduğu segmentasyon sonuçları .....	67
<b>Çizelge 4.15.</b> Akciğer, pnömoni ve arka plan gruplarının segmentasyon sonuçları .....	67
<b>Çizelge 4.16.</b> Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları.....	71
<b>Çizelge 4.17.</b> Akciğerin eşit ve pnömonili bölgelerin farklı etiket değerine sahip olduğu segmentasyon sonuçları .....	74
<b>Çizelge 4.18.</b> Akciğer, sağ pnömoni, sol pnömoni ve arka plan gruplarının segmentasyon sonuçları .....	75
<b>Çizelge 4.19.</b> Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları.....	78
<b>Çizelge 4.20.</b> Akciğerlerin farklı ve pnömonili bölgelerin eşit etiket değerine sahip olduğu segmentasyon işlemi sonuçları .....	82
<b>Çizelge 4.21.</b> Sağ akciğer, sol akciğer, pnömoni ve arka plan sınıflarının segmentasyon sonuçları.....	83
<b>Çizelge 4.22.</b> Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları.....	86
<b>Çizelge 4.23.</b> Akciğer ve pnömonili bölgelerin kendi içlerinde farklı etiket değerine sahip olduğu segmentasyon sonuçları.....	90
<b>Çizelge 4.24.</b> Sağ akciğer, sol akciğer, sağ pnömoni, sol pnömoni ve arka plan gruplarının segmentasyon sonuçları .....	91
<b>Çizelge 5.1.</b> Tüm senaryolar için ResNet-50 modelinin ortalama performans sonuçları .....	95
<b>Çizelge 5.2.</b> Tüm senaryolar için ResNet-50 modelinin sınıflara göre performans sonuçları.....	96

## 1. GİRİŞ

2019 Aralık ayında Çin'in Vuhan eyaletinde halsizlik, öksürük, nefes darlığı ve ateş ile başlayan Yeni Koronavirüs Hastalığı (COVID-19) 2020 yılının başlarında salgın olarak tanımlanmıştır. Aynı ortamda bulunan bireylere solunum ile bulaşan hastalık tüm ülkelere hızlı bir şekilde yayılmıştır. Hem ülkemize hem dünya ülkelerine yayılan salgın sosyolojik olarak devletleri etkilemiş, birçok kişinin hayatını kaybetmesine sebep olmuştur. Yapılan istatistiksel çalışmalar sonucunda COVID-19 pnömonisi genellikle 60 yaş ve üstü hastaları, kronik rahatsızlığı bulunan hastaları, kalp hastalığı bulunan hastaları, kronik solunum yolu hastalarını daha çok etkilemektedir. Vakaların %80'i hastalığı hafif koşullarda geçirmekte ve %20'si hastane koşullarında tedavi edilmektedir. COVID-19 pnömonisi sağlıklı çocuklar ve gençlerde ise hastalık nadir olarak gözükmemektedir (Sağlık Bakanlığı, 2022). COVID-19 salgını sosyal, ekonomik, kültürel, siyasi ve askeriye gibi birçok alanda ülkemizde radikal kararların alınmasına neden olmuştur. Türkiye'de ilk, orta ve lise düzeyinde eğitimlere ara verilmiş, üniversitelerde ise uzaktan eğitime geçilmiştir. Cami ve mescitlerde cemaatla namaz kılınmasına ara verilmiş, tüm kafeler, restoranlar ve müzeler geçici süreliğine kapanmıştır (Vikipedi, 2022). COVID-19 pnömonisi tanısı için boğaz sürüntüsünde bakılan gerçek zamanlı polimeraz zincir reaksiyon (RT-PCR) testi kullanılmaktadır. Fakat testin yapılmasındaki yetersizlik, test sonuçlarının elde edilme süresinin uzayabilmesi ve hastalığın erken dönemde yalancı negatiflik gösterebilmesi gibi olumsuz durumlarla karşılaşmaktadır. Bu olumsuzluklardan dolayı tanı koyma ve hastalığın daha net takibi için radyolojik görüntüleme ve bu görüntüleme tekniklerinden özellikle bilgisayarlı tomografi (BT) radyografileri yoğun olarak kullanılmaktadır (Cömert ve Kiral, 2020). Görüntülerdeki pnömoni bölgeleri uzman radyologlar tarafından incelenerek bulunmaktadır.

Bu çalışmada, açık kaynak veri seti olan ZENODO (<https://zenodo.org/record/3757476#.Ys3BzXZBxPZ>) COVID-19 BT görüntülerinin DeepLabV3+ derin öğrenme algoritması ile farklı senaryolarda semantik segmentasyonu gerçekleştirilmiştir. Veri setinde NIfTI (Neuroimaging Informatics Technology Initiative) görüntü formatında üç boyutlu (3B) BT görüntüleri ve bu görüntülere ait uzman radyologlar tarafından etiketlenmiş 3B maskeler bulunmaktadır. BT kesitleri MRICro programı kullanılarak "\*.png" uzantılı resimler şeklinde kaydedilmiştir. Maske içerisindeki piksel dağılımlarının semantik segmentasyonda

kullanılması için görüntüler üzerinde bazı ön işlemler yapılmıştır. Böylece akciğerler ve akciğer üzerinde tutulum gösteren pnömoninin aynı veya farklı etiket değerlerine sahip olduğu sekiz farklı maske veri seti oluşturulmuştur. Bu işlemin amacı, derin öğrenme algoritmasının tek sınıflı ve çok sınıflı semantik segmentasyon sürecinde hedef maskelerinin türetilmesidir. COVID-19 için anlamlı olmayan kesitler çalışmadan çıkarılmıştır. BT görüntüler ve maskeler birbirine uyumlu olacak şekilde %60 eğitim, %20 validasyon, %20 test kümesi olarak rastgele bir şekilde bölünmüştür. ResNet-18, ResNet-50, MobileNet-v2, Xception, Inception-ResNet-v2 derin öğrenme algoritmaları DeepLabV3+ modeline entegre edilerek farklı hiper parametre değerleriyle eğitim işlemi gerçekleştirilmiştir. Sekiz farklı veri kümesi ve beş farklı derin öğrenme algoritması kullanılarak kırk farklı denemede semantik segmentasyon eğitimi gerçekleştirilmiştir. Modellerin performans kriterleri hesaplanarak sonuçların karşılaştırılması yapılmıştır. Sekiz farklı senaryo için en yüksek performans kriterleri elde edilen modeller belirlenmiş, sonuçlar literatürdeki mevcut çalışmalar ile karşılaştırılmıştır.

### **1.1. Tezin Amacı ve Önemi**

Teknolojik gelişmeler sonucunda günlük hayatın büyük bir kısmında yer almaya başlayan yapay zeka uygulamalarının sağlık alanında da daha efektif olarak kullanılması için dünya üzerinde bir çok çalışmalar yapılmaktadır. Özellikle salgın hastalıkların artması, hastalık tespitinin maliyet ve aşırı zaman alması bu konularda yapay zeka çalışmalarının önünü açmıştır. Hastanelerde toplanan görüntüler radyologlar tarafından manuel olarak yorumlanmaktadır. Radyolog sayısının az olması, hasta ve görüntü sayısının fazla olması görüntü analizlerini süre bakımından maliyetli olmasına neden olmaktadır. Derin öğrenme algoritmalarının medikal görüntü segmentasyonu ve sınıflandırılmasında yüksek doğruluk oranlarında kullanılabilmesi hastalık tanı ve tespit süreçlerini hızlandırabilecektir. Bu teknolojiler üzerinde dünyadaki araştırmacılar uygulamalar geliştirmekte olup, literatürde birçok çalışma bulunmaktadır.

Bu tez çalışmasında, COVID-19 tanılı BT görüntüleri kullanılarak akciğer ve pnömoni bölgelerinin DeeplabV3+ derin öğrenme modeli ile semantik segmentasyon performansları incelenmiştir.

## **1.2. Tezin Organizasyonu**

Bu tez çalışması altı kısımdan oluşmaktadır. Birinci kısımda COVID-19 ve tespiti ile ilgili bilgi verilmiş, tezin amacı, önemi ve organizasyonu anlatılmıştır. İkinci kısımda tez için literatür taraması ve benzer çalışmalar için kaynak araştırmasına yer verilmiştir. Üçüncü kısımda COVID-19, BT, tezde kullanılan veri seti, veri ön işleme, veri büyütme, derin öğrenme ağları, sınıfların ağırlıklandırılması, hiper parametreler, değerlendirme metrikleri tanıtılmış ve bilgiler verilmiştir. Dördüncü kısımda beş derin öğrenme algoritması için sekiz farklı senaryoda gerçekleştirilen toplam kırk segmentasyon işleminin sonuçları, tablo ve görsel olarak verilmiştir. Beşinci kısımda sonuçlar ve öneriler verilmiştir. Altıncı kısımda çalışma için kullanılan referanslar verilmiştir.

## 2. KAYNAK ARAŞTIRMASI

Ma ve ark. (2020), yapmış oldukları çalışmada 20 COVID-19'lu hastanın BT görüntüleri kullanılmıştır. Bu veriler %20 test ve %80 eğitim olarak seçilmiştir. Pnömonili bölge; MSD (Myelodisplastik) akciğer tümörü, NSCLC (non-small cell lung carcinoma), yapı segmentasyonu olmak üzere 3 bölüme ayrılmıştır. Derin öğrenme ağı olarak U-Net baz alınarak geliştirilen nnU-Net kullanılmıştır. Yapılan test ve eğitim işlemlerinin sonucunda elde edilen ortalama sonuçlar; sol akciğer %85.810, sağ akciğer %87.99, pnömoni %67.322; akciğer ve pnömonili bölge iç içe olan segmentasyon için; sol akciğer %65.42, sağ akciğer %75.316, pnömonili bölge %60.826 dice katsayısı performans değerleri elde edilmiştir. Bu sonuçlardan sonra derin öğrenme algoritmalarının geliştirilmesi gerektiğini belirtilmiş ve nnU-Net kullanımını önerilmiştir (Ma ve ark., 2020).

Zhou ve ark. (2021), yapmış oldukları çalışmada, İtalyan Tıp ve Girişimsel Radyoloji Derneği'nden almış oldukları iki veri setinde toplam 473 BT görüntü kullanılmıştır. Veri seti rastgele %80 eğitim ve %20 test olarak ayrılmıştır. Çıkan sonuçları değerlendirmek için dice skoru ve hausdorff mesafesi performans metrikleri kullanılmıştır. Derin öğrenme algoritması olarak U-Net temelli yazarların geliştirdikleri sinir ağı kullanılmıştır. En son Attention U-Net, U-Net(MICCAI'15), U-Net++ (TMI'19) ve geliştirdikleri sinir ağları karşılaştırılmıştır. Sırası ile Attention U-Net, U-Net (MICCAI'15), U-Net++ (TMI'19) ve geliştirdikleri derin öğrenme ağı ile yapılan test işlemleri dice katsayısı sonuçları %75.5, %82.5, %82.6, %83.1'dir. Hausdorff mesafesi sonuçları ise sırası ile 41.3 mm, 23.4 mm, 22.2 mm, 18.8 mm olarak elde edildiği belirtilmiştir. Elde edilen sonuçlara göre geliştirdikleri U-Net derin öğrenme ağının benzer sinir ağları ve orijinal U-Net ağından daha net sonuç verdiğini belirtilmiştir (Zhou ve ark., 2021).

Wang ve ark. (2021), yapmış oldukları çalışmada, Radiopedia tarafından açık kaynak olarak verilen 20 COVID-19 hastasının BT görüntülerini, Stanford Üniversitesi tarafından halka açık kaynak olarak verilen 63 adet 3B BT görüntüden oluşan MSD COVID-19 dışı akciğer tümörü veri setini ve NSCLC Plevral Efüzyon data setinde olan 50 hastanın nazofarenks kanseri ve akciğer kanseri olarak ayrılmış BT görüntüleri kullanılmıştır. Veriler %80 test, %20 eğitim olacak şekilde ayrılmıştır. Çalışmada kullanılmak için Pytorch da geliştirilmiş olan 3B U-Net ağı olan nnU-Net derin öğrenme algoritması seçilmiştir. Kayıp fonksiyonu olarak dice ve çapraz entropinin

toplama kullanılmıştır. Yapılan test işlemleri sonucunda önceden eğitilmiş ağlar ile geliştirilen hibrit ağ arasında yaklaşık olarak 0.03 bir gelişme kaydedildiği vurgulanmıştır. Derin öğrenme algoritmalarının genel olarak başarılı sonuçlar verdiği belirtilmiştir. Fakat derin öğrenme ağlarının COVID-19 olmayan modellerde daha başarılı segmentasyon işlemi gerçekleştirdiği de vurgulanmıştır (Wang ve ark., 2021).

Zhao ve ark. (2021), yapmış oldukları çalışmada, 3 bağımsız veri setinde toplam 29 BT ve 110 kesit görüntü kullanılmıştır. 29 BT görüntü üzerinde yapılan seçme işlemleri sonucunda 1645 görüntü elde edilmiştir. Model kodlayıcı olarak ImageNet-1K üzerinden geliştirilen ResNeXt-50 kullanılmıştır. Değerlendirme metrikleri olarak dice katsayısı, piksel hatası ve geri çağırma (recall) kullanılmıştır. Derin öğrenme ağı olarak ResNeXt-50 omurgasına sahip olarak geliştirilen D2A U-Net kullanılmıştır. Kullanılan D2A U-Net ağının; U-Net, Attention U-Net, U-Net++, FCN, DeepLabV3, D2A U-Net (VGG) derin öğrenme ağlarına özellikle küçük lezyonlar için daha net sonuç verdiği vurgulanmıştır. Yapılan test işlemlerinden sonra basamak basamak U-Net sonuçların nasıl ayrıldığını ve katmanlarda doğruluk oranlarının nasıl değiştiği verilmiştir. Doğruluk oranı en yüksek olan basamak en son basamak olan U-Net+ RAB+ GAM+ PB dice katsayısı 0.7298, piksel hatası olarak 0.0311 ve geri çağırma sonucu olarak 0.7071 olduğu belirtilmiştir. Sonuç olarak ise D2A U-Net ağının benzer ağlara göre daha iyi sonuç verdiği vurgulanmıştır (Zhao ve ark., 2021b).

Khalifa ve ark. (2021), yapmış oldukları çalışmada, veri seti olarak iki farklı kaynaktan 20 COVID-19 hastasının BT görüntüleri kullanılmıştır. 3520 görüntüden oluşan veri seti %70 eğitim ve %30 test olmak üzere bölünmüştür. Önerilen görüntü işleme mimarisi ise üç aşamadan oluşmaktadır. Sırası ile ön işleme, eğitim ve test basamaklarıdır. Semantik segmentasyon mimarisi ise iki aşamadan oluşmaktadır. Her biri 9 evrişim ağı, ReLU katmanı ve maksimum havuzlamaya sahip üç katmanlı kodlayıcı giriş bloğu olarak tercih edilmiştir. Tam tersi olacak şekilde her biri 16 ters evrişim katmanı, yukarı örnekleme katmanına sahip olan üç katmanlı ve en son çıkışında ise SoftMax kullanılan bir kod çözücü çıkış bloğu olarak kullanılmıştır. Yapılan test işlemi için kaynakları DS1, DS2 olarak ayırmışlar ve en sonunda birleştirilmiş kaynak olan kısımda DS3 olarak tanımlanmıştır. Performans değerlendirme metriği olarak; doğruluk (Küresel doğruluk, Ortalama doğruluk), duyarlılık, özgüllük, kesinlik, F1Score, ortalama IoU, ağırlıklı IoU, ortalama BF puanı kullanılmıştır. DS3 birleştirilen data seti için sonuçlar; Küresel doğruluk 0.9930, Ortalama doğruluk 0.9717, kesinlik 0.9932, duyarlılık 0.9499, özgüllük 0.9499, F1score

0.9711, ağırlıklı IoU 0.9886, ortalama IoU 0.7990, ortalama BF puanı 0.8746 olarak elde edildiği belirtilmiştir. Elde edilen sonuçlardan yola çıkarak segmentasyon işleminde transfer öğreniminin bu ve benzeri çalışmalarda kullanılabileceği çıkarımında bulunulmuştur. Ayrıca daha fazla katmana sahip modeller oluşturulup değerlendirilmesi gerektiği de vurgulanmıştır (Khalifa ve ark., 2021).

Polat ve ark. (2022), yapmış oldukları çalışmada, İtalyan Tıbbi ve Girişimsel Radyoloji Derneği'nin sağladığı 40'dan fazla hastadan alınan 100 BT görüntü kullanılmıştır. Görüntüler %60 eğitim, %20 doğrulama, %20 test olarak bölünmüştür. Bölütleme işlemi için derin öğrenme algoritması olan DeepLabV3+ tercih edilmiştir. DeepLabV3+ yeniden tasarlanmış bir evrişimsel sinir ağı (ESA) modelidir. Üç farklı segmentasyon işlemi uygulanmıştır; akciğer (enfekte ve enfekte olmayan) ve arka plan; akciğer (enfekte olmayan), COVID ve arka plan; her lezyon tipinin (COVID, konsolidasyon ve plevral efüzyon) ayrı bir sınıf olarak değerlendirildiği segmentasyon işlemi uygulanmıştır. Model performansını ölçmek için dice, birleşim üzerinden kesişim (IoU), özgüllük, duyarlılık ve beş katlı çapraz doğrulama işlemi kullanılmıştır. Akciğer ve arka plan segmentasyonu için IoU katsayısı değeri akciğer 0.987 ve arka plan 0.979 olarak elde edilmiştir. Akciğer, COVID ve arka plan segmentasyonu için IoU katsayısı değeri akciğer için 0.789, COVID için 0.548 ve arka plan için 0.972 olarak elde edilmiştir. Her lezyon türünün ayrı ayrı sınıflandırıldığı segmentasyon işlemi için IoU katsayısı değeri akciğer için 0.789, COVID için 0.429, konsolidasyon için 0.345, plevral efüzyon için 0.057 ve arka plan için 0.972 olarak bulunmuştur. Yapılan test işlemlerinden sonra sonuç olarak önerilen yöntemin güçlü performansa ve büyük potansiyele sahip olduğu ve DeepLabV3+'ın bazı modifikasyonlarla daha da geliştirilebileceği vurgulanmıştır (Polat, 2022a).

Khan ve ark. (2020), yapmış oldukları çalışmada, akciğer BT görüntülerinde COVID-19'un tanımlanabilmesi için iki aşamalı derin evrişimsel sinir ağları tabanlı bir çerçeve önerilmiştir. İlk aşamada iki seviyeli ayrık dalgacık dönüşümü kullanarak BT görüntü özellikleri geliştirilmiştir. Geliştirilen BT görüntüler yazarların geliştirdikleri CoV-CTNeT kullanarak sınıflandırılmıştır. İkinci aşamada ise görüntüleri sınıflandıran ve analiz eden derin öğrenme ağı olarak ise CoV RASeg kullanılmıştır. CoV RASeg hem sınırları hem de bölge homojenliğinin aynı anda tespit etmede başarılı olduğu belirtilmiştir. Data set olarak ise SIRM tarafından verilen 459 u sağlıklı 370'i COVID-19 pnömonili toplam 829 BT görüntü tercih edilmiştir. Eğitim sırasında beş kat çaprazlama tekniği kullanılmıştır. Yapılan segmentasyon işlemi sonucunda SA-CoV-

RASeg de pnömonili bölge için 0.953 dice puanı ve 0.9873 IoU; CoV-RASeg de pnömonili bölge için 0.952 zar puanı ve 0.9865 IoU elde edilmiştir. En son diğer derin öğrenme ağlarının performansları ile geliştirilen sinir ağlarının performansları karşılaştırılmış ve önerilen modelin mevcut tekniklerden daha iyi performans verdiği belirtilmiştir (Khan ve ark., 2020).

Müller ve ark. (2020), yapmış oldukları çalışmada, Coronacases Initiative ve Radiopedia'dan toplanan 20 adet açıklamalı COVID-19 göğüs BT'si kullanılmıştır. BT görüntüleri dört sınıfta etiketlenmiştir: Arka plan, sol akciğer, sağ akciğer ve COVID-19 pnömonili olarak etiketleme işlemi gerçekleştirilmiştir. Veri kümesi üzerinde 5 kat doğrulama işlemi kullanılmıştır. Her test işleminde veri seti 16 görüntü eğitim ve 4 görüntü tahmin işlemi olmak üzere ayrılmıştır. Derin öğrenme algoritması olarak standart 3B U-Net mimarisi tercih edilmiştir. Değerlendirme metrikleri olarak dice puanı, duyarlılık (sensitivity) ve özgüllük (specificity) metrikleri kullanılmıştır. Yapılan segmentasyon işleminde dice puanı olarak akciğerler için 0.956 ve pnömoni için 0.761 benzerlik katsayılarına ulaşılmıştır. Önerilen yöntemin benzer çalışmalara göre daha iyi performans gösterdiği ve bu alanla ilgili araştırmaların devam etmesi gerektiği vurgulanmıştır (Müller ve ark., 2020).

Stifanic ve ark. (2021), yapmış oldukları çalışmada, Clinical Center'dan ve Rijeka'daki klinik hastane merkezinden (KBC Ri) toplanan toplam 245 X-Ray akciğer görüntüsü kullanılmıştır. Verilerin yüksek dengesizliğini tahmin etmek için 5 katlı çapraz doğrulama tekniği gerçekleştirilmiştir. Gerçekleştirilen segmentasyon işleminde DeepLabV3+ omurgasını kullanan Xception\_65, MobileNet-v2 ve ResNet-101 derin öğrenme algoritmaları tercih edilmiştir. Performans değerlendirme metrikleri olarak ise ortalama IoU, F1 skoru, kesinlik (accuracy), hassasiyet (precision), duyarlılık (sensitivity), özgüllük (specificity) metrikleri kullanılmıştır. Yapılan segmentasyon işlemi sonucunda en yüksek performansı veren derin öğrenme algoritması Xception\_65 olduğu vurgulanmıştır. Xception\_65 sinir ağında  $0.910 \pm 0.015$  ortalama IoU,  $0.925 \pm 0.014$  F1,  $0.968 \pm 0.005$  kesinlik,  $0.916 \pm 0.028$  hassasiyet,  $0.935 \pm 0.008$  duyarlılık ve  $0.977 \pm 0.008$  özgüllük puanları elde edilmiştir. Sonuç olarak gelecekte çalışmalar için daha fazla veri setine ve görüntüye ihtiyaç olduğunu bu sayede sistemin etkinliği sağlamlığı daha iyi analiz edilip geliştirilebileceği belirtilmiştir. Elde edilen sonuçlara göre ise önerilen yaklaşımın akciğer açısından başarılı olduğu ve klinik kullanım için büyük bir potansiyele sahip olduğu vurgulanmıştır (Štifanić ve ark., 2021).

Oulefki ve ark. (2021), yapmış oldukları çalışmada, COVID-19 BT veri setinden ve EL-BAYANE radyoloji ve medikal görüntüleme merkezinde bir hastadan alınmış olan iki BT görüntülerinden toplam 275 BT görüntüsü kullanılmıştır. Yapılan segmentasyon işleminde ilk olarak akciğer bölgesi BT görüntülerden çıkarılmıştır. Ardından sol ve sağ akciğerler ayrılmıştır. Sonrasında ise görüntü iyileştirme işlemi sağ ve sol akciğer ayrı ayrı uygulanmaktadır. Bu aşamada daha ayrıntılı BT hedef tespiti için değiştirilmiş yerel bir kontrast geliştirme önerilmiştir. Pnömonili bölge ve pnömone olmayan bölge segmentasyonu için ise kapur entropisini optimize edilerek kullanılmıştır. Bu işlemin diğer derin öğrenme algoritmalarına göre daha fazla zaman aldığı vurgulanmıştır. Değerlendirme metrikleri olarak; doğruluk, duyarlılık, F-skoru, kesinlik, MCC (Mathec Cor İlişki Katsayısı), zar, jaccard ve özgüllük metrikleri olarak tercih edilmiştir. Yapılan segmentasyon sonuçlarında doğruluk 0.98, duyarlılık 0.73, F-skoru 0.71, kesinlik 0.73, MCC 0.71, zar 0.71, jaccard 0.57 ve özgüllük 0.99 sonuçlarına ulaşılmıştır. Sonuç olarak elde edilen sonuçların benzer yapılan çalışmalar ile karşılaştırılması sonucunda önerilen yaklaşımın daha sağlam, doğru ve basit olduğu vurgulanmıştır (Oulefki ve ark., 2021).

Teixeira ve ark. (2021), yapmış oldukları çalışmada, daha önce geliştirildiği belirtilen COVID-19 veri tabanlarını (RYDLS-20) güncelleyerek daha fazla görüntü ekleyip RYDLS-20-V2 olarak adlandırıldığı belirtilmiştir. Görüntüler CXR (X-Ray) görüntülerden oluşmaktadır. Akciğer segmentasyonu için U-Net evrimsel sinir ağı ve COVID-19 tanımlaması için ise üç popüler ESA modeli: VGG16, ResNet50-v2, Inception-v3 derin öğrenme algoritmaları kullanılmıştır. Segmentasyon üç sınıflı bir sınıflandırma olarak tercih edilmiştir. COVID-19, akciğer opaklığı ve normal akciğer olmak üzere üç sınıf belirlenmiştir. Akciğer opaklığı önceden herhangi bir hastalığın neden olduğu pnömone anlamına gelmektedir. Akciğer segmentasyonunun COVID-19 tanımlanması üzerine etkisini değerlendirmek için yerel yorumlanabilir model- agnostik açıklamalar (LIME) ve gradyan ağırlıklı sınıf aktivasyon haritalaması (Grad-CAM) kullanılmıştır. Akciğer segmentasyonu için kullanılan veri seti 1645 CXR görüntüden oluşmaktadır. Bu veri seti Cohen v7labs, Montgomery, Shenzhen, JSRT, manuel olarak oluşturulan görüntülerden oluşmaktadır. Veri seti %90 train, %5 test, %5 eğitim olmak üzere ayrılmıştır. Üç sınıf segmentasyon işlemi için ise RYDLS-20-V2 olan yazarların geliştirdikleri veri seti kullanılmıştır. Görüntüler toplam 2678 CXR (Cohen, RSNA, diğerleri) görüntüden oluşmaktadır. Görüntüler %60 train, %20 test, %20 eğitim olmak üzere ayrılmıştır. Yapılan segmentasyon işlemleri sonucunda bölünmüş görüntüleri

kullanan sınıflandırma 0.034 jaccard mesafesi ve 0.982 dice katsayısına ulaşılmıştır. Çok sınıflı segmentasyon işlemi ise 0.88 ve 0.83 COVID-19 tanımlanması için F1-Skoru elde edilmiştir. Çapraz veri kümesi senaryosunda COVID-19 tanımlaması için 0.74 F1-Skoru ve 0.9 ROC eğrisi altında bir alan elde edilmiştir. Sonuç olarak elde edilen modelin iyi bir sonuç elde etmesine rağmen sınıflandırma performansı olarak güvenilir olmadığı sonucunda çıkarım yapılabileceği vurgulanmıştır (Teixeira ve ark., 2021).

Elharrouss ve ark. (2020), yapmış oldukları çalışmada, İtalya Tıbbi ve Girişimsel Radyoloji Derneği tarafından sunulan 20 COVID-19 hastasının 100 eksenel BT görüntüsü kullanılmıştır. Görüntüler 2 etikete sahiptir. İlki pnömonili bölge, ikincisi ise spesifik pnömonili bölgelerdir. Görüntüler, 50 görüntü pnömoninin tek etiket değerine sahip olduğu ve iki etiket değerine sahip olduğu şeklinde eğitim görüntüsü olarak ayarlanmıştır. Aynı sınıflandırma ile 48 görüntüden oluşan test görüntü grubu da seçilmiştir. Bölge bölütleme işlemi için 2000'den fazla görüntü kullanılmıştır. Segmentasyon işlemi için derin öğrenme ağı olarak kodlayıcı- kod çözücü mimariye sahip SegNet modeli önerilmiştir. Yapılan segmentasyon işlemi değerlendirmek için dice benzerliği, duyarlılık, özgüllük, kesinlik, F-Skoru, ortalama mutlak hata metrikleri kullanılmıştır. Önerilen SegNet ağı tekli segmentasyon işlemi için U-net, Attention-UNet, Gated-Unet, Dense-UNet, U-Net++, Semi-Inf-Net derin öğrenme ağları ile karşılaştırılmıştır. Çok sınıflı segmentasyon işlemi için önerilen ağ multi-class U-Net, DeepLabV3+, FC8s, Semi-Inf-Net derin öğrenme ağları ile karşılaştırılmıştır. Tek sınıflı segmentasyon işlemi için 0.786 dice, 0.711 duyarlılık, 0.993 özgüllük, 0.856 kesinlik, 0.784 F-Skoru, 0.076 ortalama mutlak hata sonucu; Çok sınıflı segmentasyon işlemi için 0.640 dice, 0.630 duyarlılık, 0.953 özgüllük, 0.561 kesinlik, 0.640 F-Skoru, 0.062 ortalama mutlak hata sonucu elde edilmiştir. Elde edilen sonuçlardan yola çıkarak önerilen ağın diğer derin öğrenme ağlarına göre daha başarılı olduğu vurgulanmıştır. Önerilen derin öğrenme ağına en yakın sonuçlara ise Semi-Inf-Net ulaşmıştır. Ulaşılan sonuçların eğitim ve test için daha fazla veri kullanılarak gelecekteki çalışmalarda geliştirilebileceği vurgulanmıştır (Elharrouss ve ark., 2020).

Zhao ve ark. (2021), yapmış oldukları çalışmada, COVID-19 hastalarından izinleri alınarak elde edilen 19 akciğer BT taraması kullanılmıştır. Ayrıca modelin genelleme yeteneğini test etmek için harici iki veri seti daha hazırlanmıştır. İlki Wuhan Kızıllıhaç Hastanesi'nden elde edilen iki hastanın 8 akciğer BT taramasıdır. İkincisi Kaggle tarafından halka açık sunulan 9 eksenel hacimsel BT taraması içeren veri setidir.

Yapılan çalışmada UNet++ yapısından yola çıkılarak tasarlanan SCOAT-Net önerilmiştir. Önerilen SCOAT-Net de dikkat mekanizmaları normalden farklı olarak paralel değil seri bağlandığı belirtilmiştir. SCOAT-Net'in alakasız alan özelliklerini önemli ölçüde azaltmaya yardımcı olduğu ve dolayısıyla yerel özellik çıkarımı için kanal dikkatini optimize etme zorluğunu azalttığı vurgulanmıştır. SCOAT-Net'i kullanarak akciğer opasifikasyonu segmentasyonu yapılması hedeflenmiştir. Yapılan çalışmada sonucu test etmek için beş katlı çapraz doğrulama kullanılmıştır. Akciğer opasifikasyon segmentasyonunun performansını değerlendirmek için dice benzerlik katsayısı, duyarlılık (hassasiyet), pozitif tahmin edilen değer (positive predicted value-PPV), hacim doğruluğu (volume accuracy-VA), bölgesel düzey hassasiyeti (regional level precision-RLP), bölgesel düzeyde geri çağırma (regional level recall-RLR) değerlendirme metrikleri kullanılmıştır. Akciğer opasifikasyonu segmentasyon işlemi için önerilen SCOAT-Net; PSPNet, ESPNetV2, DenseASPP, DeepLabV3+, U-Net, COPLE-Net, CE-Net, Attention U-Net, UNet+ derin öğrenme ağları ile karşılaştırılmıştır. Akciğer opasifikasyonu segmentasyon için yapılan işlem sonucunda önerilen SCOAT-Net %88.99 zar, %87.85 hassasiyet, %90.28 pozitif tahmin edilen değer, %96.25 hacim doğruluğu, %90.87 bölgesel düzey hassasiyeti, %84.33 bölgesel düzey geri çağırma metrik sonuçları elde etmiştir. Harici veri setlerinde yapılan segmentasyon işlemleri ile önerilen ağın test edildiği vurgulanmıştır. Kaggle veri setindeki 9 BT görüntüsü için ortalama %67.48 dice katsayısı elde edilmiştir. Bu sonucun diğer ağlardan başarılı olduğu da belirtilmiştir. Dikkat mekanizmaları karşılaştırmalarında ise SCOAT-Net, U-Net++ ağına oranla bazı sonuçları geliştirse de genel olarak çok da ilerleme kaydedilmediği vurgulanmıştır. SCOAT-Net ve A1 dikkat modülü dice katsayısı, hassasiyet, bölgesel düzey hassasiyetinde önemli ölçüde sonucu geliştirdiği belirtilmiştir. SCOAT-Net, A1 ve A2 dikkat modülü ise hacim doğruluğunu önemli ölçüde geliştirdiği vurgulanmıştır. Elde edilen sonuçlardan yola çıkarak önerilen SCOAT-Net'in son teknoloji ESA'lardan daha iyi performans gösterdiği belirtilmiştir. Önerilen yöntemin karmaşık görüntüler ve tıbbi senaryolar için büyük uygulama potansiyeline sahip olduğu belirtilmiş ve bu üstün özelliklerine rağmen ağlarının küçük opaklık bölgelerini tahmin edememe gibi eksiklerinin de olduğu vurgulanmıştır (Zhao ve ark., 2021a).

Yin ve ark. (2022), yapmış oldukları çalışmada, iki farklı veri kümesi kullanılmıştır. Birinci veri kümesi İtalyan Tıbbi ve Etkileşimli Radyoloji Derneği tarafından segmentlere ayrılmış olan akciğer pnömoni etiketine sahip 100 eksenel BT

görüntüsünden oluşmaktadır. İkinci veri kümesi 20 etiketli COVID-19 BT taramasından oluşan veri kümesidir. İkinci veri kümesi 1863 COVID-19, 1637 COVID-19 olmayan aksenel görüntüye sahiptir. Derin öğrenme ağı olarak U-Net tabanlı geliştirilen ve yoğun atröz uzamsal piramit havuzuna sahip SD-Unet önerilmiştir. Segmentasyon işlemi ikili ve çoklu sınıf olmak üzere iki başlık altında gerçekleştirilmiştir. Performans kriterleri olarak duyarlılık, dice katsayısı, doğruluk, özgüllük ve jaccard benzerliği kullanılmıştır. Veri setleri birleştirildikten sonra 5 kat çapraz doğrulama tekniği gerçekleştirilmiştir. Beş kat çapraz doğrulama tekniği kullanarak gerçekleştirilen iki sınıflı segmentasyon işlemi için 0.8826 duyarlılık, 0.8588 dice katsayısı, 0.9606 doğruluk, 0.9642 özgüllük, 0.7602 jaccard benzerliği sonuçlarına ulaşılmıştır. Beş kat çapraz doğrulama tekniği kullanılarak gerçekleştirilen çok sınıflı segmentasyon işlemi için ortalama değer olarak 0.5798 duyarlılık, 0.5618 dice, 0.9403 doğruluk, 0.9354 özgüllük, 0.4506 jaccard benzerliği sonuçları elde edilmiştir. Ulaşılan sonuçlar neticesinde literatüre göre daha başarılı değerler elde edildiği belirtilmiştir. Ancak uygulamada lezyon konturlarının yetersiz ayrıntıya sahip olduğu ve bu durumun uygulamada eksikliklere sebebiyet verdiği vurgulanmıştır (Yin ve ark., 2022).


### 3. MATERYAL VE YÖNTEM

Bu bölümde COVID-19 hastalığı, BT, kullanılan veri kümesi, veri kümesi üzerinde yapılan ön işleme metotları, veri artırma, DeepLabv3+ ile semantik segmentasyon, sınıfların ağırlıklandırılması, hiper parametreler ve performans kriterleri verilmiştir.

#### 3.1. COVID-19

COVID-19 2019 yılının son çeyreğinde Çin'in Vuhan bölgesinde patlak veren salgın bir hastalıktır. Bu tarihten sonra hızlı bir şekilde diğer ülkelerde de görülmeye başlamasından sonra çok kısa bir süreçte bütün dünyayı etkisi almaya başlamıştır. Yüzeyinde bulunan çubuksu uzantılar taca benzetilmesi ile Latince de taç anlamına gelen "corona" kelimesi ile telaffuz edilmeye başlanmıştır. İlk olarak SARS-CoV-2 olarak adlandırılan bu virüs sonrasında 2019 Novel Coronavirus adını almış, daha sonrasında ise COVID-19 kısaltması ile son ismi belirlenmiştir (Vikipedi, 2022).

COVID-19'un bilinen en net tipik belirtileri ise yüksek ateş, kuru öksürük ve yorgunluk olarak öne çıkmaktadır. Bu belirtilerin ortaya çıkış zamanı hastadan hastaya değişmekle birlikte her yeni mutasyonunda semptomlar farklılık gösterebilmektedir. Fakat hastalığın en çok etkilediği organ ise akciğerlerdir. Akciğerlerde buzlanmış bir yapı gibi görünüme sebebiyet vermektedir. Şekil 3.1'de veri setinde kullanılan bir COVID-19 hastasının BT görüntüsünden tek kesit verilmiştir.



**Şekil 3.1.** Veri setinde kullanılan COVID-19 pnömonili bir hastanın akciğer BT görüntüsünden bir kesit (Yang, 2020)

Pnömoni bilenen tabiri ile zatürre; akciğer dokusunun iltihaplanmasıdır. Bakteriler başta olmak üzere çeşitli mikroorganizmalara bağlı olarak meydana gelmektedir. Üşüme-titrete, 39-40°C'ye varan yüksek ateş, öksürük, iltihaplı balgam çıkarma ve ağrı pnömoni belirtilerindedir. Bazı pnömoni türlerinde ise sinsi başlangıç meydana gelebilmektedir. Birkaç gün devam eden iştahsızlık, halsizlik, eklem ve kas ağrılarını takiben kuru öksürük, ateş yükselmesi, bulantı, kusma, baş ağrısı gibi belirtileri olabilmektedir. Pnömoni ihmal edilmemesi gereken bir sağlık sorunudur. Erken teşhis edilmesi ve gecikmeden tedaviye başlanması ölümleri azalttığı bilinmektedir. Hastanın şikayetleri pnömoniyle uyumlu ise genellikle yapılan muayene ve akciğer röntgenindeki bulgularla teşhis konulabilir. Gerekirse kan ve balgam tahlilleri de yapılabilir (Ceylan, 2021).

Pnömoni akciğerlerde camsı bir yapı olarak gözükmektedir. Şekil 3.1'de verilen BT görüntüsünde kırmızı alanla etrafı çevrilmiş olan alan pnömoninin oluşturduğu camsı dokuya örnek olarak verilebilir.

Pnömoninin, genellikle 60 yaş ve üstü, kronik rahatsızlığı bulunan, kalp rahatsızlığı ve benzeri hastalıklara sahip bireylerde daha hızlı ortaya çıktığı gözlenmektedir. Sağlıklı çocuklar ve gençlerde ise pnömoninin görülme oranı daha düşük olup etkilerinin daha az olduğu belirtilmektedir (Sağlık Bakanlığı, 2022). Akciğerlerde pnömoninin varlığı ölümcül olduğu için erken tespiti ve tedavisi önem arz etmektedir. Hastalığın tespitinde en çok kullanılan yöntem RT-PCR testidir. Fakat bu testin doğruluk oranı istenilen düzeyde değildir. Hastalığın en doğru şekilde tespiti için uygulanan yöntem medikal görüntüler üzerinden değerlendirmelerdir. En çok kullanılan medikal görüntüleme teknikleri röntgen (X-Ray) ve BT görüntüleme yöntemleridir (Cömert ve Kıral, 2020). Röntgen görüntüleri çekilmesi ve sonucunun elde edilmesi zamandan ve maliyetten tasarruf sağlamaktadır. Fakat hastalığın tam ve erken tespiti için yeterli detayı buldurmamaktadır. Bundan dolayı BT görüntüler hastalığın tespiti ve hastalıklı bölgelerin segmentasyon işlemi için daha çok kullanılmaktadır. BT'nin tercih edilme sebebi görüntülerde pnömonili bölgelerin daha net izlenebilmesidir. BT görüntüler üzerinde radyologlar tarafından tespit ve segmentasyon işlemi manuel olarak yapılmaktadır. Radyolog sayısının az olması, hasta ve görüntü sayısının çok fazla olmasından dolayı manuel analizler çok fazla süre almaktadır. Bundan dolayı yapay zeka tabanlı otomatik analiz ve segmentasyon sistemleri medikal görüntüler üzerinde hızlı bir yorumlama için alternatif bir çözüm olacaktır.


### 3.2. Bilgisayarlı Tomografi

Tomografi cismin farklı açılardan iz düşüm bilgilerinden elde edilen kesit görüntülerine dayanır. Geniş anlamda iz düşüm, belli bir açıdan aydınlatılan cismin geçirdiği enerjiden oluşturulan bilgidir (Arslan, 2005). BT çekimi için kullanılan bir cihaz görüntüsü Şekil 3.2’de verilmiştir.




Şekil 3.2. Bilgisayarlı Tomografi cihazı (Alkan, 2018)

BT çalışma prensibi: Helikal (spiral) tüp inceleme sırasında sürekli dönmektedir. Tek seferde 40-80 cm’lik alan bir nefes tutma süresinde taranabilmektedir. X-ışını tüpü, kesit düzlem çevresinde 360 derece dönerek dar bir X-ışını demeti göndermektedir. X-ışınları vücuda gönderilirken ve vücuttan geçtikten sonra ölçülüp aradaki fark hesaplanarak dedektörler (sensörler) karşısına gelen dokunun X-ışınını ne oranda tuttuğu bulunmaktadır (MEB, 2011). Şekil 3.3’de Helikal BT çalışma prensibi bir model üzerinde gösterilmektedir.



Şekil 3.3. Helikal BT çalışma prensibi (MEB, 2011)

X-ışınları farklı dokulardan geçerken farklı oranlarda zayıflama karakteristiğine sahiptir. Zayıflamış olan bu X-ışınları detektörler tarafından toplanmaktadır. Analog-sayısal çeviriciler sayesinde toplanan X-ışınları dijital verilere dönüştürülür ve elde edilen bu dijital değerler Hounsfield skalasında verilen gri tonlara boyanarak kesit görüntüleri elde edilmektedir. Şekil 3.4'de Hounsfield skalası verilmiştir. BT'nin oluşturulmasında görüntüleme algoritmaları aktif bir şekilde kullanılmaktadır.



Şekil 3.4. Hounsfield skalası (MEB, 2011)

Elde edilen BT görüntülerinde organlar ve organlar üzerindeki tümör, pnömoni gibi anomaliler rahatlıkla tespit edilebilmektedir. COVID-19 gibi pnömonilerin tespitinde en güvenilir yol BT görüntülerin analizi ile gerçekleşmektedir. BT görüntüler röntgen görüntülerine göre daha ayrıntılıdır. Röntgen görüntülerinde X-ışınının geçtiği boyuttaki yapıların üst üste gelmesinden dolayı, aralarındaki yoğunluk farkı belirgin olmayıp yapıların seçilmesi zorlaşmaktadır. Bu dezavantaj ince bir vücut dilimini görüntüleyen BT'de ortadan kaldırılmaktadır (Alkan, 2018) .

### 3.3. Veri Kümesi

Bu tez çalışmasında, Ma ve ark. tarafından araştırmacıların kullanımına ücretsiz bir şekilde sunulan zenodo COVID-19 BT akciğer ve enfeksiyon segmentasyonu veri seti (*COVID-19 CT Lung and Infection Segmentation Dataset*) kullanılmıştır (Ma Jun, 2020). Veri seti Coronacases Girişimi ve Radiopaedia tarafından toplanan 3B BT görüntülerinden oluşmaktadır.

Şekil 3.5’de verilerin indirilebildiği zenodo internet sayfasının ekran görüntüsü verilmiştir (<https://zenodo.org/record/3757476#.YuxKa3ZBxPb>).

April 20, 2020 Dataset Open Access

## COVID-19 CT Lung and Infection Segmentation Dataset

Ma Jun; Ge Cheng; Wang Yixin; An Xingle; Gao Jiantao; Yu Ziqi; Zhang Mingqing; Liu Xin; Deng Xueyuan; Cao Shucheng; Wei Hao; Mei Sen; Yang Xiaoyu; Nie Ziwei; Li Chen; Tian Lu; Zhu Yuntao; Zhu Qiongjie; Dong Guoqiang; He Jian

This dataset contains 20 labeled COVID-19 CT scans. Left lung, right lung, and infections are labeled by two radiologists and verified by an experienced radiologist.

To promote the studies of annotation-efficient deep learning methods, we set up three segmentation benchmark tasks based on this dataset <https://gitee.com/junma11/COVID-19-CT-Seg-Benchmark>.

In particular, we focus on learning to segment left lung, right lung, and infections using

- pure but limited COVID-19 CT scans;
- existing labeled lung CT dataset from other non-COVID-19 lung diseases;
- heterogeneous datasets include both COVID-19 and non-COVID-19 CT scans.


Preview

COVID-19-CT-Seg\_20cases.zip

ReadMe.txt	359 Bytes
coronacases_001.nii.gz	93.2 MB
coronacases_002.nii.gz	70.1 MB
coronacases_003.nii.gz	67.3 MB
coronacases_004.nii.gz	88.9 MB
coronacases_005.nii.gz	96.5 MB
coronacases_006.nii.gz	71.6 MB
coronacases_007.nii.gz	85.0 MB
coronacases_008.nii.gz	96.9 MB
coronacases_009.nii.gz	84.7 MB
coronacases_010.nii.gz	98.7 MB
radiopaedia_10_85902_1.nii.gz	9.6 MB
radiopaedia_10_85902_3.nii.gz	120.0 MB
radiopaedia_14_85914_0.nii.gz	21.9 MB
radiopaedia_27_86410_0.nii.gz	20.2 MB
radiopaedia_29_86490_1.nii.gz	10.2 MB
radiopaedia_29_86491_1.nii.gz	11.3 MB
radiopaedia_36_86526_0.nii.gz	8.3 MB

Şekil 3.5. Veri kümesinin alındığı zenodo web sayfasının ekran görüntüsü (Ma Jun, 2020)

İki farklı grubun toplamış olduğu BT görüntülerinin çekim formatlarında ve büyüklüklerinde farklılıklar bulunmaktadır. Çalışmada homojen bir veri setinin oluşturulması için Coronacases Girişimi tarafından elde edilen 10 3B BT görüntüsü kullanılmıştır. Bu BT'ler yüksek çözünürlükte olup 512x512 görüntü boyutuna sahiptir. 8 bit derinliğine sahip görüntüler aksiyal eksende çekilmiştir. Tüm görüntülerin aynı zamanda radyologlar tarafından sınırları belirlenmiş akciğer ve pnömoni bölgelerine ait 3B maskeleri bulunmaktadır. Tüm veri seti 3B olup NIFTI medikal resim formatında olup \*.nii dosya uzantılıdır. Bu formattaki BT'lerin açılıp incelenebilmesi için kolaylık ve pratik kullanım sağlayan MRicro programı ile ön izlemeler gerçekleştirilmiştir (Rorden, 2000). Şekil 3.6'da bir 3B BT görüntünün aksiyal, sagittal ve koronal eksendeki görünümünün MRicro programı ile gösterimi verilmiştir.



Şekil 3.6. MRicro programı kullanılarak açılan NIFTI formatındaki 3B BT görüntüsü

3B BT ve maske görüntüleri MRicro programında açılarak tüm kesitler \*.png resim formatında kaydedilmiştir. NIFTI resim formatındaki 10 adet 3B BT görüntüsünde toplam 2581 kesit bulunmaktadır. Maske görüntüleri incelenerek içerisinde akciğer bölgesi bulunmayan kesitler çalışmadan çıkarılmıştır. Çizelge 3.1'de denek numarasına göre vakaların toplam kesit sayıları, düzenleme işleminden sonra oluşturulan kesit sayıları ve çalışmada kullanılan kesit aralıkları verilmiştir. Düzenleme işleminden sonra

toplam 1279 2B BT görüntüsü ve bu görüntülere karşı gelen 1279 akciğer maskesi, 1279 pnömoni maskesi elde edilmiştir.

**Çizelge 3.1.** 3B BT görüntülerinde kullanılan kesit aralıkları

Görüntü	Çalışmada Kullanılan Kesit Aralıkları	Başlangıçtaki Kesit Sayısı	Düzenleme Sonrası Kesit Sayısı
coranacases_org_001	85-237	301	153
coranacases_org_002	29-161	200	133
coranacases_org_003	43-175	200	133
coranacases_org_004	71-175	270	105
coranacases_org_005	64-168	290	105
coranacases_org_006	50-112	213	63
coranacases_org_007	78-160	249	83
coranacases_org_008	50-252	301	203
coranacases_org_009	85-196	256	112
coranacases_org_010	78-266	301	189


### 3.4. Ön İşleme

Veri kümesinde bulunan pnömoni ve akciğer bölgelerinin iç içe olduğu maske grubunda; pnömoni ve sağ akciğer etiket değerinin eşit olarak atandığı tespit edilmiştir. Bu sebepten dolayı akciğer ve pnömoni maskeleri kullanılarak etiket değerleri değiştirilip maskeler yeniden elde edilmiştir. MATLAB programında geliştirilen bir kod parçası ile ön işleme sonrasında veri kümesinde bulunan üç grup maske sekiz grup maskeye çıkartılmıştır. Bu gruplar; akciğerlerde pnömoni bölgelerinin eşit etiket değerine sahip olduğu maske grubu, akciğerlerde pnömoni bölgelerinin farklı (sağ akciğer pnömoni, sol akciğer pnömoni) etiket değerine sahip olduğu maske grubu, akciğer bölgelerinin eşit etiket değerine sahip olduğu maske grubu, akciğer bölgelerinin farklı (sağ akciğer, sol akciğer) etiket değerine sahip olduğu maske grubu, akciğer ve pnömoni bölgelerinin birbirlerinden farklı eşit etiket değerine sahip olduğu maske grubu, akciğer bölgelerinin eşit pnömoni bölgelerinin farklı etiket değerlerine sahip olduğu maske grubu, akciğer bölgelerinin farklı pnömoni bölgelerinin eşit etiket değerine sahip olduğu maske grubu, akciğer ve pnömoni bölgelerinin birbirlerinden ve birbirlerinden farklı etiket değerine sahip olduğu maske grubu olmak üzere sekiz farklı senaryoda maske grubu oluşturulmuştur. Çizelge 3.2’de senaryolar, maske grupları, sınıflar ve sınıflara ait piksel etiket numaraları verilmiştir.


Çizelge 3.2. Maske gruplarının sınıf etiket değerleri

Senaryo	Maske	Sınıflar	Etiket Değeri
Senaryo-1	Akciğerler Eşit	Akciğerler	255
		Arka Plan	0
Senaryo-2	Akciğerler Farklı	Sağ akciğer	127
		Sol akciğer	254
		Arka plan	0
Senaryo-3	Pnömoni Eşit	Pnömoni	50
		Arka plan	0
Senaryo-4	Pnömoni Farklı	Sağ pnömoni	57
		Sol pnömoni	184
		Arka plan	0
Senaryo-5	Akciğerler ve Pnömoniler Eşit	Akciğer	255
		Pnömoni	50
		Arka plan	0
Senaryo-6	Akciğerler Eşit Pnömoni Farklı	Akciğer	255
		Sağ pnömoni	57
		Sol pnömoni	184
		Arka plan	0
Senaryo-7	Akciğerler Farklı Pnömoni Eşit	Sağ akciğer	127
		Sol akciğer	254
		Pnömoni	50
		Arka plan	0
Senaryo-8	Akciğerler ve Pnömoniler Farklı	Sağ akciğer	127
		Sol akciğer	254
		Sağ pnömoni	57
		Sol pnömoni	184
		Arka plan	0


Çizelge 3.2’de verilen maske ve etiket değerlerinin görsel sonuçları, BT görüntüsü ile üst üste çakıştırılması ve renk haritaları sırasıyla aşağıdaki Şekil 3.7, Şekil 3.8, Şekil 3.9, Şekil 3.10, Şekil 3.11, Şekil 3.12, Şekil 3.13 ve Şekil 3.14’de verilmiştir.




Şekil 3.7. (a) Akciğer bölgelerinin eşit piksel etiket değerine sahip olduğu maske görüntüsünden bir kesit  
(b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü




**Şekil 3.8.** (a) Akciğer bölgelerinin farklı piksel etiket değerine sahip maske görüntüsünden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü




**Şekil 3.9.** (a) Pnömoni bölgelerinin eşit piksel etiket değerine sahip maske görüntüsünden bir kesit, (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü



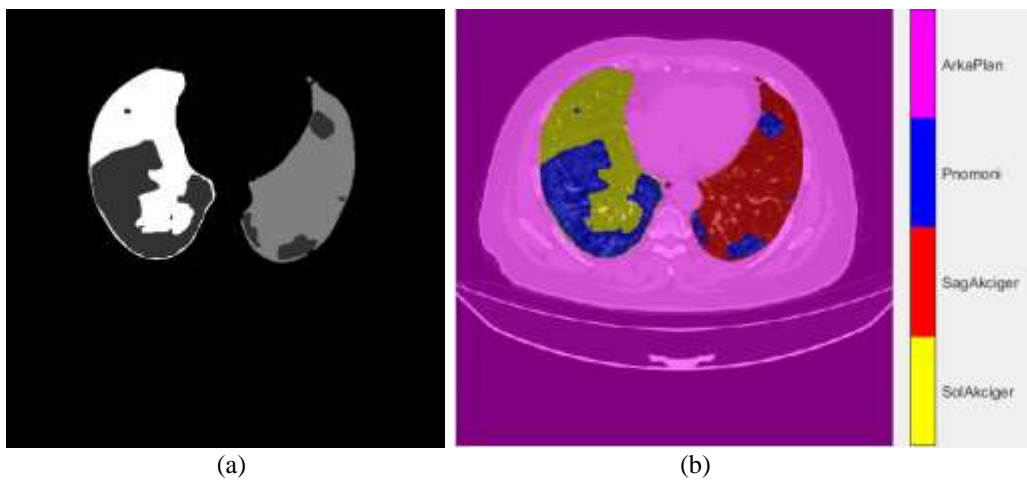
**Şekil 3.10.** (a) Pnömoni bölgelerinin farklı piksel etiket değerine sahip maske görüntüsünden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü




**Şekil 3.11.** (a) Akciğer ve pnömoni bölgelerinin eşit piksel etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü



**Şekil 3.12.** (a) Akciğer bölgelerinin eşit pnömoni bölgelerinin farklı piksel etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü



**Şekil 3.13.** (a) Akciğerler bölgelerinin farklı pnömoni bölgelerinin eşit piksel etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü



**Şekil 3.14.** (a) Akciğerler ve pnömoni bölgelerinin farklı piksel etiket değerlerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü ve maskenin üst üste çakıştırılması ile elde edilen görüntü

### 3.5. Veri Arttırma

Derin öğrenme ağlarında büyük veri kümeleri ile çalışmak model performansının değerlendirilebilmesi için önemli bir ölçüttür. Az miktarda ve benzer veri setiyle çalışıldığında modelde ezberleme (overfitting) hatası ile karşılaşılması muhtemel bir durumdur. Bu durumla karşılaşılmasını için veri arttırma (data augmentation) tekniği bu çalışmada uygulanmıştır.

Veri arttırma ayarları için MATLAB programındaki “*imageDataAugmenter*” fonksiyonu kullanılmıştır. Fonksiyona “*RandXReflection*” (x ekseninde rastgele yansıma), “*RandXTranslation*” (giriş görüntüsüne [-10,10] vektör aralığında x ekseninde uygulanan, rastgele ve sürekli düzgün bir dağılım gösteren yatay öteleme metodu), “*RandYTranslation*” (giriş görüntüsüne [-10,10] vektör aralığında y ekseninde uygulanan, rastgele ve sürekli düzgün bir dağılım gösteren dikey öteleme metodu) parametre girişleri kullanılarak veri büyütme işlemi gerçekleştirilmiştir (MATLAB, 2017b).


Derin öğrenme algoritmaları üç kanala sahip renkli görüntüler ile işlem yapacak şekilde modellenmiştir. Veri arttırma işlemi yapılırken aynı zamanda görüntüler üç kanallı resim formatına dönüştürülmüştür. Bu işlem görüntüleri renkli görüntüye dönüştürmemekte, ilgili resimleri 3 kez arka arkaya ekleyerek modellerin BT görüntülerini üç kanallı olacak şekilde işlemlerini sağlamaktadır. Hem veri arttırma ve üç kanal görüntülere dönüştürmek için MATLAB programının *pixelLabelImageDatastore* fonksiyonuna eğitim için ayrılan BT’ler ve maskeleri,








yukarıda türetilen veri artırma modeli ve ('ColorPreprocessing', 'gray2rgb') değeri parametre girişi olarak verilmiştir.

### 3.6. DeepLabV3+ ile Semantik Segmentasyon

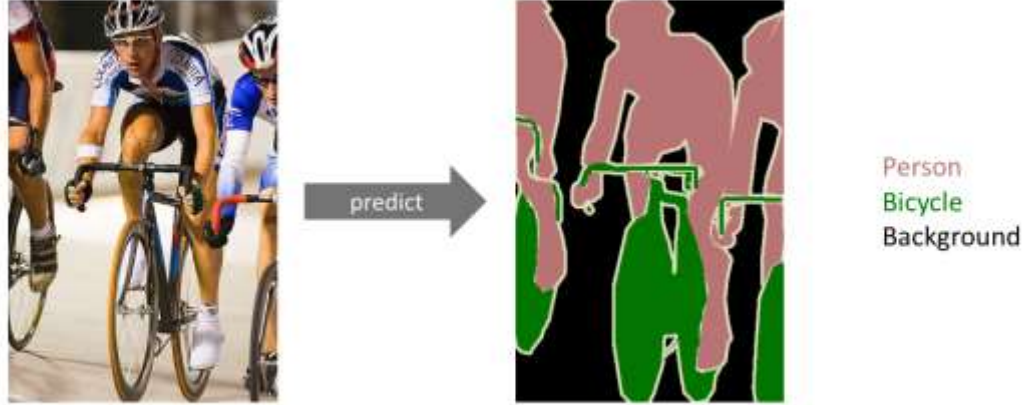
Görüntü bölütleme, görüntüyü aynı cinsten obje ve bölgelere ayırmaktır. Sağlık, jeoloji, çevre, harita, uzaktan algılama gibi otonom araçlar dahil olmak üzere birçok alanda kullanılmaktadır. Bu tez çalışmasında, derin öğrenme tabanlı görüntü bölütleme yöntemlerinden semantik segmentasyon metodu kullanılmıştır. Anlamsal bölütleme anlamına gelen semantik segmentasyon, bir görüntüde bulunan tüm objelerin piksel düzeyinde algılanması ve farklı sınıflara ait nesnelerin birbirinden ayrılmasıdır. Görseldeki tüm sınıflar ayrı ayrı gruplandırılarak semantik segmentasyon işlemi gerçekleştirilir (Yıldırım, 2022).

Şekil 3.15'de bir sokak görüntüsünde bulunan yol (road), kaldırım (sidewalk), bina (building), çit (fence), direk (pole), bitki (vegetation), araç (vehicle) ve etiketsiz (unlabel) bölgelerin anlamsal bölütleme sonucu elde edilen renk haritası verilmiştir. Şekil 3.16'da bisiklet süren üç kişinin semantik segmentasyon sonucu bisiklet (bicycle), insan (person) ve arka plan (background) sınıfları olarak elde edilen görüntü verilmiştir.



	Road		Sidewalk		Building		Fence
	Pole		Vegetation		Vehicle		Unlabel

**Şekil 3.15.** Bir sokak görüntüsü ve görüntüde bulunan yol (road), kaldırım (sidewalk), bina (building), çit (fence), direk (pole), bitki (vegetation), araç (vehicle) ve etiketsiz (unlabel) bölgelerinin anlamsal bölütleme sonucu elde edilen renk haritası (Jeong ve ark., 2018)



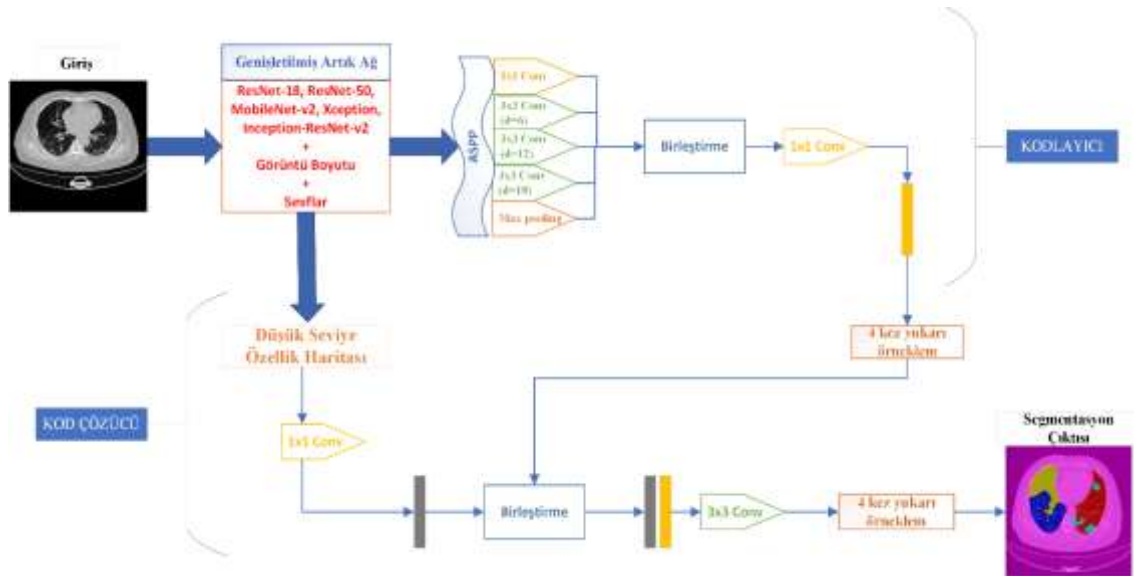
**Şekil 3.16.** Bisiklet süren üç kişinin bisiklet (bicycle), insan (person) ve arka plan (background) sınıfları olarak semantik segmentasyonu (Jordan, 2018)

Semantik segmentasyon için U-Net (Ronneberger ve ark., 2015), FCN (Long ve ark., 2015), DeepLabV3+ (Chen ve ark., 2017) ve SegNet (Badrinarayanan ve ark., 2017) derin öğrenme modelleri literatürde en çok kullanılan algoritmalarıdır. Bu tez çalışmasında, DeepLabv3+ modelinin farklı derin öğrenme tabanlı modelleri kullanılmıştır.

DeepLabV3+ ilk olarak 2015 yılında Google aracılığıyla Chen ve arkadaşları tarafından yayımlanmıştır (Chen ve ark., 2017). Yapısında bulunan ve evrişimden önce özellikleri yeniden örnekleme yarayan atröz uzaysal piramit havuzu (ASPP) sayesinde nesnelere birden çok ölçekli olarak segmentlere ayırmaktadır. Bu özelliği farklı ölçekleri hesaba katmaya yardımcı olur ve doğruluğu arttırmaktadır. En son olarak özellik haritalarını kademeli olarak azaltan ve daha yüksek anlamsal bilgileri yakalayan bir kodlayıcı modülü ile uzamsal bilgileri kurtaran bir kod çözücü eklenmiştir. Bu sayede DeepLabv3+ derin öğrenme algoritması en son halini almıştır (Menteşe ve Hançer, 2020).

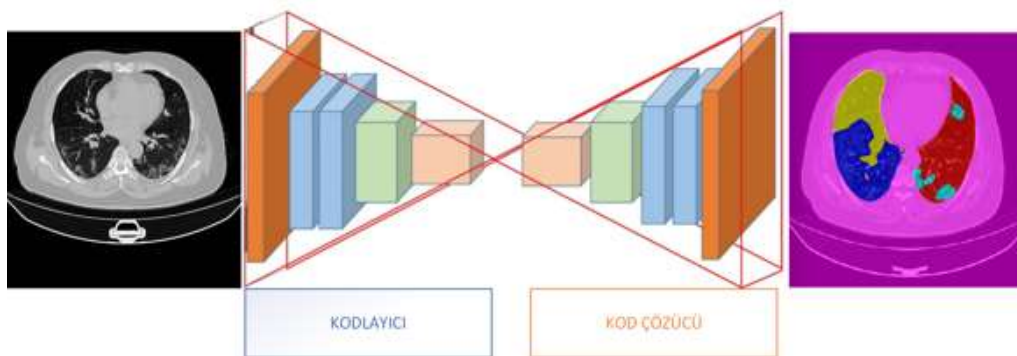
Kullanılan DeepLabv3+ derin öğrenme modelinin ana bileşenleri; omurga yapısı, atröz uzaysal piramit havuzu, genişleyen artık ağ ve dekoder modülüdür. DeepLabv3+ mimarisi Şekil 3.17.'de verilmiştir. DeepLabv3+ mimarisi her semantik segmentasyon işlemi için kullanılmıştır.

Bu tez çalışmasında, genişletilmiş artık ağ olarak ResNet-18, ResNet-50, MobileNet-v2, Xception, Inception-ResNet-v2 modelleri kullanılmıştır.



Şekil 3.17. DeepLabv3+ mimarisi

Kodlayıcı (encoder) bölümünde genişletilmiş artık ağ (dilated residual network) bulunmaktadır. Bu bölüme gönderilen görüntüler aşamalı olarak alt örnekleme gerçekleştirilen görüntülerdir. Görüntülerin çözünürlüğü üst düzey bilgileri yakalamak için kademeli olarak azaltılır. Bu özellikler ile aynı boyutta segmentasyon haritasının oluşturulması sağlanan küçük boyutlu özellik haritalarından ve orijinal görüntü kodlayıcı tarafından verimli kod çözücü modülü elde edilir. Uzamsal bilgilerin yakalandığı kod çözücü ile daha hızlı ve güçlü bir mimari oluşturulur. (Polat ve Medicine, 2022) Kodlayıcı ve kod çözücü (decoder) yapısı Şekil 3.18.'de verilmiştir.



Şekil 3.18. Kodlayıcı ve kod çözücü yapısı

Bu tez çalışmasında, DeepLabv3+ içine entegre edilerek kullanılan modeller ResNet-18, ResNet-50, MobileNet-V2, Xception, Inception-Resnet-v2 derin öğrenme modelleridir. ResNet, artık değerli nöral ağların (residual neural network) kısaltılmasıdır. ResNet-18, ilk olarak He ve ark. tarafından 2016 yılında gerçekleştirdikleri çalışma ile önerilmiştir (He ve ark., 2016). ResNet-18, 18 katmanlı bir ESA anlamına gelmekte ve 224x224x3 görüntü giriş boyutuna sahiptir. ResNet-50, ilk olarak He ve ark. tarafından 2016 yılında gerçekleştirdikleri çalışma ile önerilmiştir (He ve ark., 2016). ResNet-50, 50 katmanlı ESA anlamına gelmekte ve 224x224x3 boyutunda görüntü girişi özelliğine sahiptir. MobileNet-v2, ilk olarak Sandler ve ark. tarafından 2018 yılında yaptıkları çalışma ile önerilmiştir (Sandler ve ark., 2018). MobileNet-v2, 53 katmanlı ESA olmakta ve 224x224x3 görüntü giriş boyutuna sahiptir. Xception, ilk olarak Chollet ve ark. tarafından 2017 yılında gerçekleştirilen çalışma ile önerilmiştir (Chollet, 2017). Xception, 71 katman derinliğine ve 299x299x3 görüntü giriş boyutuna sahiptir. Inception-ResNet-v2, ilk olarak Szegedy ve ark. tarafından 2017 yılında gerçekleştirdikleri çalışma ile tanıtılmıştır (Szegedy ve ark., 2017). Inception-ResNet-v2, 164 katman derinliğine ve 299x299x3 görüntü giriş boyutuna sahiptir. Bu çalışmada kullanılan derin öğrenme modellerinin hepsi ImageNet veri tabanını üzerinden eğitilmiştir. Modeller bir milyondan fazla görüntü üzerinde eğitilmiş ve bin nesne kategorisinde sınıflandırma yapabilmektedir. MATLAB eğitilmiş olan bu modelleri bize kullanıma hazır olarak sunmaktadır (MathWorks, 2022).

Bu çalışmada, genişletilmiş artık ağların oluşturulması için MATLAB programının *deeplabv3plusLayers* fonksiyonu kullanılmıştır. Fonksiyon girişi üç parametreye sahiptir. Bu parametreler; görüntü boyutu, sınıf sayısı ve kullanılacak olan derin öğrenme modelidir. Görüntü boyutu bütün senaryolar için BT görüntülerinin satır, sütun ve kanal sayısını ifade eden 512x512x3'dür. Sınıf sayısı, her senaryo için anlamsal bölütlemesi gerçekleştirilecek olan bölgelerin sayısıdır. Derin öğrenme modelleri ise senaryoda kullanılacak olan ESA tabanlı ağlardır. DeepLabV3+ modeline derin öğrenme algoritmalarının entegrasyonu için MATLAB programında oluşturulan kod blokları ResNet-18 için Şekil 3.19'da, ResNet-50 için Şekil 3.20'de, MobileNet-v2 için Şekil 3.21'de, Xception için Şekil 3.22'de, Inception-ResNet-v2 için Şekil 3.23'de verilmiştir.

```

goruntuBoyutu = [512 512 3];
sinifSayisi = numel(siniflar);

lgraph = deeplabv3plusLayers(goruntuBoyutu, sinifSayisi, "resnet18");

```

**Şekil 3.19.** Deeplabv3+ modeline ResNet-18'in entegrasyonu için MATLAB kod bloğu

```

goruntuBoyutu = [512 512 3];
sinifSayisi = numel(siniflar);

lgraph = deeplabv3plusLayers(goruntuBoyutu, sinifSayisi, "resnet50");

```

**Şekil 3.20.** Deeplabv3+ modeline ResNet-50'nin entegrasyonu için MATLAB kod bloğu

```

goruntuBoyutu = [512 512 3];
sinifSayisi = numel(siniflar);

lgraph = deeplabv3plusLayers(goruntuBoyutu, sinifSayisi, "mobilenetv2");

```

**Şekil 3.21.** Deeplabv3+ modeline MobileNet-v2'in entegrasyonu için MATLAB kod bloğu

```

goruntuBoyutu = [512 512 3];
sinifSayisi = numel(siniflar);

lgraph = deeplabv3plusLayers(goruntuBoyutu, sinifSayisi, "xception");

```

**Şekil 3.22.** Deeplabv3+ modeline Xception'in entegrasyonu için MATLAB kod bloğu

```

goruntuBoyutu = [512 512 3];
sinifSayisi = numel(siniflar);

lgraph = deeplabv3plusLayers(goruntuBoyutu, sinifSayisi, "inceptionresnetv2");

```

**Şekil 3.23.** Deeplabv3+ modeline Inception-ResNet-v2'in entegrasyonu için MATLAB kod bloğu

### 3.7. Sınıfların Ağırlıklandırılması

Semantik segmentasyon işlemi gerçekleştirilen görüntülerde bulunan sınıfların piksel sayıları arasında çok fazla fark olabilmektedir. Bundan dolayı derin öğrenme eğitim sürecinde piksel sayısı çok fazla olan sınıfa doğru yanlı eğitim meydana gelmektedir. Bu tez çalışmasında sınıf ağırlıklandırma olarak medyan sınıf ağırlıklandırma tekniği kullanılmıştır. Bu teknikte ilk olarak görüntü frekansı bulunmaktadır. Görüntü frekansı her sınıf için ayrı ayrı hesaplanmaktadır. Görüntüdeki bir sınıfın görüntü frekansı sınıfın piksel sayısının görüntüdeki toplam piksel sayısına bölünmesi ile elde edilmektedir. Sınıfın görüntü frekansı Eşitlik 1’de verildiği hesaplanmaktadır.

$$SınıfGörüntüFrekansı = \frac{SınıfPikselSayısı}{ToplamPikselSayısı}$$

(1)

İkinci aşamada sınıfların ağırlık katsayıları bulunmaktadır. Bu katsayılar için her sınıfın ortanca (medyan) görüntü frekansı, sınıfın görüntü frekansına bölünerek bulunmaktadır. Sınıf ağırlık katsayı Eşitlik 2’de verildiği gibi hesaplanmaktadır.

$$SınıfAğırlığı = \frac{Medyan(SınıfGörüntüFrekansı)}{SınıfGörüntüFrekansı}$$

(2)

Son aşamada ise bulunan sınıf ağırlıkları, piksel sınıflandırma katmanı “*pixelClassificationLayer*” fonksiyonuna parametre girişi olarak verilmektedir (Mathworks, 2017).

### 3.8. Hiper Parametreler

Derin öğrenme modelleri tasarlanırken, modelde kullanılan algoritmaların performansını belirleyen bazı parametreler bulunmaktadır. Bu parametreler, algoritmayı tasarlayan kişi tarafından probleme, veri setine veya kullanılan sisteme göre tercih edilebilecek değişkenlerdir. Bu değişkenlere hiper parametre adı verilmektedir. Bu

çalışmada eğitim için kullanılan hiper parametreler bütün derin öğrenme modellerine göre Çizelge 3.3’de verilmiştir.

**Çizelge 3.3.** Derin öğrenme modellerinde eğitim için kullanılan hiper parametreler


Hiper Parametreler	ResNet18	ResNet50	MobileNet-v2	Xception	Inception-ResNet-v2
Momentum	0.9000	0.9000	0.9000	0.9000	0.9000
InitialLearnRate	1.0000e-03	1.0000e-03	1.0000e-03	1.0000e-03	1.0000e-03
LearnRateSchedule	piecewise	piecewise	piecewise	piecewise	piecewise
LearnRateDropFactor	0.3000	0.3000	0.3000	0.3000	0.3000
LearnRateDropPeriod	10	10	10	10	10
L2Regularization	0.0050	0.0050	0.0050	0.0050	0.0050
GradientThresholdMethod	l2norm	l2norm	l2norm	l2norm	l2norm
GradientThreshold	Inf	Inf	Inf	Inf	Inf
MaxEpochs	5	4	5	5	5
MiniBatchSize	8	4	4	2	2
Verbose	1	1	1	1	1
VerboseFrequency	2	2	2	2	2
ValidationFrequency	50	50	50	50	50
ValidationPatience	4	4	4	4	4
Shuffle	every epoch	every epoch	every epoch	every epoch	every epoch
ExecutionEnvironment	GPU	GPU	GPU	GPU	GPU
Plots	Training-progress	Training-progress	Training-progress	Training-progress	Training-progress
SequenceLength	longest	longest	longest	longest	longest
SequencePaddingValue	0	0	0	0	0
SequencePaddingDirection	right	right	right	right	right
DispatchInBackground	0	0	0	0	0
ResetInputNormalization	1	1	1	1	1
BatchNormalizationStatistics	population	population	population	population	population

Bu çalışma için kullanılan bilgisayar sistemindeki GPU’nun (Graphics Processing Unit) düşük hafızaya sahip olması nedeniyle gerçekleştirilen bazı eğitim işlemlerinde düşük hafıza (low memory) hatası alınmıştır. Bu hatanın çözümü için *maxepochs* ve *minibathsize* değerlerinde modele göre değişiklikler yapılmıştır. Diğer bütün parametreler varsayılan olarak girilmiştir. Semantik segmentasyon denemeleri için Intel(R) Core(TM) i5-10300H CPU işlemci, 4GB NVIDIA GeForce GTX 1650 ekran kartı ve 16 GB RAM hafıza boyutuna sahip dizüstü bilgisayar kullanılmıştır. Modeller için yazılan kod parçaları MATLAB programının 2021a sürümündeki derin öğrenme kütüphanesi fonksiyonları kullanılarak geliştirilmiştir.

### 3.9. Performans Kriterleri

Bu tez çalışmasında, maske (ground truth) piksel bölgeleri ile eğitim sonucu elde edilen sınıfların piksel bölgeleri karşılaştırılarak derin öğrenme modellerinin performans sonuçları hesaplanmıştır. Karşılaştırma için MATLAB programında bulunan “*evaluateSemanticSegmentation*” fonksiyonu kullanılarak test verileri analiz edilmiştir. Bu fonksiyon çıktı olarak, test sonuçlarının “*confusionmatrix*”, “*normalizedconfusionmatrix*”, “*datasetmetrics*”, “*classmetrics*”, “*imagemetrics*” performans değerlerini otomatik bir şekilde vermektedir. Tez çalışmasındaki semantik segmentasyon performans sonuçları “*datametrics*” ve “*classmetrics*” çıktıları üzerinden değerlendirilmiştir. *Datametrics* içerisinde küresel doğruluk (global accuracy), ortalama doğruluk (mean accuracy), ortalama IoU (mean IoU), ağırlıklı IoU (weighted IoU), ortalama BF skor (mean BF score) performans metrikleri bulunmaktadır. *Classmetrics* içerisinde sınıflara göre doğruluk (accuracy), IoU (jaccard katsayısı), ortalama BF skor metrikleri bulunmaktadır.

Bu değerler, semantik segmentasyon sonucu elde edilen sonuç kümesi ve radyologlar tarafından oluşturulan maske bölgelerinin kesin referans kümesi olarak alınarak üst üste çakıştırılması sonucu ilgili bölgelerdeki piksel sayıları hesaplanarak elde edilmektedir. Kesin referans kümesi ve sonuç kümesinin örtüşme durumu Şekil 3.24’de verilmiştir.



Şekil 3.24. Sonuçların kesin referans ile örtüşme durumu

Şekil 3.24’de gösterilen bölgelerin açıklamaları ve performans kriterlerinin hesaplanması aşağıda verilmektedir:

Sonuç Kümesi: Semantik segmentasyon işleminde derin öğrenme ağının sınıf için tahmin ettiği piksel kümesi

Kesin Referans Kümesi: Semantik segmentasyon işleminde derin öğrenme ağının sınıf için tahmin etmesi gereken piksel kümesi

Doğru Pozitif (DP): Derin öğrenme ağı tarafından semantik segmentasyonu gerçekleştirilen sınıfın, doğru tahmin edilen piksel sayısı

Yanlış Pozitif (YP): Derin öğrenme ağı tarafından semantik segmentasyonu gerçekleştirilen sınıfın, yanlış tahmin edilen piksel sayısı

Yanlış Negatif (YN): Derin öğrenme ağı tarafından semantik segmentasyonu gerçekleştirilen sınıfın, gerçekte sınıfın içinde tahmin edilmesi gereken fakat tahmin edilemeyen piksel sayısı

Doğruluk: Doğruluk her sınıf için tanımlanmış piksellerin yüzdesini göstermektedir. Algoritmanın sınıflardaki pikselleri ne kadar doğru tahmin edebildiğini ölçmek için kullanılır. Her sınıf için doğruluk oranı kesin referans kümesine göre sınıflandırılmış piksellerin o sınıftaki toplam piksel sayısına oranıdır (MATLAB, 2017a). Doğruluk performans metriği Eşitlik 3’de verildiği gibi hesaplanmaktadır.

$$Doğruluk = \frac{DP}{DP + YN} \quad (3)$$

Ortalama doğruluk: Tüm sınıfların doğruluk değerlerinin ortalamasıdır.

Küresel doğruluk: Görüntüdeki sınıflara özel olarak bakılmaksızın doğru sınıflandırılmış piksellerin toplam piksel sayısına oranıdır.

IoU: Jaccard benzerlik katsayısı olarak da bilinen Intersection of Union (IoU) en yaygın kullanılan metriklerden biri olmakla birlikte yanlış pozitifleri cezalandıran istatistiksel bir doğruluk ölçütüdür.

IoU özellikle, belirli bir veri kümesinde sınıf algılama kesinliğini belirlemek için kullanılan tahmin metriğidir (Khalifa ve ark., 2021). IoU, Eşitlik 4’de verildiği gibi hesaplanmaktadır.

$$IoU = \frac{DP}{DP + YP + YN} \quad (4)$$

Ortalama IoU: Önce IoU'ları sayan ve ardından ortalamalarını hesaplayan semantik segmentasyon için yaygın olarak kullanılan bir ölçüttür (Khalifa ve ark., 2021).

Ağırlıklı IoU: Her sınıfın ortalama IoU'su, o sınıftaki piksel sayısı ile ağırlıklandırılarak elde edilen performans değerlendirme metriğidir. Küçük sınıflardaki hataların toplam hata oranı üzerindeki etkisini azaltmak için kullanılır.

BF (F1) Skoru: Sınır F1 kontur eşleştirme puanının kısaltılmasıdır. Her bir sınıfın tahmin edilen sınırının gerçek sınıra ne kadar yakın tahmin edildiğini belirlemek için kullanılır (Menteşe ve Hançer, 2020). BF (F1) skoru Eşitlik 5'de verildiği gibi hesaplanmaktadır.

$$BF(F1)Skor = \frac{DP}{DP + \frac{1}{2}(YP + YN)}$$

(5)

Ortalama BF skoru: Görüntülerdeki tüm sınıfların BF skoru ortalamasıdır.

Bu tez çalışmasında, gerçekleştirilmiş semantik segmentasyon işlemlerinin performanslarını değerlendirmek için; doğruluk, küresel doğruluk, ortalama doğruluk, ortalama IoU, ağırlıklı IoU, ortalama BF puanı ve IoU metrikleri kullanılmıştır.

#### 4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA


Bu bölümde, DeepLabv3+ modelinin beş farklı derin öğrenme algoritmasına entegrasyonu ile sekiz farklı senaryo için gerçekleştirilen 40 farklı denemenin sonuçları verilmiştir. Elde edilen sonuçlar performans kriterleri ile değerlendirilerek tartışılmıştır.

##### 4.1. Eşit Etiket Değerli Akciğerlerin Semantik Segmentasyon Sonuçları

Eşit etiket değerlerine sahip akciğer bölgelerinin semantik segmentasyonu için yapılan denemelerde akciğer ve arka plan olmak üzere iki sınıf bulunmaktadır. Akciğer bölgelerine 255 etiket değeri ve arka plana 0 etiket değeri atanmıştır. İki sınıfın medyan frekans dengeleme ağırlık katsayılarının bulunması için sınıfların piksel sayıları ve görüntülerdeki toplam piksel sayısı hesaplanmıştır. Çizelge 4.1’de sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları verilmiştir. Şekil 4.1’de sınıfların piksel frekans grafiği verilmiştir.


Çizelge 4.1. Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları

Sınıflar	Piksel Sayısı	Toplam Piksel Sayısı
Akciğer	4.79E+07	3.35E+08
Arka plan	2.87E+08	3.35E+08

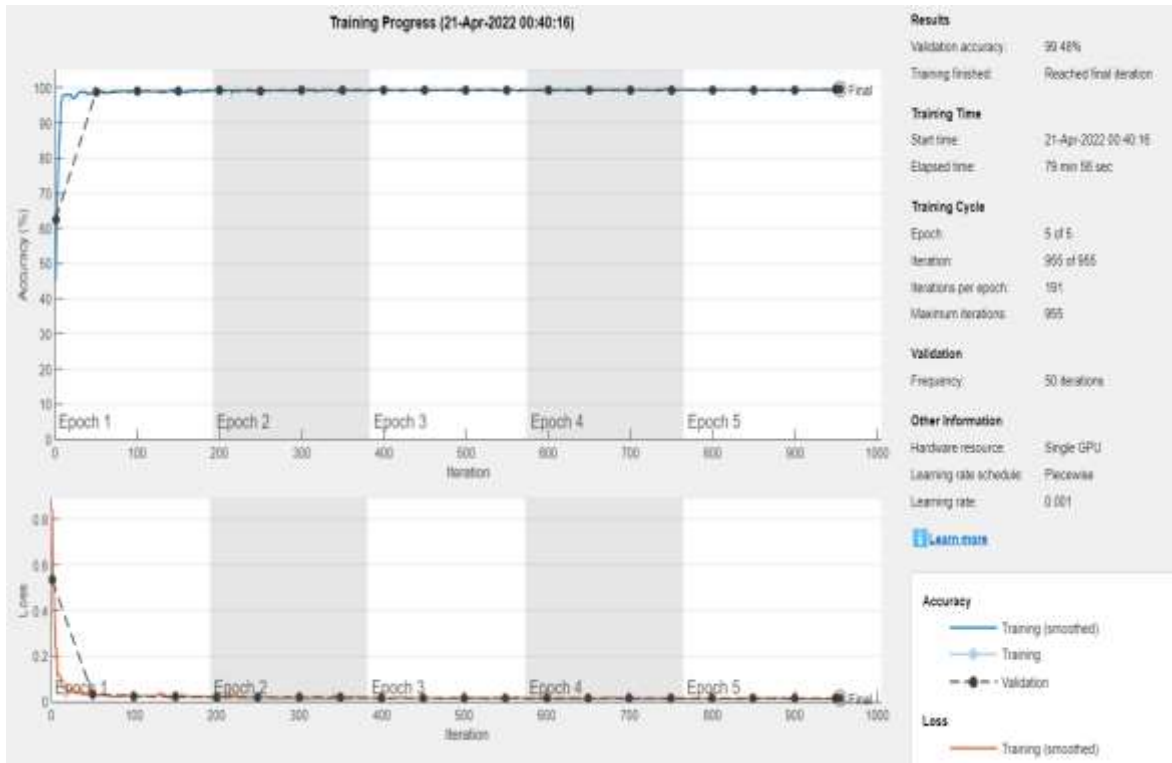


Şekil 4.1. Sınıfların piksel frekans grafiği


Medyan frekans dengeleme denklemi kullanılarak akciğer için 3.4977 ve arka plan için 0.5834 ağırlık katsayıları elde edilmiştir. Bu ağırlıklar “*pixelClassificationLayer*” fonksiyonuna parametre olarak verilerek model sınıflandırma katmanı düzenlemiştir. Veriler random bir şekilde %60 eğitim, %20 doğrulama, %20 test olarak ayrılmıştır. Veri artırma ile resimler çoğaltılmış, “*gray2rgb*” parametresi ile görüntüler üç kanallı olarak hazırlanmıştır. Beş farklı derin öğrenme modeli “*deeplabv3plusLayers*” fonksiyonuna giriş parametresi olarak verilmiş ve beş farklı eğitim işlemi gerçekleştirilmiştir. Eğitim sonucu elde edilen epok sayısı ve iterasyona göre elde edilen eğitim doğruluk ve kayıp grafiği ResNet-18 için Şekil 4.2’de, ResNet-50 için Şekil 4.3’de, MobileNet-v2 için Şekil 4.4’de, Xception için Şekil 4.5’de ve Inception-ResNet-v2 için Şekil 4.6’da verilmiştir.



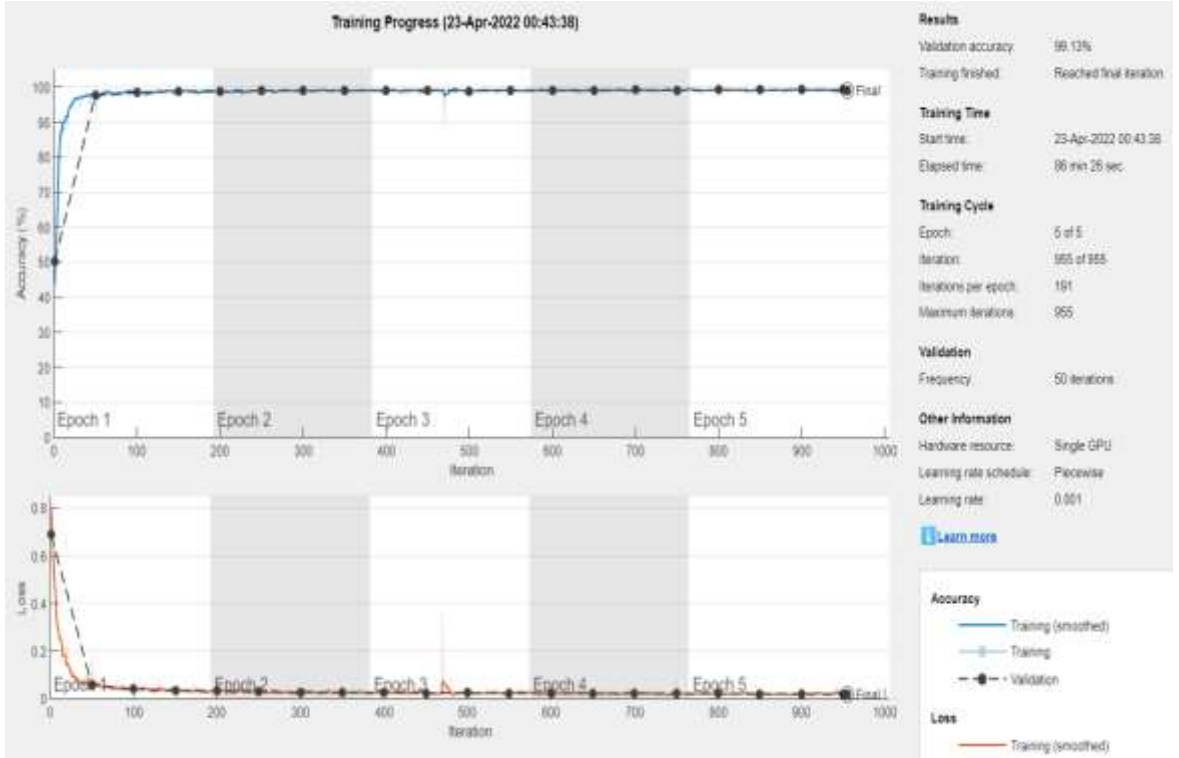
Şekil 4.2. ResNet-18 için eğitim doğruluk ve kayıp grafiği



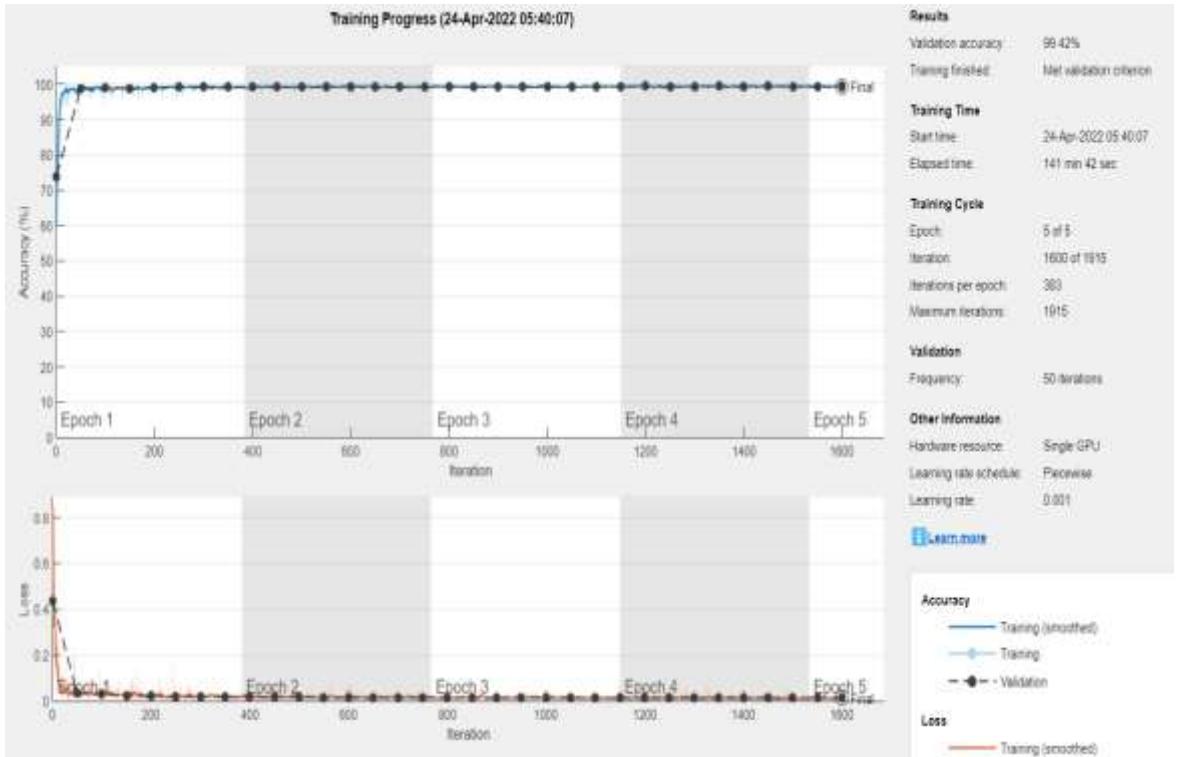
Şekil 4.3. ResNet-50 için eğitim doğruluk ve kayıp grafiği



Şekil 4.4. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği



Şekil 4.5. Xception için eğitim doğruluk ve kayıp fonksiyonu



Şekil 4.6. Inception-ResNet-v2 için eğitim doğruluk ve kayıp fonksiyonu

Eğitim işlemi sonucunda elde edilen model ağırlıkları ile sistemlerin daha önceden görmediği %20 test verisi kullanılarak semantik segmentasyon işlemi

gerçekleştirilmiştir. İşlem sonucu hesaplanan performans kriterleri Çizelge 4.2’de verilmiştir.

**Çizelge 4.2.** Akciğerlerin eşit etiket değerine sahip olduğu segmentasyon sonuçları


Derin Öğrenme Modeli	Küresel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklı IoU	Ortalama BF Puanı
ResNet-18	0.9927	0.9938	0.9705	0.9858	0.9757
ResNet-50	0.9949	0.9951	0.9789	0.9899	0.9888
MobileNet-v2	0.9941	0.9926	0.9758	0.9884	0.9766
Xception	0.9913	0.9930	0.9651	0.9831	0.9698
Inception-ResNet-v2	0.9943	0.9952	0.9766	0.9888	0.9864

Sınıfların segmentasyon işlemi sonucu performans değerleri Çizelge 4.3’de verilmiştir.


**Çizelge 4.3.** Akciğer ve arka plan sınıflarının ayrı şekilde segmentasyon işlem sonuçları

Derin Öğrenme Modeli	Sınıflar	Doğruluk	IoU	Ortalama BF Puanı
ResNet-18	Akciğerler	0.9952	0.9494	0.9642
	Arka Plan	0.9923	0.9916	0.9871
ResNet-50	Akciğerler	0.9955	0.9637	0.9836
	Arka Plan	0.9948	0.9940	0.9940
MobileNet-v2	Akciğerler	0.9906	0.9584	0.9653
	Arka Plan	0.9947	0.9932	0.9879
Xception	Akciğerler	0.9954	0.9402	0.9557
	Arka Plan	0.9907	0.9900	0.9839
Inception-ResNet-v2	Akciğerler	0.9966	0.9598	0.9803
	Arka Plan	0.9939	0.9934	0.9925


Test sonuçlarından 1 numaralı görüntünün 60. kesitindeki akciğer etiketi maskesi Şekil 4.7a’da, üst üste çakıştırılması Şekil 4.7b’de verilmiştir. Bu görüntünün eğitilen modele test olarak verilmesi ile elde edilen semantik segmentasyon sonuçları ResNet-18 için Şekil 4.8’de, ResNet-50 için Şekil 4.9’da, MobileNet-v2 için Şekil 4.10’da, Xception için Şekil 4.11’de, Inception-ResNet-v2 için Şekil 4.12’de verilmiştir.




**Şekil 4.7.** (a) Akciğerlerin eşit etiket değerine sahip olduğu 60 numaralı maske (b) Orijinal görüntü ile maskenin üst üste çakıştırılması ile oluşan görüntü



**Şekil 4.8.** ResNet-18 için semantik segmentasyon




**Şekil 4.9.** ResNet-50 için semantik segmentasyon



Şekil 4.10. MobileNet-v2 için semantik segmentasyon



Şekil 4.11. Xception için semantik segmentasyon



Şekil 4.12. InceptionResNet-v2 için semantik segmentasyon


Tüm modellerin eğitim ve test işlemlerinin sonucu birbirine yakın değerler vermektedir. Ağların doğruluk grafikleri genellikle ilk epokta hızlı bir şekilde yükselmekte, kayıp grafiği ise hızlı bir şekilde düşmektedir. Bu sonuçlar semantik segmentasyon işleminin başarılı bir eğitim süreci geçirdiğini göstermektedir. Test sonuçları incelendiğinde eşit etiket değerine sahip akciğerlerin segmentasyonu tüm ağlarda 0.95 üzerinde yüksek performans değerleri vermektedir. Ancak ResNet-50 ağı performans olarak diğer ağlardan biraz daha başarılı sonuçları ile öne çıkmaktadır. Eğitimi tamamlanmış ResNet-50 modeline verilen test görüntülerinin ortalama BF skoru 0.9836 ile akciğer sınırlarını başarılı bir şekilde tahmin ettiği, 0.9937 IoU değeri ile yüksek sınıf algılama hassasiyetine ulaştığı, 0.9955 doğruluk oranı ile güçlü piksel sınıflandırma performansı elde ettiği izlenmektedir. Bu sonuçlar COVID-19 tanılı BT görüntülerinde dokuyu değiştiren pnömoni bölgeleri olmasına rağmen eşit etiket değerine sahip akciğer bölgelerinin semantik segmentasyonun yüksek oranlarda başarılı sonuçlar verdiğini göstermektedir.

#### 4.2. İki Farklı Etiket Değerli Akciğerlerin Semantik Segmentasyon Sonuçları

Farklı etiket değerlerine sahip akciğer bölgelerinin semantik segmentasyonu için yapılan denemelerde sağ akciğer, sol akciğer ve arka plan olmak üzere üç sınıf bulunmaktadır. Sol akciğere 254 etiket değeri, sağ akciğere 127 etiket değeri ve arka plana 0 etiket değeri atanmıştır. Üç sınıfın medyan frekans dengeleme ağırlık katsayılarının bulunması için sınıfların piksel sayıları ve görüntülerdeki toplam piksel sayısı hesaplanmıştır. Çizelge 4.4’de sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları verilmiştir. Şekil 4.13’de sınıfların piksel frekans grafiği verilmiştir.


**Çizelge 4.4.** Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları

Sınıflar	Piksel Sayısı	Toplam Piksel Sayısı
Sol Akciğer	2.63E+07	3.35E+08
Sağ Akciğer	2.16E+07	3.35E+08
Arka Plan	2.87E+08	3.35E+08




Şekil 4.13. Sınıfların piksel frekans grafiği


Medyan frekans dengeleme denklemi kullanılarak sol akciğer için 1.000, sağ akciğer için 1.2192, arka plan için 0.0916 ağırlık katsayıları elde edilmiştir. Bu ağırlıklar “*pixelClassificationLayer*” fonksiyonuna parametre olarak verilerek model sınıflandırma katmanı düzenlemiştir. Veriler random bir şekilde %60 eğitim, %20 doğrulama, %20 test olarak ayrılmıştır. Veri artırma ile resimler çoğaltılmış, “*gray2rgb*” parametresi ile görüntüler üç kanallı olarak hazırlanmıştır. Beş farklı derin öğrenme modeli “*deeplabv3plusLayers*” fonksiyonuna giriş parametresi olarak verilmiş ve beş farklı eğitim işlemi gerçekleştirilmiştir. Eğitim sonucu elde edilen epok sayısı ve iterasyona göre elde edilen eğitim doğruluk ve kayıp grafiği ResNet-18 için Şekil 4.14’de, ResNet-50 için Şekil 4.15’de, MobileNet-v2 için Şekil 4.16’da, Xception için Şekil 4.17’de ve Inception-ResNet-v2 için Şekil 4.18’de verilmiştir.




Şekil 4.14. ResNet-18 için eğitim doğruluk ve kayıp grafiği



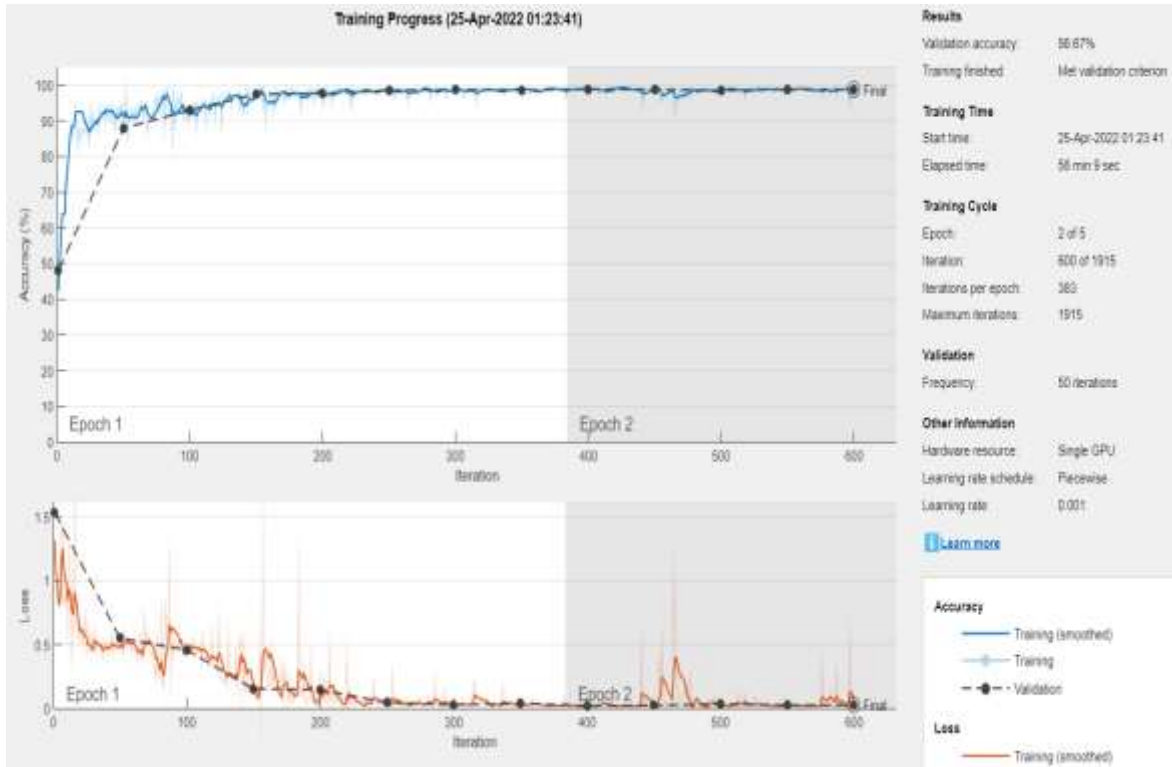
Şekil 4.15. ResNet-50 için eğitim doğruluk ve kayıp grafiği



Şekil 4.16. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği



Şekil 4.17. Xception için eğitim doğruluk ve kayıp grafiği



**Şekil 4.18.** Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği

Eğitim işlemi sonucunda elde edilen model ağırlıkları ile sistemlerin daha önceden görmediği %20 test verisi kullanılarak semantik segmentasyon işlemi gerçekleştirilmiştir. İşlem sonucu hesaplanan performans kriterleri Çizelge 4.5’de verilmiştir.

**Çizelge 4.5.** Akciğerlerin farklı etiket değerine sahip olduğu segmentasyon sonuçları


Derin Öğrenme Modeli	Küresel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklı IoU	Ortalama BF Puanı
ResNet-18	0.9900	0.9934	0.9495	0.9807	0.9570
ResNet-50	0.9927	0.9948	0.9626	0.9859	0.9764
MobileNet-v2	0.9890	0.9932	0.9449	0.9789	0.9440
Xception	0.9861	0.9825	0.9240	0.9736	0.9073
Inception-ResNet-v2	0.9866	0.9926	0.9359	0.9744	0.9283

Sınıfların segmentasyon işlemi sonucu performans değerleri Çizelge 4.6’da verilmiştir.


**Çizelge 4.6.** Sağ akciğer, sol akciğer ve arka plan sınıflarının segmentasyon sonuçları

Derin Öğrenme Modeli	Sınıflar	Doğruluk	IoU	Ortalama BF Puanı
ResNet-18	Sağ akciğer	0.9938	0.9273	0.9482
	Sol akciğer	0.9974	0.9326	0.9403
	Arka plan	0.9891	0.9887	0.9824
ResNet-50	Sağ akciğer	0.9969	0.9414	0.9681
	Sol akciğer	0.9954	0.9547	0.9697
	Arka plan	0.9922	0.9918	0.9913
MobileNet-v2	Sağ akciğer	0.9953	0.9197	0.9356
	Sol akciğer	0.9963	0.9275	0.9200
	Arka plan	0.9879	0.9876	0.9765
Xception	Sağ akciğer	0.9750	0.8941	0.8910
	Sol akciğer	0.9856	0.8913	0.8574
	Arka plan	0.9869	0.9865	0.9734
Inception-ResNet-v2	Sağ akciğer	0.9937	0.9282	0.9451
	Sol akciğer	0.9991	0.8948	0.8719
	Arka plan	0.9850	0.9847	0.9679


Test sonuçlarından 1 numaralı görüntünün 60. kesitindeki akciğer etiketi maskesi Şekil 4.19a'da, üst üste çakıştırılması Şekil 4.19b'de verilmiştir. Bu görüntünün eğitilen modele test olarak verilmesi ile elde edilen semantik segmentasyon sonuçları ResNet-18 için Şekil 4.20'de, ResNet-50 için Şekil 4.21'de, MobileNet-v2 için Şekil 4.22'de, Xception için Şekil 4.23'de, Inception-ResNet-v2 için Şekil 4.24'de verilmiştir.




**Şekil 4.19.** (a) Akciğerlerin farklı etiket değerine sahip olduğu 60 numaralı maske (b) Orijinal görüntü ile maskenin üst üste çakıştırılması ile oluşan görüntü




Şekil 4.20. ResNet-18 için semantik segmentasyon




Şekil 4.21. ResNet-50 için semantik segmentasyon işlemi



Şekil 4.22. MobileNet-v2 için semantik segmentasyon işlemi



Şekil 4.23. Xception için semantik segmentasyon



Şekil 4.24. Inception-ResNet-v2 için semantik segmentasyon

Tüm modellerin eğitim ve test işlemlerinin sonucu birbirine yakın değerler vermektedir. Ağların doğruluk grafikleri genellikle ilk epokta hızlı bir şekilde yükselmekte, kayıp grafiği ise hızlı bir şekilde düşmektedir. Bu sonuçlar semantik segmentasyon işleminin başarılı bir eğitim süreci geçirdiğini göstermektedir. Test sonuçları incelendiğinde farklı etiket değerlerine sahip akciğerlerin segmentasyonu tüm ağlarda 0.90 üzerinde yüksek performans değerleri vermektedir. Ancak ResNet-50 ağı performans olarak diğer ağlardan biraz daha başarılı sonuçları ile öne çıkmaktadır. Eğitimi tamamlanmış ResNet-50 modeline verilen test görüntülerinin ortalama BF skoru sağ akciğer için 0.9681 ve sol akciğer için 0.9697 ile akciğer sınırlarını başarılı bir şekilde tahmin ettiği, IoU değeri sağ akciğer için 0.9414 ve sol akciğer için 0.9547


ile yüksek sınıf algılama hassasiyetine ulaştığı, doğruluk oranı sağ akciğer için 0.9969 ve sol akciğer için 0.9954 ile güçlü piksel sınıflandırma performansı elde ettiği izlenmektedir. Bu sonuçlar COVID-19 tanılı BT görüntülerinde dokuyu değiştiren pnömoni bölgeleri olmasına rağmen farklı etiket değerine sahip akciğer bölgelerinin semantik segmentasyonun yüksek oranlarda başarılı sonuçlar verdiğini göstermektedir. Fakat tek etiket değerine sahip akciğer semantik segmentasyonu, iki etiket değerine sahip akciğer semantik segmentasyonuna kıyasla daha başarılı sonuçlar elde etmiştir.

### 4.3. Eşit Etiket Değerli Pnömoni Semantik Segmentasyon Sonuçları

Eşit etiket değerlerine sahip pnömoni bölgelerinin semantik segmentasyonu için yapılan denemelerde pnömoni ve arka plan olmak üzere iki sınıf bulunmaktadır. Pnömoni bölgelerine 50 etiket değeri ve arka plana ise 0 etiket değeri atanmıştır. İki sınıfın medyan frekans dengeleme ağırlık katsayılarının bulunması için sınıfların piksel sayıları ve görüntülerdeki toplam piksel sayısı hesaplanmıştır. Çizelge 4.7’de sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları verilmiştir. Şekil 4.25’de sınıfların piksel frekans grafiği verilmiştir.


**Çizelge 4.7.** Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları

Sınıflar	Piksel Sayısı	Toplam Piksel Sayısı
Pnömoni	4.47E+06	3.35E+08
Arka plan	3.30E+08	3.35E+08




**Şekil 4.25.** Sınıfların piksel frekans grafiği


Medyan frekans dengeleme denklemi kullanılarak pnömoni için 37.4361 ve arka plan için 0.5068 ağırlık katsayıları elde edilmiştir. Bu ağırlıklar “*pixelClassificationLayer*” fonksiyonuna parametre olarak verilerek model sınıflandırma katmanı düzenlemiştir. Veriler random bir şekilde %60 eğitim, %20 doğrulama, %20 test olarak ayrılmıştır. Veri artırma ile resimler çoğaltılmış, “*gray2rgb*” parametresi ile görüntüler üç kanallı olarak hazırlanmıştır. Beş farklı derin öğrenme modeli “*deeplabv3plusLayers*” fonksiyonuna giriş parametresi olarak verilmiş ve beş farklı eğitim işlemi gerçekleştirilmiştir. Eğitim sonucu elde edilen epok sayısı ve iterasyona göre elde edilen eğitim doğruluk ve kayıp grafiği ResNet-18 için Şekil 4.26’da, ResNet-50 için Şekil 4.27’de, MobileNet-v2 için Şekil 4.28’de, Xception için Şekil 4.29’da ve Inception-ResNet-v2 için Şekil 4.30’da verilmiştir.




Şekil 4.26. ResNet-18 için eğitim doğruluk ve kayıp grafiği




Şekil 4.27. ResNet-50 için eğitim doğruluk ve kayıp grafiği



Şekil 4.28. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği



Şekil 4.29. Xception için eğitim doğruluk ve kayıp grafiği



Şekil 4.30. Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği

Eğitim işlemi sonucunda elde edilen model ağırlıkları ile sistemlerin daha önceden görmediği %20 test verisi kullanılarak semantik segmentasyon işlemi

gerçekleştirilmiştir. İşlem sonucu hesaplanan performans kriterleri Çizelge 4.8’de verilmiştir.

**Çizelge 4.8.** Pnömonili bölgenin eşit etiket değerine sahip olduğu segmentasyon sonuçları


Derin Öğrenme Modeli	Küresel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklı IoU	Ortalama BF Puanı
ResNet-18	0.9863	0.9840	0.7354	0.9795	0.6908
ResNet-50	0.9907	0.9832	0.7848	0.9851	0.7991
MobileNet-v2	0.9818	0.9846	0.6992	0.9741	0.6040
Xception	0.9872	0.9778	0.7433	0.9807	0.7339
İnception-ResNet-v2	0.9817	0.9832	0.6978	0.9739	0.6489

Sınıfların segmentasyon işlemi sonucu performans değerleri Çizelge 4.9’da verilmiştir.


**Çizelge 4.9.** Pnömonili bölge ve arka plan sınıflarının segmentasyon sonuçları

Derin Öğrenme Modeli	Sınıflar	Doğruluk	IoU	Ortalama BF Puanı
ResNet-18	Pnömoni	0.9816	0.4847	0.4837
	Arka plan	0.9863	0.9861	0.8979
ResNet-50	Pnömoni	0.9756	0.5791	0.6592
	Arka plan	0.9909	0.9905	0.9390
MobileNet-v2	Pnömoni	0.9874	0.4168	0.3456
	Arka plan	0.9817	0.9816	0.8623
Xception	Pnömoni	0.9681	0.4996	0.5581
	Arka plan	0.9875	0.9871	0.9097
Inception-ResNet-v2	Pnömoni	0.9848	0.4142	0.4169
	Arka plan	0.9816	0.9814	0.8808


Test sonuçlarından 1 numaralı görüntünün 60. kesitindeki pnömoni etiketi maskesi Şekil 4.31a’da, üst üste çakıştırılması Şekil 4.31b’de verilmiştir. Bu görüntünün eğitilen modele test olarak verilmesi ile elde edilen semantik segmentasyon sonuçları ResNet-18 için Şekil 4.32’de, ResNet-50 için Şekil 4.33’de, MobileNet-v2 için Şekil 4.34’de, Xception için Şekil 4.35’de, Inception-ResNet-v2 için Şekil 4.36’da verilmiştir.




**Şekil 4.31.** (a) Pnömoninin eşit etiket değerine sahip olduğu 60 numaralı maske (b) Orijinal görüntü ile maskenin üst üste çakıştırılması ile oluşan görüntü




**Şekil 4.32.** ResNet-18 için semantik segmentasyon




**Şekil 4.33.** ResNet-50 için semantik segmentasyon



Şekil 4.34. MobileNet-v2 için semantik segmentasyon



Şekil 4.35. Xception için semantik segmentasyon



Şekil 4.36. Inception-ResNet-v2 için semantik segmentasyon


Tüm modellerin eğitim ve test işlemleri gerçekleştirilmiştir. Ağların doğruluk grafikleri genellikle ilk epokta hızlı bir şekilde yükselmekte, kayıp grafiği ise hızlı bir şekilde düşmektedir. Bu sonuçlar semantik segmentasyon işleminin başarılı bir eğitim süreci geçirdiğini göstermektedir. Test sonuçları incelendiğinde eşit etiket değerine sahip pnömoni bölgelerinin semantik segmentasyonu tüm ağlarda 0.34 üzerinde performans değerleri vermektedir. Ancak ResNet-50 ağı performans olarak diğer ağlardan daha başarılı sonuçları ile öne çıkmaktadır. Eğitimi tamamlanmış ResNet-50 modeline verilen test görüntülerinin ortalama BF skoru 0.6592 ile pnömoni sınırlarını ettiği, 0.5791 IOU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9756 doğruluk oranı ile piksel sınıflandırma performansı elde ettiği izlenmektedir. Bu sonuçlar neticesinde ResNet-50 derin öğrenme modeli, COVID-19 tanılı BT görüntülerinde eşit etiket değerine sahip pnömoni bölgeleri semantik segmentasyonun da literatür çalışmalarına kıyasla başarılı sonuçlar verdiği gözlemlenmektedir.

#### 4.4. Farklı Etiket Değerli Pnömoni Semantik Segmentasyon Sonuçları

Farklı etiket değerlerine sahip pnömoni bölgelerinin semantik segmentasyonu için yapılan denemelerde sağ pnömoni, sol pnömoni ve arka plan olmak üzere üç sınıf bulunmaktadır. Sağ pnömoniye 57 etiket değeri, sol pnömoniye 184 etiket değeri ve arka plana 0 etiket değeri atanmıştır. Üç sınıfın medyan frekans dengeleme ağırlık katsayılarının bulunması için sınıfların piksel sayıları ve görüntülerdeki toplam piksel sayısı hesaplanmıştır. Çizelge 4.10'de sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları verilmiştir. Şekil 4.37'de sınıfların piksel frekans grafiği verilmiştir.


**Çizelge 4.10.** Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları

Sınıflar	Piksel Sayısı	Toplam Piksel Sayısı
Sağ pnömoni	1.76E+06	2.96E+08
Sol pnömoni	2.70E+06	2.96E+08
Arka plan	3.30E+08	3.35E+08

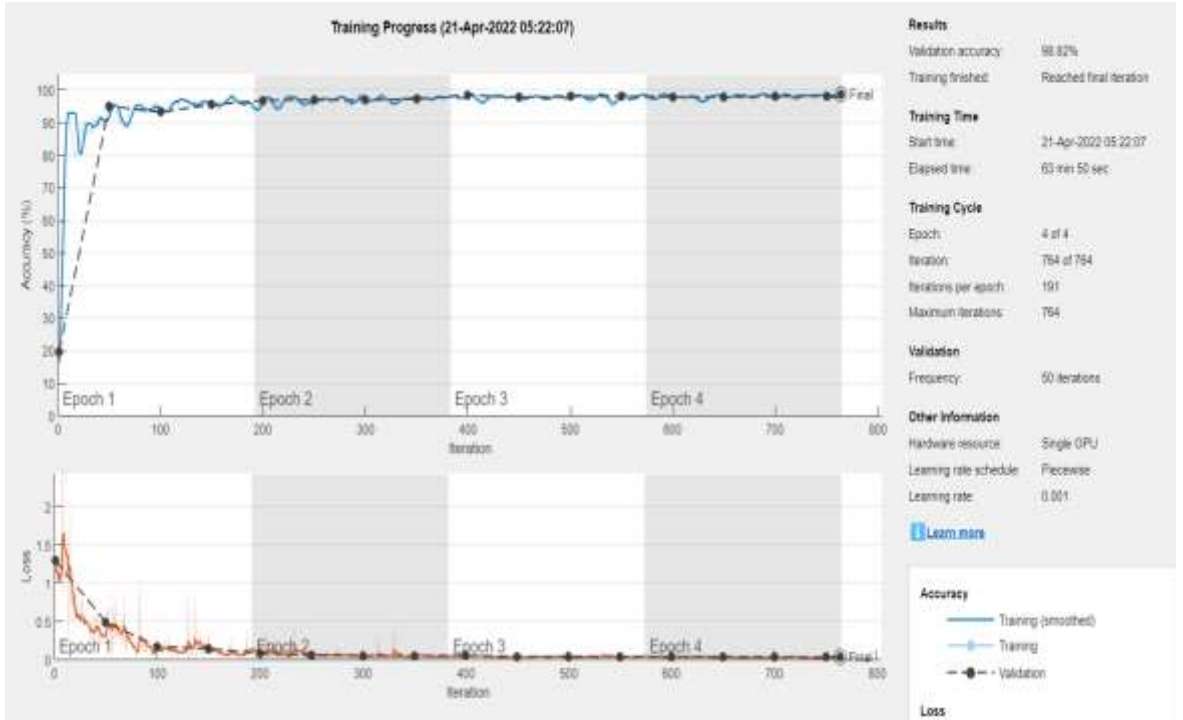


Şekil 4.37. Sınıfların piksel frekans grafiği


Medyan frekans dengeleme denklemi kullanılarak sağ pnömoni için 1.1987, sol pnömoni için 1.0000 ve arka plan için 0.0093 ağırlık katsayıları elde edilmiştir. Bu ağırlıklar “*pixelClassificationLayer*” fonksiyonuna parametre olarak verilerek model sınıflandırma katmanı düzenlemiştir. Veriler random bir şekilde %60 eğitim, %20 doğrulama, %20 test olarak ayrılmıştır. Veri artırma ile resimler çoğaltılmış, “*gray2rgb*” parametresi ile görüntüler üç kanallı olarak hazırlanmıştır. Beş farklı derin öğrenme modeli “*deeplabv3plusLayers*” fonksiyonuna giriş parametresi olarak verilmiş ve beş farklı eğitim işlemi gerçekleştirilmiştir. Eğitim sonucu elde edilen epok sayısı ve iterasyona göre elde edilen eğitim doğruluk ve kayıp grafiği ResNet-18 için Şekil 4.38’de, ResNet-50 için Şekil 4.39’da, MobileNet-v2 için Şekil 4.40’da, Xception için Şekil 4.41’de ve Inception-ResNet-v2 için Şekil 4.42’de verilmiştir.




Şekil 4.38. ResNet-18 için eğitim doğruluk ve kayıp grafiği




Şekil 4.39. ResNet-50 için eğitim doğruluk ve kayıp grafiği



Şekil 4.40. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği



Şekil 4.41. Xception için eğitim doğruluk ve kayıp grafiği



Şekil 4.42. Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği

Eğitim işlemi sonucunda elde edilen model ağırlıkları ile sistemlerin daha önceden görmediği %20 test verisi kullanılarak semantik segmentasyon işlemi gerçekleştirilmiştir. İşlem sonucu hesaplanan performans kriterleri Çizelge 4.11’de verilmiştir.

Çizelge 4.11. Pnömonili bölgelerin farklı etiket değerine sahip olduğu segmentasyon sonuçları


Derin Öğrenme Modeli	Küresel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklı IoU	Ortalama BF Puanı
ResNet-18	0.9861	0.9830	0.6479	0.9792	0.6571
ResNet-50	0.9888	0.9858	0.6899	0.9827	0.7231
MobileNet-v2	0.9776	0.9866	0.5700	0.9692	0.5061
Xception	0.9813	0.9801	0.5990	0.9735	0.6286
Inception-ResNet-v2	0.9709	0.9523	0.5189	0.9625	0.4839

Grupların semantik segmentasyon işlemi performans değerleri Çizelge 4.12’de verilmiştir.


**Çizelge 4.12.** Sağ pnömoni, sol pnömoni ve arka plan gruplarının segmentasyon sonuçları

Derin Öğrenme Ağı	Sınıflar	Doğruluk	IoU	Ortalama BF Puanı
ResNet-18	Sağ pnömoni	0.9867	0.4662	0.4485
	Sol pnömoni	0.9762	0.4916	0.5028
	Arka plan	0.9861	0.9859	0.8967
ResNet-50	Sağ pnömoni	0.9846	0.5587	0.6136
	Sol pnömoni	0.9839	0.5222	0.5566
	Arka plan	0.9889	0.9887	0.9244
MobileNet-v2	Sağ pnömoni	0.9941	0.3595	0.2510
	Sol pnömoni	0.9885	0.3731	0.2845
	Arka plan	0.9774	0.9773	0.8363
Xception	Sağ pnömoni	0.9848	0.4136	0.4719
	Sol pnömoni	0.9740	0.4023	0.4311
	Arka plan	0.9813	0.9811	0.8720
Inception-ResNet-v2	Sağ pnömoni	0.9982	0.2482	0.1389
	Sol pnömoni	0.8873	0.3370	0.3093
	Arka plan	0.9714	0.9713	0.8169


Test sonuçlarından 1 numaralı görüntünün 60. kesitindeki pnömoni etiketi maskesi Şekil 4.43a’da, üst üste çakıştırılması Şekil 4.43b’de verilmiştir. Bu görüntünün eğitilen modele test olarak verilmesi ile elde edilen semantik segmentasyon sonuçları ResNet-18 için Şekil 4.44’de, ResNet-50 için Şekil 4.45’de, MobileNet-v2 için Şekil 4.46’da, Xception için Şekil 4.47’de, Inception-ResNet-v2 için Şekil 4.48’de verilmiştir.




**Şekil 4.43.** (a) Pnömoni bölgesi farklı etiket değerine sahip maske görüntüsünden bir kesit (b) Orijinal görüntü üzerine maskenin üst üste çakıştırılması ile oluşan görüntü




Şekil 4.44. ResNet-18 için semantik segmentasyon




Şekil 4.45. ResNet-50 için semantik segmentasyon



Şekil 4.46. MobileNet-v2 için semantik segmentasyon



Şekil 4.47. Xception için semantik segmentasyon



Şekil 4.48. Inception-ResNet-v2 için semantik segmentasyon

Tüm modellerin eğitim ve test işlemleri gerçekleştirilmiştir. Ağların doğruluk grafikleri genellikle ilk epokta hızlı bir şekilde yükselmekte, kayıp grafiği ise hızlı bir şekilde düşmektedir. Bu sonuçlar semantik segmentasyon işleminin başarılı bir eğitim süreci geçirdiğini göstermektedir. Test sonuçları incelendiğinde farklı etiket değerine sahip pnömoni bölgelerinin semantik segmentasyonu tüm ağlarda farklı performans değerleri vermektedir. Ancak ResNet-50 ağı performans olarak diğer ağlardan daha başarılı sonuçları ile öne çıkmaktadır. Eğitimi tamamlanmış ResNet-50 modeline verilen test görüntülerinin ortalama BF skoru sağ pnömoni için 0.6136 ve sol pnömoni için 0.5566 ile pnömoni sınırlarını tahmin ettiği, IoU değeri sağ pnömoni için 0.5587 ve sol pnömoni için 0.5222 ile sınıf algılama hassasiyetine ulaştığı, doğruluk oranı sağ pnömoni için 0.9846 ve sol pnömoni için 0.9839 ile piksel sınıflandırma performansı


elde ettiği izlenmektedir. Bu sonuçlar neticesinde ResNet-50 derin öğrenme modeli, COVID-19 tanılı BT görüntülerinde farklı etiket değerine sahip pnömoni bölgeleri semantik segmentasyonun da literatür çalışmalarına kıyasla başarılı sonuçlar verdiği gözlemlenmektedir. Eşit etiket değerine sahip pnömoni bölgeleri semantik segmentasyonu, farklı etiket değerine sahip pnömoni bölgeleri semantik segmentasyonuna kıyasla daha yüksek performans değerlerine ulaşmıştır.

#### 4.5. Eşit Etiket Değerli Akciğer ve Pnömoni Semantik Segmentasyon Sonuçları

Akciğer ve pnömonili bölgelerin kendi içlerinde eşit etiket değerlerine sahip olduğu semantik segmentasyonu için yapılan denemelerde akciğer, pnömoni ve arka plan olmak üzere üç sınıf bulunmaktadır. Akciğere 255 etiket değeri, pnömoniyeye 50 etiket değeri ve arka plana 0 etiket değeri atanmıştır. Üç sınıfın medyan frekans dengeleme ağırlık katsayılarının bulunması için sınıfların piksel sayıları ve görüntülerdeki toplam piksel sayısı hesaplanmıştır. Çizelge 4.13’de sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları verilmiştir. Şekil 4.49’de sınıfların piksel frekans grafiği verilmiştir.


**Çizelge 4.13.** Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları

Sınıflar	Piksel Sayısı	Toplam Piksel Sayısı
Akciğer	4.35E+07	3.35E+08
Pnömoni	4.47E+06	3.35E+08
Arka plan	2.87E+08	3.35E+08




**Şekil 4.49.** Sınıfların piksel frekans grafiği


Medyan frekans dengeleme denklemi kullanılarak akciğer için 1.0000, pnömoni için 9.7045 ve arka plan için 0.1512 ağırlık katsayıları elde edilmiştir. Bu ağırlıklar “*pixelClassificationLayer*” fonksiyonuna parametre olarak verilerek model sınıflandırma katmanı düzenlemiştir. Veriler random bir şekilde %60 eğitim, %20 doğrulama, %20 test olarak ayrılmıştır. Veri artırma ile resimler çoğaltılmış, “*gray2rgb*” parametresi ile görüntüler üç kanallı olarak hazırlanmıştır. Beş farklı derin öğrenme modeli “*deeplabv3plusLayers*” fonksiyonuna giriş parametresi olarak verilmiş ve beş farklı eğitim işlemi gerçekleştirilmiştir. Eğitim sonucu elde edilen epok sayısı ve iterasyona göre elde edilen eğitim doğruluk ve kayıp grafiği ResNet-18 için Şekil 4.50’de, ResNet-50 için Şekil 4.51’de, MobileNet-v2 için Şekil 4.52’de, Xception için Şekil 4.53’de ve Inception-ResNet-v2 için Şekil 4.54’de verilmiştir.




Şekil 4.50. ResNet-18 için eğitim doğruluk ve kayıp grafiği




Şekil 4.51. ResNet-50 için eğitim doğruluk ve kayıp grafiği



Şekil 4.52. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği



Şekil 4.53. Xception için eğitim doğruluk ve kayıp grafiği



Şekil 4.54. Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği

Eğitim işlemi sonucunda elde edilen model ağırlıkları ile sistemlerin daha önceden görmediği %20 test verisi kullanılarak semantik segmentasyon işlemi

gerçekleştirilmiştir. İşlem sonucu hesaplanan performans kriterleri Çizelge 4.14’de verilmiştir.

**Çizelge 4.14.** Akciğer ve pnömonili bölgelerin kendi içlerinde eşit etiket değerine sahip olduğu segmentasyon sonuçları


Derin Öğrenme Modeli	Küresel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklı IoU	Ortalama BF Puanı
ResNet-18	0.9848	0.9653	0.8338	0.9732	0.8497
ResNet-50	0.9884	0.9687	0.8602	0.9791	0.9056
MobileNet-v2	0.9842	0.9657	0.8288	0.9724	0.8400
Xception	0.9814	0.9590	0.7841	0.9703	0.7681
Inception-ResNet-v2	0.9878	0.9698	0.8602	0.9779	0.9050

Grupların segmentasyon işlemi sonucu performans değerleri Çizelge 4.15’da verilmiştir.


**Çizelge 4.15.** Akciğer, pnömoni ve arka plan gruplarının segmentasyon sonuçları

Derin Öğrenme Modeli	Sınıflar	Doğruluk	IoU	Ortalama BF Puanı
ResNet-18	Akciğer	0.9528	0.8990	0.8799
	Pnömoni	0.9532	0.6130	0.6910
	Arka plan	0.9899	0.9893	0.9782
ResNet-50	Akciğer	0.9608	0.9200	0.9226
	Pnömoni	0.9525	0.6684	0.8034
	Arka plan	0.9929	0.9924	0.9908
MobileNet-v2	Akciğer	0.9496	0.8953	0.8694
	Pnömoni	0.9580	0.6020	0.6742
	Arka plan	0.9896	0.9891	0.9763
Xception	Akciğer	0.9072	0.8753	0.8177
	Pnömoni	0.9777	0.4857	0.5074
	Arka plan	0.9921	0.9913	0.9792
Inception-ResNet-v2	Akciğer	0.9603	0.9133	0.9186
	Pnömoni	0.9569	0.6755	0.8072
	Arka plan	0.9922	0.9918	0.9891


Test sonuçlarından 1 numaralı görüntüsünün 60. kesitindeki pnömoni etiketi maskesi Şekil 4.55a’da, üst üste çakıştırılması Şekil 4.55b’de verilmiştir. Bu görüntünün eğitilen modele test olarak verilmesi ile elde edilen semantik segmentasyon sonuçları ResNet-18 için Şekil 4.56’da, ResNet-50 için Şekil 4.57’de, MobileNet-v2 için Şekil 4.58’de, Xception için Şekil 4.59’da, Inception-ResNet-v2 için Şekil 4.60’da verilmiştir.




**Şekil 4.55.** (a) Akciğerlerin ve pnömoni bölgelerinin eşit etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü üzerine maskenin üst üste çakıştırılması ile oluşan görüntü




**Şekil 4.56.** ResNet-18 için semantik segmentasyon




**Şekil 4.57.** ResNet-50 için semantik segmentasyon



Şekil 4.58. MobileNet-v2 için semantik segmentasyon



Şekil 4.59. Xception için semantik segmentasyon



Şekil 4.60. Inception-ResNet-v2 için semantik segmentasyon

Tüm modellerin eğitim ve test işlemlerinin sonucu birbirine yakın değerler vermektedir. Ağların doğruluk grafikleri genellikle ilk epokta hızlı bir şekilde yükselmekte, kayıp grafiği ise hızlı bir şekilde düşmektedir. Bu sonuçlar semantik segmentasyon işleminin başarılı bir eğitim süreci geçirdiğini göstermektedir. Test sonuçları incelendiğinde akciğer ve pnömonili bölgelerinin kendi içlerinde eşit etiket değerine sahip olduğu semantik segmentasyonu tüm ağlarda akciğer için 0.80 üzerinde, pnömoni için 0.48 üzerinde performans değerleri vermektedir. Ancak ResNet-50 ağı performans olarak diğer ağlardan daha başarılı sonuçları ile öne çıkmaktadır. Eğitimi tamamlanmış ResNet-50 modeline verilen test görüntülerinin de akciğer için; 0.9226 ortalama BF skoru ile sınırlarını başarılı bir şekilde tahmin ettiği, 0.9200 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9608 doğruluk oranı ile piksel sınıflandırma performansı elde ettiği izlenmektedir. Pnömoni için; 0.8034 ortalama BF skoru ile sınırlarını başarılı bir şekilde tahmin ettiği, 0.6684 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9525 doğruluk oranı ile piksel sınıflandırma performansı elde etmiştir. Bu sonuçlar COVID-19 tanımlı BT görüntülerinde akciğer ve pnömonili bölgelerin kendi içlerinde eşit etiket değerine sahip olduğu semantik segmentasyonun başarılı sonuçlar verdiğini göstermektedir. Fakat modellerin büyük alana sahip akciğer bölgelerini, küçük alana sahip olan pnömoni bölgelerine kıyasla daha iyi tahmin ettiği gözlemlenmiştir.


#### **4.6. Eşit Etiket Akciğer ve Farklı Etiket Pnömoni Semantik Segmentasyon**

##### **Sonuçları**

Akciğer ve pnömonili bölgelerin kendi içlerinde farklı etiket değerlerine sahip olduğu semantik segmentasyonu için yapılan denemelerde akciğer, sağ pnömoni, sol pnömoni ve arka plan olmak üzere dört sınıf bulunmaktadır. Akciğere 255 etiket değeri, sağ pnömoniyeye 57 etiket değeri, sol pnömoniyeye 184 etiket değeri ve arka plana 0 etiket değeri atanmıştır. Dört sınıfın medyan frekans dengeleme ağırlık katsayılarının bulunması için sınıfların piksel sayıları ve görüntülerdeki toplam piksel sayısı hesaplanmıştır. Çizelge 4.16'da sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları verilmiştir. Şekil 4.61'de sınıfların piksel frekans grafiği verilmiştir.


Çizelge 4.16. Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları

Sınıflar	Piksel Sayısı	Toplam Piksel Sayısı
Akciğer	4.35E+07	3.35E+08
Sağ pnömoni	1.76E+06	2.31E+08
Sol pnömoni	2.71E+06	2.96E+08
Arka plan	2.87E+08	3.35E+08




Şekil 4.61. Sınıfların piksel frekans grafiği

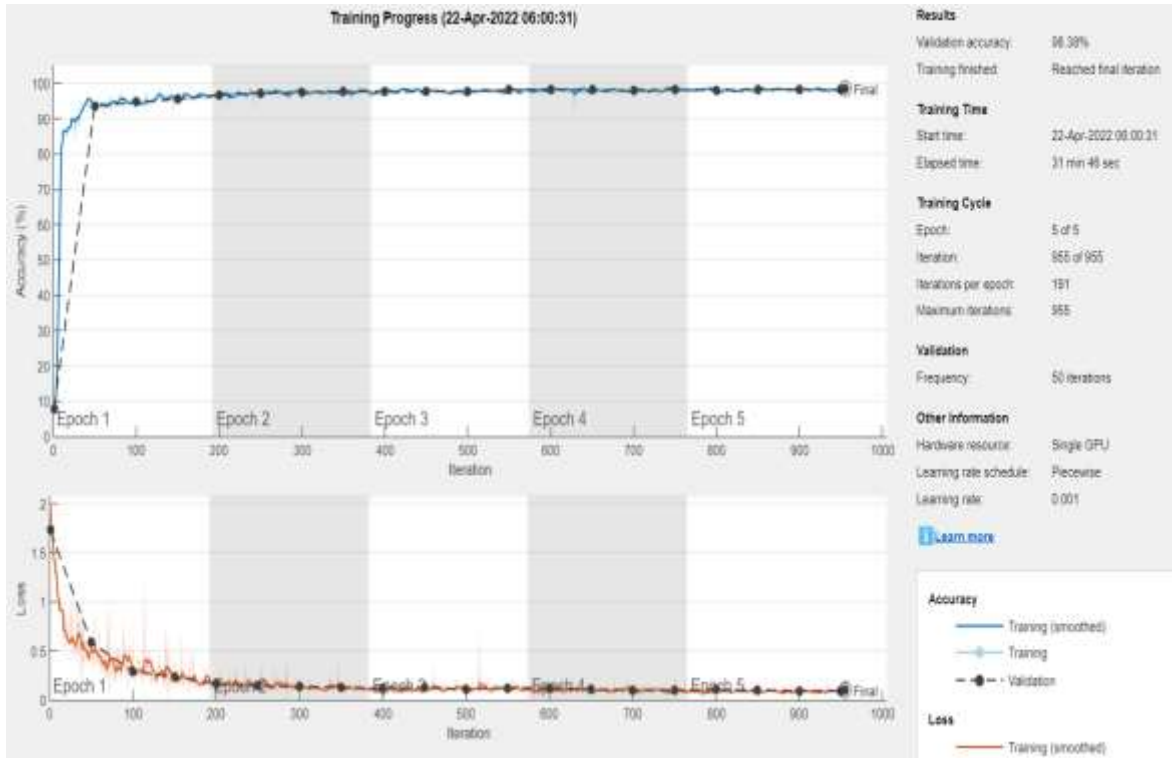
Medyan frekans dengeleme denklemi kullanılarak akciğer için 0.5352, sağ pnömoni için 9.1057, sol pnömoni için 7.5966 ve arka plan için 0.0809 ağırlık katsayıları elde edilmiştir. Bu ağırlıklar “*pixelClassificationLayer*” fonksiyonuna parametre olarak verilerek model sınıflandırma katmanı düzenlemiştir. Veriler random bir şekilde %60 eğitim, %20 doğrulama, %20 test olarak ayrılmıştır. Veri artırma ile resimler çoğaltılmış, “*gray2rbg*” parametresi ile görüntüler üç kanallı olarak hazırlanmıştır. Beş farklı derin öğrenme modeli “*deeplabv3plusLayers*” fonksiyonuna giriş parametresi olarak verilmiş ve beş farklı eğitim işlemi gerçekleştirilmiştir. Eğitim sonucu elde edilen epok sayısı ve iterasyona göre elde edilen eğitim doğruluk ve kayıp grafiği ResNet-18 için Şekil 4.62’de, ResNet-50 için Şekil 4.63’de, MobileNet-v2 için Şekil 4.64’de, Xception için Şekil 4.65’de ve Inception-ResNet-v2 için Şekil 4.66’da verilmiştir.




Şekil 4.62. ResNet-18 için eğitim doğruluk ve kayıp grafiği




Şekil 4.63. ResNet-50 için eğitim doğruluk ve kayıp grafiği



Şekil 4.64. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği



Şekil 4.65. Xception için eğitim doğruluk ve kayıp grafiği



Şekil 4.66. Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği

Eğitim işlemi sonucunda elde edilen model ağırlıkları ile sistemlerin daha önceden görmediği %20 test verisi kullanılarak semantik segmentasyon işlemi gerçekleştirilmiştir. İşlem sonucu hesaplanan performans kriterleri Çizelge 4.17’de verilmiştir.

Çizelge 4.17. Akciğerin eşit ve pnömonili bölgelerin farklı etiket değerine sahip olduğu segmentasyon sonuçları


Derin Öğrenme Modeli	Küresel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklı IoU	Ortalama BF Puanı
ResNet-18	0.9797	0.9680	0.7216	0.9662	0.7360
ResNet-50	0.9853	0.9696	0.7711	0.9747	0.8319
MobileNet-v2	0.9839	0.9604	0.7705	0.9719	0.8012
Xception	0.9797	0.9625	0.7017	0.9677	0.7306
Inception-ResNet-v2	0.9826	0.9617	0.7567	0.9701	0.8173

Sınıfların segmentasyon işlemi sonucu performans değerleri Çizelge 4.18’de verilmiştir.


**Çizelge 4.18.** Akciğer, sağ pnömoni, sol pnömoni ve arka plan gruplarının segmentasyon sonuçları

Derin Öğrenme Modeli	Sınıflar	Doğruluk	IoU	Ortalama BF Puanı
ResNet-18	Akciğer	0.9294	0.8717	0.8282
	Sağ pnömoni	0.9880	0.5051	0.4890
	Sol pnömoni	0.9676	0.5230	0.5241
	Arka plan	0.9870	0.9866	0.9686
ResNet-50	Akciğer	0.9403	0.8993	0.8741
	Sağ pnömoni	0.9714	0.6209	0.7242
	Sol pnömoni	0.9746	0.5728	0.6693
	Arka plan	0.9920	0.9914	0.9867
MobileNet-v2	Akciğer	0.9540	0.8980	0.8684
	Sağ pnömoni	0.9470	0.6181	0.6900
	Sol pnömoni	0.9519	0.5774	0.5977
	Arka plan	0.9888	0.9883	0.9717
Xception	Akciğer	0.9075	0.8685	0.8126
	Sağ pnömoni	0.9763	0.4865	0.5286
	Sol pnömoni	0.9761	0.4623	0.4734
	Arka plan	0.9902	0.9895	0.9736
Inception-ResNet-v2	Akciğer	0.9537	0.8962	0.8880
	Sağ pnömoni	0.9478	0.6079	0.7125
	Sol pnömoni	0.9582	0.5358	0.6083
	Arka plan	0.9872	0.9869	0.9707


Test sonuçlarından 1 numaralı görüntünün 60. kesitindeki pnömoni etiketi maskesi Şekil 4.67a'da, üst üste çakıştırılması Şekil 4.67b'de verilmiştir. Bu görüntünün eğitilen modele test olarak verilmesi ile elde edilen semantik segmentasyon sonuçları ResNet-18 için Şekil 4.68'de, ResNet-50 için Şekil 4.69'de, MobileNet-v2 için Şekil 4.70'de, Xception için Şekil 4.71'de, Inception-ResNet-v2 için Şekil 4.72'de verilmiştir.




**Şekil 4.67.** (a) Akciğerin eşit pnömoni bölgelerinin farklı etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü üzerine maskenin getirilmesi ile oluşan görüntü




Şekil 4.68. ResNet-18 için semantik segmentasyon




Şekil 4.69. ResNet-50 için semantik segmentasyon



Şekil 4.70. MobileNet-v2 için semantik segmentasyon



Şekil 4.71. Xception için semantik segmentasyon



Şekil 4.72. Inception-ResNet-v2 için semantik segmentasyon

Tüm modellerin eğitim ve test işlemleri gerçekleştirilmiştir. Ağların doğruluk grafikleri genellikle ilk epokta hızlı bir şekilde yükselmekte, kayıp grafiği ise hızlı bir şekilde düşmektedir. Bu sonuçlar semantik segmentasyon işleminin başarılı bir eğitim süreci geçirdiğini göstermektedir. Test sonuçları incelendiğinde akciğerlerin eşit ve pnömoni bölgelerinin farklı etiket değerine sahip olduğu semantik segmentasyonu tüm ağlarda akciğer için 0.81 üzerinde, sağ pnömoni için 0.48 üzerinde, sol pnömoni için 0.46 üzerinde performans değerleri vermektedir. Ancak ResNet-50 ağı performans olarak diğer ağlardan daha başarılı sonuçları ile öne çıkmaktadır. Eğitimi tamamlanmış ResNet-50 modeline verilen test görüntülerinin akciğerler için; ortalama BF skoru 0.8741 ile akciğer sınırlarını tahmin ettiği, 0.8993 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9403 doğruluk oranı ile piksel sınıflandırma performansı elde

ettiği izlenmektedir. Sağ pnömoni için; ortalama BF skoru 0.7242 ile sağ pnömoni sınırlarını tahmin ettiği, 0.6209 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9714 doğruluk oranı ile piksel sınıflandırma performansı elde ettiği gözlemlenmiştir. Sol pnömoni için; ortalama BF skoru 0.6693 ile sol pnömoni sınırlarını tahmin ettiği, 0.5728 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9746 doğruluk oranı ile piksel sınıflandırma performansı elde ettiği izlenmiştir. Bu sonuçlar COVID-19 tanılı BT görüntülerinde akciğerin eşit ve pnömonili bölgelerin farklı etiket değerine sahip olduğu semantik segmentasyonun başarılı sonuçlar verdiğini göstermektedir.


#### 4.7. Farklı Etiket Akciğer ve Eşit Etiket Pnömoni Semantik Segmentasyon

##### Sonuçları

Akciğer farklı etiket değerine ve pnömonili bölgelerin eşit etiket değerlerine sahip olduğu semantik segmentasyonu için yapılan denemelerde sağ akciğer, sol akciğer, pnömoni ve arka plan olmak üzere dört sınıf bulunmaktadır. Sağ akciğere 127 etiket değeri, sol akciğere 254 etiket değeri, pnömoniyeye 57 etiket değeri ve arka plana 0 etiket değeri atanmıştır. Dört sınıfın medyan frekans dengeleme ağırlık katsayılarının bulunması için sınıfların piksel sayıları ve görüntülerdeki toplam piksel sayısı hesaplanmıştır. Çizelge 4.19’da sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları verilmiştir. Şekil 4.73’de sınıfların piksel frekans grafiği verilmiştir.


**Çizelge 4.19.** Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları

Sınıflar	Piksel Sayısı	Toplam Piksel Sayısı
Sağ akciğer	1.98E+07	3.35E+08
Sol akciğer	2.36E+07	3.35E+08
Pnömoni	4.47E+06	3.35E+08
Arka plan	2.87E+08	3.35E+08




Şekil 4.73. Sınıfların piksel frekans grafiği


Medyan frekans dengeleme denklemi kullanılarak sağ akciğer için 1.0955, sol akciğer için 0.9198, pnömoni için 4.8522 ve arka plan için 0.0756 ağırlık katsayıları elde edilmiştir. Bu ağırlıklar “*pixelClassificationLayer*” fonksiyonuna parametre olarak verilerek model sınıflandırma katmanı düzenlemiştir. Veriler random bir şekilde %60 eğitim, %20 doğrulama, %20 test olarak ayrılmıştır. Veri arttırma ile resimler çoğaltılmış, “*gray2rgb*” parametresi ile görüntüler üç kanallı olarak hazırlanmıştır. Beş farklı derin öğrenme modeli “*deeplabv3plusLayers*” fonksiyonuna giriş parametresi olarak verilmiş ve beş farklı eğitim işlemi gerçekleştirilmiştir. Eğitim sonucu elde edilen epok sayısı ve iterasyona göre elde edilen eğitim doğruluk ve kayıp grafiği ResNet-18 için Şekil 4.74’de, ResNet-50 için Şekil 4.75’de, MobileNet-v2 için Şekil 4.76’da, Xception için Şekil 4.77’de ve Inception-ResNet-v2 için Şekil 4.78’de verilmiştir.




Şekil 4.74. ResNet-18 için eğitim doğruluk ve kayıp grafiği




Şekil 4.75. ResNet-50 için eğitim doğruluk ve kayıp grafiği



Şekil 4.76. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği



Şekil 4.77. Xception için eğitim doğruluk ve kayıp grafiği



**Şekil 4.78.** Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği

Eğitim işlemi sonucunda elde edilen model ağırlıkları ile sistemlerin daha önceden görmediği %20 test verisi kullanılarak semantik segmentasyon işlemi gerçekleştirilmiştir. İşlem sonucu hesaplanan performans kriterleri Çizelge 4.20’de verilmiştir.

**Çizelge 4.20.** Akciğerlerin farklı ve pnömonili bölgelerin eşit etiket değerine sahip olduğu segmentasyon işlemi sonuçları


Derin Öğrenme Modeli	Küresel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklı IoU	Ortalama BF Puanı
ResNet-18	0.9814	0.9613	0.8359	0.9670	0.8441
ResNet-50	0.9860	0.9654	0.8644	0.9748	0.8972
MobileNet-v2	0.9836	0.9577	0.8541	0.9702	0.8616
Xception	0.9833	0.9552	0.8460	0.9700	0.8641
Inception-ResNet-v2	0.9835	0.9637	0.8422	0.9711	0.8622

Sınıfların segmentasyon işlemi sonucu performans değerleri Çizelge 4.21’de verilmiştir.


**Çizelge 4.21.** Sağ akciğer, sol akciğer, pnömoni ve arka plan sınıflarının segmentasyon sonuçları

Derin Öğrenme Modeli	Sınıflar	Doğruluk	IoU	Ortalama BF Puanı
ResNet-18	Sağ akciğer	0.9525	0.8737	0.8688
	Sol akciğer	0.9516	0.8758	0.8551
	Pnömoni	0.9553	0.6085	0.6789
	Arka plan	0.9860	0.9858	0.9734
ResNet-50	Sağ akciğer	0.9731	0.9075	0.9334
	Sol akciğer	0.9505	0.8983	0.8897
	Pnömoni	0.9478	0.6619	0.7792
	Arka plan	0.9903	0.9900	0.9865
MobileNet-v2	Sağ akciğer	0.9730	0.8897	0.8883
	Sol akciğer	0.9674	0.8934	0.8665
	Pnömoni	0.9038	0.6469	0.7224
	Arka plan	0.9868	0.9865	0.9693
Xception	Sağ akciğer	0.9657	0.8843	0.8983
	Sol akciğer	0.9489	0.8815	0.8556
	Pnömoni	0.9183	0.6304	0.7248
	Arka plan	0.9881	0.9877	0.9778
Inception-ResNet-v2	Sağ akciğer	0.9581	0.8900	0.9003
	Sol akciğer	0.9364	0.8834	0.8623
	Pnömoni	0.9713	0.6065	0.7017
	Arka plan	0.9891	0.9888	0.9845


Test sonuçlarından 1 numaralı görüntünün 60. kesitindeki pnömoni etiketi maskesi Şekil 4.79a'da, üst üste çakıştırılması Şekil 4.79b'de verilmiştir. Bu görüntünün eğitilen modele test olarak verilmesi ile elde edilen semantik segmentasyon sonuçları ResNet-18 için Şekil 4.80'de, ResNet-50 için Şekil 4.81'de, MobileNet-v2 için Şekil 4.82'de, Xception için Şekil 4.83'de, Inception-ResNet-v2 için Şekil 4.84'de verilmiştir.




**Şekil 4.79.** (a) Akciğerlerin farklı pnömoni bölgelerinin eşit etiket değerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü üzerine maskenin getirilmesi ile oluşan görüntü




Şekil 4.80. ResNet-18 için semantik segmentasyon




Şekil 4.81. ResNet-50 için semantik segmentasyon



Şekil 4.82. MobileNet-v2 için semantik segmentasyon



Şekil 4.83. Xception için semantik segmentasyon



Şekil 4.84. Inception-ResNet-v2 için semantik segmentasyon

Tüm modellerin eğitim ve test işlemleri gerçekleştirilmiştir. Ağların doğruluk grafikleri genellikle ilk epokta hızlı bir şekilde yükselmekte, kayıp grafiği ise hızlı bir şekilde düşmektedir. Bu sonuçlar semantik segmentasyon işleminin başarılı bir eğitim süreci geçirdiğini göstermektedir. Test sonuçları incelendiğinde akciğerlerin farklı ve pnömoni bölgelerinin eşit etiket değerine sahip olduğu semantik segmentasyonu tüm ağlarda sağ akciğer için 0.86 üzerinde, sol akciğer için 0.85 üzerinde, pnömoni için 0.60 üzerinde performans değerleri vermektedir. Ancak ResNet-50 ağı performans olarak diğer ağlardan daha başarılı sonuçları ile öne çıkmaktadır. Eğitimi tamamlanmış ResNet-50 modeline verilen test görüntülerinin sağ akciğerler için; ortalama BF skoru 0.9334 ile sağ akciğer sınırlarını tahmin ettiği, 0.9075 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9731 doğruluk oranı ile piksel sınıflandırma performansı elde

ettiği izlenmektedir. Sol akciğer için; ortalama BF skoru 0.8897 ile sol akciğer sınırlarını tahmin ettiği, 0.8983 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9505 doğruluk oranı ile piksel sınıflandırma performansı elde ettiği gözlemlenmiştir. Pnömoni için; ortalama BF skoru 0.7792 ile pnömoni sınırlarını tahmin ettiği, 0.6619 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9478 doğruluk oranı ile piksel sınıflandırma performansı elde ettiği izlenmiştir. Bu sonuçlar COVID-19 tanılı BT görüntülerinde akciğerin farklı ve pnömonili bölgelerin eşit etiket değerine sahip olduğu semantik segmentasyonun başarılı sonuçlar verdiğini göstermektedir.


#### 4.8. Farklı Etiket Akciğer ve Farklı Etiket Pnömoni Semantik Segmentasyon

##### Sonuçları

Akciğer ve pnömonili bölgelerin kendi içlerinde farklı etiket değerlerine sahip olduğu semantik segmentasyon için yapılan denemelerde sağ akciğer, sol akciğer, sağ pnömoni, sol pnömoni ve arka plan olmak üzere beş sınıf bulunmaktadır. Sağ akciğere 127 etiket değeri, sol akciğere 254 etiket değeri, sağ pnömoniyeye 57 etiket değeri, sol pnömoniyeye 184 etiket değeri ve arka plana 0 etiket değeri atanmıştır. Beş sınıfın medyan frekans dengeleme ağırlık katsayılarının bulunması için sınıfların piksel sayıları ve görüntülerdeki toplam piksel sayısı hesaplanmıştır. Çizelge 4.22’de sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları verilmiştir. Şekil 4.85’de sınıfların piksel frekans grafiği verilmiştir.

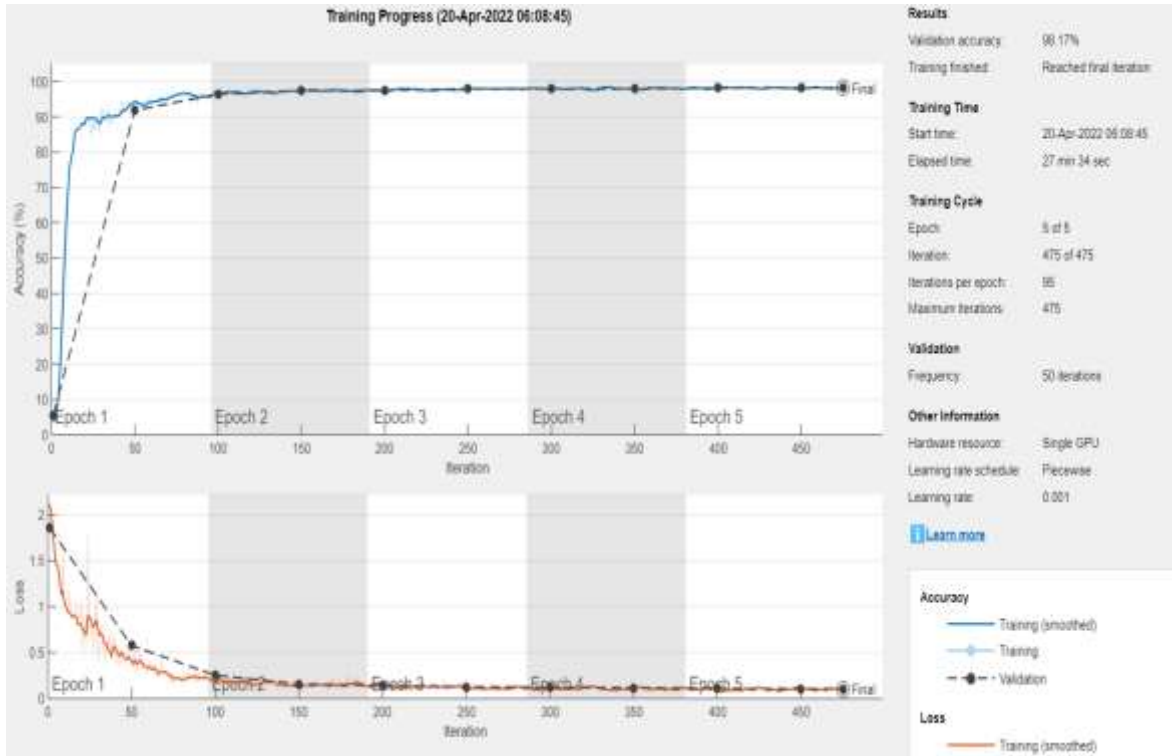
**Çizelge 4.22.** Sınıfların hesaplanan piksel sayıları ve toplam piksel sayıları

Sınıflar	Piksel Sayısı	Toplam Piksel Sayısı
Sağ akciğer	1.98E+07	3.35E+08
Sol akciğer	2.36E+07	3.35E+08
Sağ pnömoni	1.76E+06	2.31E+08
Sol pnömoni	2.71E+06	2.96E+08
Arka plan	2.87E+08	3.35E+08




Şekil 4.85. Sınıfların piksel frekans grafiği


Medyan frekans dengeleme denklemi kullanılarak sağ akciğer için 1.0000, sol akciğer için 0.8396, sağ pnömoni için 7.7646, sol pnömoni için 6.4777 ve arka plan için 0.0690 ağırlık katsayıları elde edilmiştir. Bu ağırlıklar *“pixelClassificationLayer”* fonksiyonuna parametre olarak verilerek model sınıflandırma katmanı düzenlemiştir. Veriler random bir şekilde %60 eğitim, %20 doğrulama, %20 test olarak ayrılmıştır. Veri artırma ile resimler çoğaltılmış, *“gray2rbg”* parametresi ile görüntüler üç kanallı olarak hazırlanmıştır. Beş farklı derin öğrenme modeli *“deeplabv3plusLayers”* fonksiyonuna giriş parametresi olarak verilmiş ve beş farklı eğitim işlemi gerçekleştirilmiştir. Eğitim sonucu elde edilen epok sayısı ve iterasyona göre elde edilen eğitim doğruluk ve kayıp grafiği ResNet-18 için Şekil 4.86’da, ResNet-50 için Şekil 4.87’de, MobileNet-v2 için Şekil 4.88’de, Xception için Şekil 4.89’da ve Inception-ResNet-v2 için Şekil 4.90’da verilmiştir.




Şekil 4.86. ResNet-18 için eğitim doğruluk ve kayıp grafiği




Şekil 4.87. ResNet-50 için eğitim doğruluk ve kayıp grafiği



Şekil 4.88. MobileNet-v2 için eğitim doğruluk ve kayıp grafiği



Şekil 4.89. Xception için eğitim doğruluk ve kayıp grafiği



**Şekil 4.90.** Inception-ResNet-v2 için eğitim doğruluk ve kayıp grafiği

Eğitim işlemi sonucunda elde edilen model ağırlıkları ile sistemlerin daha önceden görmediği %20 test verisi kullanılarak semantik segmentasyon işlemi gerçekleştirilmiştir. İşlem sonucu hesaplanan performans kriterleri Çizelge 4.23'de verilmiştir.

**Çizelge 4.23.** Akciğer ve pnömonili bölgelerin kendi içlerinde farklı etiket değerine sahip olduğu segmentasyon sonuçları


Derin Öğrenme Modeli	Küresel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklı IoU	Ortalama BF Puanı
ResNet-18	0.9822	0.9623	0.7869	0.9690	0.8157
ResNet-50	0.9856	0.9618	0.8219	0.9740	0.8734
MobileNet-v2	0.9820	0.9614	0.7792	0.9690	0.7964
Xception	0.9819	0.9542	0.7686	0.9691	0.7950
Inception-ResNet-v2	0.9837	0.9567	0.8139	0.9707	0.8767

Sınıfların segmentasyon işlemi sonucu performans değerleri Çizelge 4.24'de verilmiştir.


**Çizelge 4.24.** Sağ akciğer, sol akciğer, sağ pnömoni, sol pnömoni ve arka plan gruplarının segmentasyon sonuçları

Derin Öğrenme Modeli	Sınıflar	Doğruluk	IoU	Ortalama BF Puanı
ResNet-18	Sağ akciğer	0.9579	0.8858	0.8846
	Sol akciğer	0.9357	0.8806	0.8390
	Sağ pnömoni	0.9616	0.6209	0.6860
	Sol pnömoni	0.9685	0.5598	0.6088
	Arka plan	0.9877	0.9872	0.9742
ResNet-50	Sağ akciğer	0.9711	0.9051	0.9206
	Sol akciğer	0.9609	0.9059	0.8861
	Sağ pnömoni	0.9399	0.6811	0.8072
	Sol pnömoni	0.9480	0.6284	0.7128
	Arka plan	0.9891	0.9888	0.9834
MobileNet-v2	Sağ akciğer	0.9504	0.8831	0.8685
	Sol akciğer	0.9352	0.8824	0.8322
	Sağ pnömoni	0.9622	0.5907	0.6390
	Sol pnömoni	0.9710	0.5526	0.5698
	Arka plan	0.9880	0.9875	0.9740
Xception	Sağ akciğer	0.9282	0.8736	0.8342
	Sol akciğer	0.9515	0.8887	0.8451
	Sağ pnömoni	0.9794	0.5108	0.5317
	Sol pnömoni	0.9237	0.5819	0.6492
	Arka plan	0.9883	0.9880	0.9735
Inception-ResNet-v2	Sağ akciğer	0.9730	0.8892	0.9044
	Sol akciğer	0.9629	0.8974	0.9037
	Sağ pnömoni	0.9324	0.6724	0.8059
	Sol pnömoni	0.9286	0.6235	0.7395
	Arka plan	0.9869	0.9867	0.9793


Test sonuçlarından 1 numaralı görüntünün 60. kesitindeki pnömoni etiketi maskesi Şekil 4.91a'da, üst üste çakıştırılması Şekil 4.91b'de verilmiştir. Bu görüntünün eğitilen modele test olarak verilmesi ile elde edilen semantik segmentasyon sonuçları ResNet-18 için Şekil 4.92'de, ResNet-50 için Şekil 4.93'de, MobileNet-v2 için Şekil 4.94'de, Xception için Şekil 4.95'de, Inception-ResNet-v2 için Şekil 4.96'da verilmiştir.




**Şekil 4.91.** (a) Akciğerlerin ve pnömoni bölgelerinin farklı etiket değerlerine sahip olduğu maske görüntülerinden bir kesit (b) Orijinal görüntü üzerine maskenin getirilmesi ile oluşan görüntü




**Şekil 4.92.** ResNet-18 için semantik segmentasyon




**Şekil 4.93.** ResNet-50 için semantik segmentasyon



Şekil 4.94. MobileNet-v2 için semantik segmentasyon



Şekil 4.95. Xception için semantik segmentasyon



Şekil 4.96. Inception-ResNet-v2 için semantik segmentasyon

Tüm modellerin eğitim ve test işlemlerinin sonucu birbirine yakın sonuçlar vermektedir. Ağların doğruluk grafikleri genellikle ilk epokta hızlı bir şekilde yükselmekte, kayıp grafiği ise hızlı bir şekilde düşmektedir. Bu sonuçlar semantik segmentasyon işleminin başarılı bir eğitim süreci geçirdiğini göstermektedir. Test sonuçları incelendiğinde akciğer ve pnömonili bölgelerin kendi içlerinde farklı etiket değerine sahip olduğu semantik segmentasyonu tüm ağlarda akciğerler için 0.83 üzerinde, pnömoni için 0.51 üzerinde performans değerleri vermektedir. Ancak ResNet-50 ağı performans olarak diğer ağlardan daha başarılı sonuçları ile öne çıkmaktadır. Eğitimi tamamlanmış ResNet-50 modeline verilen test görüntülerinin sağ akciğer için; ortalama BF skoru 0.9206 ile sağ akciğer sınırlarını tahmin ettiği, 0.9051 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9711 doğruluk oranı ile piksel sınıflandırma performansı elde ettiği izlenmektedir. Sol akciğer için; ortalama BF skoru 0.8861 ile sol akciğer sınırlarını tahmin ettiği, 0.9059 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9609 doğruluk oranı ile piksel sınıflandırma performansı elde etmiştir. Sağ pnömoni için: ortalama BF skoru 0.8072 ile sağ pnömoni sınırlarını tahmin ettiği, 0.6811 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9399 doğruluk oranı ile piksel sınıflandırma performansı elde ettiği gözlemlenmiştir. Sol pnömoni için; ortalama BF skoru 0.7128 ile sol pnömoni sınırlarını tahmin ettiği, 0.6284 IoU değeri ile sınıf algılama hassasiyetine ulaştığı, 0.9480 doğruluk oranı ile piksel sınıflandırma performansı elde ettiği izlenmektedir. Bu sonuçlar COVID-19 tanılı BT görüntülerinde akciğer ve pnömonili bölgelerin kendi içlerinde farklı etiket değerine sahip olduğu semantik segmentasyonun başarılı sonuçlar verdiğini göstermektedir. Fakat, akciğer ve pnömonili bölgelerin eşit etiket değerine sahip olduğu semantik segmentasyon, akciğer ve pnömonili bölgelerin farklı etiket değerine sahip olduğu semantik segmentasyona göre daha yüksek performans değerleri elde etmiştir.

## 5. SONUÇLAR VE ÖNERİLER

### 5.1 Sonuçlar

Bu tez çalışmasında, COVID-19 tanılı BT görüntülerinin sekiz farklı senaryoda ve Deeplabv3+ semantik segmentasyon modeline beş farklı derin öğrenme algoritmasının entegre edilmesi ile kırk farklı deneme yapılmıştır. Tüm denemelerin eğitim doğruluk ve kayıp grafikleri incelendiğinde eğitim sürecinin başarılı bir şekilde gerçekleştiği gözlemlenmiştir. Ancak eğitilmiş ağırlara test görüntüleri verilmesi ile derin öğrenme modeline göre performans kriterlerinde farklılıklar bulunmaktadır. Bu modeller içerisinde ResNet-50 derin öğrenme algoritması daha yüksek performans değerleri ile öne çıkmaktadır. Çizelge 5.1 ve Çizelge 5.2’de tüm senaryolar için elde edilen ResNet-50 modelinin ortalama performans ve sınıflara göre performans değerleri verilmiştir.

**Çizelge 5.1.** Tüm senaryolar için ResNet-50 modelinin ortalama performans sonuçları

Senaryo	Maske	Model	Küresel Doğruluk	Ortalama Doğruluk	Ortalama IoU	Ağırlıklı IoU	Ortalama BF Puanı
<b>Senaryo-1</b>	Akciğerler Eşit	ResNet-50	0.9949	0.9951	0.9789	0.9899	0.9888
<b>Senaryo-2</b>	Akciğerler Farklı	ResNet-50	0.9927	0.9948	0.9626	0.9859	0.9764
<b>Senaryo-3</b>	Pnömoni Eşit	ResNet-50	0.9907	0.9832	0.7848	0.9851	0.7991
<b>Senaryo-4</b>	Pnömoni Farklı	ResNet-50	0.9888	0.9858	0.6899	0.9827	0.7231
<b>Senaryo-5</b>	Akciğerler ve Pnömoniler Eşit	ResNet-50	0.9884	0.9687	0.8602	0.9791	0.9056
<b>Senaryo-6</b>	Akciğerler Eşit Pnömoni Farklı	ResNet-50	0.9853	0.9696	0.7711	0.9747	0.8319
<b>Senaryo-7</b>	Akciğerler Farklı Pnömoni Eşit	ResNet-50	0.9860	0.9654	0.8644	0.9748	0.8972
<b>Senaryo-8</b>	Akciğerler ve Pnömoniler Farklı	ResNet-50	0.9856	0.9618	0.8219	0.9740	0.8734

Çizelge 5.2. Tüm senaryolar için ResNet-50 modelinin sınıflara göre performans sonuçları

Senaryo	Maske	Model	Sınıflar	Doğruluk	IoU	Ortalama BF Skoru
<b>Senaryo-1</b>	Akciğerler Eşit	ResNet-50	Akciğerler	0,9955	0,9637	0,9836
			Arka Plan	0,9948	0,9940	0,9940
<b>Senaryo-2</b>	Akciğerler Farklı	ResNet-50	Sağ akciğer	0.9969	0.9414	0.9681
			Sol akciğer	0.9954	0.9547	0.9697
			Arka plan	0.9922	0.9918	0.9913
<b>Senaryo-3</b>	Pnömoni Eşit	ResNet-50	Pnömoni	0.9756	0.5791	0.6592
			Arka plan	0.9909	0.9905	0.9390
<b>Senaryo-4</b>	Pnömoni Farklı	ResNet-50	Sağ pnömoni	0.9846	0.5587	0.6136
			Sol pnömoni	0.9839	0.5222	0.5566
			Arka plan	0.9889	0.9887	0.9244
<b>Senaryo-5</b>	Akciğerler ve Pnömoniler Eşit	ResNet-50	Akciğer	0.9608	0.9200	0.9226
			Pnömoni	0.9525	0.6684	0.8034
			Arka plan	0.9929	0.9924	0.9908
<b>Senaryo-6</b>	Akciğerler Eşit Pnömoni Farklı	ResNet-50	Akciğer	0.9403	0.8993	0.8741
			Sağ pnömoni	0.9714	0.6209	0.7242
			Sol pnömoni	0.9746	0.5728	0.6693
			Arka plan	0.9920	0.9914	0.9867
<b>Senaryo-7</b>	Akciğerler Farklı Pnömoni Eşit	ResNet-50	Sağ akciğer	0.9731	0.9075	0.9334
			Sol akciğer	0.9505	0.8983	0.8897
			Pnömoni	0.9478	0.6619	0.7792
			Arka plan	0.9903	0.9900	0.9865
<b>Senaryo-8</b>	Akciğerler ve Pnömoniler Farklı	ResNet-50	Sağ akciğer	0.9711	0.9051	0.9206
			Sol akciğer	0.9609	0.9059	0.8861
			Sağ pnömoni	0.9399	0.6811	0.8072
			Sol pnömoni	0.9480	0.6284	0.7128
			Arka plan	0.9891	0.9888	0.9834

Ortalama performans sonuçları incelendiğinde, büyük bölgeye sahip olan sınıfın anlamsal bölütlemesi denemelerinde yüksek performans değerleri elde edildiği gözlemlenmektedir. Küçük bölgeye sahip olan sınıfın semantik segmentasyon sonuçlarının büyük bölgeye sahip olan sınıfa kıyasla daha düşük performans değerlerine ulaştığı tespit edilmiştir. Genel olarak ortalama performans sonuçlarında bütün senaryolar için başarılı sonuçlara ulaşılmıştır. Sınıfların performans sonuçları incelendiğinde, küçük bölgeye sahip pnömoni bölgelerinin anlamsal bölütlemesinde, sınıflandırma yapılacak bölge sayısı arttıkça performans değerinin yükseldiği gözlemlenmektedir. Pnömoni bölgeleri semantik segmentasyon sonucu performans değerleri yükselirken akciğer bölgesi performans değerlerinin düştüğü gözlemlenmektedir. Bu sonuçlar neticesinde küçük bölgeye sahip sınıfın en yüksek performans değerine ulaşmak için görüntü üzerindeki anlamsal bölütlemesi gerçekleştirilecek olan sınıf sayısının maksimum da tutulması gerektiği sonucuna ulaşılmaktadır.

Literatürde deeplabv3+ modeline derin öğrenme algoritmaları entegre edilerek COVID-19 BT görüntülerini segmente eden iki çalışma bulunmaktadır. İki çalışma da Polat tarafından 2022 yılında DeepLabv3+ ve modifiye edilmiş DeepLabv3+ kullanılarak gerçekleştirilmiştir. Veri kümesi olarak İtalyan Tıbbi ve Girişimsel Radyoloji Derneği'nin sağladığı 40'dan fazla hastadan alınan 100 BT görüntüsü kullanılmıştır. İlk çalışmada semantik segmentasyon denemeleri 3 farklı senaryoda gerçekleştirilmiştir. İlk senaryo akciğer ve arka plan, ikinci senaryo akciğer, COVID ve arka plan, üçüncü senaryo akciğer, COVID, konsolidasyon, plevral efüzyon ve arka plan olmak üzere veri kümesi hazırlanmıştır. Akciğer ve arka plan segmentasyonu için IoU katsayı değeri akciğer için 0.987 ve arka plan için 0.979 olarak elde edilmiştir. Akciğer, COVID ve arka plan segmentasyonu için IoU katsayı değeri akciğer için 0.789, COVID için 0.548 ve arka plan için 0.972 olarak elde edilmiştir. Her lezyon türünün ayrı ayrı sınıflandırıldığı segmentasyon işlemi için IoU katsayı değeri akciğer için 0.789, COVID için 0.429, konsolidasyon için 0.345, plevral efüzyon için 0.057 ve arka plan için 0.972 olarak bulunmuştur. İkinci çalışmada ise semantik segmentasyon denemesi tek senaryoda gerçekleştirilmiştir. Bu senaryo akciğer, COVID ve arka plan sınıflarının bulunduğu senaryodur. Modifiye edilmiş DeepLabv3+'da ASPP modülündeki atroz oranları 6, 12, 18 yerine 4, 8, 12 olarak değiştirilmiştir. Yapılan değişiklik sayesinde lezyon segmentasyonunda daha başarılı sonuç elde edilmesi

amaçlanmıştır. Gerçekleştirilen eğitim ve test işlemleri sonucunda dice ve IoU metrik değerlerinin %2 oranında arttığı belirtilmiştir (Polat, 2022b).

Bu tez çalışmasındaki sonuçlar ile kıyaslandığında Polat'ın yaptığı birinci çalışmadaki ilk iki deneme senaryo-1 ve senaryo-5'e, ikinci çalışmadaki tek deneme senaryo-5'e denk gelmektedir. ResNet-50'nin en yüksek performans değerleri vermesiyle Polat'ın kullandığı model uyumludur. Ancak bu çalışmada elde edilen performans değerleri Polat'ın çalışmasına kıyasla daha yüksek elde edilmiştir. Bunun sebebi veri sayısı ve boyundaki farklılıklar, iterasyon ve mini batch size değerlerdeki farklılıklar olabilir. Polat sadece üç senaryoda ve tek algorithmada denemeler gerçekleştirirken bu tez çalışmasında sekiz senaryo ve beş algorithmada toplam kırk deneme uygulanmıştır. Dolayısıyla bu tez çalışması belirtilen makalelerdeki uygulamalardan daha kapsamlı bir içeriğe ve deneme sayısına sahiptir.

## 5.2 Öneriler

COVID-19 hastalığı 2019 yılının son çeyreğinde patlak vermiş ve bütün dünyayı hızlı bir şekilde etkisi altına almış bir salgındır. Nezleye benzeyen belirtiler ile başlayan hastalık akciğerlerde pnömoniye sebep olmakta ve erken müdahale edilmezse ölüme sebebiyet vermektedir. BT görüntüler akciğer üzerinde pnömoni olan bölgeleri daha net gösterdiği için sağlık kurumlarında sıklıkla kullanılmaktadır. Bu görüntüler üzerinde radyologlar tarafından teşhis ve ilgili bölgelerin segmentasyon işlemi manuel olarak yapılmaktadır. Radyolog sayısının az olması, hasta ve görüntü sayısının çok fazla olmasından dolayı manuel analizler çok fazla süre almaktadır. Bundan dolayı hastane ortamlarında bilgisayar tabanlı destek sistemlerinin kullanımının artmasıyla hastalığın erken teşhisi ve hata oranının en aza indirilmesi için literatürde sıklıkla çalışmalar yapılmaktadır. Bu tez çalışmasında, DeepLabv3+ semantik segmentasyon metoduna ResNet-18, ResNet-50, MobileNet-v2, Xception, Inception-ResNet-v2 derin öğrenme modelleri entegre edilerek BT görüntülerinin farklı senaryolarda segmentasyon işlemi gerçekleştirilmiştir. Zenodo web sitesinde araştırmacıların kullanımına açık kaynak olarak sunulan 10 adet 3B BT görüntüsü veri seti olarak kullanılmıştır. MATLAB ortamında yapılan denemelerde DeepLabv3+ modeline entegre edilen ResNet-50 modelinin tüm senaryolarda daha başarılı sonuçlar verdiği izlenmiştir. BT görüntülerinde pnömoni gibi küçük bölgelerin başarılı segmentasyonu için görüntülerin olabildiğince alt sınıflara ayrılması gerekliliği bu tez çalışmasındaki en önemli çıktılarından biridir.

Derin öğrenme modellerinin literatüre sunulması ile beraber görüntülerde sınıflandırma, segmentasyon, obje tespiti ve tahmin problemlerinde hızlı bir şekilde başarılı sonuçlar elde edilmektedir. Özellikle medikal alanda gerçekleştirilen çalışmalar bilgisayar destekli klinik karar destek sistemleri için hızlı çözümler üretmekte, teşhis ve tedavi sürelerini kısaltması hedeflenmektedir. Modellerin yüksek doğrulukta çözümler üretebilmesi için çok fazla veri ve etiket bilgisine ihtiyaç duyulmaktadır. Bu çalışmalar için veriler genellikle özel bir kurum veya çalışma grubu tarafından toplanarak araştırmacıların kullanımına ya özelleştirilmiş web sitelerinden ya da GitHub ve Kaggle gibi veri paylaşım sitelerinden sunulmaktadır. Türkiye OECD ülkeleri içerisinde en çok MR ve BT görüntüsü alan ülke konumundadır. Bu görüntüler Sağlık Bakanlığı veri tabanlarında depolanmakta, hasta ve doktorların her zaman e-Nabız sistemi üzerinden görüntülemelerine izin verilmektedir. Ancak veriler spesifik olarak bazı araştırmacılar tarafından etik kurul izni ile kullanılabilir. Bu sistem üzerinden tüm hastalıklara dönük verilerin etiketlenerek ülkemizdeki araştırmacıların kullanımına sunulması nitelikli derin öğrenme uygulamalarının yapılabilmesinin önünü açacaktır. Modeller sonucu elde edilen ağırlıklar PACS sistemine entegre edildiğinde, cihazdan çekilen görüntü hızlı bir şekilde sunucular üzerinde analiz edilerek doktorların bilgisayarlarına bir ön bilgi ve teşhis için yardımcı görseller getirebilir. Bu tez çalışmasında gerçekleştirilen COVID-19 ve benzeri hastalıklar için klinik karar destek sistemleri yerli yazılımlar ile ülkemize katma değer sağlayabilir. Literatürde COVID-19 BT görüntülerinin DeepLabV3+ modeli ile yapılan segmentasyon çalışmaları çok fazla olmadığından, bu tez çalışmasındaki denemeler ve sonuçlar araştırmacılara faydalı bir kaynak olacak niteliktedir.

## 6. KAYNAKLAR

- Alkan, H., 2018, Bilgisayarlı Tomografi (BT), <https://www.medikalfizik.net/tag/bilgisayarli-tomografi-nedir/>: [Ziyaret Tarihi=10.07.2022].
- Arslan, B., 2005, Bilgisayarlı tomografi ile görüntüleme yöntemleri, *Fen Bilimleri Enstitüsü*.
- Badrinarayanan, V., Kendall, A. ve Cipolla, R., 2017, Segnet: A deep convolutional encoder-decoder architecture for image segmentation, *IEEE transactions on pattern analysis and machine intelligence*, 39 (12), 2481-2495.
- Ceylan, E., 2021, Zatürre (Pnömoni) nedir? Zatürre belirtileri ve tedavisi, <https://www.medicalpark.com.tr/zature-nedir-belirtileri-ve-tedavileri-nelerdir/hg-152#:~:text=Pn%C3%B6moni%20halk%20aras%C4%B1daki%20bilinen%20tabiriyle,ki%C5%9Filere%20do%C4%9Frudan%20bula%C5%9Fma%20riski%20Ovard%C4%B1r.>: [Ziyaret Tarihi= 10.07.2022].
- Chen, L.-C., Papandreou, G., Kokkinos, I., Murphy, K. ve Yuille, A. L., 2017, Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs, *IEEE transactions on pattern analysis and machine intelligence*, 40 (4), 834-848.
- Chollet, F., 2017, Xception: Deep learning with depthwise separable convolutions, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 1251-1258.
- Cömert, S. Ş. ve Kiral, N. J. S. C. o. I. E., 2020, COVID-19 Pnömonisinin Radyolojik Bulguları.
- Elharrouss, O., Subramanian, N. ve Al-Maadeed, S., 2020, An encoder-decoder-based method for COVID-19 lung infection segmentation, *arXiv preprint arXiv:2007.00861*.
- He, K., Zhang, X., Ren, S. ve Sun, J., 2016, Deep residual learning for image recognition, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 770-778.
- Jeong, J., Yoon, T. S. ve Park, J. B., 2018, Towards a meaningful 3D map using a 3D lidar and a camera, *Sensors*, 18 (8), 2571.
- Jordan, J., 2018, An overview of semantic image segmentation., <https://www.jeremyjordan.me/semantic-segmentation/>: [Ziyaret Tarihi: 10.07.2022].
- Khalifa, N. E. M., Manogaran, G., Taha, M. H. N. ve Loey, M., 2021, A deep learning semantic segmentation architecture for COVID- 19 lesions discovery in limited chest CT datasets, *Expert Systems*, e12742.
- Khan, S. H., Sohail, A., Khan, A. ve Lee, Y. S., 2020, Classification and region analysis of COVID-19 infection using lung CT images and deep convolutional neural networks, *arXiv preprint arXiv:2009.08864*.
- Long, J., Shelhamer, E. ve Darrell, T., 2015, Fully convolutional networks for semantic segmentation, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 3431-3440.
- Ma, J., Wang, Y., An, X., Ge, C., Yu, Z., Chen, J., Zhu, Q., Dong, G., He, J. ve He, Z., 2020, Towards efficient COVID-19 CT annotation: A benchmark for lung and infection segmentation.
- Ma Jun, G. C., Wang Yixin, An Xingle, Gao Jiantao, Yu Ziqi, Zhang Minqing, Liu Xin, Deng Xueyuan, Cao Shucheng, Wei Hao, Mei Sen, Yang Xiaoyu, Nie Ziwei, Li

- Chen, Tian Lu, Zhu Yuntao, Zhu Qiongjie, Dong Guoqiang, He Jian, 2020, COVID-19 CT Lung and Infection Segmentation Dataset, <https://zenodo.org/record/3757476#.YscChmDP1Pa>: [Ziyaret Tarihi: 20.06.2021].
- Mathworks, 2017, Semantic Segmentation Using Deep Learning, <https://www.mathworks.com/help/vision/ug/semantic-segmentation-using-deep-learning.html>: [Ziyaret Tarihi= 15.06.2022].
- MathWorks, 2022, Pretrained Deep Neural Networks, <https://www.mathworks.com/help/deeplearning/ug/pretrained-convolutional-neural-networks.html>: [Ziyaret Tarihi= 10.07.2022].
- MATLAB, 2017a, evaluateSemanticSegmentation, <https://www.mathworks.com/help/vision/ref/evaluatesemanticsegmentation.html#d123e206237>: [Ziyaret Tarihi: 20.06.2020].
- MATLAB, 2017b, imageDataAugmenter, <https://www.mathworks.com/help/deeplearning/ref/imagedataaugmenter.html>: [Ziyaret Tarihi: 20.06.2022].
- MEB, 2011, Radyoloji-Bilgisayarlı Tomografi Cihazları, [http://www.megep.meb.gov.tr/mte\\_program\\_modul/moduller\\_pdf/Bilgisayarlı%20C4%B1%20Tomografi%20Cihazlar%C4%B1.pdf](http://www.megep.meb.gov.tr/mte_program_modul/moduller_pdf/Bilgisayarlı%20C4%B1%20Tomografi%20Cihazlar%C4%B1.pdf):
- Menteşe, E. ve Hançer, E., 2020, Histopatoloji görüntülerde derin öğrenme yöntemleri ile çekirdek segmentasyonu, *Avrupa Bilim ve Teknoloji Dergisi*, 95-102.
- Müller, D., Rey, I. S. ve Kramer, F. J. a. p. a., 2020, Automated chest ct image segmentation of covid-19 lung infection based on 3d u-net.
- Oulefki, A., Agaian, S., Trongtirakul, T. ve Laouar, A. K., 2021, Automatic COVID-19 lung infected region segmentation and measurement using CT-scans images, *Pattern Recognition*, 114, 107747.
- Polat, H., 2022a, Multi-task semantic segmentation of CT images for COVID-19 infections using DeepLabV3+ based on dilated residual network, *Physical and Engineering Sciences in Medicine*, 1-13.
- Polat, H., 2022b, A modified DeepLabV3+ based semantic segmentation of chest computed tomography images for COVID- 19 lung infections, *International Journal of Imaging Systems and Technology*.
- Polat, H. J. P. ve Medicine, E. S. i., 2022, Multi-task semantic segmentation of CT images for COVID-19 infections using DeepLabV3+ based on dilated residual network, 1-13.
- Ronneberger, O., Fischer, P. ve Brox, T., 2015, U-net: Convolutional networks for biomedical image segmentation, *International Conference on Medical image computing and computer-assisted intervention*, 234-241.
- Rorden, C., 2000, MRicro, <https://people.cas.sc.edu/rorden/mricro/mricro.html>: [Ziyaret Tarihi: 05.02.2021].
- Sağlık Bakanlığı, 2022, COVID-19 Nedir?, <https://covid19.saglik.gov.tr/TR-66300/covid-19-nedir-.html>: [Ziyaret Tarihi: 19.06.2022].
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. ve Chen, L.-C., 2018, Mobilenetv2: Inverted residuals and linear bottlenecks, *Proceedings of the IEEE conference on computer vision and pattern recognition*, 4510-4520.
- Štifanić, D., Musulin, J., Jurilj, Z., Šegota, S., Lorencin, I., Anđelić, N., Vlahinić, S., Šušteršič, T., Blagojević, A. ve Filipović, N., 2021, Semantic segmentation of chest X-ray images based on the severity of COVID-19 infected patients, *EAI Endorsed Transactions on Bioengineering and Bioinformatics*, 1, e3.

- Szegedy, C., Ioffe, S., Vanhoucke, V. ve Alemi, A. A., 2017, Inception-v4, inception-resnet and the impact of residual connections on learning, *Thirty-first AAAI conference on artificial intelligence*.
- Teixeira, L. O., Pereira, R. M., Bertolini, D., Oliveira, L. S., Nanni, L., Cavalcanti, G. D. ve Costa, Y. M., 2021, Impact of lung segmentation on the diagnosis and explanation of COVID-19 in chest X-ray images, *Sensors*, 21 (21), 7116.
- Vikipedi, 2022, Türkiye'de COVID-19 pandemisi, [https://tr.wikipedia.org/wiki/T%C3%BCrkiye%27de\\_COVID-19\\_pandemisi](https://tr.wikipedia.org/wiki/T%C3%BCrkiye%27de_COVID-19_pandemisi): [Ziyaret Tarihi: 20.06.2022].
- Wang, Y., Zhang, Y., Liu, Y., Tian, J., Zhong, C., Shi, Z., Zhang, Y. ve He, Z., 2021, Does non-COVID-19 lung lesion help? investigating transferability in COVID-19 CT image segmentation, *Computer Methods and Programs in Biomedicine*, 202, 106004.
- Yang, M. J. G. C. W. Y. A. X. G. J. Y. Z. Z. M. L. X. D. X. C. S. W. H. M. S., 2020, COVID-19 CT Lung and Infection Segmentation Dataset, [https://zenodo.org/record/3757476#\\_YrI5u3ZBxPZ](https://zenodo.org/record/3757476#_YrI5u3ZBxPZ): [20.06.2021].
- Yıldırım, B., 2022, camvid data ile semantik segmentasyon, [https://prezi.com/p/gks0qswhp33\\_/camvid-data-ile-semantik-segmentasyon/](https://prezi.com/p/gks0qswhp33_/camvid-data-ile-semantik-segmentasyon/): [Ziyaret Tarihi=12.07.2022].
- Yin, S., Deng, H., Xu, Z., Zhu, Q. ve Cheng, J., 2022, SD-UNet: A Novel Segmentation Framework for CT Images of Lung Infections, *Electronics*, 11 (1), 130.
- Zhao, S., Li, Z., Chen, Y., Zhao, W., Xie, X., Liu, J., Zhao, D. ve Li, Y., 2021a, SCOAT-Net: A novel network for segmenting COVID-19 lung opacification from CT images, *Pattern Recognition*, 119, 108109.
- Zhao, X., Zhang, P., Song, F., Fan, G., Sun, Y., Wang, Y., Tian, Z., Zhang, L. ve Zhang, G., 2021b, D2A U-Net: Automatic segmentation of COVID-19 CT slices based on dual attention and hybrid dilated convolution, *Computers in biology and medicine*, 135, 104526.
- Zhou, T., Canu, S. ve Ruan, S., 2021, Automatic COVID- 19 CT segmentation using U- Net integrated spatial and channel attention mechanism, *International Journal of Imaging Systems and Technology*, 31 (1), 16-27.