



**İSKENDERUN TEKNİK**  
ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

**YÜKSEK  
LİSANS  
TEZİ**

**ADAPTİF YÖNTEMLERLE  
İYİLEŞTİRİLMİŞ GÖĞÜS  
RÖNTGENLERİNDEN DERİN  
ÖĞRENME İLE COVID-19 TESPİTİ**

**Süleyman Serhan NARLI**

**BİLGİSAYAR MÜHENDİSLİĞİ  
ANABİLİM DALI**

**TEMMUZ 2021**





**ADAPTİF YÖNTEMLERLE İYİLEŞTİRİLMİŞ GÖĞÜS  
RÖNTGENLERİNDEN DERİN ÖĞRENME İLE COVID-19 TESPİTİ**

**Süleyman Serhan NARLI**

**YÜKSEK LİSANS TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**İSKENDERUN TEKNİK ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**Temmuz 2021**

Süleyman Serhan NARLI tarafından hazırlanan “ADAPTİF YÖNTEMLERLE İYİLEŞTİRİLMİŞ GÖĞÜS RÖNTGENLERİNDEN DERİN ÖĞRENME İLE COVID-19 TESPİTİ” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile İskenderun Teknik Üniversitesi Bilgisayar Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

**Danışman:** Dr. Öğr. Üyesi Gökhan ALTAN

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

**Başkan:** Doç. Dr. Yakup KUTLU

Bilgisayar Mühendisliği Anabilim Dalı, İskenderun Teknik Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

**Üye:** Doç. Dr. Kenan YILDIRIM

Matematik Eğitimi Anabilim Dalı, Muş Alparslan Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

**Üye:** Dr. Öğr. Üyesi Murat KÖKLÜ

Bilgisayar Mühendisliği Anabilim Dalı, Selçuk Üniversitesi

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum.

Tez Savunma Tarihi: 01/07/2021

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Doç. Dr. Ersin Bahçeci  
Lisansüstü Eğitim Enstitüsü Müdürü

## ETİK BEYAN

İskenderun Teknik Üniversitesi Lisans Üstü Eğitim Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez üzerinde Yükseköğretim Kurulu tarafından hiçbir değişiklik yapılamayacağı için tezin bilgisayar ekranında görüntülendiğinde asıl nüsha ile aynı olması sorumluluğunun tarafıma ait olduğunu,
- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar karesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu, bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İmza

Süleyman Serhan Narlı

28/05/2021

# ADAPTİF YÖNTEMLERLE İYİLEŞTİRİLMİŞ GÖĞÜS RÖNTGENLERİNDEN DERİN ÖĞRENME İLE COVID-19 TESPİTİ

(Yüksek Lisans Tezi)

Süleyman Serhan NARLI

İSKENDERUN TEKNİK ÜNİVERSİTESİ  
MÜHENDİSLİK VE FEN BİLİMLERİ ENSTİTÜSÜ

Mayıs 2021

## ÖZET

Derin Öğrenme (DL), günümüzde en popüler Makine Öğrenme (ML) algoritmasıdır, Medikal Görüntü işleme alanında sınıflandırmadaki yüksek performansı sayesinde gün geçtikçe kullanımı yaygınlaşmaktadır. Derin Öğrenme bir sinir ağı yapısından esinlenerek oluşturulmuştur ve birçok parametre içermektedir, yüksek başarımından dolayı birçok hastalığın sınıflandırmasında kullanılmaktadır. Görüntü işleme alanında da oldukça sık kullanılan Derin Öğrenme algoritmaları, görüntü üzerindeki pikselleri farklı katmanlarda işleyerek sınıflandırma yapmaktadır. Görüntü DL ile sınıflandırmadan önce üzerinde farklı ön işleme metotları ile sınıflandırmanın daha başarılı olmasını sağlanabilmektedir. Bu çalışmada Yerel Histogram Eşitleme (LHE) ve Uyarlanabilir Histogram Eşitleme (AHE) kullanılarak farklı Derin Öğrenme mimarilerinin COVID üzerindeki etkisi araştırılmıştır, görüntüler, Histogram Eşitleme kullanılarak ve Histogram Eşitleme kullanılmadan incelenerek bu filtrenin başarıma olan etkisi belirlenmiştir, Ayrıca her iki Histogram Eşitleme için farklı parametreler test edilerek en başarılı parametreler belirlenmiştir. Sınıflandırma için Chest X-Ray görüntüleri kullanılmıştır, veriseti COVID, Pneumonia ve Normal görüntülerden oluşmaktadır, Akciğer görüntüleri veriseti üzerinde iki ayrı düzenleme yapılarak birinci veriseti akciğer görüntüleri sağ ve sol lob olarak kırılmıştır, ikinci veriseti üzerinde herhangi bir kırılma işlemi yapılmamıştır. Her bir Histogram Eşitleme farklı parametreler ile test edilerek her parametrenin başarıma olan etkisi gözlemlenmiştir. DarkNet19, VGG16, AlexNet, MobileNet ve Inception gibi farklı DL mimarileri kullanılarak sınıflandırma başarımı tespit edilmiştir. Bu modeller küçük veriseti ile eğitilerek öğrenim transferi ile daha büyük veriseti üzerinde test edilmiştir, böylece küçük veriseti ile öğrenilen ağırlıkların büyük veri setinde test edilmesi ile başarımların elde edilmiştir.

Anahtar Kelimeler : Medikal Görüntü İşleme, Covid-19, Derin Öğrenme, Yerel Histogram Eşitleme, Pnömoni, Uyarlanabilir Histogram Eşitleme.

Sayfa Adedi : 107

Danışman : Dr. Öğr. Üyesi Gökhan ALTAN

COVID-19 Detection using Deep learning on Chest X-rays Enhanced by Adaptive Methods  
(M. Sc. Thesis)

Süleyman Serhan NARLI

ISKENDERUN TECHNICAL UNIVERSITY  
ENGINEERING AND SCIENCE INSTITUTE

May 2021

ABSTRACT

Deep Learning (DL) is the most popular Machine Learning (ML) algorithm today. Its use is becoming widespread day by day thanks to its high performance in classification in the field of Medical Image processing. Deep Learning is inspired by a neural network structure and includes many parameters. Due to its high performance, it is used in the classification of many diseases. Deep Learning algorithms, which are frequently used in the field of image processing, classify the pixels on the image by processing them in different layers. Before classifying the image with DL, it can be ensured that the classification is more successful with different preprocessing methods. In this study, the effect of different Deep Learning architectures on COVID was investigated using Local Histogram Equalization (LHE) and Adaptive Histogram Equalization (AHE), images were examined using Histogram Equalization and without using Histogram Equalization, and the effect of this filter on achievement was determined. The most successful parameters were determined by testing. Chest X-Ray images were used for classification, the dataset consists of COVID, Pneumonia and Normal images, Lung images were made in two separate arrangements on the dataset, and the first dataset was cropped as right and left lobe lung images, no clipping was performed on the second dataset. Each Histogram Equalization was tested with different parameters and the effect of each parameter on achievement was observed. Classification performance has been determined using different DL architectures such as DarkNet19, VGG16, AlexNet, MobileNet and Inception. These models were trained with a small dataset and tested on a larger dataset with learning transfer, so performance results were obtained by testing the weights learned with a small dataset on a large dataset.

Key Words : Deep Learning, Convolutional Neural Networks, Chest X-Ray, Local Histogram Equalization, Medical Image Analysis, Adaptive Histogram Equalization.

Page Number : 107

Supervisor : Assist. Prof. Dr. Gökhan ALTAN

## TEŐEKKÜR

Bu tez alıřmam sũresince her konuda, anlayıř ve desteęini esirgemeyen, bu akademik yolculukta bana her konuda destek veren ve alıřmalarımda bana yol gũsteren danıřmanım Dr. Őęr. Őyesi Gũkhan ALTAN'a ve tũm hocalarıma ilgi ve yardımlarından dolayı teőekkũrũ bir bor bilirim. Rũntgen gũrũntũleri ve sonuların tıbbi doęrulaması iin desteklerinden dolayı Dr. Sinan İNCE'ye teőekkũr ederim. Sevgi ve Őzverileriyle bugũnlere gelmemi saęlayan, hořgũrũleri ile her zaman yanımda olan sevgili anneme, babama, kardeřlerime ve arkadařlarıma teőekkũrlerimi sunarım.



## İÇİNDEKİLER

|  | <b>Sayfa</b> |
|--|--------------|
| ÖZET .....   | iv           |
| ABSTRACT.....  | v            |
| TEŞEKKÜR.....  | vi           |
| İÇİNDEKİLER .....                                      | vii          |
| ÇİZELGELERİN LİSTESİ.....                              | x            |
| ŞEKİLLERİN LİSTESİ .....                               | xii          |
| SİMGELER VE KISALTMALAR.....                           | xiv          |
| 1. GİRİŞ.....  | 1            |
| 1.1. Motivasyon.....                                   | 1            |
| 1.2. Tezin Kapsamı.....                                | 2            |
| 1.3. Tezin Önemi ve Farklılıkları .....                | 2            |
| 1.4. Tez Organizasyonu.....                            | 3            |
| 2. LİTERATÜR TARAMASI .....                            | 5            |
| 2.1. Derin Öğrenme Çalışmaları .....                   | 5            |
| 2.2. Göğüs Röntgen Filmi Analizleri .....              | 6            |
| 2.2.1. COVID-19 Analizleri.....                        | 8            |
| 2.3. Covid-19 ve Pnömoni Analizleri .....              | 11           |
| 3. MATERYAL VE METOT .....                             | 14           |
| 3.1. Derin Öğrenme.....                                | 14           |
| 3.2. Evrişimsel Sinir Ağları.....                      | 16           |
| 3.2.1. Aktivasyon ve Evrişim Katmanı .....             | 16           |
| 3.2.2. Derin öğrenme ile optimizasyon .....            | 18           |
| 3.2.3. Öğrenme aktarımı (Transfer Learning) .....      | 20           |
| 3.3. Ön Eğitilmiş Popüler Derin Öğrenme Modelleri..... | 22           |
| 3.3.1. AlexNet Mimarisi.....                           | 22           |
| 3.3.2. VGGNet Mimarisi.....                            | 22           |



|   | <b>Sayfa</b> |
|---|--------------|
| 3.3.3. MobileNet Mimarisi .....                                       | 23           |
| 3.3.4. DarkNet19 Mimarisi .....                                       | 24           |
| 3.4. Histogram Eşitleme .....   | 25           |
| 3.4.1. Bölgesel histogram eşitleme (LHE) .....                        | 26           |
| 3.4.2. Yoğunluk sınırlı uyarlanabilir histogram eşitleme (CLAHE)..... | 29           |
| 3.5. Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM).....  | 30           |
| 3.6. Kullanılan Veri Seti.....  | 31           |
| 3.7. Veri Setleri üzerine stratejiler .....                           | 33           |
| 3.7.1. Strateji 1 .....   | 33           |
| 3.7.2. Strateji 2 .....   | 35           |
| 3.7.3. Strateji 3 .....   | 36           |
| 3.7.4. Strateji 4 .....   | 38           |
| 3.7.5. Strateji 5 .....   | 38           |
| 3.7.6. Strateji 6 .....   | 39           |
| 3.8. Performans kriterleri ve İstatistiksel Analiz.....               | 40           |
| 4. ARAŞTIRMA BULGULARI.....   | 42           |
| 4.1. Strateji 1 ile Elde Edilen Sonuçlar .....                        | 42           |
| 4.1.1. Strateji 1 AlexNet Sonuçları .....                             | 42           |
| 4.1.2. Strateji 1 MobileNet Sonuçları.....                            | 42           |
| 4.1.3. Strateji 1 VGG16 Sonuçları .....                               | 43           |
| 4.2. Strateji 2 ile Elde Edilen Sonuçlar .....                        | 43           |
| 4.2.1. Strateji 2 AlexNet Sağ-Sol Lob CXR Sonuçları .....             | 44           |
| 4.2.2. Strateji 2 AlexNet Sol Lob CXR Sonuçları .....                 | 44           |
| 4.2.3. Strateji 2 AlexNet Sağ Lob CXR Sonuçları.....                  | 45           |
| 4.2.4. Strateji 2 DarkNet19 Sağ-Sol Lob CXR Sonuçları.....            | 45           |
| 4.2.5. Strateji 2 DarkNet19 Sol Lob CXR Sonuçları .....               | 46           |

**Sayfa**

|  |     |
|--|-----|
| 4.2.6. Strateji 2 DarkNet19 Sağ Lob CXR Sonuçları..... | 46  |
| 4.3. Strateji 3 ile Elde Edilen Sonuçlar .....         | 47  |
| 4.4. Strateji 4 ile Elde Edilen Sonuçlar .....         | 85  |
| 4.5. Strateji 5 ile Elde Edilen Sonuçlar .....         | 86  |
| 4.6. Strateji 6 ile Elde Edilen Sonuçlar .....         | 88  |
| 4.6.1. Covid-19 ve Sağlıklı CXR Eğitim Sonuçları ..... | 88  |
| 4.6.2. Covid-19 ve Pnömoni CXR Eğitim Sonuçları .....  | 90  |
| 4.7. Farklı Stratejiler için Grad-CAM Gösterimi .....  | 93  |
| 4.7.1. Strateji 1 için Grad-CAM.....                   | 93  |
| 4.7.2. Strateji 3 ve 4 için Grad-CAM .....             | 93  |
| 5. SONUÇ VE ÖNERİLER.....                              | 96  |
| KAYNAKLAR .....  | 102 |

## ÇİZELGELERİN LİSTESİ

| <b>Çizelge</b>  | <b>Sayfa</b> |
|---|--------------|
| Çizelge 3.1. Kullanılan CXR görüntü sayısı.....   | 32           |
| Çizelge 3.2. Strateji 3 için farklı kombinasyonlar .....                                  | 37           |
| Çizelge 4.1. AlexNet için strateji 1 sonuçları .....                                      | 42           |
| Çizelge 4.2. MobileNet için strateji 1 sonuçları .....                                    | 42           |
| Çizelge 4.3. VGG16 için strateji 1 sonuçları .....  | 43           |
| Çizelge 4.4. AlexNet sağ-sol birlikte CXR strateji 1 sonuçları .....                      | 44           |
| Çizelge 4.5. AlexNet sol lob CXR strateji 1 sonuçları .....                               | 44           |
| Çizelge 4.6. AlexNet sağ lob CXR strateji 1 sonuçları.....                                | 45           |
| Çizelge 4.7. DarkNet19 sağ-sol lob CXR strateji 1 sonuçları .....                         | 45           |
| Çizelge 4.8. DarkNet19 sol lob CXR strateji 1 sonuçları .....                             | 46           |
| Çizelge 4.9. DarkNet19 sağ lob CXR strateji 1 sonuçları .....                             | 46           |
| Çizelge 4.10. AlexNet kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3) .....   | 47           |
| Çizelge 4.11. AlexNet kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6) .....   | 48           |
| Çizelge 4.12. AlexNet kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,7 - 1) .....     | 49           |
| Çizelge 4.13. AlexNet Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3).....       | 50           |
| Çizelge 4.14. AlexNet Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6).....       | 51           |
| Çizelge 4.15. AlexNet Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,7 - 1).....         | 52           |
| Çizelge 4.16. AlexNet Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3).....       | 53           |
| Çizelge 4.17. AlexNet Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6).....       | 54           |
| Çizelge 4.18. AlexNet Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,7 - 1).....         | 55           |
| Çizelge 4.19. DarkNet19 kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3).....  | 56           |
| Çizelge 4.20. DarkNet19 kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6).....  | 57           |
| Çizelge 4.21. DarkNet19 kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,7 - 1).....    | 58           |
| Çizelge 4.22. DarkNet19 Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3).....     | 59           |
| Çizelge 4.23. DarkNet19 Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6).....     | 60           |
| Çizelge 4.24. DarkNet19 Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,7 - 1).....       | 61           |
| Çizelge 4.25. DarkNet19 Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3).....     | 62           |
| Çizelge 4.26. DarkNet19 Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6).....     | 63           |
| Çizelge 4.27. DarkNet19 Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,7 - 1).....       | 64           |
| Çizelge 4.28. MobileNet kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3) ..... | 65           |
| Çizelge 4.29. MobileNet kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6) ..... | 66           |
| Çizelge 4.30. MobileNet kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,7 - 1) .....   | 67           |
| Çizelge 4.31. MobileNet Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3).....     | 68           |
| Çizelge 4.32. MobileNet Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6).....     | 69           |

| <b>Çizelge</b>   | <b>Sayfa</b> |
|--|--------------|
| Çizelge 4.33. MobileNet Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,7 - 1).....    | 70           |
| Çizelge 4.34. MobileNet Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3) ..... | 71           |
| Çizelge 4.35. MobileNet Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6) ..... | 72           |
| Çizelge 4.36. MobileNet Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,7 - 1) .....   | 73           |
| Çizelge 4.37. VGG16 kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3).....   | 74           |
| Çizelge 4.38. VGG16 kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6).....   | 75           |
| Çizelge 4.39. VGG16 kırılmamış CXR strateji 3 sonuçları (clip_limit: 0,7 - 1).....     | 76           |
| Çizelge 4.40. VGG16 Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3).....      | 77           |
| Çizelge 4.41. VGG16 Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6).....      | 78           |
| Çizelge 4.42. VGG16 Sol Lob CXR strateji 3 sonuçları (clip_limit: 0,7 - 1).....        | 79           |
| Çizelge 4.43. VGG16 Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,1 - 0,3).....      | 80           |
| Çizelge 4.44. VGG16 Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,4 - 0,6).....      | 81           |
| Çizelge 4.45. VGG16 Sağ Lob CXR strateji 3 sonuçları (clip_limit: 0,7 - 1).....        | 82           |
| Çizelge 4.46. AlexNet strateji 4 için test sonuçları.....                              | 85           |
| Çizelge 4.47. DarkNet19 strateji 4 için test sonuçları .....                           | 85           |
| Çizelge 4.48. MobileNet strateji 4 için test sonuçları.....                            | 85           |
| Çizelge 4.49. VGG16 strateji 4 için test sonuçları.....                                | 86           |
| Çizelge 4.50. AlexNet strateji 5 için eğitim/test sonuçları .....                      | 87           |
| Çizelge 4.51. DarkNet19 strateji 5 için eğitim/test sonuçları .....                    | 87           |
| Çizelge 4.52. MobileNet strateji 5 için eğitim/test sonuçları.....                     | 87           |
| Çizelge 4.53. VGG16 strateji 5 için eğitim/test sonuçları .....                        | 88           |
| Çizelge 4.54. AlexNet 2'li sınıflandırma sonuçları (Covid-19 ve Sağlıklı) .....        | 89           |
| Çizelge 4.55. DarkNet19 2'li sınıflandırma sonuçları (Covid-19 ve Sağlıklı) .....      | 89           |
| Çizelge 4.56. MobileNet 2'li sınıflandırma sonuçları (Covid-19 ve Sağlıklı).....       | 89           |
| Çizelge 4.57. VGG16 2'li sınıflandırma sonuçları (Covid-19 ve Sağlıklı) .....          | 90           |
| Çizelge 4.58. AlexNet 2'li sınıflandırma sonuçları (Covid-19 ve Pnömoni) .....         | 91           |
| Çizelge 4.59. DarkNet19 2'li sınıflandırma sonuçları (Covid-19 ve Pnömoni) .....       | 91           |
| Çizelge 4.60. MobileNet 2'li sınıflandırma sonuçları (Covid-19 ve Pnömoni).....        | 91           |
| Çizelge 4.61. VGG16 2'li sınıflandırma sonuçları (Covid-19 ve Pnömoni) .....           | 92           |
| Çizelge 4.62. Strateji 3 ve 4 için AlexNet ve VGG16 Grad-CAM gösterimleri .....        | 94           |
| Çizelge 4.63. Strateji 3 ve 4 için MobileNet ve DarkNet19 Grad-CAM gösterimleri.....   | 95           |
| Çizelge 5.1. Literatürde bulunan benzer çalışmaların karşılaştırılması .....           | 100          |
| Çizelge 5.2. Tüm stratejiler için elde edilen en başarılı sonuçlar .....               | 101          |

## ŞEKİLLERİN LİSTESİ

| <b>Şekil</b>   | <b>Sayfa</b> |
|--|--------------|
| Şekil 3.1. Örnek bir yapay sinir ağı yapısı.....   | 14           |
| Şekil 3.2. Biyolojik Sinir Ağı Yapısı.....   | 15           |
| Şekil 3.3. Evrimsel Sinir Ağında Evrişim (Filtreleme) İşlemi .....   | 16           |
| Şekil 3.4. Aktivasyon Fonksiyonları Örneği.....  | 17           |
| Şekil 3.5. Ortalama ve Max Ortaklama İşlemi .....  | 19           |
| Şekil 3.6. Basit Bir CNN Yapısı.....   | 20           |
| Şekil 3.7. AlexNet Modeli Örneği .....   | 22           |
| Şekil 3.8. MobileNet genel yapısı.....   | 23           |
| Şekil 3.9. DarkNet19 Mimarisi.....   | 25           |
| Şekil 3.10. Düşük Yoğunluklu Görüntüye Uygulanan Histogram Eşitleme (Gonzalez, Woods ve Prentice Hall, 2008) ..... | 26           |
| Şekil 3.11. Histogram Eşitleme ile Kontrast Seviyesinin Düzenlenmesi .....   | 27           |
| Şekil 3.12. Orijinal CXR Covid-19 Görüntüsü ile Farklı Selem değerleri için LHE Sonuçları                          | 28           |
| Şekil 3.13. Farklı HE yöntemleri ile yoğunluk dağılımı.....  | 29           |
| Şekil 3.14. Grad-CAM'e genel bakış (Selvaraju, Ramprasaath ve diğerleri, 2017) .....                               | 31           |
| Şekil 3.15. Kırılmış Covid-19 görüntüsü.....   | 33           |
| Şekil 3.16. Covidx veritabanından alınan Covid-19 (a), Pnömoni (b) ve Sağlıklı (c) görüntüleri                     | 33           |
| Şekil 3.17. Strateji 1 adımları .....  | 34           |
| Şekil 3.18. Veri çerçevelerinin oluşturulması.....   | 35           |
| Şekil 3.19. Strateji 2'de oluşturulan veri çerçeveleri.....  | 36           |
| Şekil 3.20. Strateji 3'te oluşturulan veri çerçeveleri.....  | 37           |
| Şekil 3.21. Strateji 4'te oluşturulan .....  | 38           |
| Şekil 3.22. Strateji 5'te uygulanan adımlar.....   | 39           |
| Şekil 3.23. Strateji 6'da uygulanan 2'li sınıflandırma (Covid-19 ve Sağlıklı CXR).....                             | 39           |
| Şekil 3.24. Strateji 6'da uygulanan 2'li sınıflandırma (Covid-19 ve Pneumonia CXR).....                            | 40           |
| Şekil 3.25. Karışıklık matrisine örnek bir görüntü .....   | 41           |
| Şekil 4.1. Strateji 3 AlexNet en iyi sonuçları.....  | 83           |
| Şekil 4.2. Strateji 3 DarkNet19 en iyi sonuçları .....   | 83           |
| Şekil 4.3. Strateji 3 MobileNet en iyi sonuçları.....  | 84           |
| Şekil 4.4. Strateji 3 VGG16 en iyi sonuçları .....   | 84           |
| Şekil 4.5. Strateji 4 en iyi test sonuçları .....  | 86           |
| Şekil 4.6. Strateji 5 en iyi test sonuçları .....  | 88           |
| Şekil 4.7. Strateji 6 2'li sınıf sonuçları (Covid-19 ve Sağlıklı).....   | 90           |

| <b>Şekil</b>  | <b>Sayfa</b> |
|---|--------------|
| Şekil 4.8. Strateji 6 2'li sınıf sonuçları (Covid-19 ve Pnömoni)..... | 92           |
| Şekil 4.9. Strateji 1 için farklı Grad-CAM görüntüleri.....           | 93           |



## SİMGELER VE KISALTMALAR

Bu çalışmada kullanılmış simgeler ve kısaltmalar, açıklamaları ile birlikte aşağıda sunulmuştur.

| <b>Simgeler</b>    | <b>Açıklamalar</b>   |
|--------------------|--|
| $\delta$           | Delta  |
| $\theta$           | Teta   |
| $\alpha$           | Alfa   |
| $\beta$            | Beta   |
| $\gamma$           | Gamma  |
| <b>TanH</b>        | Hiperbolik Tanjant   |
| <b>Kısaltmalar</b> | <b>Açıklamalar</b>   |
| <b>AHE</b>         | Uyarlanabilir Histogram Eşitleme   |
| <b>AMBE</b>        | Orijinal Görüntünün Parlaklığı ile Geliştirilmiş Görüntünün Parlaklığı Arasındaki Fark |
| <b>ARDS</b>        | Akut Solunum Sıkıntısı Sendromunu  |
| <b>CAD</b>         | Bilgisayar Destekli Teşhis   |
| <b>CLAHE</b>       | Yoğunluk Sınırlı Uyarlanabilir Histogram Eşitleme                                      |
| <b>CNN</b>         | Evrişimsel Sinir Ağları  |
| <b>COVID-19</b>    | Şiddetli Akut Solunum Yolu Sendromu Korona Virüsü 2                                    |
| <b>CXR</b>         | Göğüs Röntgen Filmi  |
| <b>DL</b>          | Derin Öğrenme  |
| <b>DNN</b>         | Derin Sinir Ağları   |
| <b>FN</b>          | Yanlış Negatif   |
| <b>FP</b>          | Yanlış Pozitif   |
| <b>GANs</b>        | Üretken Çekişmeli Sinir Ağı  |

|                 |   |
|-----------------|---|
| <b>GHE</b>      | Global Histogram Eşitleme                           |
| <b>Grad-CAM</b> | Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması     |
| <b>ILSVRC</b>   | ImageNet Büyük Ölçekli Görsel Tanıma Yarışması      |
| <b>LHE</b>      | Bölgesel Histogram Eşitleme                         |
| <b>ML</b>       | Makine Öğrenimi                                     |
| <b>MLP</b>      | Çok Katmanlı Algılayıcı                             |
| <b>MSE</b>      | Minimum Kare Hatası                                 |
| <b>NIH</b>      | Ulusal Sağlık Enstitüleri Klinik Merkezi            |
| <b>PSNR</b>     | Yeniden Yapılandırılmış Görüntü Kalitesinin Tahmini |
| <b>ReLu</b>     | Düzeltilmiş Doğrusal Birim                          |
| <b>ROI</b>      | İlgi Alanı Bölgesi                                  |
| <b>RT-PCR</b>   | Ters Transkripsiyon Polimeraz Zincir Reaksiyonu     |
| <b>SIRM</b>     | Italian Society of Medical Radiology                |
| <b>SNR</b>      | Sinyal Gücünün Gürültü Gücüne Oranı                 |
| <b>TL</b>       | Öğrenme Aktarımı                                    |
| <b>TN</b>       | Gerçek Negatif                                      |
| <b>TP</b>       | Gerçek Pozitif                                      |
| <b>VGG</b>      | Visual Geometry Group Network                       |
| <b>X-Ray</b>    | Röntgen Filmi                                       |
| <b>YSA</b>      | Yapay Sinir Ağları                                  |



# 1. GİRİŞ

## 1.1. Motivasyon

Aralık 2019'da bilinen ilk varlığının bildirildiği pozitif yönelimli ve tek iplicikle RNA virüsü olan yeni tip bir korona virüsü olan SARS-CoV-2 ya da açık adıyla şiddetli akut solunum yolu sendromu korona virüsü 2 (COVID-19), tüm dünyayı etkisi altına alarak binlerce insanın ölümüne neden oldu, pek çok bilim insanı bu virüs üzerinde çalışarak aşı geliştirmeye çalışmaktadırlar. COVID-19 virüsünün etkilerini azaltmak için erken tanı koyulması oldukça önemlidir, COVID-19 virüsünü tespit etmek için birçok yöntem kullanılmaktadır ve bunlar arasında en hızlı yöntemlerden bir tanesi olan göğüs röntgeni(X-Ray) yöntemi ile COVID-19 tespit edilebilmektedir. Günümüzde medikal görüntü işleme ile hastalık tespiti için birçok bilgisayarlı teknik geliştirilmiştir, son zamanlarda görüntü işlemede en sık kullanılan yöntem ise makine öğrenmesi alanında kullanılan derin öğrenme (DL) ile sınıflandırma yöntemidir. Derin öğrenme algoritmaları ile medikal görüntüler eğitilerek derin öğrenme modelinde bulunan katmanların bu görüntülerdeki öznelikleri öğrenilmesi, katmanlar arasında bulunan ağların ağırlıklarının güncellenmesiyle sağlanır, böylece oluşturulan derin öğrenme mimarisi derin öğrenme katmanları arasında görüntüyü öğrenmiş olur ve bunun sonucunda model belli bir başarımla sınıflandırma yapabilir. Geleneksel tıbbi görüntü işlemede X-ray görüntülerinin patolojik etkilerinin saptanmasında görüntünün yerel ve morfolojik özellikleri oldukça önemlidir, bu özelliklerin çıkarılması ve karakterize edilmesiyle birlikte görüntünün öznelikleri tespit edilir.

Covid-19 hastalığının dünya çapındaki etkilerinin gittikçe artmasıyla birlikte, kullanılan tanı yöntemlerinin maliyeti açısından X-ray görüntüleri diğer tanı yöntemleriyle kıyaslandığında oldukça hızlı ve ucuz bir yöntem olarak kabul edilmektedir. Covid-19 hastalığında yüksek başarımlı erken teşhis ile hastalığın akciğerler üzerinde ilerlemesinin engellenmesi hayati bir önem taşımaktadır, bu da X-ray görüntüleri üzerinden yapılacak olan teşhisin önemini arttırmaktadır, bu bakımdan bilgisayar destekli hastalık teşhisi alanında yapılacak olan çalışmaların hastalığın hızlı tespitinin yanında yüksek başarımlı tespitinin de önemini ortaya koymaktadır. Bu çalışmada X-ray görüntülerinin yerel özelliklerinin tespitine yardımcı olan piksel bazlı görüntü işleme tekniklerinin (Histogram eşitleme) tıbbi görüntü sınıflandırma üzerindeki etkileri araştırılmıştır.

## 1.2. Tezin Kapsamı

Tıbbi görüntü işlemede dijital görüntüde bulunan patolojik durumların tespiti için birçok farklı algoritma geliştirilmiştir, bu çalışmada dijital görüntü üzerindeki patolojik özneliklerin tespiti için bir önışleme adımı olarak Histogram Eşitleme yöntemi önerilmiştir. Tıbbi görüntülerin sınıflandırma sürecinde X-ray veri setleri seçilir, görüntü piksel boyutu düzenlenerek tüm görüntüler tek bir ortak boyut haline getirilir, önışleme ile görüntüde farklı nokta işleme tekniklerinin kullanılmasıyla piksel değerlerinde değışiklik yapılarak görüntünün öznelikleri daha belirgin hale getirilir, bu işlemlerden sonra düzenlenen görüntüler hastalıklı ve sağlıklı (veya 1,0 şeklinde) şekilde etiketlenerek bir derin öğrenme modeline girdi olarak verilir, bu sürecin devamında eğitilen veri setinin bir kısmı test için ayrılarak, eğitilen modelin ağırlıkları ile test edilir. Bu çalışmada tüm bu süreçler ayrıntılı bir şekilde işlenerek sonuçlar detaylı bir şekilde değerlendirilmiştir. Görüntü işlemede derin öğrenmenin kullanımının popülerliğinin artmasıyla birçok yeni derin öğrenme modeli geliştirilmiştir, bu çalışmada popüler olarak kullanılan AlexNet, VGG16, DarkNet19 ve MobileNet modelleri kullanılarak veri setleri eğitilmiştir. Pnömoni teşhisi konulmuş akciğer görüntüleri ve sağlıklı akciğer görüntüleri Ulusal Sağlık Enstitüleri Klinik Merkezi (NIH) Chest X-Ray verisetinden seçilmiştir, Covid-19 teşhisi konulmuş görüntüler ise COVIDx veri kümesinden seçilmiştir, bu veriseti COVID-19 pozitif hasta vakalarının sayısı açısından en büyük açık erişim karşılaştırma veri kümesidir<sup>1</sup>. Buna benzer birçok veriseti halka açıkça kullanıma sunulmuştur, çalışmanın ilerleyen bölümlerinde kullanılan veriseti hakkında detaylı bilgiler yer almaktadır.

## 1.3. Tezin Önemi ve Farklılıkları

Bilgisayar destekli tıbbi görüntü işleme çeşitli zorluklar içermektedir, bu zorluklardan bazıları görüntü kalitesi, X-ray görüntüleri için akciğer dışındaki bölgelerin (kalp, omuzlar, kaburgalar vb.) değışkenliğinden ötürü ve farklı parametrelerin (yaş, cinsiyet, genel sağlık durumu, madde kullanımı vb.) görüntüler üzerindeki etkisi sınıflandırma işlemini zorlaştıran sebeplerden bazılarıdır, bu etkileri en alt seviyeye indirmek için farklı önışleme teknikleri geliştirilmiştir. Bu çalışmada Histogram Eşitleme tekniği kullanılarak akciğer bölgelerinin (bronşlar, alveoller vb.) daha belirgin hale getirilmesi amaçlanmıştır, Histogram Eşitleme tekniğinin iki farklı algoritması kullanılmıştır; 1) Yerel Histogram Eşitleme, 2) Uyarlanabilir Histogram Eşitleme, bu iki farklı algoritmanın farklı parametrelerle görüntü üzerindeki etkisi kıyaslanmıştır. Veri seti, çevrimiçi yayınlanmış olan açık kaynaklardan hazır olarak elde edilerek oluşturulmuştur, tezin

---

<sup>1</sup> <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>

ileri bölümlerinde bu konu hakkında detaylı bilgiler verilecektir. Bu çalışmada kullanılan veri setinin içerdiği görüntü sayısının fazla olmasından dolayı elde edilen sonuçların Covid-19 tespitinde eğitim ve test sonuçlarının genelleyici bir etkisinin incelenmesi açısından önemlidir, farklı veri setleri ile farklı stratejiler denenmiştir;

Veri seti 1: 428 Covid-19, 500 Pnömoni ve 500 Sağlıklı görüntülerden oluşmaktadır.

Veri seti 2: Sağ ve sol akciğer lobları kırılarak sadece akciğer görüntülerinin olduğu sağ ve sol loblar için toplamda 856 Covid-19, 1000 Pnömoni ve 1000 Sağlıklı görüntülerden oluşmaktadır.

Veri seti 3: 3615 Covid-19, 3500 Pnömoni ve 3500 Sağlıklı görüntülerden oluşmaktadır.

Strateji 1: veri seti 2'ye farklı değerlerde bölgesel histogram eşitleme uygulandıktan sonra farklı derin öğrenme modelleri için sağ ve sol lob birlikte modele verilmesi ile eğitim/test sonuçlarının değerlendirilmesi.

Strateji 2: veri seti 2'ye farklı değerlerde bölgesel histogram eşitleme uygulandıktan sonra farklı derin öğrenme modelleri için sağ ve sol lob ayrı olarak modele verilmesi ile eğitim/test sonuçlarının değerlendirilmesi.

Strateji 3: veri seti 1 ve 2'ye uyarlanabilir histogram eşitleme için farklı parametrelerin denenmesinden sonra eğitim/test sonuçlarının değerlendirilmesi.

Strateji 4: Strateji 3'te elde edilen en iyi modellerin ağırlıkları kullanılarak veri seti 3'e test işleminin uygulanması (3615 Covid-19, 250 Pnömoni ve 250 Sağlıklı) ve sonuçların değerlendirilmesi.

Strateji 5: Strateji 3'te elde edilen en iyi modellerin ağırlıkları kullanılarak veri seti 3'e eğitim işleminin uygulanması ve sonuçların değerlendirilmesi.

Bu stratejiler değerlendirilerek akciğer röntgeni görüntü sayısının farklı modeller üzerindeki etkisi ve az veri ile eğitilen modellerin çok sayıda test verisi üzerindeki performansı değerlendirilmiştir, bu da başarıyı genelleme açısından oldukça önemlidir.

#### **1.4. Tez Organizasyonu**

Tez'in ilerleyen kısımlarında derin öğrenme ile bilgisayar destekli tıbbi görüntü sınıflandırma alanında yapılan çalışmalar hakkında literatür taraması kısmı yer almaktadır, sonrasında akciğer röntgen analizleri ve Covid-19 ile Pnömoni hastalıkları ile ilgili yapılmış çalışmalar hakkında kısaca bilgi verilmiştir. Materyal ve metot kısmında bu çalışmada kullanılan derin öğrenme

modelleri, öğrenme aktarımı ve histogram eşitleme hakkında bilgi verilmiştir. Eğitilen veri seti için öğrenmenin gerçekleştiği bölgeler ve özneliklerin göğüs röntgeni üzerinde hangi bölgelerde etkili olduğunu göstermek için Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) ile görüntüleme yöntemi kullanılmıştır ve bu konuda bilgi verilmiştir. Kullanılan veri seti, özellikleri, hangi kaynaklardan sağlandığı, boyutları ve genel geçerliliği hakkında bilgi verilerek hangi stratejilerle nasıl kullanıldığı hakkında detaylı bilgilere yer verilmiştir. Tez'in ilerleyen kısımlarında her strateji için elde edilen sonuçlar hakkında değerlendirme yapılmıştır.



## 2. LİTERATÜR TARAMASI

### 2.1. Derin Öğrenme Çalışmaları

Derin öğrenme birçok alanda popüler bir şekilde kullanılmaktadır, derin öğrenmenin temelinde Yapay Sinir Ağları (YSA) yer almaktadır. YSA modeli insan beyninden esinlenerek, beyin fonksiyonlarının işleyişine benzer bir işleyiş ile mantıksal hesaplamaların yapılması için insan sinir sistemine benzer bir model ortaya konulmuştur (McCulloch ve Pitts, 1948). 1957’de Frank Rosenblatt, sinir ağı olarak bilinen şeyin ilk prototipi olan algılayıcıyı (Perceptron) tasarladı (Rosenblatt, 1958; Rosenblatt, 1962), bu yapının sadece basit mantıksal problemlerin çözebildiğini ve XOR işlevinin bile öğrenilemediği görülünce bu alandaki çalışmalar azalıp tarihin karanlık rafları arasına kaldırıldı (Minsky ve Papert, 1969). 1970’lerde geri yayılım algoritmasının ortaya çıkmasıyla Derin Sinir Ağlarında (DNN) bir gelişme gerçekleşti (Paul, 1974), yalnız DNN’de yaşanan bu gelişme tam olarak anlaşılmadı. 1980’lerin ortalarında geri yayılım algoritmasının tamamen anlaşılmasıyla birlikte bu algoritma YSA’ya uygulanarak çok katmanlı algılayıcılar (MLP) ortaya çıkmış oldu. DNN, veri kümelerinden herhangi bir özellik çıkarıcı olmaksızın algoritmalarla eğitilmiş çok katmanlı bir algılayıcı olarak modellenen bir YSA’dır, daha yüksek veya daha derin sayıda işleme yapabilen katmandan oluşur, aynı zamanda doğrusal olmayan karmaşık işlemlerin çözülmesinde de kullanılabilir. Derin Öğrenme, makine çevirisi, konuşma tanıma, nesne algılama, yüz tanıma gibi birçok farklı yapay zeka teknolojisini önemli ölçüde geliştirdi (LeCun, Bengio ve Hinton, 2015). Derin mimari yapısı, derin öğrenmeye daha birçok karmaşık AI görevini çözme olasılığını verir (Bengio, 2009). Günümüzde kullanılan Makine Öğrenimi (ML) algoritmaları, sağlık hizmetleri, eğitim, finans, yönetim, üretim, pazarlama vb. alanlarda hayatımızı etkilemektedir ve etkilemeye devam edecektir (Jordan ve Mitchell, 2015).

Araştırmacılar derin öğrenmeyi birçok farklı alanlara uyarlamışlardır, örneğin (Osako ve diğerleri, 2015) yinelenen sinir ağları algoritmasını kullanarak konuşma sinyallerinden gürültü gidermeyi başardılar, (Gatys ve diğerleri, 2015), farklı tasarımlara sahip görüntüler oluşturmak için sinir ağlarını kullandılar, (Gupta ve Wang, 2015), gen ifadelerinin kümelenme modellerini keşfetmek için yığılmış otomatik kodlayıcıları kullandılar, (Wang ve Yang, 2016), aynı anda birden fazla yöntemden duygu analizine izin vermek için derin öğrenmeyi kullandılar, bu ve bunun gibi birçok alanda derin öğrenmenin etkilerini görmekteyiz ve görmeye devam edeceğiz. Bu çalışmada da derin öğrenmenin medikal görüntü işleme alanında nasıl kullanıldığını ve farklı ön işleme algoritmalarıyla birlikte kullanılmasının başarıma etkileri değerlendirilmiştir.

DL alanında, Evrimsel Sinir Ağları (CNN), uzaysal yapıyı koruma ve görüntü özelliklerini tanıma yeteneği nedeniyle tipik olarak nesne algılama ve görüntü sınıflandırma problemini çözmek için kullanılır. LeNet-5, 1998 yılında, pratikte başarıyla kullanılan ilk CNN somutlaştırmasıdır (Lecun ve diğerleri, 1998). Yalnızca yedi adet 1 katman ile rakam tanıma probleminde yüksek performans elde etti. 2012 yılında, AlexNet (Krizhevsky, Sutskever ve Hinton, 2012), büyük ölçekli nesne algılama ve görüntü sınıflandırma görevleri için bir kıyaslama olan ImageNet Büyük Ölçekli Görsel Tanıma Yarışmasında (ILSVRC) (Russakovsky ve diğerleri, 2015) girdi ve önceki tüm derin öğrenme tabanlı olmayan modellerden daha iyi performans göstermeyi başardı. 2013'te ZFNet (Zeiler ve Fergus, 2014), AlexNet'in mimarisini daha iyi hiperparametreler ile tasarlayarak başarıyı arttırmıştır. 2014 yılında, VGGNet (Simonyan ve Zisserman, 2014) ve GoogLeNet (Szegedy ve diğerleri, 2015), tasarımları ile sınıflandırma performansında büyük bir sıçrama yapmıştır. VGGNet ve GoogLeNet arasındaki ortak nokta, her ikisinin de daha derin mimariye sahip olmasıdır. 2015'te ILSVRC'nin galibi, 152 katmandan (ResNet) oluşan bir derin sinir ağı mimarisi ağı oluşturularak (He ve diğerleri, 2016), bir CNN modelinin büyük ölçekli nesne tanıma görevlerinde insandan daha iyi performans göstermesi ile CNN modellerinin gelecek vaat eden bir sistem olduğuna işaret etmiştir.

## 2.2. Göğüs Röntgen Filmi Analizleri

Tıbbi röntgenler genellikle kemikler, göğüs, dişler, kafatası vb. Gibi bazı hassas insan vücudu parçalarını teşhis etmek için kullanılır. Tıp uzmanları, vücut organlarındaki kırıkları veya anormallikleri keşfetmek ve görselleştirmek için birkaç on yıl boyunca bu tekniği kullandılar (Er, Yumusak ve Temurtas, 2010). X-ray, göğüs ve iç organların görüntüsünü oluşturan hasta için rahatsız edici olmayan, ucuz maliyetli bir radyoloji testidir. Göğüs X-ray testi yapmak için göğüs, bir X-ray makinesinden gelen radyasyona hızlı bir şekilde sunulur ve bir filmde veya bir bilgisayarda bir görüntü oluşturulur (Jaeger ve diğerleri, 2014). Göğüs röntgeni yorumlanması, plörezi, efüzyon, pnömoni, bronşit, infiltrasyon, nodül, ateletazi, perikardit, kardiyomegali, pnömotoraks, kırıklar ve diğerleri gibi birçok durumu ve hastalığı teşhis edebilir (Er, Yumusak ve Temurtas, 2010).

Göğüs X-ray görüntüleri, farklı yapıları karakterize eden parlaklık veya bulanıklıkla son derece zıttır. Örneğin, göğüs bölücü kemikleri (kaburgalar ve omurlar) daha fazla miktarda radyasyonu özümseyebilir ve bu çizgiler boyunca filmde daha beyaz görünebilir. Göğüs X-ray ayrıca göğüs röntgeni, göğüs röntgeni veya CXR olarak adlandırılır.

CXR akciğer görüntüsü, çoğunlukla havadan oluşmuş olan akciğer dokusu, radyasyonun

çoğunun geçmesini sağlar ve CXR görüntüsünün o bölgede daha koyu bir görünüm oluşmasına sebep olur. Kalp ve aort bölgeleri beyazımsı görünür, ancak tipik olarak daha yoğun olan kemiklerden daha az parlak olmaktadır.

CXR testleri, çeşitli nedenlerle doktorlar tarafından istenir. Bu temel radyoloji testi ile çok sayıda klinik durum değerlendirilebilir. CXR üzerinde tanınan temel koşulların bir kısmı şunları içerir:

- Zatürre (Pneumonia)
- Genişlemiş kalp
- Akciğer kitlesi
- Kaburga çatlakları
- Akciğer çevresindeki sıvı (pleural radiation)
- Akciğer çevresinde hava (pneumothorax)

Sonuç olarak, CXR testi, çok az radyasyon tehlikesi olan basit, ekonomik ve orta derecede zararsız bir sistemdir. Ayrıca çevrimiçi veri tabanı sistemlerinden kolayca erişilebilir olması birçok çalışma alanında kullanılabilir.

CXR görüntülerinin teşhis edilmesi radyologlar için zor bir görev olarak kabul edilir. Bu nedenle son yıllarda doktorların bir CXR görüntüsünü değerlendirmesinde yardımcı olmak Bilgisayar Destekli Teşhis (CAD) sistemleri geliştirilmiştir, ancak bu sistemler CXR görüntülerinden hastalık çıkarımında anlamlı bir sonuca ulaşamamıştır (El-solh ve diğerleri, 1999).

Son zamanlarda, derin öğrenme tabanlı sistemler ile medikal görüntü sınıflandırmada birçok gelişme yaşanmıştır. Derin öğrenme ile, CXR görüntülerinin sınıflandırılmasında yüksek başarımlar elde edilmiştir. Bu başarı, araştırmacıları hastalık sınıflandırma görevinde derin öğrenmenin kullanılmasını tıbbi görüntülere uygulanması konusunda motive etmiştir, ve sonuç olarak derin öğrenmenin farklı görüntü sınıflarını ayırt eden yararlı bir sistem olarak kullanılabilirliği herkes tarafından kabul edilmiştir (Ashizawa ve diğerleri, 1999). CNN, görüntülerden farklı düzey özelliklerini çıkarma gücü nedeniyle çeşitli tıbbi görüntülerin tanı ve sınıflandırmasına uygulanmıştır.

CXR görüntüleri üzerinde yapılan çalışmalardan bir tanesi de kemik dokusunun akciğer görüntüsünden çıkarılma işlemidir, buna segmentasyon işlemi denmektedir. (Cernazanu-glavan, Holban ve Holban, 2013), CNN kullanarak göğüs röntgeni segmentasyonunu tanımladılar, Çalışmalarında, göğüs röntgeni için otomatik bir segmentasyon sistemi geliştirerek, kemik dokularını görüntünün geri kalanından ayırma kapasitesine sahip bir sistem geliştirmişlerdir.

Yakın zamanda yapılan başka bir çalışmada, hastaların göğüs röntgenlerinin kanser olup

olmadığına (iyi huylu veya kötü huylu) göre sınıflandırılmasında bazı görüntü işleme tekniklerinin uygulanmasını sunulmuştur. Çalışmada, görüntülerin sınıflandırılması için gerekli olan alan, çevre, çap ve düzensizlik gibi bazı geometrik özellikler çıkartılarak; otomatik bir sınıflandırma sistemi geliştirildi, ayrıca, sınıflandırma doğruluğuna ilişkin sonuçların paralel bir karşılaştırması için doku özellikleri dikkate alınmıştır. Çalışmada kullanılan doku özellikleri, ortalama gri seviyesi, standart sapma, pürüzsüzlük, üçüncü moment, tekdüzelik ve entropidir. Sınıflandırıcı olarak geri yayılım sinir ağı kullanılmış ve çalışmada %83 doğruluk kaydedilmiştir (Patil ve Kuchanur, 2012).

Tıbbi hastalıkların sınıflandırılmasında makine öğrenimi algoritmaları da kullanılmıştır, ancak performansları doğruluk, hesaplama süresi ve elde edilen minimum kare hatası (MSE) açısından derin öğrenme kadar verimli değildi. Bu çalışmada, Covid-19, Pnömoni ve Normal (sağlıklı) CXR görüntüleri kullanılarak farklı histogram eşitleme algoritması parametreleri karşılaştırılarak ve yine farklı derin öğrenme modelleri kullanılarak en başarılı parametreler kaydedilerek modellerin başarımı kıyaslanmıştır.

### **2.2.1. COVID-19 Analizleri**

COVID-19 pandemisi, şiddetli akut solunum sendromu korona virüs 2'nin (SARS-CoV-2) neden olduğu devam eden bir pandemidir. Çoğu insan sadece hafif ila orta şiddette semptomlara sahipken, bazı hastalar pnömoni ve akut solunum sıkıntısı sendromunu (ARDS) içeren ciddi hastalıklar geliştirmiştir. COVID-19'un yayılmasını kontrol etmek için hastaların etkili bir şekilde taranması kritik önem taşır. Şimdiye kadar altın standart tarama yöntemi, COVID-19'u genetik olarak tespit etmek için tasarlanmış ters transkripsiyon polimeraz zincir reaksiyonu (RT-PCR) testidir. Ancak sadece %30 ile %60 arasında değişen pozitif bir orana sahiptir (Ai ve diğerleri, 2020), (Yang ve diğerleri, 2020).

Pnömoni ve ARDS gibi ciddi hastalıklar geliştiren hastalar için, iyi bir tarama yöntemi, göğüs radyografisinin COVID-19 viral enfeksiyon göstergeleri için analiz edildiği radyografi incelemesidir. Viral enfeksiyon göstergeleri gizli olabilir ve radyologların COVID-19 pnömonisini normal vakalardan veya diğer pnömonilerden ayırt etmeleri zordur. Bu nedenle, göğüs radyografisi görüntülerinde COVID-19 pnömonisini tespit etmeye yardımcı olabilecek bilgisayar destekli teşhis sistemleri oldukça arzu edilmektedir.

CNN'in bu alanda kullanımına örnek gösterilebilecek çalışmalardan bir tanesi de (Wang ve diğerleri, 2021), çalışmalarında yazarlar, ilgi alanı bölgeleri (ROI) ile eğitilmiş bir CNN modeli önerirler, doğruluk değeri %85,2, özgüllük değeri %83 ve duyarlılık değeri ise %67 olarak elde



etmişlerdir. CNN'ler kullanılarak elde edilebilecek başarılı sonuçlara bir diğer örnek (Wang, Lin ve Wong, 2020) tarafından sunulmuştur, %92,4 doğruluk, %80 duyarlılık ve %88,9 özgüllük elde eden COVID-Net CNN ağı önerilmiştir. Başka bir çalışmada da COVIDX-Net adlı bir yöntem (Hemdan, Shouman ve Karar, 2020) tarafından sunulmuştur. COVIDXNet, Visual Geometry Group Network'ün (VGG19) değiştirilmiş bir sürümü ve Google MobileNet'in ikinci sürümü gibi yedi farklı derin evrişimli sinir ağı modeli mimarisi içerir. Her derin sinir ağı modeli, hastanın durumunu negatif veya pozitif COVID-19 vakası olarak sınıflandırmak için X-ışını görüntüsünün normalleştirilmiş yoğunluklarını analiz etmektedir, sınıflandırma sonuçlarına göre, sağlıklı görüntüler için f1-score değeri %89 ve COVID-19 için f1-score değeri %91 olarak elde edilmiştir.

Kalinovsky (2016), çalışmasında derin öğrenme kullanarak akciğer görüntüsü segmentasyonu için SegNet mimarisini kullanmıştır, bu mimari Derin Kodlayıcı-Kod Çözücü Evrişimli Sinir Ağları olarak bilinmektedir, bu model 4 kodlayıcı ve 4 kod çözücü katmanlardan oluşmaktadır. Segmentasyon işleminden önce Histogram Eşitleme tekniği kullanılarak her görüntünün yoğunluk seviyesi dönüştürülmüştür, böylece akciğer bölgeleri daha belirgin bir hale gelerek segmentasyon işlemine katkıda bulunmuştur. Toplamda 357 adet X-ray görüntüsü için manuel olarak segmente edilmiş akciğer maskesi eğitilmiştir. Test sonuçlarına göre ortalama başarımlık değeri %96,2 olarak kaydedilmiştir, bu çalışmada Derin Kodlayıcı-Kod Çözücü Evrişimli Sinir Ağları'nın X-ray görüntülerinin segmentasyonu için kullanılmasının avantajları ön plana çıkarılmıştır, modelin basitliği açısından ve başarımlık değerinin yüksek olmasından bu yöntemin umut verici olduğu belirtilmiştir (Kalinovsky ve Kovalev, 2016).

Saha (2021), çalışmasında Evrişimli Sinir Ağları ile makine öğrenme sınıflandırıcılarını (rastgele orman, destek vektör makinesi, karar ağacı ve AdaBoost) birlikte kullanarak ile Covid-19 hastalığı için sınıflandırma yapmıştır. Toplamda 2300 (farklı kaynaklardan) Covid-19 görüntüsü ve 2300 adet Normal (sağlıklı) görüntü kullanılmıştır. Oluşturulan model (EMCNet) VGG-16 modelinden esinlenerek yapılmıştır, modelin mimarisi basitleştirilerek öğrenim aktarımı kullanılmıştır. Öğrenim aktarımında ImageNet veri setinin eğitilmesi sonucunda elde edilen ağırlıklar ile yeni veri seti üzerinde öznelik çıkarımında kullanılması hedeflenmiştir, önerilen modelde derin öğrenme ile elde edilen öznelik matrisi makine öğrenimi sınıflandırıcılarına girdi olarak verilmiştir. Bu sınıflandırıcılar, rastgele orman, destek vektör makinesi, karar ağacı ve AdaBoost. Sınıflandırma parametrelerinin ayarlanması için grid arama algoritması kullanılarak elde edilen her sınıflandırıcı sonucu için çoğunluk oylaması kullanılarak nihai etiket için karar verilmiştir, böylece ortak bir sınıflandırıcı kümesi oluşturularak en başarılı sınıflandırıcı sonuçları seçilmiştir. Covid-19 sınıfı için, doğruluk %96,52, kesinlik %100,

duyarlılık %96,52 ve f1-score %98,23 olarak kaydedilmiştir. Normal (sağlıklı) görüntüler için doğruluk %100, kesinlik %96,64, duyarlılık %100 ve f1-score %98,29 olarak kaydedilmiştir. İkili sınıflandırma sonucunda elde edilen en yüksek doğruluk değeri %98,91, kesinlik %100, duyarlılık %97,82 ve f1-score %98,89 olarak elde edilmiştir. Bu çalışmada sınıflandırmada farklı bir yol izlenerek makine öğrenimi sınıflandırıcıları kullanılarak doğruluk oranı maksimize edilmiştir, derin öğrenme ile elde edilen özneteliklerin makine öğrenme sınıflandırıcıları ile ortak kullanımının avantajları belirtilmiştir (Saha, Sadi ve Islam, 2021).

Haghanifar (2020), çalışmasında 780 Pozitif Covid-19, 5000 sağlıklı ve 4600 NIH CXR-14 veri setinden görüntüler kullanmıştır. Görüntü boyutları (320,320) ölçüsüne düşürülmüştür ve normalize edilmiştir. Görüntülerin kontrastı, histogram eşitleme kullanılarak düzenlenmiştir, bu sayede kitle ve nodüller daha belirgin hale getirilmiştir. Bunu için Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE) algoritması kullanılmıştır, görüntüler üzerinde histogram eşitleme uygulandıktan sonra U-Net ile semantik segmentasyon işlemi uygulanmıştır, bu sayede görüntüden akciğer lobları tespit edilerek segmente edilmiştir. Bu çalışmada COVID-CXNet modeli önerilmiştir, bu model CheXNet-bazlı modelden oluşturulmuştur, 431 katman ve yaklaşık 7M parametreden oluşturulmuştur. Bu modelin diğer modellere göre avantajı yüksek hızda eğitim yapmasından kaynaklanıyor. Base model ise 5 evrişim katmanından ve tam bağlantılı katmandan oluşturulmuştur, Base model kullanılarak 300 adet görüntü eğitilmiştir ve 120 adet görüntü test adımı için kullanılmıştır ve bunun sonucunda elde edilen başarımlar değeri %96,72 olarak kaydedilmiştir ve aynı model için NIH CXR-14 veriseti kullanılarak 3000 adet sağlıklı ve 400 adet Covid-19 görüntüsü için elde edilen başarımlar %98,68, f1-score değeri ise %94,0 olarak kaydedilmiştir. COVID-CXNet modeli kullanılarak, akciğer segmentasyonu yapılmadan 3628 X-ray görüntüsü kullanılarak yapılan eğitim sonucunda ortalama başarımlar değeri %99,04 ve f1-score değeri %96,0 olarak kaydedilmiştir, görüntüler üzerinde segmentasyon işlemi uygulandıktan sonra elde edilen ortalama başarımlar %98,62 ve f1-score değeri %94,0 olarak elde edilmiştir. Sonuç olarak Haghanifar bu çalışmasında yeni bir model önermiştir, X-ray görüntüleri üzerinde segmentasyon işlemi yapılmıştır, segmentasyon yapılmadan önce CLAHE kullanılarak akciğer lobları daha belirgin hale getirilmiştir ve bunun avantajı vurgulanmıştır (Haghanifar, Majdabadi ve Ko, 2020).

CXR görüntülerinin hızlı ve doğru analizine duyulan ihtiyaçtan dolayı son teknoloji CNN modellerine dayanan bir dizi COVID-19 tespit modeli önerildi ve sonuçların umut verici olduğu görüldü (Chowdhury ve diğerleri, 2020). Ancak, bu çalışmalar sonuçları ikili sınıflandırma (COVID-19 ve COVID-19 dışı vakalar) veya üç sınıflı sınıflandırma (COVID-19 pnömoni, diğer pnömoni ve normal vakalar) sorunu altında küçük veri kümeleri üzerine rapor etmektedir.

### 2.3. Covid-19 ve Pnömoni Analizleri

Literatürde Covid-19 hastalığı ile viral Pnömoni ayrı sınıflarda değerlendirilerek bu iki hastalığın bulguları birbirine benzese de farklı sınıflara ayrıldıkları bilinmektedir, birçok çalışmada ikili sınıflandırma ile bu iki hastalığın yüksek başarımlarla ayırt edilebildikleri görülmüştür.

Apostolopoulos (2020), çalışmasında X-ray görüntüleri analizi için öğrenme aktarımını kullanarak iki farklı veriseti üzerinde denemeler yapmıştır. Birinci veriseti 224 adet Covid-19 görüntüsü, 700 tane Bacterial Pneumonia ve 504 adet Sağlıklı görüntüleri içermektedir. Bu veriseti için 5 farklı model üzerinde deneme yapmıştır. VGG19, MobileNet v2, Inception, Xception ve Inception ResNet v2 modelleri arasında 2 sınıf bazlı sınıflandırma sonuçlarında en başarılı model VGG19 ile %98,75 elde edilmiştir. 3 Sınıf bazlı sınıflandırma sonucunda ise en başarılı model VGG19 ile %93,48 gibi bir başarımla elde etmiştir, kesinlik değeri %92,85 ve duyarlılık değeri %98,75 olarak ölçülmüştür. Bu makalede bir diğer veriseti de 224 Covid-19, 714 bakteriyel ve viral Pnömoni (400 bakteriyel ve 314 viral) ve 504 Sağlıklı görüntülerden oluşmaktadır ve bu veriseti ile MobileNet v2 ile Öğrenme Aktarımı (TL) kullanılarak sınıflandırma başarımları 2 sınıf bazlı için başarımla %96,78 ve 3 sınıf bazlı sınıflandırma için başarımla %94,72, kesinlik değeri %98,66 ve duyarlılık değeri %96,46 olarak ölçülmüştür. Sonuç olarak; Apostolopoulos, bu çalışmasında X-ray görüntüleri üzerinde farklı modellerin öğrenme aktarımını ile sınıflandırma başarımlarını test ederek en başarılı modelin VGG19 ve MobileNet v2 olduğunu tespit etmiştir (Apostolopoulos ve Mpesiana, 2020).

Das (2020), çalışmasında Inception-NetV3 modelinin değiştirilmiş bir versiyonunu önermektedir, geliştirilen modelde pozitif Covid-19 görüntü sayısının eksikliğinden dolayı aşırı uyumu önlemeyi amaçlamaktadır. Inception-NetV3 modeli ImageNet veriseti için geliştirilen bir modeldir ve mimari yapısı karmaşıktır, önerilen modelde kullanılacak veri sayısının az olmasından dolayı aşırı uyumu önleme amaçlı orijinal modelden, eğitilebilir parametrelerin sayısı azaltılmıştır. Veriseti, Covid-19 pozitif 162 adet görüntü, Pneumonia ve Viral bakteri görüntü sayısı 4280 ve sağlıklı görüntü sayısı 1583 adet görüntüden oluşmaktadır. Bu çalışmanın sonucunda Inception-NetV3 ile sınıflandırma başarımları doğruluk değeri (50 pozitif Covid-19 görüntü, 50 negatif Covid-19 görüntü) %97,0, kesinlik %94,0 ve duyarlılık değeri %100 olarak ölçülmüştür. Önerilen model olan Truncated Inception Net ile sınıflandırma başarımları (162 adet pozitif Covid-19 ve 80 adet Pneumonia) %94,04, kesinlik değeri %88,0 ve duyarlılık değeri %100,0 olarak ölçülmüştür. Truncated Inception Net modeli için diğer bir veriseti (162 adet pozitif Covid-19 ve 1583 adet pnömoni) üzerinde sınıflandırma başarımları %100, kesinlik değeri

%100 ve duyarlılık değeri %100 olarak kaydedilmiştir. Sonuç olarak bu çalışmada Inception-NetV3 modelinin mimari yapısı değiştirilerek eğitilebilir katman sayısı azaltılmıştır ve bu sayede aşırı uyum önlenmiştir, ayrıca parametre sayısında (21.7 milyondan 2.1 milyona düşürülmüştür) azalma olmuştur, bu da eğitim süresini düşürerek önerilen modelin avantajını ön plana çıkarmıştır (Das, Santosh ve Pal, 2020).

Chowdhury (2020), çalışmasında MobileNetV2, ResNet18, ResNet101, VGG19 ve DenseNet201 modellerini kullanarak X-ray görüntülerini eğitmiştir, Eğitim işleminden önce veri setine ön işleme ve segmentasyon işlemi uygulanmıştır. Ön işleme adımında veri seti, yukarıda bahsettiğimiz modeller için 224,224 boyutuna indirgenmiştir. Veri seti SqueezeNet için 227,227 piksel boyutuna indirgenmiştir ve son olarak Inception v3 modeli için veriseti 299,299 boyutuna indirgenmiştir. Segmentasyon işleminde görüntülere döndürme ve çevirme işlemi uygulanmıştır. çalışmal'de segmentasyon işlemleri görüntülere uygulanmadan eğitim yapılmıştır, ve bu denemede 423 adet pozitif Covid-19, 423 adet viral pnömoni ve 423 adet sağlıklı görüntüleri kullanılmıştır (eğitim için 304, test için 85 adet görüntü), çalışma2'de 423 adet Covid-19 görüntüsünden elde edilmiş 2128 adet segmentasyon uygulanmış görüntü kullanılmıştır, 1579 sağlıklı görüntüden elde edilmiş 2274 adet segmentasyon uygulanmış görüntü kullanılmıştır ve 1485 adet viral pnömoni görüntüsünde elde edilmiş 2138 adet segmentasyon uygulanmış görüntü kullanılmıştır. Her iki çalışmada da 5-katlamalı çapraz doğrulama işlemi gerçekleştirilmiştir. Her iki çalışmada da en iyi başarımları sonucunu ChexNet modeli vermiştir, 2 sınıflı eğitim için segmentasyon olmadan doğruluk %99,41, kesinlik %99,42, duyarlılık %99,41 ve f1-score %99,41 olarak kaydedilmiştir. Segmentasyon işlemi uygulandıktan sonra elde edilen başarımlar %99,69, kesinlik %99,69, duyarlılık %99,69 ve f1-score %99,69 olarak kaydedilmiştir. 3 sınıflı eğitimde segmentasyon olmadan ChexNet ile başarımlar %97,74, kesinlik %96,61, duyarlılık %96,61 ve f1-score %96,61 olarak elde edilmiştir. Segmentasyon uygulanan görüntüler için en iyi sonuç DenseNet201 modeli ile başarımlar %97,94, kesinlik %97,95, duyarlılık %97,94 ve f1-score %97,94 olarak kaydedilmiştir. Bu çalışmada 2 sınıflı ve 3 sınıflı eğitime dikkat çekilerek segmentasyon işleminin başarımlardaki etkisi incelenmiştir, aynı zamanda farklı modeller karşılaştırılarak başarımlar sonuçları belirlenmiştir (Chowdhury ve diğerleri, 2020).

El-Asnaoui (2020), çalışmasında 231 adet pozitif Covid-19, 1493 viral pnömoni, 2780 bakteriyel pnömoni ve 1583 sağlıklı görüntüler kullanmıştır. Ön işleme için yoğunluk normalizasyonu ve CLAHE uygulanmıştır. VGG16, VGG19, DenseNet201, Inception-ResNetV2, InceptionV3, Resnet50 ve MobileNetV2 modelleri kullanılarak veriseti eğitilmiştir.

Inception-ResnetV2 modeli sonucunda en yüksek başarımlar elde edilmiştir, doğruluk değeri %92,18, kesinlik %92,11, duyarlılık %96,06, özgüllük %92,38 ve f1-score değeri %92.07 olarak kaydedilmiştir. Bu çalışmada önışleme metodunda CLAHE kullanılmasına dikkat çekilmiştir ve farklı derin öğrenme modellerinin Covid-19 görüntülerinin sınıflandırma üzerindeki başarımları ölçülmüştür (El Asnaoui ve Chawki, 2020).

Singh (2021), çalışmasında 573 adet(50 test, 50 doğrulama) Covid-19 görüntüsü, 6041 adet Pneumonia görüntüsü ve 8851 Sağlıklı görüntüsü kullanmıştır. Önışleme olarak %25 rasgele döndürme, yatay çevirme ve Gauss bulanıklığı kontrastı kullanmıştır. U-net modeli ile segmentasyon işlemi uygulanarak bunun için sınırlı uyarlamalı histogram eşitleme kullanılmıştır. Bu çalışmada ek olarak Üretken Çekişmeli Sinir Ağı (GANs) kullanılarak X-ray görüntü veriseti sayısı artırılmıştır. X-ray görüntülerini sınıflandırmak için farklı modellerden (Densenet169, Densenet121, ResNet50, Vgg19 ve Vgg16) yararlanılmıştır, Ham (önışleme ve segmentasyon uygulamadan) veriseti için en iyi başarımlar %89,34 olarak ölçülmüştür. Sadece segmentasyon uygulanmış veriseti için başarımlar değeri %94,67, sadece önışleme uygulanmış veriseti için başarımlar değeri %94,67 ve son olarak segmentasyon ile önışleme uygulanmış veriseti için başarımlar değeri %95,34 olarak kaydedilmiştir. Önerilen modelde, VGG16, ResNet-50, DenseNet-121 ve DenseNet-169'u temel model eğitimi olarak ve budanmış bir modellerin birleştirilmesi çerçevesinde Naive-Bayes meta-öğrenicisi olarak uygulanmıştır ve elde edilen başarımlar değeri %98,67 olarak kaydedilmiştir.

Horry (2020), çalışmasında veriseti üzerinde Histogram Eşitleme kullanarak segmentasyon işlemi uygulamıştır, sınıflandırma için 5 farklı derin öğrenme modeli kullanılmıştır (VGG16-VGG19, ResNet50, InceptionV3 ve Xception). Deney 1'de Normal (200 görüntü) ve Covid-19 (100 görüntü) ve Pneumonia (100 görüntü) şeklinde sınıflandırma yapılmıştır, ortalama başarımlar değerleri şu şekildedir; VGG16 için başarımlar %82, VGG19 için başarımlar %83, ResNet50 için başarımlar %70, InceptionV3 için başarımlar %68 ve son olarak Xception için başarımlar %69 olarak kaydedilmiştir.

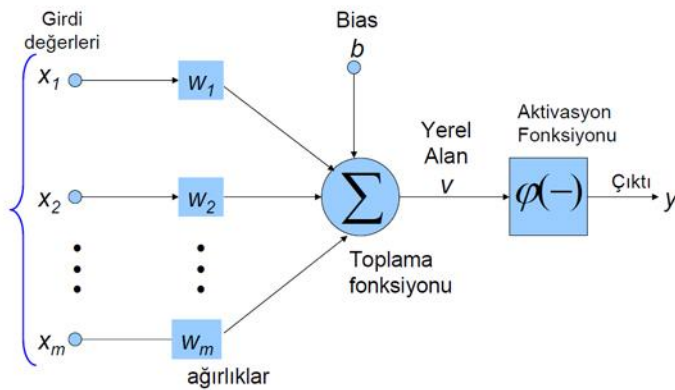
Deney 2'de Covid-19 (100 görüntü) ve Pneumonia (100 görüntü) şeklinde sınıflandırma yapılmıştır. VGG16 için başarımlar %83, VGG19 için başarımlar %83, ResNet50 için başarımlar %67, InceptionV3 için başarımlar %41 ve son olarak Xception için başarımlar %30 olarak kaydedilmiştir.

### 3. MATERYAL VE METOT

Bu bölümde öncelikle derin öğrenmenin ne olduğundan ve nasıl çalıştığından bahsedilmiştir. Ardından CNN hakkında bilgi verilerek kullandığı parametreler açıklanmıştır, CNN yapısında kullanılan öğrenme yöntemleri, popüler derin öğrenme modelleri ve optimizasyon hakkında bilgi verilmiştir.

#### 3.1. Derin Öğrenme

DL, YSA katmanlarının bir araya gelmesiyle oluşan bir makine öğrenimi yöntemidir. Sinir ağları, bir dizi nöron ve bağlantıdan oluşur. Bir nöron, önceki nöronlardan birçok girdi alır ve bir çıktı üretir. Çıktı, genellikle doğrusal olmayan, nöronun aktivasyon fonksiyonunun izlediği girdilerin ağırlıklı toplamıdır. Nöronlar katmanlar halinde düzenlenmiştir, aynı katmandaki nöronlar birbirine bağlı değildir. Öncesi olmayan nöronlara giriş nöronları, son katmandaki nöronlara ise çıkış nöronları denir. Giriş nöronu ile çıkış nöronu arasındaki katman sayısı büyükse, buna derin sinir ağı denir. Kesin bir tanım yoktur, ancak genel olarak sekizden fazla katman sayısı kullanıldığında "derin" olarak kabul edilir (Krizhevsky, Sutskever ve Hinton, 2012). Derin öğrenme ilk olarak yapay sinir ağlarına yeni bir yaklaşım getirilmesiyle birlikte ortaya çıkmıştır, bu yaklaşım DL olarak adlandırılmıştır (Hinton, Osindero ve Teh, 2006).



Şekil 3.1. Örnek bir yapay sinir ağı yapısı

Derin öğrenme, çok katmanlı algılayıcı modelden oluşmaktadır (Şekil 3.1.). Derin öğrenme modeli kendi içinde Denetimli Öğrenme, Denetimsiz Öğrenme ve Pekiştirmeli Öğrenme olarak 3'e ayrılmaktadır.

Denetimli bir öğrenme algoritması eğitilirken, eğitim verileri doğru çıktılarla eşleştirilmiş girdilerden oluşacaktır. Eğitim sırasında, algoritma verilerde istenen çıktılarla ilişkili sınıfları arayacaktır. Eğitimden sonra, denetimli bir öğrenme algoritması yeni görünmeyen girdileri

alacak ve yeni girdilerin hangi etiketin önceki eğitim verilerine göre sınıflandırılacağını belirleyecektir. Denetimli öğrenme modelinin amacı, yeni sunulan girdi verileri için doğru etiketi tahmin etmektir. En basit haliyle, denetimli bir öğrenme algoritması basitçe şu eşitlikle yazılabilir:


$$Y = f(x) \quad (3.1)$$

Burada  $Y$ ,  $x$  giriş değerine bir sınıf atayan bir eşleme fonksiyonu tarafından belirlenen tahmin edilen çıktıdır. Girdi özelliklerini tahmin edilen bir çıktıya bağlamak için kullanılan işlev, eğitim sırasında makine öğrenimi modeli tarafından oluşturulur (Shipp ve diğerleri, 2002).

Denetimsiz öğrenmede bir çıkış etiketi verilmeksizin giriş görüntüleri ağı girişlerine uygulanır. Ağdaki katmanlarda sonuç verileri oluşturulur, buna göre oluşan çıkışlarda elde edilen sonuç değerleri çıkış değerlerine benziyorsa eğer bu değerler belli bir kümeye alınır. Burada her küme belli bir sınıfı temsil etmektedir (Hastie ve Tibshirani, 2009). Burada asıl amaç kümelemedir, denetimsiz öğrenme, benzer grupları keşfetmek veya yoğunluk tahmini olarak bilinen verilerin uzayda nasıl dağıldığını belirlemek için kullanılır.

Pekiştirmeli öğrenme, ağa giren veriyle alakalı çıkış verisinin ne olması gerektiği bilgisi verilmez, yönlendirme olmadığı için bu öğrenme biçiminde deneyim söz konusudur, bir ödül mekanizması kurularak modelin izlediği yola göre ödül verilmezse model ağırlıkları tekrardan güncellenerek doğru bir sonuç üretmek için, model kendini tekrardan eğitmektedir (Chapelle, Schölkopf ve Zien, 2009).

DL'yi oluşturan YSA, beyin nöronlarına benzer yapıda geliştirilmiştir, biyolojik sinir ağı yapısında (Şekil 3.2.) bulunan Hücre Gövdesi Transfer Fonksiyonuna, Dentrit Toplama Fonksiyonuna, Aksonlar Yapay Nöron Çıkışına, Sinapslar Ağırlıklara ve bunlardan oluşan Nöron ise İşlemci Elemanına benzemektedir (Bkz. Şekil 3.1.).

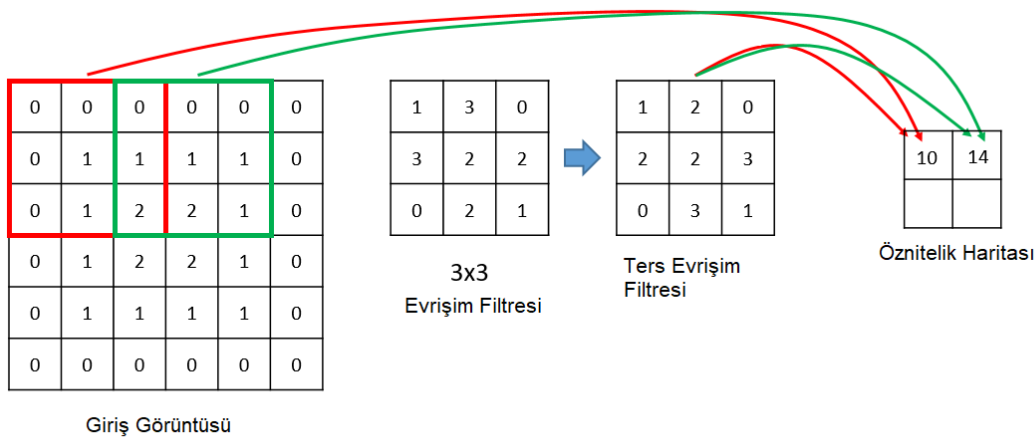


Şekil 3.2. Biyolojik Sinir Ağı Yapısı

### 3.2. Evrişimsel Sinir Ağları

CNN, çok katmanlı ileri beslemeli bir yapay sinir ağıdır, derin öğrenmenin katmanları içinde yer almaktadır. Temelinde filtreleme yer almaktadır, kullanılacak olan filtre ile görüntüde bulunan öznitelikleri belirgin hale getirmektedir, sınıflandırma işlemlerinde başarılı sonuçlar üretmektedir. Farklı boyuttaki filtreler kullanılarak özniteliklerin baskınlık değerleri artırılabilir ve bu sayede modele giriş olarak verilen veri için herhangi bir öznitelik çıkarma algoritması kullanılması zorunlu değildir (Simard, Steinkraus ve Platt, 2003).

Bu yapı ilk olarak LeCun ve arkadaşları tarafından LeNet adı altında sunulmuştur, bu yapıyı gradyan temelli olarak ortaya çıkarmışlardır ve bu ağ yapısına evrişimsel sinir ağı adı verilmiştir (Lecun ve diğerleri, 1998). Şekil 3.3.'te evrişimsel sinir ağında filtreleme işlemine ait bir örnek gösterilmektedir.



Şekil 3.3. Evrişimsel Sinir Ağında Evrişim (Filtreleme) İşlemi

CNN kullanıldığı derin öğrenme modelinde birçok farklı parametreler vardır, bu parametreler ile öğrenme işlemi gerçekleştirilmektedir. Çok katmanlı bir derin öğrenme modelinde birden fazla evrişim katmanı, aktivasyon katmanı, ortaklama katmanı, tam normalleştirme, sınıflandırıcı katman ve tam bağlı katman bulunmaktadır, bunlardan ayrı ek katmanlar da bulunmaktadır. Sonuçlar her zaman için sınıflandırıcı katmanda üretilmektedir, her katman kendisine ait görevi yerine getirerek öğrenme işlevi gerçekleştirilmektedir.

#### 3.2.1. Aktivasyon ve Evrişim Katmanı

Bu katman girdi verileri üzerinde işlem yaparak, Sinir Ağlarının sonuna veya arasına yerleştirilen bir düğümdür. Nöronun aktif ediliyor edilmeyeceğine karar vermeye yardımcı



olmaktadır, bu süreç giriş sinyali üzerinde yapılan doğrusal olmayan dönüşümdür. Bu dönüşüm uygulandıktan sonra girdi olarak bir sonraki nöron katmanına gönderilir. Aktivasyon fonksiyonu olarak sigmoid, hiperbolik tanjant, sinüs, step, eşik değer fonksiyonları kullanılmaktadır. Pek çok aktivasyon fonksiyonu olmasına karşın derin öğrenme mimarilerinde ReLu (Rectified Linear Unit) (Nair ve Hinton, 2010) fonksiyonu kullanılmaktadır (Krizhevsky, Sutskever ve Hinton, 2012).

Sigmoid fonksiyonu aşağıdaki matematiksel Eş 3.2’de gösterilmiştir:

$$y = \sigma(x) = 1/(1 + \exp - x) \quad (3.2)$$

Bu fonksiyon aldığı değeri 0 ile 1 arasında bir değere dönüştürür, bu bölgede gradyan değeri hemen hemen sıfırdır. Bu nedenle, geri yayılım algoritması parametrelerini ve önceki sinir katmanlarının parametrelerini değiştirmede başarısız olur.

Hiperbolik Tanjant (TanH) fonksiyonu aşağıdaki matematiksel Eş 3.3’de gösterilmiştir:


$$y = 2\sigma(2x) - 1 \quad (3.3)$$

Aldığı değeri -1 ile 1 arasında bir değere dönüştürür. Ancak sigmoid fonksiyonu ile aynı dezavantaja sahiptir.

ReLu fonksiyonu aşağıdaki matematiksel Eş 3.4’de gösterilmiştir:

$$y = \max(0, x) \quad (3.4)$$

ReLu, doğrusal olmayan formu nedeniyle son zamanlarda oldukça popüler hale geldi. Aktivasyon işlemi sonucunda elde edilen değer negatif ise 0 pozitif ise 1 değerini alır. Aktivasyon fonksiyonlarının işlevi Şekil 3.4.’te yer almaktadır.



Şekil 3.4. Aktivasyon Fonksiyonları Örneği

Modele verilen girdiyi piksel olarak işler, örneğin, bir görüntü matrisi  $N \times N \times 3$  (yükseklik, genişlik, derinlik) olarak ifade edilir, burada görüntü üç kanaldan oluştuğundan evrişim katmanında kullanılan filtre de 3 katmanlı olacaktır. Bu katman giriş görüntüde bulunan belirli özelliklerin varlığını tespit etmek için kullanılmaktadır. Filtre, giriş görüntüsünün genişliği ve yüksekliği boyunca kaydırılarak bir öznitelik haritası oluşturur (Bkz. Şekil 3.3.). Evrişim katmanı için aşağıdaki eşitlik verilmiştir:

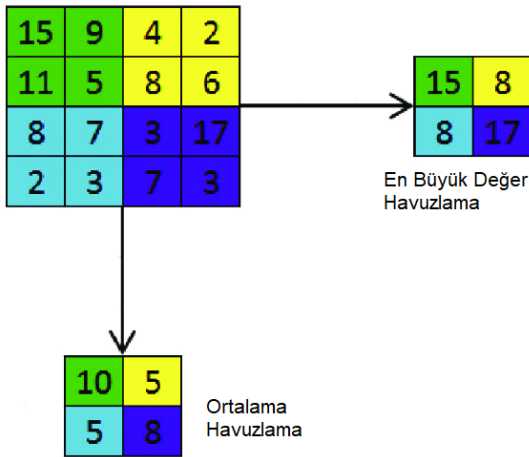
$$zk = fk * x \quad (3.5)$$

Bu eşitliğe göre burada  $x$  değeri giriş görüntüsünü,  $fk$  değeri filtre sayısını ve  $*$  işlemi de evrişim operatörünü göstermektedir. Her modelde birden çok evrişim katmanı kullanılabilir.

### 3.2.2. Derin öğrenme ile optimizasyon

#### Ortaklama (Pooling) Katmanı

Bu katman girdi verisinin boyutunu azaltmaktadır. Genelde aktivasyon katmanından sonra kullanılmaktadır. Ortaklama işlemi veride kayıplar oluşturmaktadır, ancak ağda dolaşacak olan veri sayısının azalması ile ağın daha hızlı olmasını sağlamaktadır, bu da ağdaki hesaplama miktarının ve kullanılacak bellek boyutunun azalması anlamına gelmektedir (Hinton ve diğerleri, 2012). Ortaklama işleminde en çok kullanılan en büyük değer (Max Pooling) ortaklama ve ortalama (Average) ortaklama işlemleridir. Ortaklama işleminde  $N \times N$  boyutlu bir matris görüntü matrisi üzerinde gezdirilerek en büyük ortaklama değeri için  $N \times N$  boyutlu gezdirilen matrisin içindeki en büyük değer seçilir, ortalama ortaklama değeri için ise  $N \times N$  boyutlu matris içinde bulunan tüm değerlerin ortalaması alınarak  $1 \times 1$  boyutunda bir değer elde edilir.



Şekil 3.5. Ortalama ve Max Ortaklama İşlemi

### Tam Normalleştirme (Batch Normalization) Katmanı

Bu katman, çoğunlukla daha hızlı birleşmeye yardımcı olduğu için hızla çok popüler bir hale gelmiştir (Ioffe ve Szegedy, 2015). Her eğitilebilir katmanın girdilerini özellikler arasında karşılaştırılabilir hale getirmek için bir normalleştirme adımı (girdileri sıfır ortalamaya ve birim varyans kaydırma işlemi) gereklidir. Bunu yaparak, ağ öğrenimini korurken yüksek bir öğrenme oranı sağlar. Ayrıca TanH ve Sigmoid gibi aktivasyon fonksiyonlarının doygunluk modunda takılıp kalmamasına izin verir (örneğin 0'a eşit gradyan).

### Tam Bağlı (Fully Connected) Katman

Bu katman bir CNN ağının son katmanıdır, burada tüm nöronlar bir dizi şeklindedir, burada bulunan nöronların tamamı bu katmana bağlı önceki katmandaki aktivasyonların hepsine tam bağlı durumdadır, sınıflandırma işleminin sonucu bu katmana bağlıdır (Lin, Chen ve Yan, 2013).

### Çıkarma (Dropout) Katmanı

Bu katman, ağın ezberleme olayını yani aşırı öğrenme durumunu ortadan kaldırmak için kullanılmaktadır, ezber yapan düğümler ağın dışına atılır ve böylece ezberleme durumunu engellemiş olur (Srivastava ve diğerleri, 2014).

### Uyarlanabilir Moment Tahmini Optimizasyonu (ADAM)

Adam, önerilen Uyarlanabilir Moment Tahmini anlamına gelir (Kingma ve Ba, 2014). Adam, bir kombinasyon momentum yöntemidir. Aşağıdaki Eş. 3.6 ve Eş. 3.7'de görüldüğü üzere:

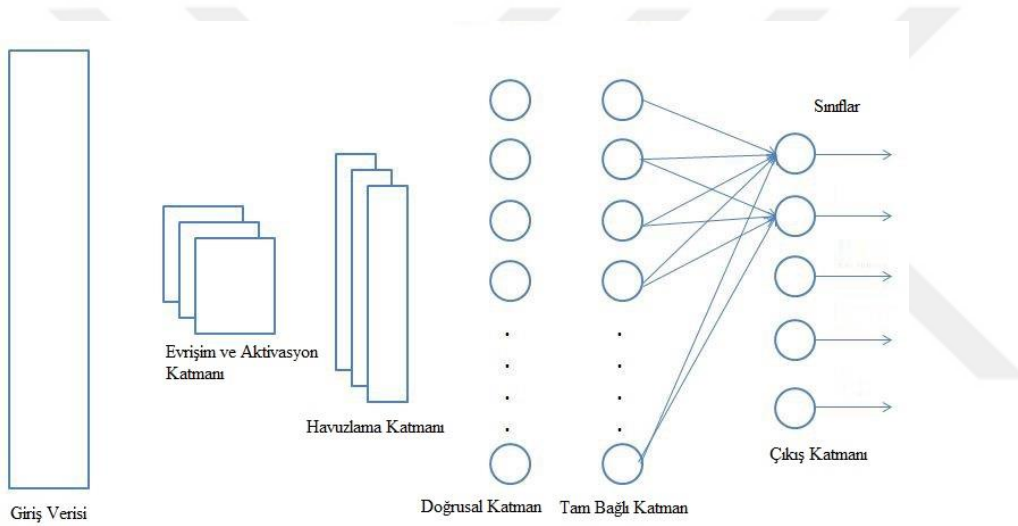
$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (3.6)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (3.7)$$

Bu eşitliklerde  $v_t$  değeri önceki gradyanların kare ortalaması,  $m_t$  ise, önceki gradyanların ortalamasını temsil etmektedir.  $m_t$  ve  $v_t$  sırasıyla gradyanların ilk momentinin (ortalama) ve ikinci momentinin (ortalananmamış varyans) tahminleri yapılarak, her parametre için uyarlanabilir öğrenme oranları hesaplanmış olur.

### Sınıflandırma Katmanı

Bu katman, istenilen sınıf sayısına göre belli bir fonksiyona bağlı olarak sınıflandırma sonucunu üretir. Son katman olarak bilinen sınıflandırma katmanı için genellikle Softmax sınıflandırıcı fonksiyonu kullanılır (Cireşan ve diğerleri, 2011).



Şekil 3.6. Basit Bir CNN Yapısı

Genel olarak, evrışimsel sinir ağları bu yapılardan oluşmaktadır, Şekil 3.6.'da gösterildiği üzere bir CNN modelinin temel adımları yer almaktadır.

### **3.2.3. Öğrenme aktarımı (Transfer Learning)**

Derin sinir ağlarının başarılı bir şekilde eğitilmesi genellikle büyük ölçekli bir veri kümesi ve uzun bir eğitim süresi gerektirir. Dahası, birçok derin öğrenme modeli için temel bir varsayım, eğitim ve test verilerinin aynı dağıtımdan alınması gerektiğidir. Veri sayısının modelin eğitilmesi için gerekenden az olduğu durumlarda, önceden öğrenilen bilgileri farklı bir veri dağıtımı, görev veya etki alanı için saklamak ve yeniden kullanmak çok önemlidir. Öğrenme aktarımı, önceden eğitilmiş bir modelin yeni model ve görev için başlangıç noktası olarak yeniden kullanıldığı bir makine öğrenimi yöntemidir. Sadece eğitim verilerini toplama ihtiyacını

azaltmakla kalmaz, aynı zamanda eğitim sürecini de hızlandırır (CARUANA, 1997; Thrun, 1996).

Geleneksel olarak, Derin sinir ağları, görüntü sınıflandırması için en büyük veri kümelerinden biri olan (1000'den fazla nesne sınıfına ait 14 milyondan fazla görüntü) ve çok güçlü olan ImageNet (Deng ve diğerleri, 2009) gibi çok büyük miktarda etiketli veri kümeleri gerektirir. Bununla birlikte, artık öğrenim aktarımı, etiketli veri kümelerinde eksikliğin olduğu ve derin öğrenme ile sıfırdan eğitiminin hesaplama açısından pahalı olabileceği tıbbi görüntü tanıma sistemlerinde etkili bir çözüm sunabileceği görülmüştür. Bu bağlamda, iki öğrenme aktarımı tekniği görüntü tanıma görevleri için yaygın olarak uygulanmıştır: (1) Bir özellik çıkarıcı olarak önceden eğitilmiş ağlar ve (2) önceden eğitilmiş bir ağın ince ayarı (fine-tuning) (Litjens ve diğerleri, 2017). Öğrenme aktarımı, halihazırda öğrenilmiş olan ve yeni ilişkili bir problemde kullanılmak üzere veriyi sınıflandırmak için kullanılan bir yöntemdir.

Pan ve Yang (Pan, Jialin ve Yang, 2010), öğrenme aktarımını üç farklı kategoride değerlendirmişlerdir:

Endüktif öğrenme aktarımı: Bu öğrenme aktarımında, öğrenme aktarımının yapılacağı alan eğitilen alanla aynı veya farklı olabilir, ancak eğitilen alan ve öğrenme aktarımının yapılacağı alana bakılmaksızın farklı kabul edilir. Burada öğrenim aktarımı yapıldıktan sonra tekrardan bir eğitim ve ağırlıkların güncellenmesi söz konusudur.

Transdüktif transfer öğrenme: Bu yaklaşımda, öğrenim aktarımı yapılacak olan veri ile eğitilmiş veri farklılık göstermektedir. Başka bir deyişle, önceden eğitilen veri büyük miktarlarda etiketli veri içerebilirken, öğrenim aktarımı yapılacak olan veri herhangi bir etiket içermez. Bu yaklaşımın diğer özel varyantları literatürde alan adaptasyonu, ortak varyant kayması ve örnek seçim yanlılığını içerecek şekilde tanımlanmıştır (Patel ve diğerleri, 2015).

Denetimsiz öğrenme aktarımı: burada, eğitilen veri ve aktarılan öğrenmede kullanılan veri için etiket kullanımı yoktur. Bununla birlikte, hedef sınıflandırmanın kaynak sınıflandırmadan farklı olabileceği ancak kaynak sınıflandırma karşılaştırılabilir olduğu için endüktif öğrenme aktarımına oldukça benzemektedir.

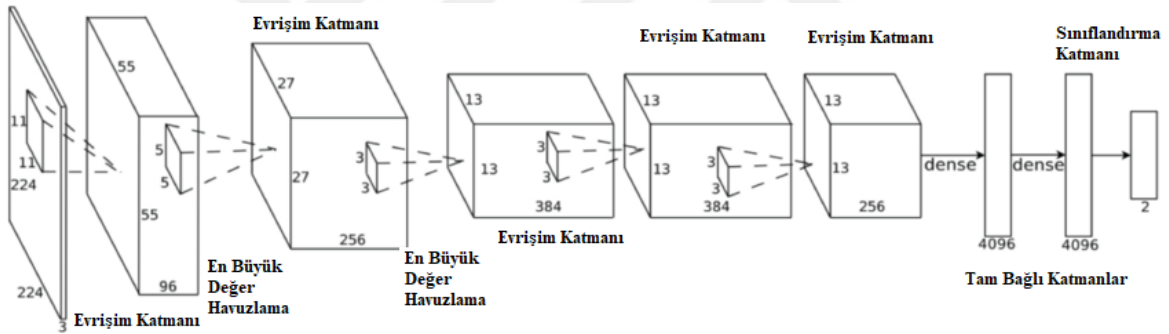
Bu çalışmada, farklı derin öğrenme stratejilerinde öğrenim aktarımı kullanılarak az sayıda eğitilen veri setinin, modelde elde edilen aynı ağırlıkların öğrenme aktarımı ile çok sayıda görüntü üzerindeki başarımı değerlendirilmiştir.

### 3.3. Ön Eğitilmiş Popüler Derin Öğrenme Modelleri

#### 3.3.1. AlexNet Mimarisi

AlexNet Derin öğrenmede evrimsel sinir ağlarını yaygınlaştıran ilk çalışmalardan biridir. AlexNet (Krizhevsky, Sutskever ve Hinton, 2012), 2012 ImageNet ILSVRC yarışmasında diğer el yapımı modellerden önemli ölçüde daha iyi performans göstermiştir. LeNet ile karşılaştırıldığında bu ağ daha derin ve daha büyüktür (5 evrimsel katman, 3 maksimum ortaklama ve 3 tam bağlı katman), Şekil 3.7.'de AlexNet mimarisinin yapısı gösterilmiştir. Önemli özellikleri şu şekildedir:

- Aktivasyon katmanı olarak ReLu fonksiyonu seçilmiştir.
- Araya ortaklama katmanı gelmeden evrimsel katmanı ile aktivasyon katmanının istiflenmesi yöntemi.
- Ortalama ortaklama yerine en büyük değer ortaklama yöntemi kullanılmıştır.



Şekil 3.7. AlexNet Modeli Örneği

#### 3.3.2. VGGNet Mimarisi

Bu model ile 2014 yılında ILSVRC yarışmasında çok başarılı bir performans sergilemiştir (Simonyan ve Zisserman, 2014). Tasarlanan bu mimari için 6 farklı evrimsel katmanı modeli önerilmiştir, buna göre; 11, 13, 16 ve 19 tane farklı evrimsel katmanından oluşan modeller sunulmuştur. Bu mimaride evrimsel filtre boyut 3x3 olarak seçilerek daha önceki mimarilere göre farklı bir tasarım meydana getirilmiştir. Bu çalışmada VGG16 (Han, Mao ve Dally, 2015) modeli kullanılmıştır.

### 3.3.3. MobileNet Mimarisi

MobileNet mimarisinin farklı versiyonları tanıtılmıştır, buna göre MobileNetV1 (Howard ve diğerleri, 2017) mimarisinde geleneksel evrişim katmanı yerine derinlemesine ayrılabilir evrişim katmanı kullanılmıştır. Derinlemesine ayrılabilir evrişim, ilk versiyonunda iki boyutlu uzamsal ayrılabilir evrişim olarak kullanılmıştır, evrişim katmanında kullanılan iki boyutlu (yükseklik-genişlik) filtreyi iki küçük çekirdeğe bölerek işlem yapmaktadır. Örnek olarak 3x3 olan çekirdek boyutu için 3x1 ve 1x3 olarak ayrı çekirdekler üzerinden işlem yaparak her biri 3 çarpmalı iki adet evrişim işlemi gerçekleşir. Bu, normal bir evrişim katmanına göre çok daha az öğrenilen parametre gerektirir, ancak yaklaşık olarak aynı şeyi yapar.

MobileNetV1, arka arkaya bu bloklardan 13'ünden oluşur. Uzamsal boyutları azaltmak için maksimum ortaklamayı kullanmaz, ancak bazı derinlemesine katmanların 2 adımı vardır. Sonunda, sınıflandırmayı yapmak için tamamen bağlı bir katman veya  $1 \times 1$  evrişim adımını izleyen genel bir ortalama havuz katmanı vardır, Şekil 3.8.'de MobileNet genel yapısı gösterilmiştir.

| Katman          | Boyut                                | Giriş Boyutu               |
|-----------------|--------------------------------------|----------------------------|
| Conv / s2       | $3 \times 3 \times 3 \times 32$      | $224 \times 224 \times 3$  |
| Conv dw / s1    | $3 \times 3 \times 32$ dw            | $112 \times 112 \times 32$ |
| Conv / s1       | $1 \times 1 \times 32 \times 64$     | $112 \times 112 \times 32$ |
| Conv dw / s2    | $3 \times 3 \times 64$ dw            | $112 \times 112 \times 64$ |
| Conv / s1       | $1 \times 1 \times 64 \times 128$    | $56 \times 56 \times 64$   |
| Conv dw / s1    | $3 \times 3 \times 128$ dw           | $56 \times 56 \times 128$  |
| Conv / s1       | $1 \times 1 \times 128 \times 128$   | $56 \times 56 \times 128$  |
| Conv dw / s2    | $3 \times 3 \times 128$ dw           | $56 \times 56 \times 128$  |
| Conv / s1       | $1 \times 1 \times 128 \times 256$   | $28 \times 28 \times 128$  |
| Conv dw / s1    | $3 \times 3 \times 256$ dw           | $28 \times 28 \times 256$  |
| Conv / s1       | $1 \times 1 \times 256 \times 256$   | $28 \times 28 \times 256$  |
| Conv dw / s2    | $3 \times 3 \times 256$ dw           | $28 \times 28 \times 256$  |
| Conv / s1       | $1 \times 1 \times 256 \times 512$   | $14 \times 14 \times 256$  |
| 5x Conv dw / s1 | $3 \times 3 \times 512$ dw           | $14 \times 14 \times 512$  |
| Conv / s1       | $1 \times 1 \times 512 \times 512$   | $14 \times 14 \times 512$  |
| Conv dw / s2    | $3 \times 3 \times 512$ dw           | $14 \times 14 \times 512$  |
| Conv / s1       | $1 \times 1 \times 512 \times 1024$  | $7 \times 7 \times 512$    |
| Conv dw / s2    | $3 \times 3 \times 1024$ dw          | $7 \times 7 \times 1024$   |
| Conv / s1       | $1 \times 1 \times 1024 \times 1024$ | $7 \times 7 \times 1024$   |
| Avg Pool / s1   | Havuzlama 7x7                        | $7 \times 7 \times 1024$   |
| FC / s1         | 1024 x 1000                          | $1 \times 1 \times 1024$   |
| Softmax / s1    | Sınıflandırıcı                       | $1 \times 1 \times 1000$   |

Şekil 3.8. MobileNet genel yapısı

MobileNetV2 (2018) mimarisinde, derinlemesine evrişim katmanı ortada kullanılmıştır, genişleme katmanı olarak bilinen  $1 \times 1$  bir kıvrımdır. Bu, kanal sayısını artırır. Derinlemesine evrişim katmanından sonra, izdüşüm katmanı veya darboğaz katmanı olarak bilinen kanalların sayısını tekrar azaltan başka bir  $1 \times 1$  kıvrım vardır, Şekil 3.8.'de bu yapıya bir örnek

gösterilmiştir. MnasNet (Tan ve diğerleri, 2019), MobileNetV2 yapısını kullanmıştır. Bu mimari 3 470 000 parametre içermektedir.

MobileNetV3 (2019) mimarisinde Şekil 3.8.'de görüldüğü gibi katmanların kombinasyonundan bloklar oluşturularak bu mimaride kullanılmıştır (Ramachandran, Zoph ve Le, 2017), Bu çalışmada MobileNetV3 mimarisi kullanılmıştır. MobileNetV3 mimarisindeki temel değişiklikler şu şekildedir:

- Katmanlar yeniden tasarlanmıştır.
- ReLU6 yerine HardSwish metodu kullanılmıştır (Avenash ve Viswanath, 2019).
- Squeeze-and-excitation modülü kullanılmıştır (Hu, Shen ve Sun, 2018).
- MobileNetV3 ile elde edilen eğitilebilir parametre sayısı 5 400 000.

Bu çalışmada MobileNet genel mimarisi kullanılarak farklı veri seti stratejileri için sonuçları değerlendirilmiştir.

### **3.3.4. DarkNet19 Mimarisi**

DarkNet19 mimarisi, YOLOv2'nin (Redmon ve Farhadi, 2016) temeli olarak kullanılmak üzere yeni bir sınıflandırma modeli olarak önerilmiştir. VGG modeline benzer şekilde 3x3 evrişim filtresi kullanılmıştır ve her en büyük değer ortaklaması katmanından sonra filtre sayısı ikiye katlanmaktadır. Sınıflandırma katmanında önce ortalama ortaklama katmanı kullanılmıştır, ortalama ortaklama ile 3x3 boyutlu evrişim katmanı arasında 1x1 boyutlu evrişim filtresi kullanılarak özellik temsili ortaya çıkarılmaktadır (Lin, Chen ve Yan, 2013). DarkNet19 mimarisi, 19 adet evrişim katmanı, 5 adet en büyük ortaklama katmanı içermektedir, Şekil 3.9.'da model yapısı verilmiştir.



| Type          | Filters | Size/Stride | Output    |
|---------------|---------|-------------|-----------|
| Convolutional | 32      | 3 × 3       | 224 × 224 |
| Maxpool       |         | 2 × 2/2     | 112 × 112 |
| Convolutional | 64      | 3 × 3       | 112 × 112 |
| Maxpool       |         | 2 × 2/2     | 56 × 56   |
| Convolutional | 128     | 3 × 3       | 56 × 56   |
| Convolutional | 64      | 1 × 1       | 56 × 56   |
| Convolutional | 128     | 3 × 3       | 56 × 56   |
| Maxpool       |         | 2 × 2/2     | 28 × 28   |
| Convolutional | 256     | 3 × 3       | 28 × 28   |
| Convolutional | 128     | 1 × 1       | 28 × 28   |
| Convolutional | 256     | 3 × 3       | 28 × 28   |
| Maxpool       |         | 2 × 2/2     | 14 × 14   |
| Convolutional | 512     | 3 × 3       | 14 × 14   |
| Convolutional | 256     | 1 × 1       | 14 × 14   |
| Convolutional | 512     | 3 × 3       | 14 × 14   |
| Convolutional | 256     | 1 × 1       | 14 × 14   |
| Convolutional | 512     | 3 × 3       | 14 × 14   |
| Maxpool       |         | 2 × 2/2     | 7 × 7     |
| Convolutional | 1024    | 3 × 3       | 7 × 7     |
| Convolutional | 512     | 1 × 1       | 7 × 7     |
| Convolutional | 1024    | 3 × 3       | 7 × 7     |
| Convolutional | 512     | 1 × 1       | 7 × 7     |
| Convolutional | 1024    | 3 × 3       | 7 × 7     |
| Convolutional | 1000    | 1 × 1       | 7 × 7     |
| Avgpool       |         | Global      | 1000      |
| Softmax       |         |             |           |

Şekil 3.9. DarkNet19 Mimarisi

### 3.4. Histogram Eşitleme

Görüntü işlemedeki en temel ve basit, ancak güçlü araçlardan biri histogram eşitleme işlemidir. Bu işlem ile, basitçe görüntüde bulunan sayısallaştırılmış her noktanın veya pikselin yoğunluk seviyelerinin frekans sayısı çıkarılmaktadır. Histogram eşitleme, bir görüntünün kontrastının düzeltilmesine olanak tanır (Jaehne 1991). Histogramın, tümü düşük yoğunluk aralığında bulunan bir dizi yoğunluk düzeyini ortaya çıkarmaktadır, her bir mevcut değer yeni bir düzeye eşlenebilir, böylece yeni histogram, mevcut yoğunluk düzeylerinin tüm aralığını kapsayacak şekilde ölçeklenir. Histogram, piksel yoğunluğunu gösteren bir grafikdir.

Gonzalez ve Woods (Gonzalez, Woods ve Hall, 2008) tarafından 2008 yılında yapılan tanımlamaya göre; histogram eşitleme, kontrastı artırmak için görüntü yoğunluklarını ayarlayan bir tekniktir, Şekil 3.10.'da bu teknik gösterilmiştir.

Aşağıdaki Eş.3.8'e göre:

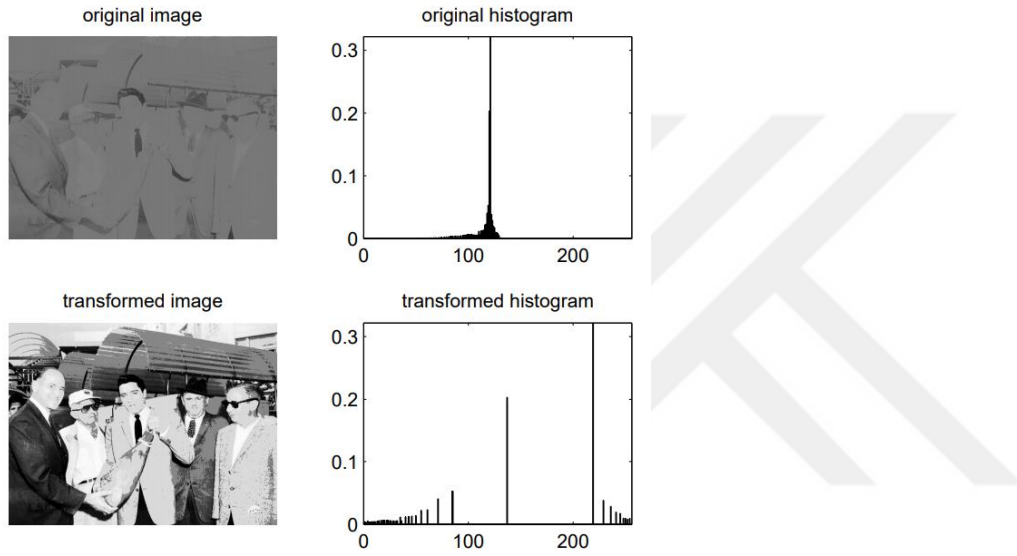
$$p_n = \frac{n \text{ yoğunluğa sahip piksel sayısı}}{\text{toplam piksel sayısı}}, n = 0, 1, \dots, L - 1 \quad (3.8)$$

$f$ , 0 ile  $L - 1$  arasında değişen tamsayı piksel yoğunluklarına sahip bir  $m_r$  ile  $m_c$  matrisi olarak temsil edilen belirli bir görüntüdür.  $L$ , yoğunluk değerlerinin sayısıdır, bu değer genellikle 256 olmaktadır.  $P$  ise, her olası yoğunluk için normalleştirilmiş  $f$  görüntüsünün histogramıdır.

Histogram eşitlenmiş görüntü  $g$ , Eş. 3.9'da gösterilen şekilde tanımlanacaktır:

$$g_{i,j} = \text{floor} \left( (L - 1) \sum_{n=0}^{f_{i,j}} p_n \right) \quad (3.9)$$

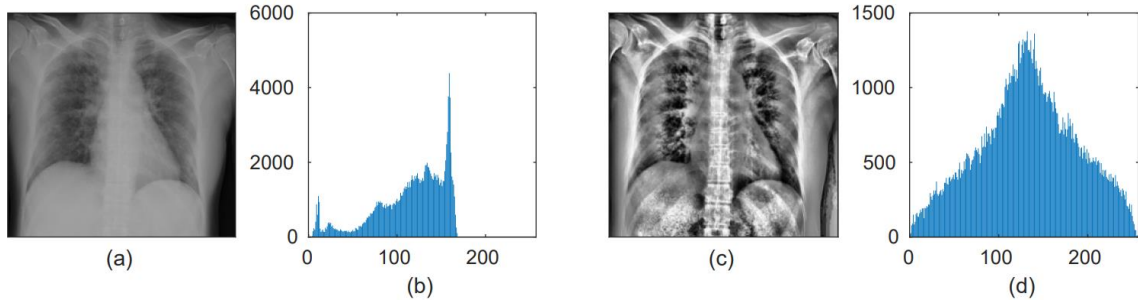
Floor, değeri en yakın en yakın tamsayıya yuvarlayan bir fonksiyondur.



Şekil 3.10. Düşük Yoğunluklu Görüntüye Uygulanan Histogram Eşitleme (Gonzalez, Woods ve Hall, 2008)

### 3.4.1. Bölgesel histogram eşitleme (LHE)

Global histogram eşitleme (GHE), genel olarak global bir ton haritası ping işlemidir ve her pikselin gri seviyesinin görüntünün genel histogram yoğunluk değeri hesaplanarak yeniden oluşturulmasına izin verir. Ancak, bu işlemler aynı anda hem karanlık hem de parlak görüntü bölgelerinde kontrastı artırmada başarısız olur. Bu sorunu çözmek için, bu ayarlanabilir pencere boyutu (yarıçap veya disk) ile yüzen bir pencerede bölgesel histogram eşitlemesinin (LHE) gerçekleştirilmesi önerilmiştir. Histogram eşitleme, görüntünün küçük bölünmüş alanlarına bağımsız olarak uygulanır, böylece görüntünün farklı bölgeleri için kontrast ayarı korunur (Caselles ve diğerleri, 1999; Kim, Kim ve Hwang, 2001).



Şekil 3.11. Histogram Eşitleme ile Kontrast Seviyesinin Düzenlenmesi

Şekil 3.11.'de görüldüğü gibi, (a) histogram eşitleme uygulanmamış CXR görüntüsü ve bu görüntünün histogram grafiği (b). (c) Histogram eşitleme uygulanmış CXR görüntüsü ve onun histogram grafiği (d). Görüldüğü üzere (b) ve (d) grafiğinin kontrast dağılımına baktığımızda histogram eşitleme uygulanan görüntüde kontrast yoğunluk düzeylerinin eşit şekilde dağılımı yapıldığı görülebilmektedir<sup>2</sup>.


Bu çalışmada kullanılan bölgesel histogram eşitleme, Python yazılım dilinin skimage kütüphanesi ile gerçekleştirilmiştir<sup>3</sup>. Bu fonksiyonun parametreleri şu şekildedir:

Giriş görüntüsü ( $M \times N$  boyutunda matris dizisi) Selem değeri, histogram eşitlemenin uygulanacağı bölgesel piksel yarıçapını belirlemektedir. Mask değeri, bölgesel histogram eşitlemenin belli piksel değerinin üzerindeki bölgelere uygulanması olarak tanımlanmaktadır. Bu değer varsayılan olarak bırakılarak her piksel değerinin bölgesel histogram eşitlemesi yapılmıştır. Çıkış görüntüsü, giriş görüntüsü ile aynı matris boyutunda bir çıkış elde edilir.

Bu çalışmada, farklı bölgesel yarıçapı (selem) değerleri için histogram eşitleme uygulanmıştır. Selem parametresine verilen farklı yarıçap değerleri CXR görüntüleri üzerinde uygulanarak piksel yoğunluklarına göre akciğer görüntüsündeki özellikleri en belirgin hale getiren selem değerleri belirlenmiştir. Belirlenen Selem değerleri; 10, 20, 30, 40, 60, 80, 100, 120 ve 150. Bu değerler farklı derin öğrenme modelleri ile test edilerek bölgesel histogram eşitlemenin medikal görüntüler üzerindeki etkileri araştırılmıştır. Şekil 3.12.'de farklı selem değerleri için Covid-19 görüntüsüne uygulanmış LHE sonuçları görülmektedir. Araştırma bulguları kısmında elde edilen sonuçlar detaylı bir şekilde anlatılmıştır.

<sup>2</sup> [https://docs.opencv.org/master/d5/daf/tutorial\\_py\\_histogram\\_equalization.html](https://docs.opencv.org/master/d5/daf/tutorial_py_histogram_equalization.html)

<sup>3</sup> <https://github.com/scikit-image/scikit-image/blob/main/skimage/filters/rank/generic.py#L391-L438>



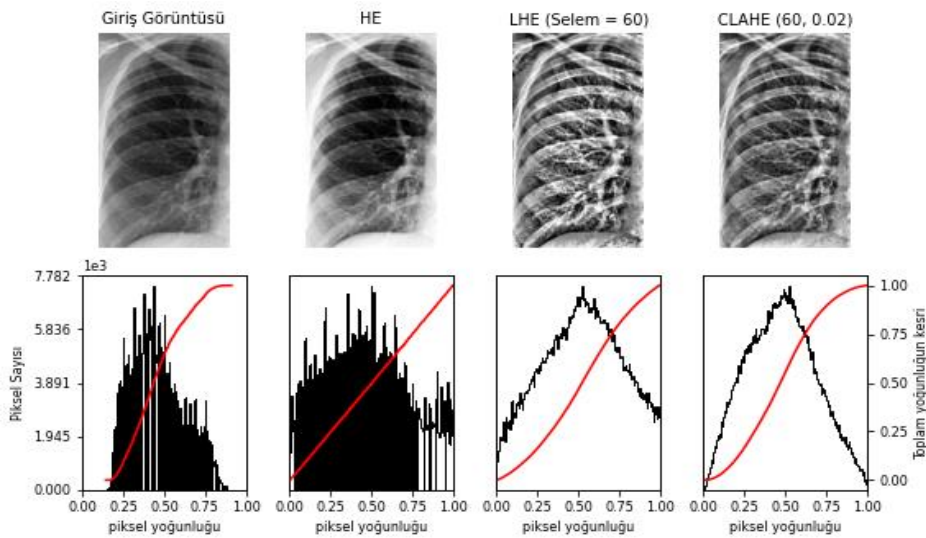
Şekil 3.12. Orijinal CXR Covid-19 Görüntüsü ile Farklı Selem değerleri için LHE Sonuçları

### 3.4.2. Yoğunluk sınırlı uyarlanabilir histogram eşitleme (CLAHE)

Yoğunluk Sınırlı Uyarlanabilir histogram eşitleme (CLAHE), LHE gibi görüntünün yoğunluk seviyesini iyileştirmede kullanılan bir tekniktir. CLAHE, Tıbbi görüntü işlemede piksel yoğunluk seviyesini yeniden düzenleme ve gürültü giderme amaçlı sıkça kullanılmaktadır (Li, Wang ve Yu, 1994). Histogram eşitlemenin bir varyasyonu olan CLAHE, Hummel (Hummel, 1977; Hummel ve Robert, 1975), Ketcham (Ketcham ve David, 1976), ve Pizer (Stephen ve Pizer, 1981) tarafından bağımsız olarak geliştirilmiştir ve çok sayıda görüntü üzerinde uygulanarak başarılı sonuçlara ulaşılmıştır.

CLAHE, genel histogram eşitlemenin aksine, toplam görüntü yoğunluk seviyesi yerine görüntünün bölgesel pikselleri üzerinde belirlenmiş bir yoğunluk seviyesine göre çalışmaktadır. Görüntüde bulunan parazit ve gürültüleri yok etmek yoğunluk seviyesi artışı sınırlandırılmaktadır (Zuiderveld ve Karel, 1994).

CLAHE, uyarlanabilir histogram eşitlemeden (AHE) farklı olarak yoğunluk değer güncellemesini, kullanıcı tarafından belirlenen bir maksimum (clip\_limit) değere göre yapmaktadır. Böylece yoğunluk seviyesi düzgün olan bölgeleri etkilemez ve gürültünün aşırı artmasını engeller. Sonuç olarak CLAHE ile, LHE'de olduğu gibi histogram eşitlemesinin uygulanacağı piksel yarıçapı belirlenir ve LHE'ye ek olarak CLAHE'de yoğunluk limiti (clip\_limit) yine kullanıcı tarafından belirlenerek görüntüdeki ayrıntıların daha belirgin hale gelmesini sağlar (Pizer, 1986).



Şekil 3.13. Farklı HE yöntemleri ile yoğunluk dağılımı

Senthilkumar (R.Senthilkumar ve Senthilmurugan, 2014), çalışmasında, genel histogram eşitlemesi; AHE ve CLAHE olan bu üç görüntü histogram eşitlemesi algoritmalarını MATLAB ile CXR görüntüleri üzerinde kullanmıştır, elde edilen işlenmiş görüntülere, sinyal gücünün gürültü gücüne oranı (SNR), yeniden yapılandırılmış görüntü kalitesinin tahmin standardı (PSNR), referans sinyal ile bozulmuş sinyal arasındaki ortalama kare farkı (MSE), entropi ve orijinal görüntünün parlaklığı ile geliştirilmiş görüntünün parlaklığı arasındaki farkı (AMBE) gibi görüntü kalitesini ölçen teknikler uygulanarak yapılan inceleme sonucunda; CLAHE ile yapılan histogram eşitleme yönteminin diğer yöntemlerden daha başarılı olduğu belirlenmiştir.

Bu çalışmada CLAHE algoritması kullanılarak farklı parametreler denenerek en başarılı değerler seçilmiştir, bu fonksiyonun içerdiği parametreler bu şekildedir:

- Giriş görüntüsü (MxN boyutunda matris dizisi)
- Histogram eşitlemenin uygulanacağı bölge yarıçapı değeri “kernel\_size”
- Yoğunluk eşik değerini belirleyen “clip\_limit” parametresi
- Çıkış görüntüsü, giriş görüntüsü ile aynı matris boyutunda bir çıkış elde edilir.

### 3.5. Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM)

Grad-CAM, çok çeşitli CNN mimarilerine uygulanabilen CNN'nin son evrişim katmanına akan gradyan bilgisini kullanan bir görselleştirme tekniğidir (Selvaraju ve diğerleri, 2017). Bu çalışmada bu görselleştirme tekniği kullanılarak son evrişim katmanında öğrenilen özniteliklerin gradyan bilgisi kullanılarak CXR sınıflandırmasında ön plana çıkan öznitelik bölgeleri görselleştirilmiştir.

Eş.3.10'da görüldüğü gibi sınıf ayrımlı yerelleştirme haritasını elde etmek için Grad-CAM, bir evrişim katmanının özellik haritaları A'ya göre  $y^c$  gradyanını (c sınıfı için puan) hesaplar. Geri akan bu gradyanlar,  $\alpha_k^c$  önem ağırlıklarını elde etmek için küresel ortalama havuzda toplanır, Eş. 3.10:

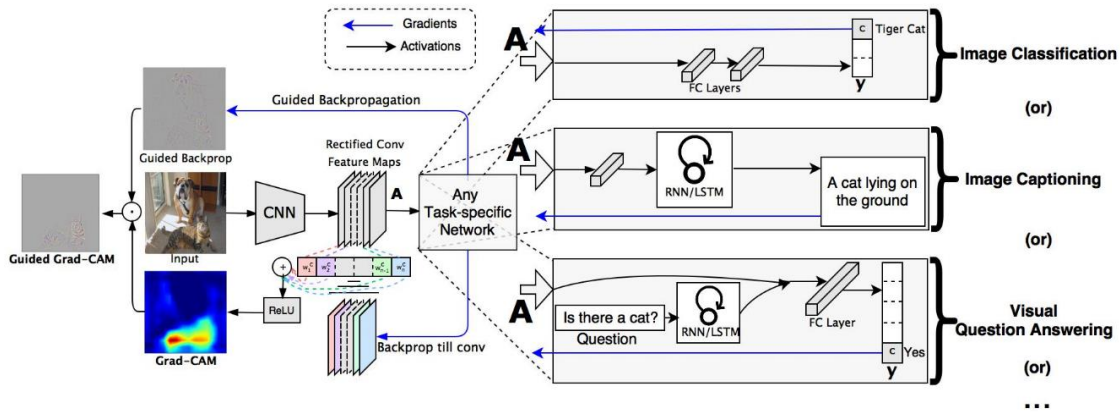
$$\alpha_k^c = \frac{1}{z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \quad (3.10)$$

Grad-CAM ısı haritası, özellik haritalarının ağırlıklı bir birleşimidir,  $\alpha_k^c$  hesaplaması ardından bir ReLU gelir, Eş. 3.11:

$$L_{Grad-CAM}^c = \text{ReLU}(\sum_k \alpha_k^c A^k) \quad (3.11)$$

Şekil 3.14.'te görüldüğü üzere, Grad-CAM: Girdi olarak bir görüntü veya ilgili bir sınıf verildiğinde, görüntünün kategori olarak belirlenmesi için göreve özel hesaplamalar yoluyla

iletilir. Gradyanlar, 1'e ayarlanan istenen sınıf (kaplan, kedi) hariç tüm sınıflar için sıfıra ayarlanır. Bu sinyal daha sonra Grad-CAM lokalizasyonunu hesaplamak için birleştirilen, rektifiye edilmiş evrişimli özellik haritalarına geri yayılır (mavi ısı haritası) modelin belirli bir kararı vermek için nereye bakması gerektiğini gösterir. Son olarak hem yüksek çözünürlüklü hem de konseptte özel Grad-CAM görselleştirmelerini elde etmek için ısı haritası güdümlü geri yayılımla noktasal olarak çarpım işlemi gerçekleştirilmektedir.



Şekil 3.14. Grad-CAM'e genel bakış (Selvaraju, Ramprasaath ve diğerleri, 2017)

### 3.6. Kullanılan Veri Seti

Bu çalışmada kullanılan veri setleri, NIH<sup>4</sup> göğüs röntgeni veritabanı, Pnömoni CXR görüntüleri<sup>5</sup> ve COVID-19 Radyografi veritabanı<sup>6</sup> dahil olmak üzere iki büyük ölçekli göğüs röntgeni veritabanı kullanılmıştır. NIH göğüs röntgeni veri seti, hiçbir bulgusu olmayan 30.805 hastadan ve pnömoni ve daha fazlası dahil olmak üzere on dört akciğer hastalığından alınan 112K'dan fazla göğüs röntgeninden oluşur. ConvNets'in göğüs röntgenlerinde benzer semptomlara sahip hastalıkların belirlenmesindeki performansını kontrol etmek için bakteriyel pnömoni ve sağlıklı dışında kalan patolojik durumları hariç tuttuk. Pnömoni (bakteriyel) semptomlarının COVID-19 (viral pnömoni) ile benzerliği nedeniyle, çoklu vaka tanımlaması araştırmacılar tarafından sıklıkla çalışılmaktadır. Göğüs Röntgeni Görüntüleri (Pnömoni) veri seti, iki uzman hekim tarafından teşhis edilen pnömoni ve bulgu olmayan 5,8K'nın üzerinde akciğer görüntüsünden oluşmaktadır. COVID-19 ile göğüs röntgenleri, COVID-19 pozitif vaka sayısı açısından en büyük açık erişim veri seti olan COVIDx veri setinden elde edilmiştir. COVID-19 pozitif olarak

<sup>4</sup> <https://www.kaggle.com/nih-chest-xrays/data>

<sup>5</sup> <https://www.kaggle.com/paultimothymooney/chest-xray-pneumonia>

<sup>6</sup> <https://www.kaggle.com/tawsifurrahman/covid19-radiography-database>

3616 adet göğüs röntgeni var ve dünya çapında devam eden vakalar nedeniyle güncellenmeye devam ediyor. İtalyan Tıp Derneği, Girişimsel Radyoloji (SIRM) COVID-19 veri tabanının, Covid-19 veri kümesinin ve birçok yayının kaynaklarının bir parçası olarak kullanılmıştır.

Göğüs röntgeni, çözünürlük ve derinlik dâhil olmak üzere teknik özelliklerde geniş bir varyasyona sahiptir. Bu nedenle, her görüntünün standart bir formda yeniden boyutlandırılması gerekir. Ancak pnömoni ve sağlıklı göğüs röntgeni dikdörtgen şeklinde (Örn: 1900x1400), COVID-19 vakaları kare şeklindedir (299x299). Bu şekilde dikdörtgen göğüs röntgeni kare formda yeniden boyutlandırılarak esnetilerek akciğerlerin anatomik şeklinde kayba neden olur. Bu nedenle göğüs röntgenlerine kare şeklinde yeniden boyutlandırma ve ön şekli koruyarak bozulmayı önlemek için sıfır öteleme uygulanmıştır.

COVID-19 Radyografi veritabanından 428 adet Covid-19 görüntüsü seçilmiştir, bunun yanında NIH göğüs röntgeni veritabanından 500 adet pnömoni ve 500 adet sağlıklı görüntü seçilerek, kullanılan birinci veri seti bu görüntülerden oluşmaktadır. Bu veri seti için akciğer bölgeleri kırılarak sağ ve sol akciğer lobu şeklinde ayrı bir veri seti oluşturulmuştur. Kırılan veri seti için 856 yeni Covid-19 (sağ ve sol lob olarak), 1000 adet pnömoni ve 1000 adet sağlıklı görüntüler elde edilmiştir.


Kullanılan diğer veri seti Covidx veritabanından seçilerek, 3615 adet Covid-19 görüntüsü, 3500 adet pnömoni ve 3500 adet sağlıklı akciğer görüntüsü kullanılmıştır, Şekil 3.16.'da örnek görüntüler sunulmuştur.

Çizelge 3.1. Kullanılan CXR görüntü sayısı

| Veritabanı           | Covid-19 Sayısı | Pnömoni Sayısı | Sağlıklı Sayısı |
|----------------------|-----------------|----------------|-----------------|
| NIH                  | 428             | 500            | 500             |
| NIH (sağ ve sol lob) | 856             | 1000           | 1000            |
| Covidx               | 3615            | 3500           | 3500            |


NIH veritabanından seçilen CXR görüntüleri için uygulanan kırma işlemi ile her görüntüden sadece akciğer bölgesi seçilerek boyun ve karn bölgesi iskelet şeklinin eğitime dahil edilmemesi amaçlanmıştır, Şekil 3.15.'te örnek olarak kırılmış bir Covid-19 görüntüsü sunulmuştur.





Şekil 3.15. Kırpılmış Covid-19 görüntüsü

Bu şekilde kırılan görüntülerde eğitim için CNN modeline girdi olarak verilirken 112x224 boyutuna dönüştürülerek verilmiştir, bu şekilde görüntü boyutu korunmaya çalışılmıştır.



(a)

(b)

(c)

Şekil 3.16. Covidx veritabanından alınan Covid-19 (a), Pnömoni (b) ve Sağlıklı (c) görüntüleri

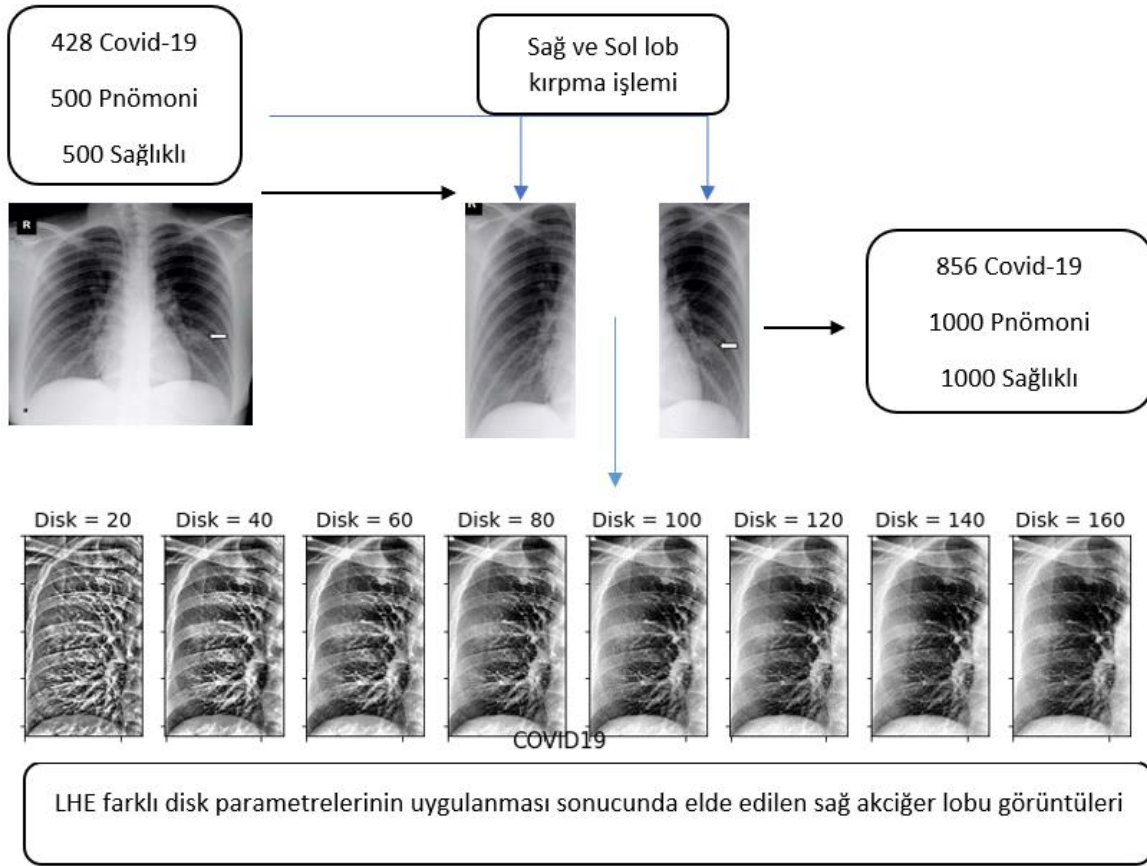
### 3.7. Veri Setleri üzerine stratejiler

Bu çalışmada iki farklı kaynaktan elde edilen veri setleri üzerinde önışleme (kırpma, LHE, CLAHE) adımları gerçekleştirilerek farklı stratejiler oluşturulmuştur. Her bir strateji için farklı ön eğitimli popüler modeller kullanılarak, veri setleri eğitilmiştir.

#### 3.7.1. Strateji 1

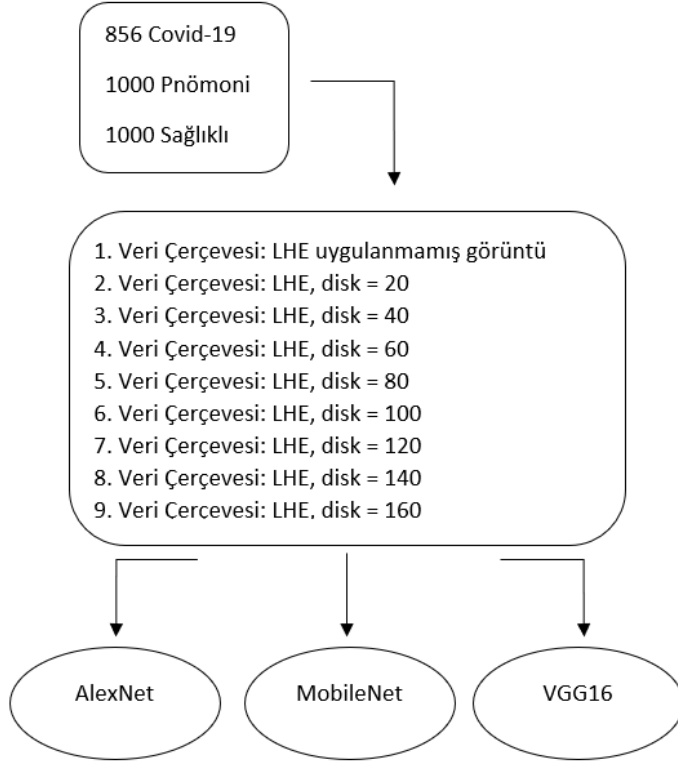
Bu stratejide NIH veri seti kullanılarak, 428 Covid-19 pozitif, 500 pnömoni, 500 sağlıklı (toplam 1428 adet CXR görüntüsü) görüntüleri seçilerek her bir görüntüden sağ akciğer lobu ve sol akciğer lobu kırpılmıştır. Kırpma işlemi dikdörtgen şeklinde, yalnızca akciğer loblarını kapsayacak şekilde gerçekleştirilmiştir (Bkz. Şekil 3.15.). Kırpma işleminden sonra her bir

görüntüden iki adet görüntü elde edilerek toplamda 2856 CXR görüntüsü işleme hazır hale getirilmiştir.



Şekil 3.17. Strateji 1 adımları

LHE'nin farklı Selem (disk) parametreleri sağ ve sol akciğer lobu üzerinde uygulanarak, görüntüde bulunan öznelilikler daha belirgin hale getirilmiştir, Şekil 3.17.'de kırma işlemi sonucunda elde edilen CXR görüntüleri ve farklı disk değerleri için LHE uygulanmış örnek görüntüler sunulmuştur. Eğitim işlemi için AlexNet, MobileNet ve VGG16 modelleri kullanılarak sağ ve sol akciğer lobları birlikte eğitilmiştir. Toplamda 2856 adet sağ ve sol akciğer CXR görüntüleri için 9 farklı veri çerçevesi üretilerek seçilen 3 modelde eğitim işlemi uygulanmıştır, Şekil 3.18.'de farklı veri çerçeveleri için kullanılan disk değerleri ve eğitim için kullanılan modeller yer almaktadır.



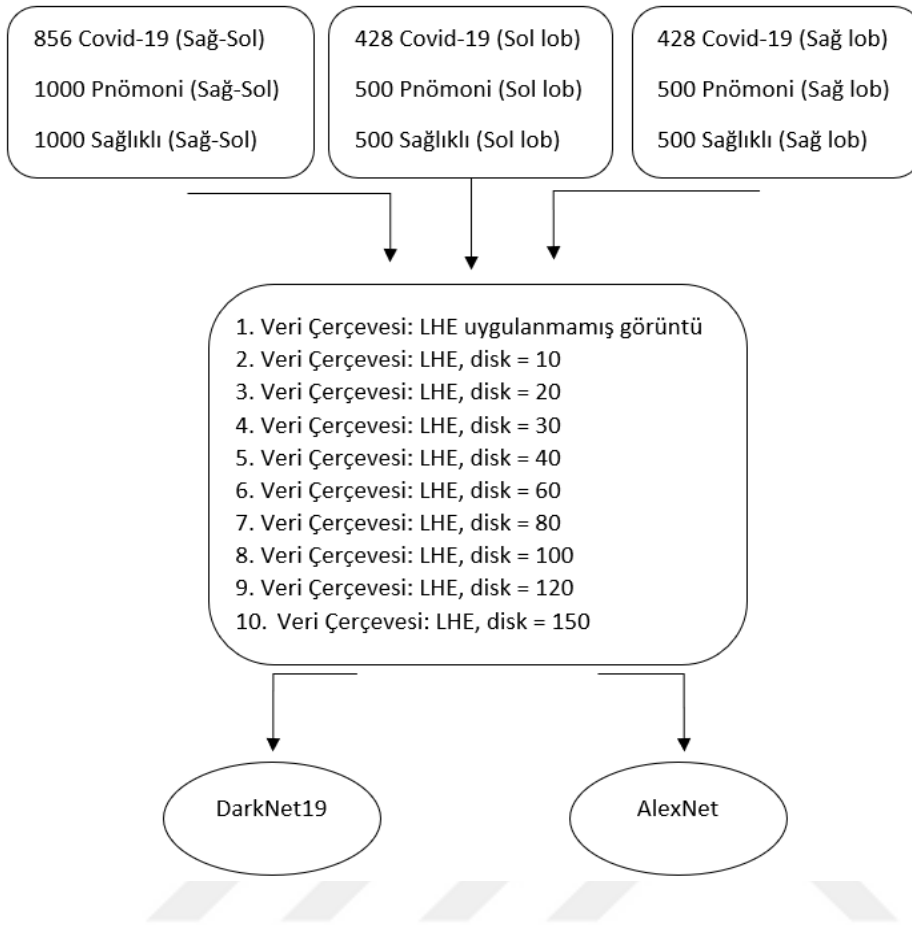
Şekil 3.18. Veri çerçevelerinin oluşturulması

### 3.7.2. Strateji 2

Bu kısımda Strateji 1’de kullanılan veri seti ile aynı veri seti kullanılarak farklı disk değerleri için LHE uygulanmıştır. Strateji 2’de model eğitimi için hazırlanan veri çerçeveleri sağ ve sol akciğer lobları ayrı ve beraber olacak şekilde oluşturulmuştur. Eğitim için DarkNet19 ve AlexNet modelleri seçilerek, toplamda 30 farklı veri çerçevesi bu modellerle eğitilmiştir.

Bu stratejide kullanılan veri çerçeveleri, CXR görüntülerinin farklı önışleme uygulanmış durumlarından oluşmaktadır. Kırpılmış olan CXR görüntüleri için sağ akciğer lobu, sol akciğer lobu ve sağ-sol (birlikte) akciğer lobları için farklı LHE disk parametreleri uygulanmıştır. Böylece 30 farklı veri çerçevesi elde edildikten sonra, her bir veri çerçevesi AlexNet ve DarkNet19 olmak üzere iki farklı modelle eğitilmiştir.

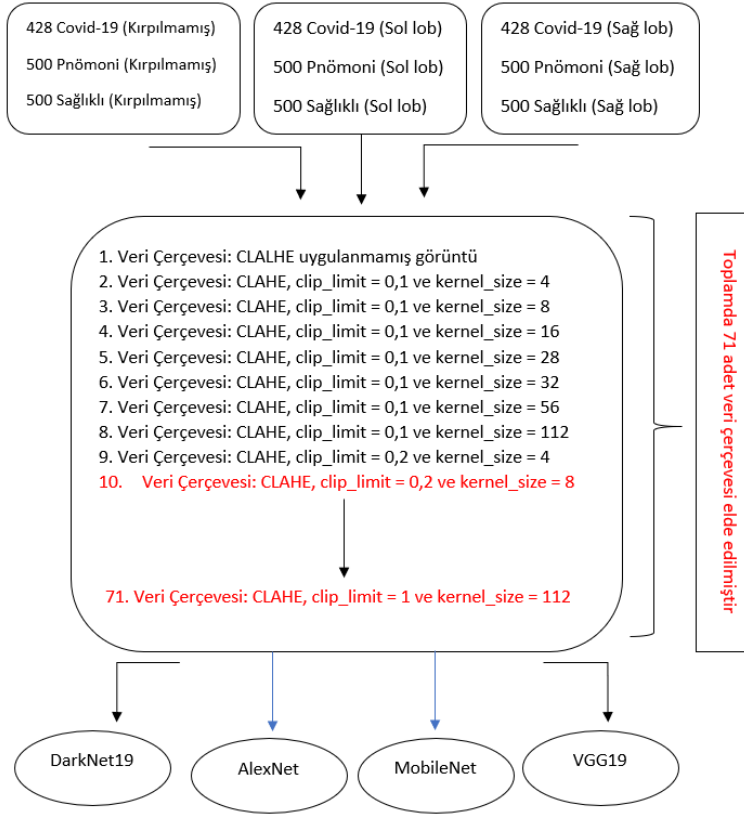
Şekil 3.19.’da görüldüğü üzere Strateji 2’de kullanılan veri çerçeveleri, uygulanan LHE disk parametreleri ve kullanılan modeller sunulmuştur.



Şekil 3.19. Strateji 2’de oluşturulan veri çerçeveleri

### 3.7.3. Strateji 3

Bu stratejide de NIH veri seti kullanılarak, kırılmış ve kırılmamış görüntüler üzerinde CLAHE uygulanmıştır. CLAHE işleminde iki farklı parametre (*clip\_limit*, *kernel\_size*) için farklı kombinasyonlar test edilerek veri çerçeveleri oluşturulmuştur. CLAHE işleminde kullanılan *clip\_limit* parametresi, yoğunluk eşik değeridir ve *kernel\_size* (disk) parametresi, CLAHE’nin uygulanacağı bölgenin yarıçap değeridir. Farklı parametre değerlerinden toplamda 71 adet veri çerçevesi oluşturulmuştur ve her bir veri çerçevesi, AlexNet, VGG16, MobileNet ve DarkNet19 modelleri ile eğitilmiştir. Eğitim sonucunda her bir model için en iyi 5 başarıyı elde eden CLAHE parametreleri belirlenmiştir. Şekil 3.20.’de Strateji 3’te veri çerçevelerine uygulanan farklı CLAHE parametreleri gösterilmiştir. Her bir veri seti grubu için toplamda 71 adet veri çerçevesi oluşturulmuştur, 3 veri seti grubu için uygulanan farklı CLAHE parametreleri sonrasında 211 adet farklı veri çerçevesi elde edilmiştir, her veri çerçevesi 4 farklı model ile eğitilmiştir ve bunun sonucunda eğitim sayısı 844 adet olarak elde edilmiştir, Çizelge 3.2.’de eğitilen toplam



Şekil 3.20. Strateji 3'te oluşturulan veri çerçeveleri

veri çerçevesi sayısı detaylı olarak sunulmuştur. Toplam eğitim sayısı, 1 adet CLAHE uygulanmamış veri çerçevesi, 4 farklı model 4 eğitim sonucu ve 4 (model) x 3 (kırılmamış, sağ ve sol) x 7 (kernel\_size) x 10 (clip\_limit) = 840 + 4 = 844 eğitim sayısı elde edilmiştir.

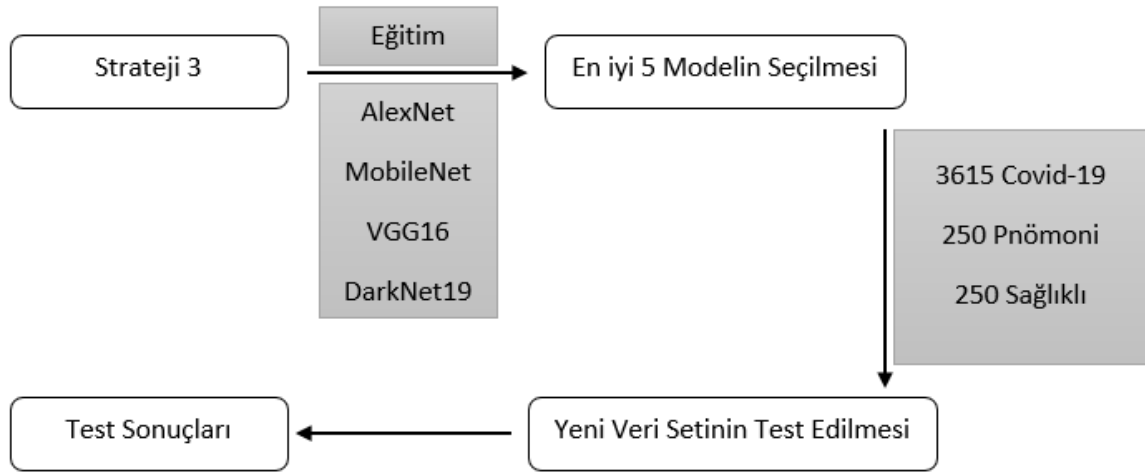
Çizelge 3.2. Strateji 3 için farklı kombinasyonlar

|                       | Farklı Kombinasyonlar   | Kombinasyon Sayısı:                          |
|-----------------------|---|--|
| Veri Seti             | 1. 1428 adet kırılmamış CXR<br>2. 1428 adet sağ lob<br>3. 1428 adet sol lob           | 3 farklı veri grubu                          |
| Kernel_size           | 4, 8, 16, 28, 32, 56, 112   | 7 farklı kernel_size                         |
| Clip_limit            | 0,1- 0,2-0,3- 0,4-0,5- 0,6- 0,7- 0,8- 0,9- 1  | 10 farklı clip_limit                         |
| CNN Modelleri         | 1. AlexNet<br>2. VGG16<br>3. MobileNet<br>4. DarkNet19                                | 4 farklı CNN modeli                          |
| Toplam eğitim sayısı: | 1 adet CLAHE uygulanmamış veri çerçevesi, 4 farklı model için 1 x 4 = 4 eğitim sonucu | 3 x 7 x 10 x 4 = 840 + 4 = 844 eğitim sayısı |

### 3.7.4. Strateji 4

Burada Strateji 3'te elde edilen başarımlar sonuçlarına göre her bir model için 5 farklı en iyi başarımları veren parametreler belirlenmiştir ve model ağırlıkları kaydedilmiştir. Covidx veritabanından seçilen 3615 Covid-19, 3500 Pnömoni ve 3500 sağlıklı CXR görüntülerine seçilen en iyi CLAHE parametreleri uygulanarak yeni veri çerçeveleri oluşturulmuştur. Kaydedilen model ağırlıkları, öğrenme aktarımı metodu kullanılarak oluşturulan veri çerçeveleri bu ağırlıklar ile CNN modelinde test edilmiştir.

Strateji 3'te az sayıda görüntü içeren (1428 adet görüntü) veri seti, AlexNet, VGG16, MobileNet ve DarkNet19 modelleri ile eğitildikten sonra ağırlıkları kaydedilerek, Strateji 4'te oluşturulan yeni veri seti bu ağırlıklar ile test edilmiştir. Test edilen yeni veri seti 3615 Covid-19, 250 Pnömoni ve 250 sağlıklı CXR görüntüsü içermektedir. Bu strateji, daha önce eğitilen az sayıda görüntü içeren veri setinin model ağırlıklarının, daha çok sayıda görüntü içeren veri seti üzerinde test edilerek, doğruluk başarımları ile eğitilen modellerin genelleme özelliği ortaya konulmuştur. Seçilen en iyi 5 model kırılmamış CXR görüntülerini içermektedir. Şekil 3.21.'de Strateji 4 adımları sunulmuştur.

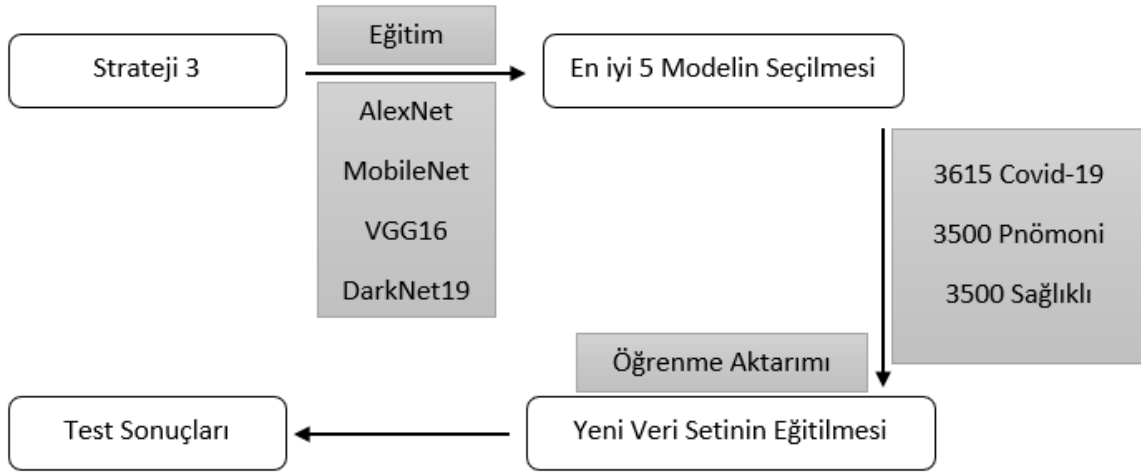


Şekil 3.21. Strateji 4'te oluşturulan

### 3.7.5. Strateji 5

Bu kısımda Strateji 3'te her CNN modeli için elde edilen en iyi 5 sonucun ağırlıkları kullanılarak öğrenim aktarımı ile bu ağırlıklar kullanılarak Covidx veri setinin tekrardan eğitilmesi sağlanmıştır, Covidx veri setinde 3615 Covid-19, 3500 Pnömoni ve 3500 Sağlıklı CXR

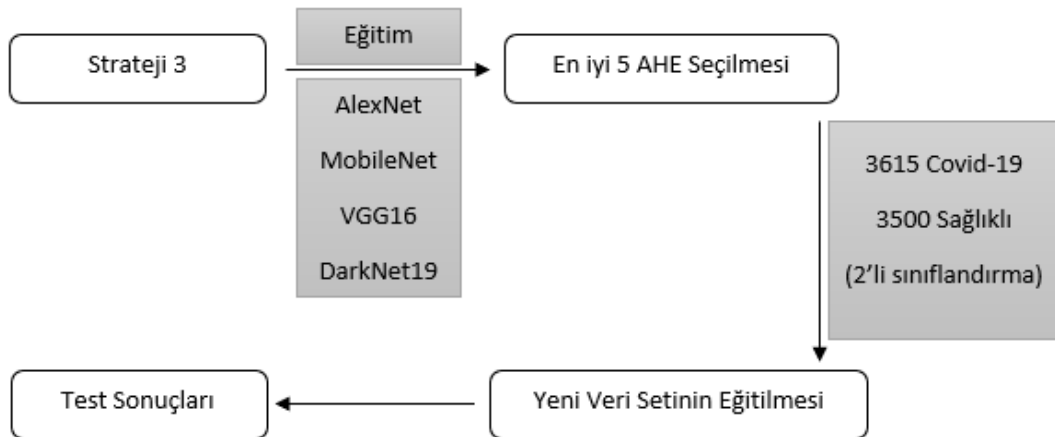
görüntüleri yer almaktadır. Daha önce eğitilmiş (428 Covid-19, 500 Pnömoni, 500 Sağlıklı) az sayıdaki kırılmamış görüntülerden elde edilen ağ ağırlıkları, Covidx veri setine tekrardan uygulanmıştır.



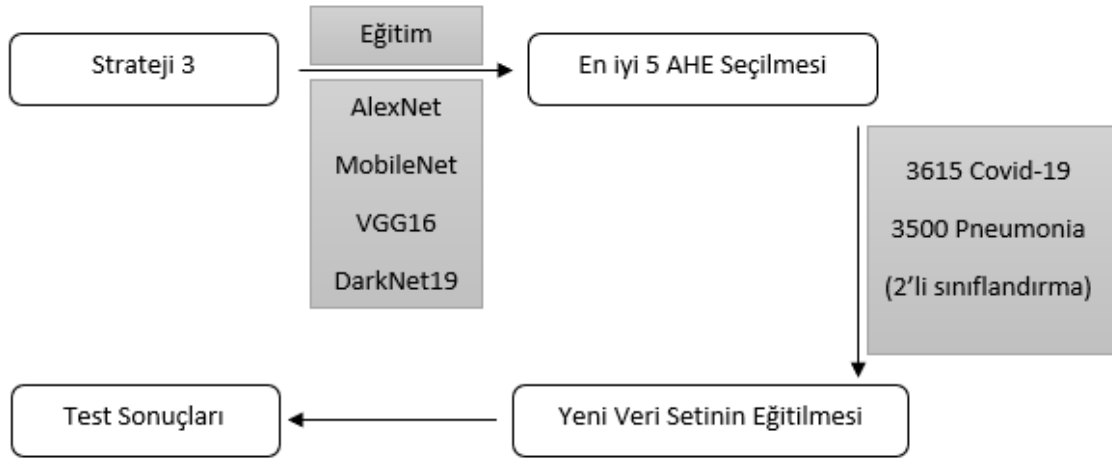
Şekil 3.22. Strateji 5'te uygulanan adımlar

### 3.7.6. Strateji 6

Bu kısımda AlexNet, DarkNet19, MobileNet ve VGG16 modelleri için elde edilen en iyi 5 sonucun AHE Kernel\_size ve Clip\_limit değerleri kullanılarak Covidx veri setinin 2 sınıf için eğitilmesi ve sınıflandırması sağlanmıştır. Birinci eğitimde Covidx veri setinden 3615 Covid-19 ve 3500 Sağlıklı CXR görüntüleri yer almıştır. İkinci eğitimde ise, 3615 Covid-19 ve 3500 Pneumonia CXR görüntüleri eğitilip sınıflandırılmıştır.



Şekil 3.23. Strateji 6'da uygulanan 2'li sınıflandırma (Covid-19 ve Sağlıklı CXR)



Şekil 3.24. Strateji 6'da uygulanan 2'li sınıflandırma (Covid-19 ve Pneumonia CXR)

### 3.8. Performans kriterleri ve İstatistiksel Analiz

Bu çalışmada uygulanan stratejilerin performansını değerlendirmek için Doğruluk, Kesinlik, Duyarlılık, F1 Skor ve karışıklık matrisi metrikleri kullanılmıştır.

Doğruluk, Bir testin doğruluğu, hastayı ve sağlıklı vakaları doğru şekilde ayırt etme özelliğidir. Her durumda gerçek pozitif ve gerçek negatifin oranının hesaplanmasıdır, Eş.3.12'de gösterilmiştir.

Kesinlik, Bir testin özgüllüğü, sağlıklı vakaları doğru şekilde belirleme yeteneğidir. Sağlıklı vakalarda gerçek negatif oranının hesaplanmasıdır, Eş.3.13'de gösterilmiştir.

Duyarlılık, Bir testin duyarlılığı, hasta vakalarını doğru şekilde belirleme yeteneğidir. Hasta vakalarda gerçek pozitif oranının hesaplanmasıdır, Eş.3.14'de gösterilmiştir.

F1-Skor, bir testin doğruluğunun bir ölçüsüdür, kesinlik ve duyarlılığın harmonik ortalamasıdır. Maksimum 1 (mükemmel kesinlik ve duyarlılık) ve minimum 0'a sahip olabilir. Genel olarak, modelin kesinliğinin ve sağlamlığının bir ölçüsüdür, Eş.3.15'de gösterilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.12)$$

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (3.13)$$



$$Duyarluluk = \frac{TP}{TP+FN} \quad (3.14)$$

$$F1 \text{ Skor} = 2 * \frac{Duyarluluk * Hassasiyet}{Duyarluluk+Hassasiyet} \quad (3.15)$$


Karışıklık Matrisi: Makine öğrenimi sınıflandırma problemi için bir performans ölçümüdür. Öngörülen ve gerçek değerlerin 4 farklı kombinasyonunu içeren bir tablodur, Şekil 3.25.'de örnek bir matris sunulmuştur:

Gerçek pozitif (TP), hasta olarak doğru şekilde tanımlanan vakaların sayısıdır.

Yanlış pozitif (FP), hasta olarak hatalı şekilde tanımlanan vakaların sayısıdır.

Gerçek negatif (TN), sağlıklı olarak doğru şekilde tanımlanan vakaların sayısıdır.

Yanlış negatif (FN), yanlış olarak sağlıklı olarak tanımlanan vakaların sayısıdır.



Şekil 3.25. Karışıklık matrisine örnek bir görüntü

## 4. ARAŞTIRMA BULGULARI

### 4.1. Strateji 1 ile Elde Edilen Sonuçlar

#### 4.1.1. Strateji 1 AlexNet Sonuçları

Bu kısımda AlexNet modeli ile Strateji 1 için elde edilen sonuçlar yer almaktadır. AlexNet modeli kullanılarak CXR sağ ve sol lob birlikte eğitilmiş görüntüler kullanılmıştır. Bu Stratejide farklı LHE parametreleri için sonuçlar elde edilmiştir. Strateji 1 için elde edilen sonuçlarda, kesinlik, duyarlılık ve f1-skor sonuçları ağırlıklı ortalama olarak kaydedilmiştir.

Çizelge 4.1. AlexNet için strateji 1 sonuçları

| Disk Değeri | Eğitim/Test     | Doğruluk    | Kesinlik    | Duyarlılık  | F1-Skor     |
|-------------|-----------------|-------------|-------------|-------------|-------------|
| LHE olmadan | 2284/572        | 0,91        | 0,91        | 0,91        | 0,91        |
| 20          | 2284/572        | 0,85        | 0,85        | 0,85        | 0,85        |
| 40          | 2284/572        | 0,92        | 0,92        | 0,92        | 0,92        |
| <b>60</b>   | <b>2284/572</b> | <b>0,94</b> | <b>0,94</b> | <b>0,94</b> | <b>0,94</b> |
| <b>80</b>   | <b>2284/572</b> | <b>0,94</b> | <b>0,94</b> | <b>0,94</b> | <b>0,94</b> |
| 100         | 2284/572        | 0,93        | 0,94        | 0,93        | 0,93        |
| <b>120</b>  | <b>2284/572</b> | <b>0,94</b> | <b>0,94</b> | <b>0,94</b> | <b>0,94</b> |
| <b>140</b>  | <b>2284/572</b> | <b>0,94</b> | <b>0,94</b> | <b>0,94</b> | <b>0,94</b> |
| <b>160</b>  | <b>2284/572</b> | <b>0,94</b> | <b>0,94</b> | <b>0,94</b> | <b>0,94</b> |

#### 4.1.2. Strateji 1 MobileNet Sonuçları

Çizelge 4.2. MobileNet için strateji 1 sonuçları

| Disk Değeri | Eğitim/Test     | Doğruluk    | Kesinlik    | Duyarlılık  | F1-Skor     |
|-------------|-----------------|-------------|-------------|-------------|-------------|
| LHE olmadan | 2284/572        | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> |
| 20          | 2284/572        | 0,91        | 0,93        | 0,91        | 0,91        |
| 40          | 2284/572        | 0,96        | 0,96        | 0,96        | 0,96        |
| <b>60</b>   | <b>2284/572</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> |
| 80          | 2284/572        | 0,97        | 0,97        | 0,97        | 0,97        |

Çizelge 4.2. (Devam) MobileNet için strateji 1 sonuçları

|            |                 |             |             |             |             |
|------------|-----------------|-------------|-------------|-------------|-------------|
| <b>100</b> | <b>2284/572</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> |
| <b>120</b> | <b>2284/572</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> |
| <b>140</b> | <b>2284/572</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> |
| 160        | 2284/572        | 0,91        | 0,93        | 0,91        | 0,91        |

### 4.1.3. Strateji 1 VGG16 Sonuçları

Çizelge 4.3. VGG16 için strateji 1 sonuçları

| <b>Disk Değeri</b> | <b>Eğitim/Test</b> | <b>Doğruluk</b> | <b>Kesinlik</b> | <b>Duyarlılık</b> | <b>F1-Skor</b> |
|--------------------|--------------------|-----------------|-----------------|-------------------|----------------|
| <b>LHE olmadan</b> | <b>2284/572</b>    | <b>0,97</b>     | <b>0,97</b>     | <b>0,97</b>       | <b>0,97</b>    |
| 20                 | 2284/572           | 0,94            | 0,94            | 0,94              | 0,94           |
| 40                 | 2284/572           | 0,94            | 0,94            | 0,94              | 0,94           |
| 60                 | 2284/572           | 0,95            | 0,95            | 0,95              | 0,95           |
| 80                 | 2284/572           | 0,96            | 0,96            | 0,96              | 0,96           |
| 100                | 2284/572           | 0,95            | 0,95            | 0,95              | 0,95           |
| 120                | 2284/572           | 0,96            | 0,96            | 0,96              | 0,96           |
| <b>140</b>         | <b>2284/572</b>    | <b>0,97</b>     | <b>0,96</b>     | <b>0,96</b>       | <b>0,96</b>    |
| <b>160</b>         | <b>2284/572</b>    | <b>0,97</b>     | <b>0,97</b>     | <b>0,97</b>       | <b>0,97</b>    |

## 4.2. Strateji 2 ile Elde Edilen Sonuçlar

Bu kısımda, AlexNet ve DarkNet19 modelleri ile eğitilen CXR görüntüleri için elde edilen sonuçlar yer almaktadır. Sağ ve sol lob birlikte, sağ lob ayrı ve sol lob ayrı olarak oluşturulan veri çerçevesinin eğitimi ile elde edilen sonuçlar ayrı çizelgelerde belirtilmiştir. Oluşturulan veri çerçeveleri AlexNet ve Darknet19 modelleri ile eğitilmiştir.

#### 4.2.1. Strateji 2 AlexNet Sağ-Sol Lob CXR Sonuçları

Çizelge 4.4. AlexNet sağ-sol birlikte CXR strateji 1 sonuçları

| Disk Değeri | Eğitim/Test     | Doğruluk    | Kesinlik    | Duyarlılık  | F1-Skor     |
|-------------|-----------------|-------------|-------------|-------------|-------------|
| LHE olmadan | 2284/572        | 0,91        | 0,92        | 0,91        | 0,91        |
| 10          | 2284/572        | 0,89        | 0,89        | 0,89        | 0,89        |
| 20          | 2284/572        | 0,88        | 0,88        | 0,88        | 0,88        |
| 30          | 2284/572        | 0,90        | 0,90        | 0,90        | 0,90        |
| 40          | 2284/572        | 0,92        | 0,92        | 0,92        | 0,92        |
| 60          | 2284/572        | 0,94        | 0,95        | 0,94        | 0,94        |
| 80          | 2284/572        | 0,94        | 0,94        | 0,94        | 0,94        |
| 100         | 2284/572        | 0,96        | 0,96        | 0,96        | 0,96        |
| <b>120</b>  | <b>2284/572</b> | <b>0,97</b> | <b>0,97</b> | <b>0,97</b> | <b>0,96</b> |
| 150         | 2284/572        | 0,96        | 0,96        | 0,96        | 0,96        |

#### 4.2.2. Strateji 2 AlexNet Sol Lob CXR Sonuçları

Çizelge 4.5. AlexNet sol lob CXR strateji 1 sonuçları

| Disk Değeri | Eğitim/Test     | Doğruluk    | Kesinlik    | Duyarlılık  | F1-Skor     |
|-------------|-----------------|-------------|-------------|-------------|-------------|
| LHE olmadan | 1142/286        | 0,91        | 0,92        | 0,91        | 0,91        |
| 10          | 1142/286        | 0,93        | 0,94        | 0,93        | 0,93        |
| 20          | 1142/286        | 0,94        | 0,94        | 0,94        | 0,94        |
| 30          | 1142/286        | 0,91        | 0,91        | 0,91        | 0,91        |
| 40          | 1142/286        | 0,92        | 0,93        | 0,92        | 0,92        |
| 60          | 1142/286        | 0,95        | 0,95        | 0,95        | 0,95        |
| <b>80</b>   | <b>1142/286</b> | <b>0,96</b> | <b>0,96</b> | <b>0,96</b> | <b>0,96</b> |
| 100         | 1142/286        | 0,93        | 0,93        | 0,93        | 0,93        |
| 120         | 1142/286        | 0,93        | 0,93        | 0,93        | 0,93        |
| 150         | 1142/286        | 0,93        | 0,93        | 0,93        | 0,93        |

### 4.2.3. Strateji 2 AlexNet Sağ Lob CXR Sonuçları

Çizelge 4.6. AlexNet sağ lob CXR strateji 1 sonuçları

| Disk Değeri | Eğitim/Test     | Doğruluk    | Kesinlik    | Duyarlılık  | F1-Skor     |
|-------------|-----------------|-------------|-------------|-------------|-------------|
| LHE olmadan | 1142/286        | 0,95        | 0,95        | 0,95        | 0,95        |
| 10          | 1142/286        | 0,85        | 0,85        | 0,85        | 0,85        |
| 20          | 1142/286        | 0,85        | 0,85        | 0,85        | 0,85        |
| 30          | 1142/286        | 0,92        | 0,92        | 0,92        | 0,92        |
| 40          | 1142/286        | 0,93        | 0,93        | 0,93        | 0,93        |
| 60          | 1142/286        | 0,94        | 0,94        | 0,94        | 0,94        |
| 80          | 1142/286        | 0,95        | 0,95        | 0,95        | 0,95        |
| <b>100</b>  | <b>1142/286</b> | <b>0,96</b> | <b>0,96</b> | <b>0,96</b> | <b>0,96</b> |
| 120         | 1142/286        | 0,93        | 0,93        | 0,93        | 0,93        |
| 150         | 1142/286        | 0,93        | 0,93        | 0,93        | 0,93        |

### 4.2.4. Strateji 2 DarkNet19 Sağ-Sol Lob CXR Sonuçları

Çizelge 4.7. DarkNet19 sağ-sol lob CXR strateji 1 sonuçları

| Disk Değeri | Eğitim/Test     | Doğruluk    | Kesinlik    | Duyarlılık  | F1-Skor     |
|-------------|-----------------|-------------|-------------|-------------|-------------|
| LHE olmadan | 2284/572        | 0,96        | 0,96        | 0,96        | 0,96        |
| 10          | 2284/572        | 0,98        | 0,98        | 0,98        | 0,98        |
| 20          | 2284/572        | 0,92        | 0,92        | 0,92        | 0,92        |
| 30          | 2284/572        | 0,95        | 0,96        | 0,95        | 0,96        |
| <b>40</b>   | <b>2284/572</b> | <b>0,99</b> | <b>0,99</b> | <b>0,99</b> | <b>0,99</b> |
| 60          | 2284/572        | 0,97        | 0,97        | 0,97        | 0,97        |
| 80          | 2284/572        | 0,95        | 0,95        | 0,95        | 0,95        |
| 100         | 2284/572        | 0,97        | 0,97        | 0,97        | 0,97        |
| 120         | 2284/572        | 0,98        | 0,98        | 0,98        | 0,98        |
| 150         | 2284/572        | 0,98        | 0,98        | 0,98        | 0,98        |

#### 4.2.5. Strateji 2 DarkNet19 Sol Lob CXR Sonuçları

Çizelge 4.8. DarkNet19 sol lob CXR strateji 1 sonuçları

| Disk Değeri        | Eğitim/Test     | Doğruluk    | Kesinlik    | Duyarlılık  | F1-Skor     |
|--------------------|-----------------|-------------|-------------|-------------|-------------|
| <b>LHE olmadan</b> | <b>1142/286</b> | <b>0,99</b> | <b>0,99</b> | <b>0,99</b> | <b>0,99</b> |
| 10                 | 1142/286        | 0,97        | 0,97        | 0,97        | 0,97        |
| 20                 | 1142/286        | 0,98        | 0,98        | 0,98        | 0,98        |
| 30                 | 1142/286        | 0,95        | 0,95        | 0,95        | 0,95        |
| 40                 | 1142/286        | 0,91        | 0,92        | 0,91        | 0,90        |
| 60                 | 1142/286        | 0,96        | 0,96        | 0,96        | 0,96        |
| 80                 | 1142/286        | 0,98        | 0,98        | 0,98        | 0,98        |
| 100                | 1142/286        | 0,97        | 0,97        | 0,97        | 0,97        |
| 120                | 1142/286        | 0,97        | 0,97        | 0,97        | 0,97        |
| 150                | 1142/286        | 0,98        | 0,98        | 0,98        | 0,98        |

#### 4.2.6. Strateji 2 DarkNet19 Sağ Lob CXR Sonuçları

Çizelge 4.9. DarkNet19 sağ lob CXR strateji 1 sonuçları

| Disk Değeri | Eğitim/Test     | Doğruluk    | Kesinlik    | Duyarlılık  | F1-Skor     |
|-------------|-----------------|-------------|-------------|-------------|-------------|
| LHE olmadan | 1142/286        | 0,96        | 0,96        | 0,96        | 0,96        |
| 10          | 1142/286        | 0,97        | 0,97        | 0,97        | 0,97        |
| 20          | 1142/286        | 0,97        | 0,97        | 0,97        | 0,97        |
| <b>30</b>   | <b>1142/286</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> |
| 40          | 1142/286        | 0,95        | 0,95        | 0,95        | 0,95        |
| 60          | 1142/286        | 0,96        | 0,96        | 0,96        | 0,96        |
| 80          | 1142/286        | 0,97        | 0,97        | 0,97        | 0,97        |
| <b>100</b>  | <b>1142/286</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> | <b>0,98</b> |
| 120         | 1142/286        | 0,95        | 0,95        | 0,95        | 0,95        |
| 150         | 1142/286        | 0,96        | 0,96        | 0,96        | 0,96        |

### 4.3. Strateji 3 ile Elde Edilen Sonuçlar

Bu kısımda, strateji 3'te anlatılan farklı CLAHE parametreleri için 4 farklı model eğitimi ile elde edilen başarımlar sunulmuştur.

Çizelge 4.10. AlexNet kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|---------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| CLAHE olmadan |             | 1142/286        | 0,93357        | 0,93333        | 0,93357        | 0,93342        |
| <b>0,1</b>    | <b>4</b>    | <b>1142/286</b> | <b>0,96503</b> | <b>0,96545</b> | <b>0,96503</b> | <b>0,96495</b> |
| <b>0,1</b>    | <b>8</b>    | <b>1142/286</b> | <b>0,96154</b> | <b>0,96272</b> | <b>0,96154</b> | <b>0,96124</b> |
| 0,1           | 16          | 1142/286        | 0,95804        | 0,96104        | 0,95804        | 0,95772        |
| 0,1           | 28          | 1142/286        | 0,79371        | 0,87207        | 0,79371        | 0,79271        |
| 0,1           | 32          | 1142/286        | 0,94406        | 0,94975        | 0,94406        | 0,94336        |
| <b>0,1</b>    | <b>56</b>   | <b>1142/286</b> | <b>0,96154</b> | <b>0,96399</b> | <b>0,96154</b> | <b>0,96115</b> |
| 0,1           | 112         | 1142/286        | 0,94406        | 0,94401        | 0,94406        | 0,94368        |
| 0,2           | 4           | 1142/286        | 0,95455        | 0,95522        | 0,95455        | 0,95476        |
| 0,2           | 8           | 1142/286        | 0,87413        | 0,90720        | 0,87413        | 0,98667        |
| 0,2           | 16          | 1142/286        | 0,95455        | 0,95499        | 0,95455        | 0,95342        |
| 0,2           | 28          | 1142/286        | 0,94056        | 0,94053        | 0,94056        | 0,94053        |
| 0,2           | 32          | 1142/286        | 0,95804        | 0,95810        | 0,95804        | 0,95800        |
| 0,2           | 56          | 1142/286        | 0,95804        | 0,95809        | 0,95804        | 0,95783        |
| 0,2           | 112         | 1142/286        | 0,94755        | 0,95009        | 0,94755        | 0,94715        |
| 0,3           | 4           | 1142/286        | 0,89510        | 0,91180        | 0,89510        | 0,89778        |
| 0,3           | 8           | 1142/286        | 0,96154        | 0,96163        | 0,96154        | 0,96142        |
| 0,3           | 16          | 1142/286        | 0,95050        | 0,95169        | 0,95105        | 0,95130        |
| 0,3           | 28          | 1142/286        | 0,95105        | 0,95346        | 0,95105        | 0,95114        |
| 0,3           | 32          | 1142/286        | 0,95105        | 0,95141        | 0,95105        | 0,90840        |
| 0,3           | 56          | 1142/286        | 0,90559        | 0,92038        | 0,90559        | 0,90571        |
| 0,3           | 112         | 1142/286        | 0,94056        | 0,94553        | 0,94056        | 0,93930        |

Çizelge 4.11. AlexNet kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,4        | 4           | 1142/286        | 0,92308        | 0,92339        | 0,92308        | 0,92293        |
| 0,4        | 8           | 1142/286        | 0,84615        | 0,89153        | 0,84615        | 0,85232        |
| 0,4        | 16          | 1142/286        | 0,91958        | 0,92057        | 0,91958        | 0,91956        |
| 0,4        | 28          | 1142/286        | 0,93706        | 0,94075        | 0,93706        | 0,93617        |
| 0,4        | 32          | 1142/286        | 0,93706        | 0,93698        | 0,93706        | 0,93661        |
| 0,4        | 56          | 1142/286        | 0,91259        | 0,91588        | 0,91259        | 0,91291        |
| 0,4        | 112         | 1142/286        | 0,95804        | 0,96047        | 0,95804        | 0,95756        |
| 0,5        | 4           | 1142/286        | 0,91608        | 0,92308        | 0,91608        | 0,91372        |
| 0,5        | 8           | 1142/286        | 0,94755        | 0,95118        | 0,94755        | 0,94659        |
| 0,5        | 16          | 1142/286        | 0,95105        | 0,95208        | 0,95105        | 0,95038        |
| <b>0,5</b> | <b>28</b>   | <b>1142/286</b> | <b>0,96853</b> | <b>0,96854</b> | <b>0,96853</b> | <b>0,96852</b> |
| 0,5        | 32          | 1142/286        | 0,93706        | 0,93690        | 0,93706        | 0,93675        |
| 0,5        | 56          | 1142/286        | 0,94056        | 0,94127        | 0,94056        | 0,94079        |
| 0,5        | 112         | 1142/286        | 0,94755        | 0,94872        | 0,94755        | 0,94739        |
| 0,6        | 4           | 1142/286        | 0,90909        | 0,91335        | 0,90909        | 0,91019        |
| 0,6        | 8           | 1142/286        | 0,87762        | 0,89139        | 0,87762        | 0,87455        |
| 0,6        | 16          | 1142/286        | 0,94755        | 0,95033        | 0,94755        | 0,94690        |
| 0,6        | 28          | 1142/286        | 0,87063        | 0,89680        | 0,87063        | 0,87350        |
| 0,6        | 32          | 1142/286        | 0,94755        | 0,95178        | 0,94755        | 0,94676        |
| 0,6        | 56          | 1142/286        | 0,79371        | 0,87823        | 0,79371        | 0,77772        |
| 0,6        | 112         | 1142/286        | 0,93706        | 0,93961        | 0,93706        | 0,93658        |



Çizelge 4.12. AlexNet kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,76224        | 0,82153        | 0,76224        | 0,75437        |
| 0,7        | 8           | 1142/286        | 0,94755        | 0,94873        | 0,94755        | 0,94748        |
| 0,7        | 16          | 1142/286        | 0,95105        | 0,95390        | 0,95105        | 0,95067        |
| 0,7        | 28          | 1142/286        | 0,95105        | 0,95330        | 0,95105        | 0,95050        |
| 0,7        | 32          | 1142/286        | 0,93706        | 0,94316        | 0,93706        | 0,93624        |
| 0,7        | 56          | 1142/286        | 0,93706        | 0,93700        | 0,93706        | 0,93696        |
| 0,7        | 112         | 1142/286        | 0,95455        | 0,95523        | 0,95455        | 0,95457        |
| 0,8        | 4           | 1142/286        | 0,87063        | 0,89007        | 0,87063        | 0,86135        |
| 0,8        | 16          | 1142/286        | 0,90909        | 0,91905        | 0,90909        | 0,90909        |
| 0,8        | 28          | 1142/286        | 0,93706        | 0,94140        | 0,93706        | 0,93638        |
| 0,8        | 32          | 1142/286        | 0,86713        | 0,89955        | 0,86713        | 0,86476        |
| <b>0,8</b> | <b>56</b>   | <b>1142/286</b> | <b>0,96503</b> | <b>0,96556</b> | <b>0,96503</b> | <b>0,96491</b> |
| 0,8        | 112         | 1142/286        | 0,91958        | 0,92074        | 0,91958        | 0,92004        |
| 0,9        | 4           | 1142/286        | 0,87413        | 0,88290        | 0,87413        | 0,87414        |
| 0,9        | 8           | 1142/286        | 0,95455        | 0,95632        | 0,95455        | 0,95408        |
| 0,9        | 28          | 1142/286        | 0,95105        | 0,95225        | 0,95105        | 0,95091        |
| 0,9        | 32          | 1142/286        | 0,95105        | 0,95225        | 0,95105        | 0,95091        |
| 0,9        | 56          | 1142/286        | 0,95455        | 0,95495        | 0,95455        | 0,95422        |
| 0,9        | 112         | 1142/286        | 0,94406        | 0,94898        | 0,94406        | 0,94314        |
| 1          | 4           | 1142/286        | 0,94755        | 0,94845        | 0,94755        | 0,94736        |
| 1          | 8           | 1142/286        | 0,93007        | 0,93758        | 0,93007        | 0,92949        |
| 1          | 16          | 1142/286        | 0,95455        | 0,95460        | 0,95455        | 0,95450        |
| 1          | 32          | 1142/286        | 0,96154        | 0,96218        | 0,96154        | 0,96154        |
| 1          | 56          | 1142/286        | 0,95455        | 0,95437        | 0,95455        | 0,95444        |
| 1          | 112         | 1142/286        | 0,95455        | 0,95441        | 0,95455        | 0,95435        |

Çizelge 4.13. AlexNet Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|---------------|-------------|-------------|----------|----------|------------|---------|
| CLAHE olmadan |             | 1142/286    | 0,95105  | 0,95135  | 0,95105    | 0,95049 |
| 0,1           | 4           | 1142/286    | 0,93007  | 0,93467  | 0,93007    | 0,92984 |
| 0,1           | 8           | 1142/286    | 0,93706  | 0,94271  | 0,93706    | 0,93715 |
| 0,1           | 16          | 1142/286    | 0,89510  | 0,91464  | 0,89510    | 0,89110 |
| 0,1           | 28          | 1142/286    | 0,95105  | 0,95380  | 0,95105    | 0,95027 |
| 0,1           | 32          | 1142/286    | 0,90210  | 0,91975  | 0,90210    | 0,89734 |
| 0,1           | 56          | 1142/286    | 0,94406  | 0,94755  | 0,94406    | 0,94385 |
| 0,1           | 112         | 1142/286    | 0,91958  | 0,92108  | 0,91958    | 0,92012 |
| 0,2           | 4           | 1142/286    | 0,61189  | 0,74540  | 0,61189    | 0,57930 |
| 0,2           | 8           | 1142/286    | 0,86014  | 0,88827  | 0,86014    | 0,85506 |
| 0,2           | 16          | 1142/286    | 0,94056  | 0,94346  | 0,94056    | 0,93941 |
| 0,2           | 28          | 1142/286    | 0,94056  | 0,94073  | 0,94056    | 0,94026 |
| 0,2           | 32          | 1142/286    | 0,95455  | 0,95761  | 0,95455    | 0,95410 |
| 0,2           | 56          | 1142/286    | 0,94755  | 0,95198  | 0,94755    | 0,94661 |
| 0,2           | 112         | 1142/286    | 0,92308  | 0,92437  | 0,92308    | 0,92288 |
| 0,3           | 4           | 1142/286    | 0,74825  | 0,85056  | 0,74825    | 0,75131 |
| 0,3           | 8           | 1142/286    | 0,23080  | 0,31290  | 0,92308    | 0,92014 |
| 0,3           | 16          | 1142/286    | 0,94056  | 0,94209  | 0,94056    | 0,94100 |
| 0,3           | 28          | 1142/286    | 0,85664  | 0,89476  | 0,85664    | 0,86116 |
| 0,3           | 32          | 1142/286    | 0,95804  | 0,96049  | 0,95804    | 0,95779 |
| 0,3           | 56          | 1142/286    | 0,94755  | 0,95060  | 0,94755    | 0,94775 |
| 0,3           | 112         | 1142/286    | 0,94755  | 0,94875  | 0,94755    | 0,94697 |

Çizelge 4.14. AlexNet Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,4        | 4           | 1142/286        | 0,75175        | 0,81264        | 0,75175        | 0,70919        |
| 0,4        | 8           | 1142/286        | 0,82867        | 0,86303        | 0,82867        | 0,80882        |
| 0,4        | 16          | 1142/286        | 0,94406        | 0,94483        | 0,94406        | 0,94366        |
| 0,4        | 28          | 1142/286        | 0,91259        | 0,92319        | 0,91259        | 0,91129        |
| 0,4        | 32          | 1142/286        | 0,94755        | 0,94974        | 0,94755        | 0,94715        |
| 0,4        | 56          | 1142/286        | 0,89161        | 0,91706        | 0,89161        | 0,89039        |
| 0,4        | 112         | 1142/286        | 0,93007        | 0,93155        | 0,93007        | 0,93044        |
| 0,5        | 4           | 1142/286        | 0,93706        | 0,93713        | 0,93706        | 0,93634        |
| 0,5        | 8           | 1142/286        | 0,91958        | 0,93212        | 0,91958        | 0,91835        |
| 0,5        | 16          | 1142/286        | 0,94755        | 0,95210        | 0,94755        | 0,94676        |
| 0,5        | 28          | 1142/286        | 0,93706        | 0,93758        | 0,93706        | 0,93684        |
| 0,5        | 32          | 1142/286        | 0,93357        | 0,93620        | 0,93357        | 0,93198        |
| 0,5        | 56          | 1142/286        | 0,90909        | 0,92083        | 0,90909        | 0,90935        |
| 0,5        | 112         | 1142/286        | 0,91608        | 0,91952        | 0,91608        | 0,91446        |
| 0,6        | 4           | 1142/286        | 0,92308        | 0,92298        | 0,92308        | 0,92240        |
| 0,6        | 8           | 1142/286        | 0,91608        | 0,92998        | 0,91608        | 0,91300        |
| 0,6        | 16          | 1142/286        | 0,95105        | 0,95236        | 0,95105        | 0,95106        |
| 0,6        | 28          | 1142/286        | 0,87413        | 0,88963        | 0,87413        | 0,87692        |
| 0,6        | 32          | 1142/286        | 0,95804        | 0,95943        | 0,95804        | 0,95807        |
| <b>0,6</b> | <b>56</b>   | <b>1142/286</b> | <b>0,96154</b> | <b>0,96288</b> | <b>0,96154</b> | <b>0,96121</b> |
| <b>0,6</b> | <b>112</b>  | <b>1142/286</b> | <b>0,96503</b> | <b>0,96499</b> | <b>0,96503</b> | <b>0,96496</b> |

Çizelge 4.15. AlexNet Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,92308        | 0,92336        | 0,92308        | 0,92211        |
| 0,7        | 8           | 1142/286        | 0,79021        | 0,85668        | 0,79021        | 0,78168        |
| 0,7        | 16          | 1142/286        | 0,86713        | 0,89573        | 0,86713        | 0,85748        |
| 0,7        | 28          | 1142/286        | 0,96154        | 0,96251        | 0,96154        | 0,96123        |
| 0,7        | 32          | 1142/286        | 0,93357        | 0,93645        | 0,93357        | 0,93413        |
| 0,7        | 56          | 1142/286        | 0,96503        | 0,96671        | 0,96503        | 0,96464        |
| <b>0,7</b> | <b>112</b>  | <b>1142/286</b> | <b>0,96853</b> | <b>0,96946</b> | <b>0,96853</b> | <b>0,96841</b> |
| 0,8        | 4           | 1142/286        | 0,91259        | 0,91857        | 0,91259        | 0,91147        |
| 0,8        | 8           | 1142/286        | 0,90210        | 0,91407        | 0,90210        | 0,89563        |
| 0,8        | 16          | 1142/286        | 0,90909        | 0,92117        | 0,90909        | 0,91033        |
| 0,8        | 28          | 1142/286        | 0,94056        | 0,94171        | 0,94056        | 0,93935        |
| 0,8        | 32          | 1142/286        | 0,93357        | 0,93631        | 0,93357        | 0,93334        |
| 0,8        | 56          | 1142/286        | 0,95105        | 0,95229        | 0,95105        | 0,95046        |
| 0,8        | 112         | 1142/286        | 0,93357        | 0,93517        | 0,93357        | 0,93227        |
| 0,9        | 4           | 1142/286        | 0,71329        | 0,82760        | 0,71329        | 0,69248        |
| 0,9        | 8           | 1142/286        | 0,91259        | 0,91949        | 0,91259        | 0,90924        |
| 0,9        | 16          | 1142/286        | 0,96154        | 0,96251        | 0,96154        | 0,96179        |
| 0,9        | 32          | 1142/286        | 0,92657        | 0,93415        | 0,92657        | 0,92519        |
| 0,9        | 56          | 1142/286        | 0,93357        | 0,94263        | 0,93357        | 0,93284        |
| 0,9        | 112         | 1142/286        | 0,94056        | 0,94141        | 0,94056        | 0,94086        |
| 1          | 4           | 1142/286        | 0,91259        | 0,91663        | 0,91259        | 0,91373        |
| 1          | 8           | 1142/286        | 0,92657        | 0,92999        | 0,92657        | 0,92397        |
| 1          | 16          | 1142/286        | 0,96154        | 0,96153        | 0,96154        | 0,96148        |
| <b>1</b>   | <b>28</b>   | <b>1142/286</b> | <b>0,96503</b> | <b>0,96547</b> | <b>0,96503</b> | <b>0,96514</b> |
| 1          | 32          | 1142/286        | 0,93357        | 0,93539        | 0,93357        | 0,93385        |
| 1          | 56          | 1142/286        | 0,93357        | 0,93597        | 0,93357        | 0,93219        |
| 1          | 112         | 1142/286        | 0,93706        | 0,93771        | 0,93706        | 0,93732        |

Çizelge 4.16. AlexNet Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|---------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| CLAHE olmadan |             | 1142/286        | 0,94755        | 0,94856        | 0,94755        | 0,94719        |
| 0,1           | 4           | 1142/286        | 0,91259        | 0,92767        | 0,91259        | 0,91413        |
| <b>0,1</b>    | <b>8</b>    | <b>1142/286</b> | <b>0,95455</b> | <b>0,95448</b> | <b>0,95455</b> | <b>0,95416</b> |
| 0,1           | 16          | 1142/286        | 0,94056        | 0,94111        | 0,94056        | 0,94032        |
| 0,1           | 28          | 1142/286        | 0,94406        | 0,94523        | 0,94406        | 0,94315        |
| 0,1           | 32          | 1142/286        | 0,93007        | 0,93068        | 0,93007        | 0,92990        |
| 0,1           | 56          | 1142/286        | 0,93007        | 0,93178        | 0,93007        | 0,92931        |
| 0,1           | 112         | 1142/286        | 0,91259        | 0,91270        | 0,91259        | 0,91230        |
| 0,2           | 4           | 1142/286        | 0,94056        | 0,94224        | 0,94056        | 0,94087        |
| 0,2           | 8           | 1142/286        | 0,94755        | 0,95375        | 0,94755        | 0,94847        |
| 0,2           | 16          | 1142/286        | 0,93007        | 0,93127        | 0,93007        | 0,92855        |
| 0,2           | 28          | 1142/286        | 0,92657        | 0,92697        | 0,92657        | 0,92607        |
| 0,2           | 32          | 1142/286        | 0,94056        | 0,94221        | 0,94056        | 0,94076        |
| 0,2           | 56          | 1142/286        | 0,81469        | 0,85866        | 0,81469        | 0,79687        |
| 0,2           | 112         | 1142/286        | 0,93007        | 0,92967        | 0,93007        | 0,92980        |
| 0,3           | 4           | 1142/286        | 0,93706        | 0,93834        | 0,93706        | 0,93714        |
| 0,3           | 8           | 1142/286        | 0,87063        | 0,89857        | 0,87063        | 0,86649        |
| 0,3           | 16          | 1142/286        | 0,91259        | 0,92304        | 0,91259        | 0,91022        |
| 0,3           | 28          | 1142/286        | 0,93706        | 0,93752        | 0,93706        | 0,93586        |
| 0,3           | 32          | 1142/286        | 0,93007        | 0,93109        | 0,93007        | 0,93031        |
| 0,3           | 56          | 1142/286        | 0,93706        | 0,93780        | 0,93706        | 0,93736        |
| 0,3           | 112         | 1142/286        | 0,92657        | 0,92670        | 0,92657        | 0,92662        |

Çizelge 4.17. AlexNet Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,4        | 4           | 1142/286        | 0,92308        | 0,92572        | 0,92308        | 0,92324        |
| 0,4        | 8           | 1142/286        | 0,93007        | 0,93201        | 0,93007        | 0,93034        |
| 0,4        | 16          | 1142/286        | 0,90210        | 0,90950        | 0,90210        | 0,90234        |
| 0,4        | 28          | 1142/286        | 0,94406        | 0,94367        | 0,94406        | 0,94379        |
| <b>0,4</b> | <b>32</b>   | <b>1142/286</b> | <b>0,95105</b> | <b>0,95080</b> | <b>0,95105</b> | <b>0,95070</b> |
| 0,4        | 56          | 1142/286        | 0,94406        | 0,94812        | 0,94406        | 0,94452        |
| 0,4        | 112         | 1142/286        | 0,94406        | 0,94438        | 0,94406        | 0,94389        |
| 0,5        | 4           | 1142/286        | 0,85315        | 0,88748        | 0,85315        | 0,85507        |
| 0,5        | 8           | 1142/286        | 0,85315        | 0,88233        | 0,85315        | 0,84641        |
| 0,5        | 16          | 1142/286        | 0,94755        | 0,94900        | 0,94755        | 0,94794        |
| 0,5        | 28          | 1142/286        | 0,92308        | 0,92336        | 0,92308        | 0,92222        |
| 0,5        | 32          | 1142/286        | 0,91608        | 0,91566        | 0,91608        | 0,91556        |
| 0,5        | 56          | 1142/286        | 0,94056        | 0,94138        | 0,94056        | 0,94016        |
| 0,5        | 112         | 1142/286        | 0,93007        | 0,92967        | 0,93007        | 0,92980        |
| 0,6        | 4           | 1142/286        | 0,66084        | 0,82128        | 0,66084        | 0,62453        |
| 0,6        | 8           | 1142/286        | 0,85664        | 0,88898        | 0,85664        | 0,85665        |
| <b>0,6</b> | <b>16</b>   | <b>1142/286</b> | <b>0,95455</b> | <b>0,95461</b> | <b>0,95455</b> | <b>0,95442</b> |
| 0,6        | 28          | 1142/286        | 0,95105        | 0,95167        | 0,95105        | 0,95113        |
| 0,6        | 32          | 1142/286        | 0,88462        | 0,90491        | 0,88462        | 0,88066        |
| 0,6        | 56          | 1142/286        | 0,93007        | 0,93091        | 0,93007        | 0,92964        |
| 0,6        | 112         | 1142/286        | 0,89860        | 0,91391        | 0,89860        | 0,89825        |

Çizelge 4.18. AlexNet Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,89161        | 0,90781        | 0,89161        | 0,89149        |
| 0,7        | 8           | 1142/286        | 0,94755        | 0,94852        | 0,94755        | 0,94787        |
| 0,7        | 28          | 1142/286        | 0,90909        | 0,91344        | 0,90909        | 0,91003        |
| 0,7        | 32          | 1142/286        | 0,93706        | 0,93761        | 0,93706        | 0,93718        |
| 0,7        | 56          | 1142/286        | 0,93706        | 0,93659        | 0,93706        | 0,93676        |
| 0,7        | 112         | 1142/286        | 0,93357        | 0,93416        | 0,93357        | 0,93339        |
| 0,8        | 8           | 1142/286        | 0,94406        | 0,94465        | 0,94406        | 0,94420        |
| 0,8        | 16          | 1142/286        | 0,90559        | 0,91274        | 0,90559        | 0,90311        |
| 0,8        | 28          | 1142/286        | 0,92308        | 0,92421        | 0,92308        | 0,92173        |
| 0,8        | 32          | 1142/286        | 0,92308        | 0,92325        | 0,92308        | 0,92190        |
| 0,8        | 56          | 1142/286        | 0,90210        | 0,90818        | 0,90210        | 0,89839        |
| <b>0,8</b> | <b>112</b>  | <b>1142/286</b> | <b>0,95455</b> | <b>0,95477</b> | <b>0,95455</b> | <b>0,95461</b> |
| 0,9        | 4           | 1142/286        | 0,83566        | 0,85337        | 0,83566        | 0,83408        |
| 0,9        | 8           | 1142/286        | 0,93706        | 0,93949        | 0,93706        | 0,93761        |
| 0,9        | 16          | 1142/286        | 0,93357        | 0,93630        | 0,93357        | 0,93280        |
| <b>0,9</b> | <b>28</b>   | <b>1142/286</b> | <b>0,95455</b> | <b>0,95461</b> | <b>0,95455</b> | <b>0,95442</b> |
| 0,9        | 32          | 1142/286        | 0,91259        | 0,91924        | 0,91259        | 0,91141        |
| 0,9        | 56          | 1142/286        | 0,91608        | 0,92991        | 0,91608        | 0,91360        |
| 0,9        | 112         | 1142/286        | 0,94056        | 0,94028        | 0,94056        | 0,94029        |
| 1          | 4           | 1142/286        | 0,93007        | 0,93041        | 0,93007        | 0,93022        |
| 1          | 16          | 1142/286        | 0,91958        | 0,92648        | 0,91958        | 0,91716        |
| 1          | 28          | 1142/286        | 0,93007        | 0,93035        | 0,93007        | 0,92978        |
| 1          | 32          | 1142/286        | 0,94056        | 0,94144        | 0,94056        | 0,94035        |
| 1          | 56          | 1142/286        | 0,92657        | 0,93018        | 0,92657        | 0,92657        |
| 1          | 112         | 1142/286        | 0,92657        | 0,93535        | 0,92657        | 0,92717        |

Çizelge 4.19. DarkNet19 kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|---------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| CLAHE olmadan |             | 1142/286        | 0,96154        | 0,96173        | 0,96154        | 0,99147        |
| 0,1           | 4           | 1142/286        | 0,95804        | 0,95988        | 0,95804        | 0,95781        |
| <b>0,1</b>    | <b>8</b>    | <b>1142/286</b> | <b>0,98252</b> | <b>0,98334</b> | <b>0,98252</b> | <b>0,98246</b> |
| 0,1           | 16          | 1142/286        | 0,93706        | 0,94178        | 0,93706        | 0,93640        |
| 0,1           | 28          | 1142/286        | 0,96503        | 0,96516        | 0,96503        | 0,96485        |
| 0,1           | 32          | 1142/286        | 0,95105        | 0,95313        | 0,95105        | 0,95080        |
| 0,1           | 56          | 1142/286        | 0,95455        | 0,95904        | 0,95455        | 0,95385        |
| 0,1           | 112         | 1142/286        | 0,73427        | 0,81884        | 0,73427        | 0,72721        |
| 0,2           | 4           | 1142/286        | 0,65734        | 0,84084        | 0,65734        | 0,65468        |
| 0,2           | 8           | 1142/286        | 0,85664        | 0,89055        | 0,85664        | 0,84359        |
| 0,2           | 16          | 1142/286        | 0,96154        | 0,96347        | 0,96154        | 0,96114        |
| 0,2           | 28          | 1142/286        | 0,96154        | 0,96236        | 0,96154        | 0,96137        |
| 0,2           | 32          | 1142/286        | 0,94406        | 0,94741        | 0,94406        | 0,94329        |
| 0,2           | 56          | 1142/286        | 0,96154        | 0,96399        | 0,96154        | 0,96128        |
| 0,2           | 112         | 1142/286        | 0,96154        | 0,96399        | 0,96154        | 0,96128        |
| 0,3           | 4           | 1142/286        | 0,63636        | 0,78229        | 0,63636        | 0,57008        |
| 0,3           | 8           | 1142/286        | 0,91958        | 0,92794        | 0,91958        | 0,91550        |
| 0,3           | 16          | 1142/286        | 0,96853        | 0,96875        | 0,96853        | 0,96848        |
| 0,3           | 28          | 1142/286        | 0,95105        | 0,95486        | 0,95105        | 0,95151        |
| 0,3           | 32          | 1142/286        | 0,92308        | 0,92815        | 0,92308        | 0,92293        |
| 0,3           | 56          | 1142/286        | 0,94755        | 0,95252        | 0,94755        | 0,94676        |
| 0,3           | 112         | 1142/286        | 0,96503        | 0,96556        | 0,96503        | 0,96491        |



Çizelge 4.20. DarkNet19 kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| <b>0,4</b> | <b>4</b>    | <b>1142/286</b> | <b>0,97902</b> | <b>0,97951</b> | <b>0,97902</b> | <b>0,97879</b> |
| 0,4        | 8           | 1142/286        | 0,94755        | 0,95020        | 0,94755        | 0,94819        |
| 0,4        | 16          | 1142/286        | 0,96853        | 0,96870        | 0,96853        | 0,96857        |
| 0,4        | 28          | 1142/286        | 0,94056        | 0,94783        | 0,94056        | 0,93972        |
| 0,4        | 32          | 1142/286        | 0,91958        | 0,93396        | 0,91958        | 0,91977        |
| 0,4        | 56          | 1142/286        | 0,96503        | 0,96503        | 0,96503        | 0,96503        |
| 0,4        | 112         | 1142/286        | 0,94755        | 0,95148        | 0,94755        | 0,94706        |
| 0,5        | 4           | 1142/286        | 0,70629        | 0,83432        | 0,70629        | 0,63972        |
| 0,5        | 8           | 1142/286        | 0,96853        | 0,96947        | 0,96853        | 0,96845        |
| 0,5        | 16          | 1142/286        | 0,72727        | 0,82753        | 0,72727        | 0,64720        |
| 0,5        | 28          | 1142/286        | 0,94406        | 0,94563        | 0,94406        | 0,94351        |
| 0,5        | 32          | 1142/286        | 0,95804        | 0,96023        | 0,95804        | 0,95777        |
| 0,5        | 56          | 1142/286        | 0,96154        | 0,96399        | 0,96154        | 0,96128        |
| 0,5        | 112         | 1142/286        | 0,96503        | 0,96509        | 0,96503        | 0,96493        |
| 0,6        | 4           | 1142/286        | 0,86713        | 0,90346        | 0,86713        | 0,86071        |
| <b>0,6</b> | <b>8</b>    | <b>1142/286</b> | <b>0,98252</b> | <b>0,98263</b> | <b>0,98252</b> | <b>0,98244</b> |
| 0,6        | 16          | 1142/286        | 0,96154        | 0,96399        | 0,96154        | 0,96128        |
| 0,6        | 28          | 1142/286        | 0,91958        | 0,92737        | 0,91958        | 0,91921        |
| 0,6        | 32          | 1142/286        | 0,95105        | 0,95195        | 0,95105        | 0,95086        |
| 0,6        | 56          | 1142/286        | 0,92308        | 0,93684        | 0,92308        | 0,92299        |
| 0,6        | 112         | 1142/286        | 0,96853        | 0,96854        | 0,96853        | 0,96852        |

Çizelge 4.21. DarkNet19 kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,91259        | 0,92764        | 0,91259        | 0,90920        |
| 0,7        | 8           | 1142/286        | 0,97203        | 0,97279        | 0,97203        | 0,97182        |
| <b>0,7</b> | <b>16</b>   | <b>1142/286</b> | <b>0,97203</b> | <b>0,97282</b> | <b>0,97203</b> | <b>0,97205</b> |
| 0,7        | 28          | 1142/286        | 0,92657        | 0,92738        | 0,92657        | 0,92580        |
| 0,7        | 32          | 1142/286        | 0,92657        | 0,92711        | 0,92657        | 0,92679        |
| 0,7        | 56          | 1142/286        | 0,96154        | 0,96347        | 0,96154        | 0,96114        |
| 0,7        | 112         | 1142/286        | 0,96503        | 0,96496        | 0,96503        | 0,96486        |
| 0,8        | 4           | 1142/286        | 0,95804        | 0,95869        | 0,95804        | 0,95782        |
| 0,8        | 8           | 1142/286        | 0,94056        | 0,94700        | 0,94056        | 0,94166        |
| 0,8        | 16          | 1142/286        | 0,96154        | 0,96425        | 0,96154        | 0,96091        |
| 0,8        | 28          | 1142/286        | 0,95804        | 0,95786        | 0,95804        | 0,95790        |
| 0,8        | 32          | 1142/286        | 0,96154        | 0,96404        | 0,96154        | 0,96149        |
| 0,8        | 56          | 1142/286        | 0,95105        | 0,95330        | 0,95105        | 0,95050        |
| 0,8        | 112         | 1142/286        | 0,95804        | 0,96025        | 0,95804        | 0,95733        |
| 0,9        | 4           | 1142/286        | 0,95105        | 0,95411        | 0,95105        | 0,95116        |
| 0,9        | 8           | 1142/286        | 0,97203        | 0,97201        | 0,97203        | 0,97197        |
| 0,9        | 16          | 1142/286        | 0,92657        | 0,92806        | 0,92657        | 0,92585        |
| 0,9        | 28          | 1142/286        | 0,96853        | 0,96908        | 0,96853        | 0,96828        |
| 0,9        | 32          | 1142/286        | 0,94056        | 0,94528        | 0,94056        | 0,93990        |
| 0,9        | 56          | 1142/286        | 0,90909        | 0,92117        | 0,90909        | 0,91132        |
| 0,9        | 112         | 1142/286        | 0,95804        | 0,95825        | 0,95804        | 0,95808        |
| 1          | 4           | 1142/286        | 0,96154        | 0,96246        | 0,96154        | 0,96128        |
| 1          | 8           | 1142/286        | 0,96154        | 0,96163        | 0,96154        | 0,96146        |
| 1          | 16          | 1142/286        | 0,95455        | 0,95612        | 0,95455        | 0,95428        |
| 1          | 28          | 1142/286        | 0,94406        | 0,94696        | 0,94406        | 0,94393        |
| 1          | 56          | 1142/286        | 0,93706        | 0,93987        | 0,93706        | 0,93759        |
| <b>1</b>   | <b>112</b>  | <b>1142/286</b> | <b>0,97552</b> | <b>0,97601</b> | <b>0,97552</b> | <b>0,97537</b> |

Çizelge 4.22. DarkNet19 Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|---------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| CLAHE olmadan |             | 1142/286        | 0,98951        | 0,98956        | 0,98951        | 0,98952        |
| 0,1           | 4           | 1142/286        | 0,95105        | 0,95246        | 0,95105        | 0,95024        |
| 0,1           | 8           | 1142/286        | 0,93007        | 0,93342        | 0,93007        | 0,92951        |
| 0,1           | 16          | 1142/286        | 0,96503        | 0,96618        | 0,96503        | 0,96461        |
| 0,1           | 28          | 1142/286        | 0,96503        | 0,96544        | 0,96503        | 0,96470        |
| 0,1           | 32          | 1142/286        | 0,96154        | 0,96236        | 0,96154        | 0,96163        |
| <b>0,1</b>    | <b>56</b>   | <b>1142/286</b> | <b>0,97203</b> | <b>0,97209</b> | <b>0,97203</b> | <b>0,97199</b> |
| 0,1           | 112         | 1142/286        | 0,96503        | 0,96632        | 0,96503        | 0,96487        |
| <b>0,2</b>    | <b>4</b>    | <b>1142/286</b> | <b>0,97552</b> | <b>0,97593</b> | <b>0,97552</b> | <b>0,97550</b> |
| 0,2           | 8           | 1142/286        | 0,94755        | 0,95167        | 0,94755        | 0,94799        |
| 0,2           | 16          | 1142/286        | 0,96503        | 0,96567        | 0,96503        | 0,96498        |
| 0,2           | 28          | 1142/286        | 0,95105        | 0,95087        | 0,95105        | 0,95094        |
| 0,2           | 32          | 1142/286        | 0,95105        | 0,95311        | 0,95105        | 0,95026        |
| 0,2           | 56          | 1142/286        | 0,95804        | 0,95912        | 0,95804        | 0,95762        |
| 0,2           | 112         | 1142/286        | 0,96154        | 0,96161        | 0,96154        | 0,96150        |
| 0,3           | 4           | 1142/286        | 0,95804        | 0,95829        | 0,95804        | 0,95777        |
| 0,3           | 8           | 1142/286        | 0,96503        | 0,96523        | 0,96503        | 0,96484        |
| 0,3           | 16          | 1142/286        | 0,95455        | 0,95520        | 0,95455        | 0,95439        |
| 0,3           | 28          | 1142/286        | 0,95105        | 0,95330        | 0,95105        | 0,95082        |
| 0,3           | 32          | 1142/286        | 0,93357        | 0,93938        | 0,93357        | 0,93177        |
| 0,3           | 56          | 1142/286        | 0,96154        | 0,96345        | 0,96154        | 0,96099        |
| 0,3           | 112         | 1142/286        | 0,94406        | 0,94659        | 0,94406        | 0,94339        |

Çizelge 4.23. DarkNet19 Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|------------|-------------|-------------|----------|----------|------------|---------|
| 0,4        | 4           | 1142/286    | 0,94755  | 0,95018  | 0,94755    | 0,94752 |
| 0,4        | 8           | 1142/286    | 0,96853  | 0,97040  | 0,96853    | 0,96859 |
| 0,4        | 16          | 1142/286    | 0,97203  | 0,97313  | 0,97203    | 0,97192 |
| 0,4        | 28          | 1142/286    | 0,96853  | 0,96863  | 0,96853    | 0,96833 |
| 0,4        | 32          | 1142/286    | 0,95105  | 0,95253  | 0,95105    | 0,95064 |
| 0,4        | 56          | 1142/286    | 0,96154  | 0,96251  | 0,96154    | 0,96108 |
| 0,4        | 112         | 1142/286    | 0,95804  | 0,95921  | 0,95804    | 0,95783 |
| 0,5        | 4           | 1142/286    | 0,92657  | 0,93370  | 0,92657    | 0,92677 |
| 0,5        | 8           | 1142/286    | 0,95804  | 0,95821  | 0,95804    | 0,95755 |
| 0,5        | 16          | 1142/286    | 0,95105  | 0,95134  | 0,95105    | 0,95112 |
| 0,5        | 28          | 1142/286    | 0,96503  | 0,96499  | 0,96503    | 0,96479 |
| 0,5        | 32          | 1142/286    | 0,95455  | 0,95526  | 0,95455    | 0,95395 |
| 0,5        | 56          | 1142/286    | 0,91552  | 0,97633  | 0,97552    | 0,97538 |
| 0,5        | 112         | 1142/286    | 0,96853  | 0,96876  | 0,96853    | 0,96840 |
| 0,6        | 4           | 1142/286    | 0,96503  | 0,96663  | 0,96503    | 0,96459 |
| 0,6        | 8           | 1142/286    | 0,95804  | 0,96065  | 0,95804    | 0,95712 |
| 0,6        | 16          | 1142/286    | 0,95804  | 0,96185  | 0,95804    | 0,95745 |
| 0,6        | 28          | 1142/286    | 0,96503  | 0,96496  | 0,96503    | 0,96475 |
| 0,6        | 32          | 1142/286    | 0,96853  | 0,96852  | 0,96853    | 0,96839 |
| 0,6        | 56          | 1142/286    | 0,96154  | 0,96158  | 0,96154    | 0,96154 |
| 0,6        | 112         | 1142/286    | 0,95455  | 0,95528  | 0,95455    | 0,95410 |

Çizelge 4.24. DarkNet19 Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,91958        | 0,92323        | 0,91958        | 0,91944        |
| 0,7        | 8           | 1142/286        | 0,93706        | 0,93788        | 0,93706        | 0,93663        |
| 0,7        | 16          | 1142/286        | 0,97203        | 0,97310        | 0,97203        | 0,97161        |
| 0,7        | 28          | 1142/286        | 0,95455        | 0,95461        | 0,95455        | 0,95442        |
| 0,7        | 32          | 1142/286        | 0,94755        | 0,95281        | 0,94755        | 0,94676        |
| 0,7        | 56          | 1142/286        | 0,84266        | 0,85960        | 0,84266        | 0,84278        |
| 0,7        | 112         | 1142/286        | 0,95804        | 0,95846        | 0,95804        | 0,95771        |
| 0,8        | 4           | 1142/286        | 0,95105        | 0,95332        | 0,95105        | 0,94999        |
| 0,8        | 8           | 1142/286        | 0,95455        | 0,95541        | 0,95455        | 0,95379        |
| 0,8        | 16          | 1142/286        | 0,88811        | 0,89998        | 0,88811        | 0,88560        |
| 0,8        | 28          | 1142/286        | 0,94755        | 0,94754        | 0,94755        | 0,94684        |
| 0,8        | 32          | 1142/286        | 0,96154        | 0,96180        | 0,96154        | 0,96145        |
| 0,8        | 56          | 1142/286        | 0,95455        | 0,95467        | 0,95455        | 0,95425        |
| 0,8        | 112         | 1142/286        | 0,95804        | 0,95921        | 0,95804        | 0,95783        |
| 0,9        | 4           | 1142/286        | 0,93357        | 0,93493        | 0,93357        | 0,93234        |
| 0,9        | 16          | 1142/286        | 0,97203        | 0,97365        | 0,97203        | 0,97176        |
| 0,9        | 28          | 1142/286        | 0,93357        | 0,93829        | 0,93357        | 0,93387        |
| 0,9        | 32          | 1142/286        | 0,96154        | 0,96223        | 0,96154        | 0,96131        |
| 0,9        | 56          | 1142/286        | 0,96154        | 0,96192        | 0,96154        | 0,96121        |
| 0,9        | 112         | 1142/286        | 0,94406        | 0,94433        | 0,94406        | 0,94381        |
| <b>1</b>   | <b>4</b>    | <b>1142/286</b> | <b>0,97902</b> | <b>0,97956</b> | <b>0,97902</b> | <b>0,97892</b> |
| <b>1</b>   | <b>8</b>    | <b>1142/286</b> | <b>0,97902</b> | <b>0,97913</b> | <b>0,97902</b> | <b>0,97894</b> |
| 1          | 16          | 1142/286        | 0,95804        | 0,95786        | 0,95804        | 0,95783        |
| <b>1</b>   | <b>28</b>   | <b>1142/286</b> | <b>0,97902</b> | <b>0,97912</b> | <b>0,97902</b> | <b>0,97900</b> |
| 1          | 32          | 1142/286        | 0,95804        | 0,95902        | 0,95804        | 0,95754        |
| 1          | 56          | 1142/286        | 0,96853        | 0,97055        | 0,96853        | 0,96851        |
| 1          | 112         | 1142/286        | 0,96853        | 0,96932        | 0,96853        | 0,96834        |

Çizelge 4.25. DarkNet19 Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|---------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| CLAHE olmadan |             | 1142/286        | 0,97902        | 0,97906        | 0,97902        | 0,97896        |
| 0,1           | 4           | 1142/286        | 0,86014        | 0,88673        | 0,98601        | 0,85171        |
| <b>0,1</b>    | <b>8</b>    | <b>1142/286</b> | <b>0,97203</b> | <b>0,97240</b> | <b>0,97203</b> | <b>0,97199</b> |
| 0,1           | 16          | 1142/286        | 0,96154        | 0,96144        | 0,96154        | 0,96143        |
| 0,1           | 28          | 1142/286        | 0,95105        | 0,95097        | 0,95105        | 0,95094        |
| 0,1           | 32          | 1142/286        | 0,94056        | 0,94327        | 0,94056        | 0,94074        |
| 0,1           | 56          | 1142/286        | 0,91958        | 0,91995        | 0,91958        | 0,91905        |
| 0,1           | 112         | 1142/286        | 0,94755        | 0,94856        | 0,94755        | 0,94719        |
| 0,2           | 4           | 1142/286        | 0,93706        | 0,93734        | 0,93706        | 0,93708        |
| 0,2           | 8           | 1142/286        | 0,94755        | 0,94896        | 0,94755        | 0,94764        |
| 0,2           | 16          | 1142/286        | 0,93706        | 0,94000        | 0,93706        | 0,93553        |
| 0,2           | 28          | 1142/286        | 0,94406        | 0,94384        | 0,94406        | 0,94344        |
| 0,2           | 32          | 1142/286        | 0,94755        | 0,94813        | 0,94755        | 0,94706        |
| 0,2           | 56          | 1142/286        | 0,91958        | 0,92363        | 0,91958        | 0,91970        |
| 0,2           | 112         | 1142/286        | 0,94755        | 0,94888        | 0,94755        | 0,94785        |
| 0,3           | 4           | 1142/286        | 0,96154        | 0,96140        | 0,96154        | 0,96134        |
| 0,3           | 8           | 1142/286        | 0,94755        | 0,94845        | 0,94755        | 0,94739        |
| 0,3           | 16          | 1142/286        | 0,95804        | 0,95790        | 0,95804        | 0,95773        |
| 0,3           | 28          | 1142/286        | 0,95105        | 0,95096        | 0,95105        | 0,95077        |
| 0,3           | 32          | 1142/286        | 0,92308        | 0,92293        | 0,92308        | 0,92160        |
| 0,3           | 56          | 1142/286        | 0,95804        | 0,95786        | 0,95804        | 0,95790        |
| 0,3           | 112         | 1142/286        | 0,93706        | 0,93934        | 0,93706        | 0,93679        |

Çizelge 4.26. DarkNet19 Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|------------|-------------|-------------|----------|----------|------------|---------|
| 0,4        | 4           | 1142/286    | 0,94406  | 0,94406  | 0,94406    | 0,94386 |
| 0,4        | 8           | 1142/286    | 0,94755  | 0,94958  | 0,94755    | 0,94663 |
| 0,4        | 16          | 1142/286    | 0,94755  | 0,95093  | 0,94755    | 0,94798 |
| 0,4        | 28          | 1142/286    | 0,95455  | 0,95428  | 0,95455    | 0,95428 |
| 0,4        | 32          | 1142/286    | 0,74825  | 0,83643  | 0,74825    | 0,73973 |
| 0,4        | 56          | 1142/286    | 0,95455  | 0,95440  | 0,95455    | 0,95445 |
| 0,4        | 112         | 1142/286    | 0,94406  | 0,94428  | 0,94406    | 0,94361 |
| 0,5        | 4           | 1142/286    | 0,94406  | 0,94595  | 0,94406    | 0,94306 |
| 0,5        | 8           | 1142/286    | 0,95804  | 0,95820  | 0,95804    | 0,95776 |
| 0,5        | 16          | 1142/286    | 0,94406  | 0,94510  | 0,94406    | 0,94308 |
| 0,5        | 28          | 1142/286    | 0,95105  | 0,95133  | 0,95105    | 0,95107 |
| 0,5        | 32          | 1142/286    | 0,94755  | 0,94759  | 0,94755    | 0,94741 |
| 0,5        | 56          | 1142/286    | 0,94056  | 0,94030  | 0,94056    | 0,93998 |
| 0,5        | 112         | 1142/286    | 0,84266  | 0,88550  | 0,84266    | 0,84110 |
| 0,6        | 4           | 1142/286    | 0,90909  | 0,91651  | 0,90909    | 0,90874 |
| 0,6        | 8           | 1142/286    | 0,94406  | 0,94433  | 0,94406    | 0,94322 |
| 0,6        | 16          | 1142/286    | 0,95105  | 0,95237  | 0,95105    | 0,95083 |
| 0,6        | 28          | 1142/286    | 0,93357  | 0,93354  | 0,93357    | 0,93284 |
| 0,6        | 32          | 1142/286    | 0,83566  | 0,87682  | 0,83566    | 0,83407 |
| 0,6        | 56          | 1142/286    | 0,94406  | 0,94374  | 0,94406    | 0,94338 |
| 0,6        | 112         | 1142/286    | 0,94406  | 0,94496  | 0,94406    | 0,94377 |

Çizelge 4.27. DarkNet19 Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,95804        | 0,95889        | 0,95804        | 0,95748        |
| <b>0,7</b> | <b>8</b>    | <b>1142/286</b> | <b>0,96853</b> | <b>0,96849</b> | <b>0,96853</b> | <b>0,96838</b> |
| <b>0,7</b> | <b>16</b>   | <b>1142/286</b> | <b>0,96503</b> | <b>0,96499</b> | <b>0,96503</b> | <b>0,96479</b> |
| 0,7        | 28          | 1142/286        | 0,94060        | 0,94370        | 0,94060        | 0,94366        |
| 0,7        | 32          | 1142/286        | 0,93706        | 0,93650        | 0,93706        | 0,93655        |
| 0,7        | 56          | 1142/286        | 0,95455        | 0,95467        | 0,95455        | 0,95422        |
| 0,7        | 112         | 1142/286        | 0,93357        | 0,93695        | 0,93357        | 0,93413        |
| 0,8        | 4           | 1142/286        | 0,95804        | 0,95820        | 0,95804        | 0,95800        |
| 0,8        | 8           | 1142/286        | 0,95455        | 0,95688        | 0,95455        | 0,95506        |
| 0,8        | 16          | 1142/286        | 0,90909        | 0,91615        | 0,90909        | 0,90845        |
| 0,8        | 28          | 1142/286        | 0,93706        | 0,93807        | 0,93706        | 0,93644        |
| 0,8        | 32          | 1142/286        | 0,93357        | 0,93295        | 0,93357        | 0,93310        |
| 0,8        | 56          | 1142/286        | 0,95105        | 0,95141        | 0,95105        | 0,95116        |
| 0,9        | 4           | 1142/286        | 0,93357        | 0,93652        | 0,93357        | 0,93309        |
| 0,9        | 8           | 1142/286        | 0,95804        | 0,95943        | 0,95804        | 0,95807        |
| 0,9        | 16          | 1142/286        | 0,95455        | 0,95438        | 0,95455        | 0,95407        |
| 0,9        | 28          | 1142/286        | 0,93357        | 0,93391        | 0,93357        | 0,93297        |
| 0,9        | 32          | 1142/286        | 0,95455        | 0,95559        | 0,95455        | 0,95386        |
| 0,9        | 56          | 1142/286        | 0,94406        | 0,94517        | 0,94406        | 0,94347        |
| 0,9        | 112         | 1142/286        | 0,93706        | 0,94272        | 0,93706        | 0,93694        |
| 1          | 4           | 1142/286        | 0,95455        | 0,95673        | 0,95455        | 0,95488        |
| 1          | 8           | 1142/286        | 0,96154        | 0,96140        | 0,96154        | 0,96134        |
| <b>1</b>   | <b>16</b>   | <b>1142/286</b> | <b>0,96503</b> | <b>0,96490</b> | <b>0,96503</b> | <b>0,96491</b> |
| <b>1</b>   | <b>28</b>   | <b>1142/286</b> | <b>0,97203</b> | <b>0,97210</b> | <b>0,97203</b> | <b>0,97204</b> |
| 1          | 32          | 1142/286        | 0,92657        | 0,93343        | 0,92657        | 0,92714        |
| 1          | 56          | 1142/286        | 0,96503        | 0,96490        | 0,96503        | 0,96490        |
| 1          | 112         | 1142/286        | 0,96154        | 0,96143        | 0,96154        | 0,96147        |



Çizelge 4.28. MobileNet kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|---------------|-------------|-------------|----------|----------|------------|---------|
| CLAHE olmadan |             | 1142/286    | 0,84615  | 0,85249  | 0,84615    | 0,84311 |
| 0,1           | 4           | 1142/286    | 0,87063  | 0,87152  | 0,87063    | 0,86875 |
| 0,1           | 8           | 1142/286    | 0,80070  | 0,79768  | 0,80070    | 0,79847 |
| 0,1           | 16          | 1142/286    | 0,86364  | 0,86331  | 0,86364    | 0,86346 |
| 0,1           | 28          | 1142/286    | 0,88112  | 0,88061  | 0,88112    | 0,88028 |
| 0,1           | 32          | 1142/286    | 0,89860  | 0,89784  | 0,89860    | 0,89704 |
| 0,1           | 56          | 1142/286    | 0,90210  | 0,90307  | 0,90210    | 0,90157 |
| 0,1           | 112         | 1142/286    | 0,91608  | 0,91515  | 0,91608    | 0,91491 |
| 0,2           | 4           | 1142/286    | 0,86014  | 0,85790  | 0,86014    | 0,85770 |
| 0,2           | 8           | 1142/286    | 0,88462  | 0,88498  | 0,88462    | 0,88271 |
| 0,2           | 16          | 1142/286    | 0,88112  | 0,88056  | 0,88112    | 0,88054 |
| 0,2           | 28          | 1142/286    | 0,86014  | 0,86595  | 0,98601    | 0,85865 |
| 0,2           | 32          | 1142/286    | 0,91608  | 0,91677  | 0,91607    | 0,91628 |
| 0,2           | 56          | 1142/286    | 0,89860  | 0,90335  | 0,89860    | 0,89648 |
| 0,2           | 112         | 1142/286    | 0,92308  | 0,92370  | 0,92308    | 0,92223 |
| 0,3           | 4           | 1142/286    | 0,86364  | 0,86280  | 0,86364    | 0,86218 |
| 0,3           | 8           | 1142/286    | 0,88462  | 0,88639  | 0,88462    | 0,88450 |
| 0,3           | 16          | 1142/286    | 0,90909  | 0,90914  | 0,90909    | 0,90850 |
| 0,3           | 28          | 1142/286    | 0,91259  | 0,91192  | 0,91259    | 0,91173 |
| 0,3           | 32          | 1142/286    | 0,92308  | 0,92274  | 0,92308    | 0,92241 |
| 0,3           | 56          | 1142/286    | 0,91958  | 0,92047  | 0,91958    | 0,91988 |
| 0,3           | 112         | 1142/286    | 0,91608  | 0,91572  | 0,91608    | 0,91584 |

Çizelge 4.29. MobileNet kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,4        | 4           | 1142/286        | 0,86014        | 0,85862        | 0,86014        | 0,85905        |
| 0,4        | 8           | 1142/286        | 0,89161        | 0,89131        | 0,89161        | 0,89127        |
| 0,4        | 16          | 1142/286        | 0,90559        | 0,90479        | 0,90559        | 0,90498        |
| <b>0,4</b> | <b>28</b>   | <b>1142/286</b> | <b>0,94755</b> | <b>0,94808</b> | <b>0,94755</b> | <b>0,94664</b> |
| 0,4        | 32          | 1142/286        | 0,91958        | 0,91905        | 0,91958        | 0,91919        |
| 0,4        | 56          | 1142/286        | 0,93357        | 0,93317        | 0,93357        | 0,93315        |
| 0,4        | 112         | 1142/286        | 0,92308        | 0,92552        | 0,92308        | 0,92182        |
| 0,5        | 4           | 1142/286        | 0,88462        | 0,88566        | 0,88462        | 0,88472        |
| 0,5        | 8           | 1142/286        | 0,89161        | 0,89449        | 0,89161        | 0,89061        |
| 0,5        | 16          | 1142/286        | 0,92308        | 0,92330        | 0,92308        | 0,92205        |
| <b>0,5</b> | <b>28</b>   | <b>1142/286</b> | <b>0,95455</b> | <b>0,95432</b> | <b>0,95455</b> | <b>0,95431</b> |
| 0,5        | 32          | 1142/286        | 0,93706        | 0,93681        | 0,93706        | 0,93681        |
| 0,5        | 56          | 1142/286        | 0,91958        | 0,91886        | 0,91958        | 0,91888        |
| 0,5        | 112         | 1142/286        | 0,93706        | 0,93693        | 0,93706        | 0,93693        |
| 0,6        | 4           | 1142/286        | 0,89161        | 0,89048        | 0,89161        | 0,89070        |
| 0,6        | 8           | 1142/286        | 0,91958        | 0,91953        | 0,91958        | 0,91934        |
| 0,6        | 16          | 1142/286        | 0,92657        | 0,92590        | 0,92657        | 0,92560        |
| <b>0,6</b> | <b>28</b>   | <b>1142/286</b> | <b>0,95455</b> | <b>0,95438</b> | <b>0,95455</b> | <b>0,95407</b> |
| 0,6        | 32          | 1142/286        | 0,94406        | 0,94409        | 0,94406        | 0,94379        |
| 0,6        | 56          | 1142/286        | 0,91259        | 0,91343        | 0,91259        | 0,91254        |
| 0,6        | 112         | 1142/286        | 0,91608        | 0,91559        | 0,91608        | 0,91578        |

Çizelge 4.30. MobileNet kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,89161        | 0,89092        | 0,89161        | 0,89099        |
| 0,7        | 8           | 1142/286        | 0,90210        | 0,90416        | 0,90210        | 0,90268        |
| 0,7        | 16          | 1142/286        | 0,93706        | 0,93740        | 0,93706        | 0,93680        |
| 0,7        | 28          | 1142/286        | 0,93706        | 0,93654        | 0,93706        | 0,93624        |
| <b>0,7</b> | <b>32</b>   | <b>1142/286</b> | <b>0,95455</b> | <b>0,95467</b> | <b>0,95455</b> | <b>0,95456</b> |
| 0,7        | 56          | 1142/286        | 0,93357        | 0,93369        | 0,93357        | 0,93325        |
| 0,7        | 112         | 1142/286        | 0,92657        | 0,92768        | 0,92657        | 0,92540        |
| 0,8        | 4           | 1142/286        | 0,85664        | 0,87458        | 0,85664        | 0,86020        |
| 0,8        | 8           | 1142/286        | 0,94755        | 0,94742        | 0,94755        | 0,94736        |
| 0,8        | 16          | 1142/286        | 0,94406        | 0,94428        | 0,94406        | 0,94361        |
| 0,8        | 28          | 1142/286        | 0,94755        | 0,94800        | 0,94755        | 0,94684        |
| 0,8        | 32          | 1142/286        | 0,94755        | 0,94819        | 0,94755        | 0,94734        |
| 0,8        | 56          | 1142/286        | 0,91259        | 0,91184        | 0,91259        | 0,91193        |
| 0,8        | 112         | 1142/286        | 0,92657        | 0,92630        | 0,92657        | 0,92621        |
| 0,9        | 4           | 1142/286        | 0,88462        | 0,88291        | 0,88462        | 0,88294        |
| <b>0,9</b> | <b>8</b>    | <b>1142/286</b> | <b>0,95455</b> | <b>0,95438</b> | <b>0,95455</b> | <b>0,95411</b> |
| 0,9        | 16          | 1142/286        | 0,93706        | 0,93650        | 0,93706        | 0,93655        |
| 0,9        | 28          | 1142/286        | 0,94056        | 0,94008        | 0,94056        | 0,93987        |
| 0,9        | 32          | 1142/286        | 0,94755        | 0,94917        | 0,94755        | 0,94691        |
| 0,9        | 56          | 1142/286        | 0,93357        | 0,93417        | 0,93357        | 0,93375        |
| 0,9        | 112         | 1142/286        | 0,93706        | 0,93811        | 0,93706        | 0,93635        |
| 1          | 16          | 1142/286        | 0,81469        | 0,81456        | 0,81469        | 0,81248        |
| 1          | 28          | 1142/286        | 0,86014        | 0,85810        | 0,86014        | 0,85836        |
| 1          | 32          | 1142/286        | 0,84615        | 0,85265        | 0,84615        | 0,84768        |
| 1          | 56          | 1142/286        | 0,88811        | 0,88747        | 0,88811        | 0,88749        |
| 1          | 112         | 1142/286        | 0,86713        | 0,87106        | 0,86713        | 0,86806        |

Çizelge 4.31. MobileNet Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|---------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| CLAHE olmadan |             | 1142/286        | 0,92308        | 0,92611        | 0,92308        | 0,92231        |
| 0,1           | 4           | 1142/286        | 0,85315        | 0,81192        | 0,85215        | 0,85207        |
| 0,1           | 8           | 1142/286        | 0,78671        | 0,78744        | 0,78671        | 0,78277        |
| 0,1           | 16          | 1142/286        | 0,79371        | 0,80091        | 0,79371        | 0,79623        |
| 0,1           | 28          | 1142/286        | 0,86364        | 0,86266        | 0,86364        | 0,86294        |
| 0,1           | 32          | 1142/286        | 0,83566        | 0,83845        | 0,83566        | 0,83678        |
| 0,1           | 56          | 1142/286        | 0,83916        | 0,83854        | 0,83916        | 0,83552        |
| 0,1           | 112         | 1142/286        | 0,86364        | 0,86446        | 0,86364        | 0,86400        |
| 0,2           | 4           | 1142/286        | 0,93357        | 0,93582        | 0,93357        | 0,93406        |
| <b>0,2</b>    | <b>8</b>    | <b>1142/286</b> | <b>0,96503</b> | <b>0,96521</b> | <b>0,96503</b> | <b>0,96510</b> |
| 0,2           | 16          | 1142/286        | 0,89161        | 0,89482        | 0,89161        | 0,89194        |
| 0,2           | 28          | 1142/286        | 0,87762        | 0,87764        | 0,87762        | 0,87696        |
| 0,2           | 32          | 1142/286        | 0,87413        | 0,87986        | 0,87413        | 0,87046        |
| 0,2           | 56          | 1142/286        | 0,89161        | 0,89077        | 0,89161        | 0,89086        |
| 0,2           | 112         | 1142/286        | 0,90559        | 0,90591        | 0,90559        | 0,90570        |
| 0,3           | 4           | 1142/286        | 0,81469        | 0,81719        | 0,81469        | 0,81518        |
| 0,3           | 8           | 1142/286        | 0,87413        | 0,87723        | 0,87413        | 0,87266        |
| 0,3           | 16          | 1142/286        | 0,90559        | 0,90945        | 0,90559        | 0,90378        |
| 0,3           | 28          | 1142/286        | 0,90559        | 0,90782        | 0,90559        | 0,90466        |
| 0,3           | 32          | 1142/286        | 0,88811        | 0,88733        | 0,88811        | 0,88736        |
| 0,3           | 56          | 1142/286        | 0,90909        | 0,90834        | 0,90909        | 0,90859        |
| 0,3           | 112         | 1142/286        | 0,87413        | 0,87321        | 0,87413        | 0,87347        |

Çizelge 4.32. MobileNet Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,4        | 4           | 1142/286        | 0,84266        | 0,84424        | 0,84266        | 0,84129        |
| 0,4        | 8           | 1142/286        | 0,86364        | 0,86714        | 0,86364        | 0,86035        |
| 0,4        | 16          | 1142/286        | 0,91608        | 0,91603        | 0,91608        | 0,91572        |
| 0,4        | 28          | 1142/286        | 0,89860        | 0,90214        | 0,89860        | 0,89708        |
| 0,4        | 32          | 1142/286        | 0,92308        | 0,92471        | 0,92308        | 0,92267        |
| 0,4        | 56          | 1142/286        | 0,91958        | 0,92033        | 0,91958        | 0,91912        |
| 0,4        | 112         | 1142/286        | 0,87413        | 0,88364        | 0,87413        | 0,87398        |
| 0,5        | 4           | 1142/286        | 0,84615        | 0,84823        | 0,84615        | 0,84340        |
| 0,5        | 8           | 1142/286        | 0,89860        | 0,89974        | 0,89860        | 0,89778        |
| 0,5        | 16          | 1142/286        | 0,93007        | 0,93064        | 0,93007        | 0,92957        |
| 0,5        | 28          | 1142/286        | 0,90559        | 0,90668        | 0,90559        | 0,90470        |
| 0,5        | 32          | 1142/286        | 0,90909        | 0,90884        | 0,90909        | 0,90853        |
| 0,5        | 56          | 1142/286        | 0,90909        | 0,91151        | 0,90909        | 0,90877        |
| 0,5        | 112         | 1142/286        | 0,90909        | 0,91062        | 0,90909        | 0,90892        |
| 0,6        | 4           | 1142/286        | 0,83916        | 0,83745        | 0,83916        | 0,83544        |
| 0,6        | 8           | 1142/286        | 0,88112        | 0,88533        | 0,88112        | 0,87839        |
| 0,6        | 16          | 1142/286        | 0,91608        | 0,91613        | 0,91608        | 0,91606        |
| 0,6        | 28          | 1142/286        | 0,93007        | 0,93025        | 0,93007        | 0,93011        |
| <b>0,6</b> | <b>32</b>   | <b>1142/286</b> | <b>0,94406</b> | <b>0,94479</b> | <b>0,94406</b> | <b>0,94426</b> |
| 0,6        | 56          | 1142/286        | 0,90909        | 0,92539        | 0,90909        | 0,90794        |
| 0,6        | 112         | 1142/286        | 0,91608        | 0,91879        | 0,91608        | 0,91571        |

Çizelge 4.33. MobileNet Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,85664        | 0,85581        | 0,85664        | 0,85519        |
| 0,7        | 8           | 1142/286        | 0,89510        | 0,89448        | 0,89510        | 0,89432        |
| 0,7        | 16          | 1142/286        | 0,91958        | 0,91930        | 0,91958        | 0,91906        |
| 0,7        | 28          | 1142/286        | 0,93007        | 0,93088        | 0,93007        | 0,92955        |
| 0,7        | 32          | 1142/286        | 0,93706        | 0,93711        | 0,93706        | 0,93677        |
| 0,7        | 56          | 1142/286        | 0,93007        | 0,93418        | 0,93007        | 0,93018        |
| 0,7        | 112         | 1142/286        | 0,93357        | 0,93467        | 0,93357        | 0,93316        |
| 0,8        | 4           | 1142/286        | 0,87413        | 0,87788        | 0,87413        | 0,87180        |
| 0,8        | 8           | 1142/286        | 0,89510        | 0,89614        | 0,89510        | 0,89435        |
| 0,8        | 16          | 1142/286        | 0,92308        | 0,92296        | 0,92308        | 0,92255        |
| 0,8        | 28          | 1142/286        | 0,92657        | 0,92690        | 0,92657        | 0,92584        |
| 0,8        | 32          | 1142/286        | 0,93357        | 0,93385        | 0,93357        | 0,93333        |
| <b>0,8</b> | <b>56</b>   | <b>1142/286</b> | <b>0,94406</b> | <b>0,94440</b> | <b>0,94406</b> | <b>0,94370</b> |
| 0,8        | 112         | 1142/286        | 0,91259        | 0,91603        | 0,91259        | 0,91275        |
| 0,9        | 4           | 1142/286        | 0,88112        | 0,88330        | 0,88112        | 0,87959        |
| 0,9        | 8           | 1142/286        | 0,90210        | 0,90198        | 0,90210        | 0,90199        |
| 0,9        | 16          | 1142/286        | 0,93706        | 0,93869        | 0,93706        | 0,93659        |
| 0,9        | 28          | 1142/286        | 0,93706        | 0,93948        | 0,93706        | 0,93670        |
| 0,9        | 32          | 1142/286        | 0,92657        | 0,92649        | 0,92657        | 0,92617        |
| <b>0,9</b> | <b>56</b>   | <b>1142/286</b> | <b>0,94056</b> | <b>0,94219</b> | <b>0,94056</b> | <b>0,93957</b> |
| 0,9        | 112         | 1142/286        | 0,90909        | 0,91018        | 0,90909        | 0,90837        |
| 1          | 8           | 1142/286        | 0,90210        | 0,90360        | 0,90210        | 0,90202        |
| 1          | 16          | 1142/286        | 0,92308        | 0,92609        | 0,92308        | 0,92163        |
| <b>1</b>   | <b>28</b>   | <b>1142/286</b> | <b>0,93007</b> | <b>0,93175</b> | <b>0,93007</b> | <b>0,92937</b> |
| 1          | 32          | 1142/286        | 0,94056        | 0,94077        | 0,94056        | 0,94028        |
| 1          | 56          | 1142/286        | 0,92308        | 0,92387        | 0,92308        | 0,92174        |
| 1          | 112         | 1142/286        | 0,94056        | 0,94211        | 0,94056        | 0,93988        |

Çizelge 4.34. MobileNet Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|---------------|-------------|-------------|----------|----------|------------|---------|
| CLAHE olmadan |             | 1142/286    | 0,93357  | 0,93531  | 0,93357    | 0,93365 |
| 0,1           | 4           | 1142/286    | 0,80070  | 0,81554  | 0,80070    | 0,79905 |
| 0,1           | 8           | 1142/286    | 0,76573  | 0,76321  | 0,76573    | 0,76420 |
| 0,1           | 16          | 1142/286    | 0,85664  | 0,85805  | 0,85664    | 0,85600 |
| 0,1           | 28          | 1142/286    | 0,87413  | 0,87376  | 0,87413    | 0,87162 |
| 0,1           | 32          | 1142/286    | 0,88462  | 0,88656  | 0,88462    | 0,88187 |
| 0,1           | 56          | 1142/286    | 0,88112  | 0,98801  | 0,88112    | 0,87997 |
| 0,1           | 112         | 1142/286    | 0,90559  | 0,90534  | 0,90559    | 0,90533 |
| 0,2           | 4           | 1142/286    | 0,81818  | 0,81986  | 0,81818    | 0,81820 |
| 0,2           | 8           | 1142/286    | 0,82867  | 0,82916  | 0,82867    | 0,82864 |
| 0,2           | 16          | 1142/286    | 0,88462  | 0,88558  | 0,88462    | 0,88413 |
| 0,2           | 28          | 1142/286    | 0,91608  | 0,91700  | 0,91608    | 0,91520 |
| 0,2           | 32          | 1142/286    | 0,89860  | 0,89768  | 0,89860    | 0,89696 |
| 0,2           | 56          | 1142/286    | 0,88811  | 0,88800  | 0,88811    | 0,88596 |
| 0,2           | 112         | 1142/286    | 0,90210  | 0,90155  | 0,90210    | 0,90086 |
| 0,3           | 4           | 1142/286    | 0,82517  | 0,82550  | 0,82517    | 0,82492 |
| 0,3           | 8           | 1142/286    | 0,87413  | 0,87382  | 0,87413    | 0,87376 |
| 0,3           | 16          | 1142/286    | 0,90909  | 0,91019  | 0,90909    | 0,90929 |
| 0,3           | 28          | 1142/286    | 0,90909  | 0,90937  | 0,90909    | 0,90770 |
| 0,3           | 32          | 1142/286    | 0,89510  | 0,89736  | 0,89510    | 0,89251 |
| 0,3           | 56          | 1142/286    | 0,89510  | 0,89531  | 0,89510    | 0,89381 |
| 0,3           | 112         | 1142/286    | 0,92657  | 0,92619  | 0,92657    | 0,92633 |

Çizelge 4.35. MobileNet Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|------------|-------------|-------------|----------|----------|------------|---------|
| 0,4        | 4           | 1142/286    | 0,83217  | 0,83564  | 0,83217    | 0,83290 |
| 0,4        | 8           | 1142/286    | 0,86014  | 0,85978  | 0,86014    | 0,85966 |
| 0,4        | 16          | 1142/286    | 0,91608  | 0,91603  | 0,91608    | 0,91594 |
| 0,4        | 28          | 1142/286    | 0,90210  | 0,90389  | 0,90210    | 0,90101 |
| 0,4        | 32          | 1142/286    | 0,89860  | 0,89887  | 0,89860    | 0,89777 |
| 0,4        | 56          | 1142/286    | 0,91259  | 0,91200  | 0,91259    | 0,91186 |
| 0,4        | 112         | 1142/286    | 0,93007  | 0,93378  | 0,93007    | 0,93039 |
| 0,5        | 4           | 1142/286    | 0,82867  | 0,83021  | 0,82867    | 0,82813 |
| 0,5        | 8           | 1142/286    | 0,86713  | 0,86861  | 0,86713    | 0,86747 |
| 0,5        | 16          | 1142/286    | 0,90559  | 0,90499  | 0,90559    | 0,90467 |
| 0,5        | 28          | 1142/286    | 0,90559  | 0,90473  | 0,90559    | 0,90456 |
| 0,5        | 32          | 1142/286    | 0,88811  | 0,88788  | 0,88811    | 0,88683 |
| 0,5        | 56          | 1142/286    | 0,92308  | 0,92324  | 0,92308    | 0,92235 |
| 0,5        | 112         | 1142/286    | 0,89860  | 0,89888  | 0,89860    | 0,89705 |
| 0,6        | 4           | 1142/286    | 0,84266  | 0,84763  | 0,98426    | 0,84203 |
| 0,6        | 8           | 1142/286    | 0,88462  | 0,88509  | 0,88462    | 0,88285 |
| 0,6        | 16          | 1142/286    | 0,91259  | 0,91205  | 0,91259    | 0,91169 |
| 0,6        | 28          | 1142/286    | 0,91259  | 0,91315  | 0,91259    | 0,91189 |
| 0,6        | 32          | 1142/286    | 0,92308  | 0,92392  | 0,92308    | 0,92271 |
| 0,6        | 56          | 1142/286    | 0,90909  | 0,90937  | 0,90909    | 0,90921 |
| 0,6        | 112         | 1142/286    | 0,90559  | 0,90534  | 0,90559    | 0,90498 |



Çizelge 4.36. MobileNet Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,83217        | 0,84094        | 0,83217        | 0,83277        |
| 0,7        | 8           | 1142/286        | 0,89161        | 0,89108        | 0,89161        | 0,89087        |
| 0,7        | 16          | 1142/286        | 0,92657        | 0,92600        | 0,92657        | 0,92601        |
| 0,7        | 28          | 1142/286        | 0,91607        | 0,91682        | 0,91607        | 0,91465        |
| 0,7        | 32          | 1142/286        | 0,91958        | 0,91929        | 0,91958        | 0,91897        |
| 0,7        | 56          | 1142/286        | 0,91608        | 0,91578        | 0,91608        | 0,91516        |
| 0,7        | 112         | 1142/286        | 0,91958        | 0,91888        | 0,91958        | 0,91887        |
| 0,8        | 4           | 1142/286        | 0,86713        | 0,87199        | 0,86713        | 0,86798        |
| 0,8        | 8           | 1142/286        | 0,87762        | 0,87961        | 0,87762        | 0,87675        |
| 0,8        | 16          | 1142/286        | 0,93357        | 0,93295        | 0,93357        | 0,93288        |
| 0,8        | 28          | 1142/286        | 0,91608        | 0,91613        | 0,91608        | 0,91590        |
| 0,8        | 32          | 1142/286        | 0,91259        | 0,91209        | 0,91259        | 0,91198        |
| 0,8        | 56          | 1142/286        | 0,93357        | 0,93465        | 0,93357        | 0,93324        |
| 0,8        | 112         | 1142/286        | 0,94406        | 0,94373        | 0,94406        | 0,94377        |
| 0,9        | 4           | 1142/286        | 0,83217        | 0,84591        | 0,83217        | 0,83141        |
| 0,9        | 8           | 1142/286        | 0,89510        | 0,89568        | 0,89510        | 0,89364        |
| 0,9        | 16          | 1142/286        | 0,94056        | 0,94042        | 0,94056        | 0,93984        |
| 0,9        | 28          | 1142/286        | 0,90559        | 0,90517        | 0,90559        | 0,90398        |
| 0,9        | 32          | 1142/286        | 0,92308        | 0,92350        | 0,92308        | 0,92215        |
| 0,9        | 56          | 1142/286        | 0,92308        | 0,92284        | 0,92308        | 0,92281        |
| 1          | 4           | 1142/286        | 0,93357        | 0,93348        | 0,93357        | 0,93337        |
| 1          | 8           | 1142/286        | 0,93706        | 0,93817        | 0,93706        | 0,93725        |
| <b>1</b>   | <b>16</b>   | <b>1142/286</b> | <b>0,95455</b> | <b>0,95505</b> | <b>0,95455</b> | <b>0,95447</b> |
| <b>1</b>   | <b>28</b>   | <b>1142/286</b> | <b>0,95105</b> | <b>0,95163</b> | <b>0,95105</b> | <b>0,95061</b> |
| <b>1</b>   | <b>32</b>   | <b>1142/286</b> | <b>0,95804</b> | <b>0,95814</b> | <b>0,95804</b> | <b>0,95786</b> |
| <b>1</b>   | <b>56</b>   | <b>1142/286</b> | <b>0,94755</b> | <b>0,95016</b> | <b>0,94755</b> | <b>0,94699</b> |
| <b>1</b>   | <b>112</b>  | <b>1142/286</b> | <b>0,96154</b> | <b>0,96164</b> | <b>0,96154</b> | <b>0,96154</b> |

Çizelge 4.37. VGG16 kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|---------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| CLAHE olmadan |             | 1142/286        | 0,94406        | 0,94449        | 0,94406        | 0,94353        |
| <b>0,1</b>    | <b>4</b>    | <b>1142/286</b> | <b>0,97552</b> | <b>0,97557</b> | <b>0,97552</b> | <b>0,97542</b> |
| 0,1           | 8           | 1142/286        | 0,96503        | 0,96588        | 0,96503        | 0,96451        |
| 0,1           | 16          | 1142/286        | 0,95804        | 0,95932        | 0,95804        | 0,95748        |
| <b>0,1</b>    | <b>28</b>   | <b>1142/286</b> | <b>0,97203</b> | <b>0,97222</b> | <b>0,97203</b> | <b>0,97188</b> |
| 0,1           | 32          | 1142/286        | 0,95455        | 0,95815        | 0,95455        | 0,95415        |
| 0,1           | 56          | 1142/286        | 0,95455        | 0,95529        | 0,95455        | 0,95420        |
| 0,1           | 112         | 1142/286        | 0,95455        | 0,95544        | 0,95455        | 0,95405        |
| 0,2           | 4           | 1142/286        | 0,95804        | 0,95872        | 0,95804        | 0,95743        |
| <b>0,2</b>    | <b>8</b>    | <b>1142/286</b> | <b>0,97203</b> | <b>0,97334</b> | <b>0,97203</b> | <b>0,97167</b> |
| 0,2           | 16          | 1142/286        | 0,96853        | 0,96856        | 0,96853        | 0,96849        |
| 0,2           | 28          | 1142/286        | 0,96154        | 0,96147        | 0,96154        | 0,96137        |
| 0,2           | 32          | 1142/286        | 0,95804        | 0,95878        | 0,95804        | 0,95746        |
| <b>0,2</b>    | <b>56</b>   | <b>1142/286</b> | <b>0,97203</b> | <b>0,97248</b> | <b>0,97203</b> | <b>0,97196</b> |
| 0,2           | 112         | 1142/286        | 0,95105        | 0,95151        | 0,95105        | 0,95071        |
| 0,3           | 4           | 1142/286        | 0,94056        | 0,94063        | 0,94056        | 0,94012        |
| <b>0,3</b>    | <b>8</b>    | <b>1142/286</b> | <b>0,97203</b> | <b>0,97313</b> | <b>0,97203</b> | <b>0,97192</b> |
| 0,3           | 16          | 1142/286        | 0,95105        | 0,95119        | 0,95105        | 0,95060        |
| 0,3           | 28          | 1142/286        | 0,95804        | 0,95790        | 0,95804        | 0,95790        |
| 0,3           | 32          | 1142/286        | 0,95455        | 0,95470        | 0,95455        | 0,95438        |
| 0,3           | 56          | 1142/286        | 0,96853        | 0,96858        | 0,96853        | 0,96839        |
| 0,3           | 112         | 1142/286        | 0,94056        | 0,94049        | 0,94056        | 0,93984        |

Çizelge 4.38. VGG16 kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|------------|-------------|-------------|----------|----------|------------|---------|
| 0,4        | 4           | 1142/286    | 0,95804  | 0,96039  | 0,95804    | 0,95738 |
| 0,4        | 8           | 1142/286    | 0,97203  | 0,97279  | 0,97203    | 0,97182 |
| 0,4        | 16          | 1142/286    | 0,94056  | 0,94011  | 0,94056    | 0,94026 |
| 0,4        | 28          | 1142/286    | 0,95804  | 0,95901  | 0,95804    | 0,95788 |
| 0,4        | 32          | 1142/286    | 0,94056  | 0,94219  | 0,94056    | 0,94024 |
| 0,4        | 56          | 1142/286    | 0,95804  | 0,96023  | 0,95804    | 0,95777 |
| 0,4        | 112         | 1142/286    | 0,95804  | 0,96066  | 0,95804    | 0,95746 |
| 0,5        | 4           | 1142/286    | 0,96853  | 0,96874  | 0,96853    | 0,96827 |
| 0,5        | 8           | 1142/286    | 0,92657  | 0,92969  | 0,92657    | 0,92725 |
| 0,5        | 16          | 1142/286    | 0,95804  | 0,95939  | 0,95804    | 0,95766 |
| 0,5        | 28          | 1142/286    | 0,95455  | 0,95433  | 0,95455    | 0,95442 |
| 0,5        | 32          | 1142/286    | 0,95455  | 0,95678  | 0,95455    | 0,95407 |
| 0,5        | 56          | 1142/286    | 0,96503  | 0,96632  | 0,96503    | 0,96487 |
| 0,5        | 112         | 1142/286    | 0,94406  | 0,94406  | 0,94406    | 0,94354 |
| 0,6        | 4           | 1142/286    | 0,96154  | 0,96136  | 0,96154    | 0,96143 |
| 0,6        | 8           | 1142/286    | 0,95804  | 0,96049  | 0,95804    | 0,95779 |
| 0,6        | 16          | 1142/286    | 0,93007  | 0,93022  | 0,93007    | 0,92960 |
| 0,6        | 28          | 1142/286    | 0,94755  | 0,94769  | 0,94755    | 0,94747 |
| 0,6        | 32          | 1142/286    | 0,95105  | 0,95103  | 0,95105    | 0,95080 |
| 0,6        | 56          | 1142/286    | 0,96154  | 0,96176  | 0,96154    | 0,96141 |
| 0,6        | 112         | 1142/286    | 0,96154  | 0,96192  | 0,96154    | 0,96121 |

Çizelge 4.39. VGG16 kırılmamış CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|------------|-------------|-------------|----------|----------|------------|---------|
| 0,7        | 4           | 1142/286    | 0,95804  | 0,95902  | 0,95804    | 0,95754 |
| 0,7        | 8           | 1142/286    | 0,94755  | 0,94737  | 0,94755    | 0,94722 |
| 0,7        | 16          | 1142/286    | 0,95455  | 0,95425  | 0,95455    | 0,95427 |
| 0,7        | 28          | 1142/286    | 0,95105  | 0,95068  | 0,95105    | 0,95079 |
| 0,7        | 32          | 1142/286    | 0,92657  | 0,92971  | 0,92657    | 0,92661 |
| 0,7        | 56          | 1142/286    | 0,95105  | 0,95173  | 0,95105    | 0,95066 |
| 0,7        | 112         | 1142/286    | 0,95804  | 0,95865  | 0,95804    | 0,95763 |
| 0,8        | 4           | 1142/286    | 0,91608  | 0,92765  | 0,91608    | 0,91561 |
| 0,8        | 8           | 1142/286    | 0,96853  | 0,96893  | 0,96853    | 0,96833 |
| 0,8        | 16          | 1142/286    | 0,95105  | 0,95225  | 0,95105    | 0,95091 |
| 0,8        | 28          | 1142/286    | 0,94755  | 0,94858  | 0,94755    | 0,94764 |
| 0,8        | 32          | 1142/286    | 0,93706  | 0,93673  | 0,93706    | 0,93684 |
| 0,8        | 56          | 1142/286    | 0,95804  | 0,95887  | 0,95804    | 0,95772 |
| 0,8        | 112         | 1142/286    | 0,96154  | 0,96192  | 0,96154    | 0,96121 |
| 0,9        | 4           | 1142/286    | 0,96154  | 0,96163  | 0,96154    | 0,96153 |
| 0,9        | 8           | 1142/286    | 0,95455  | 0,95432  | 0,95455    | 0,95431 |
| 0,9        | 16          | 1142/286    | 0,94056  | 0,94031  | 0,94056    | 0,94031 |
| 0,9        | 28          | 1142/286    | 0,94755  | 0,94719  | 0,94755    | 0,94732 |
| 0,9        | 32          | 1142/286    | 0,94056  | 0,94061  | 0,94056    | 0,94021 |
| 0,9        | 56          | 1142/286    | 0,94056  | 0,94708  | 0,94056    | 0,93950 |
| 0,9        | 112         | 1142/286    | 0,96853  | 0,96852  | 0,96853    | 0,96839 |
| 1          | 16          | 1142/286    | 0,95455  | 0,95476  | 0,95455    | 0,95414 |
| 1          | 28          | 1142/286    | 0,93007  | 0,93220  | 0,93007    | 0,92970 |
| 1          | 32          | 1142/286    | 0,96503  | 0,96524  | 0,96503    | 0,96477 |
| 1          | 56          | 1142/286    | 0,93706  | 0,94249  | 0,93706    | 0,93628 |
| 1          | 112         | 1142/286    | 0,95455  | 0,95447  | 0,95455    | 0,95428 |

Çizelge 4.40. VGG16 Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|---------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| CLAHE olmadan |             | 1142/286        | 0,95455        | 0,95728        | 0,95455        | 0,95446        |
| 0,1           | 4           | 1142/286        | 0,95105        | 0,95082        | 0,95105        | 0,95080        |
| 0,1           | 8           | 1142/286        | 0,96503        | 0,96544        | 0,96503        | 0,96470        |
| <b>0,1</b>    | <b>16</b>   | <b>1142/286</b> | <b>0,97203</b> | <b>0,97222</b> | <b>0,97203</b> | <b>0,97188</b> |
| 0,1           | 28          | 1142/286        | 0,96154        | 0,96195        | 0,96154        | 0,96103        |
| 0,1           | 32          | 1142/286        | 0,96503        | 0,96583        | 0,96503        | 0,96471        |
| 0,1           | 56          | 1142/286        | 0,94056        | 0,94010        | 0,94056        | 0,94009        |
| 0,1           | 112         | 1142/286        | 0,93706        | 0,93713        | 0,93706        | 0,93641        |
| 0,2           | 4           | 1142/286        | 0,95105        | 0,95143        | 0,95105        | 0,95032        |
| 0,2           | 8           | 1142/286        | 0,91608        | 0,92256        | 0,91608        | 0,91259        |
| 0,2           | 16          | 1142/286        | 0,96503        | 0,96527        | 0,96503        | 0,96476        |
| 0,2           | 28          | 1142/286        | 0,95455        | 0,95516        | 0,95455        | 0,95414        |
| 0,2           | 32          | 1142/286        | 0,93357        | 0,93313        | 0,93357        | 0,93266        |
| 0,2           | 56          | 1142/286        | 0,94755        | 0,94776        | 0,94755        | 0,94713        |
| 0,2           | 112         | 1142/286        | 0,95105        | 0,95076        | 0,95105        | 0,95084        |
| <b>0,3</b>    | <b>4</b>    | <b>1142/286</b> | <b>0,96853</b> | <b>0,96849</b> | <b>0,96853</b> | <b>0,96845</b> |
| 0,3           | 8           | 1142/286        | 0,94406        | 0,94378        | 0,94406        | 0,94386        |
| 0,3           | 16          | 1142/286        | 0,94406        | 0,94431        | 0,94406        | 0,94348        |
| 0,3           | 28          | 1142/286        | 0,94755        | 0,94746        | 0,94755        | 0,94711        |
| 0,3           | 32          | 1142/286        | 0,95455        | 0,95475        | 0,95455        | 0,95394        |
| 0,3           | 56          | 1142/286        | 0,95455        | 0,95619        | 0,95455        | 0,95388        |
| 0,3           | 112         | 1142/286        | 0,94056        | 0,94708        | 0,94056        | 0,93950        |

Çizelge 4.41. VGG16 Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,4        | 4           | 1142/286        | 0,92657        | 0,92749        | 0,92657        | 0,92582        |
| 0,4        | 8           | 1142/286        | 0,95455        | 0,95477        | 0,95455        | 0,95461        |
| 0,4        | 16          | 1142/286        | 0,93007        | 0,93388        | 0,93007        | 0,93045        |
| 0,4        | 28          | 1142/286        | 0,95804        | 0,95902        | 0,95804        | 0,95754        |
| 0,4        | 32          | 1142/286        | 0,95455        | 0,95526        | 0,95455        | 0,95395        |
| 0,4        | 56          | 1142/286        | 0,94056        | 0,94277        | 0,94056        | 0,93950        |
| 0,4        | 112         | 1142/286        | 0,94406        | 0,94544        | 0,94406        | 0,94329        |
| 0,5        | 4           | 1142/286        | 0,95804        | 0,95819        | 0,95804        | 0,95800        |
| 0,5        | 8           | 1142/286        | 0,95455        | 0,95438        | 0,95455        | 0,95411        |
| 0,5        | 16          | 1142/286        | 0,93706        | 0,93936        | 0,93706        | 0,93631        |
| 0,5        | 28          | 1142/286        | 0,95105        | 0,95152        | 0,95105        | 0,95035        |
| 0,5        | 32          | 1142/286        | 0,96154        | 0,96188        | 0,96154        | 0,96117        |
| 0,5        | 56          | 1142/286        | 0,94406        | 0,94522        | 0,94406        | 0,94342        |
| 0,5        | 112         | 1142/286        | 0,93706        | 0,93692        | 0,93706        | 0,93635        |
| 0,6        | 4           | 1142/286        | 0,96503        | 0,96565        | 0,96503        | 0,96522        |
| <b>0,6</b> | <b>8</b>    | <b>1142/286</b> | <b>0,96598</b> | <b>0,96544</b> | <b>0,96598</b> | <b>0,96470</b> |
| 0,6        | 16          | 1142/286        | 0,93007        | 0,93178        | 0,93007        | 0,92997        |
| 0,6        | 28          | 1142/286        | 0,95105        | 0,95148        | 0,95105        | 0,95056        |
| 0,6        | 32          | 1142/286        | 0,95455        | 0,95611        | 0,95455        | 0,95410        |
| 0,6        | 56          | 1142/286        | 0,95105        | 0,95136        | 0,95105        | 0,95069        |
| 0,6        | 112         | 1142/286        | 0,94755        | 0,94723        | 0,94755        | 0,94715        |

Çizelge 4.42. VGG16 Sol Lob CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)

| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,95455        | 0,95474        | 0,95455        | 0,95452        |
| 0,7        | 8           | 1142/286        | 0,94056        | 0,94046        | 0,94056        | 0,93982        |
| 0,7        | 16          | 1142/286        | 0,93706        | 0,93833        | 0,93706        | 0,93657        |
| 0,7        | 28          | 1142/286        | 0,94755        | 0,9475         | 0,94755        | 0,94700        |
| 0,7        | 32          | 1142/286        | 0,94755        | 0,94848        | 0,94755        | 0,94723        |
| 0,7        | 56          | 1142/286        | 0,94406        | 0,9437         | 0,94406        | 0,94375        |
| 0,7        | 112         | 1142/286        | 0,95455        | 0,95544        | 0,95455        | 0,95405        |
| 0,8        | 4           | 1142/286        | 0,94056        | 0,94167        | 0,94056        | 0,94005        |
| 0,8        | 8           | 1142/286        | 0,94406        | 0,94365        | 0,94406        | 0,94373        |
| 0,8        | 16          | 1142/286        | 0,95455        | 0,95447        | 0,95455        | 0,95444        |
| 0,8        | 28          | 1142/286        | 0,94406        | 0,94374        | 0,94406        | 0,94351        |
| 0,8        | 32          | 1142/286        | 0,95804        | 0,95856        | 0,95804        | 0,95758        |
| 0,8        | 56          | 1142/286        | 0,95105        | 0,95071        | 0,95105        | 0,95072        |
| 0,8        | 112         | 1142/286        | 0,95455        | 0,95476        | 0,95455        | 0,95414        |
| 0,9        | 4           | 1142/286        | 0,96154        | 0,96258        | 0,96154        | 0,96143        |
| 0,9        | 8           | 1142/286        | 0,95804        | 0,95828        | 0,95804        | 0,95788        |
| 0,9        | 16          | 1142/286        | 0,95804        | 0,95809        | 0,95804        | 0,95783        |
| 0,9        | 28          | 1142/286        | 0,94406        | 0,94381        | 0,94406        | 0,94358        |
| 0,9        | 32          | 1142/286        | 0,94406        | 0,94711        | 0,94406        | 0,94299        |
| 0,9        | 56          | 1142/286        | 0,94755        | 0,94757        | 0,94755        | 0,94703        |
| 0,9        | 112         | 1142/286        | 0,95804        | 0,9595         | 0,95804        | 0,95755        |
| <b>1</b>   | <b>4</b>    | <b>1142/286</b> | <b>0,96853</b> | <b>0,9696</b>  | <b>0,96853</b> | <b>0,96869</b> |
| 1          | 8           | 1142/286        | 0,96853        | 0,9696         | 0,96853        | 0,96869        |
| <b>1</b>   | <b>16</b>   | <b>1142/286</b> | <b>0,96154</b> | <b>0,96161</b> | <b>0,96154</b> | <b>0,96150</b> |
| 1          | 28          | 1142/286        | 0,96853        | 0,96848        | 0,96853        | 0,96845        |
| 1          | 32          | 1142/286        | 0,94406        | 0,94463        | 0,94406        | 0,94336        |
| 1          | 56          | 1142/286        | 0,94755        | 0,94874        | 0,94755        | 0,94667        |
| 1          | 112         | 1142/286        | 0,95455        | 0,95514        | 0,95455        | 0,95427        |

Çizelge 4.43. VGG16 Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,1 - 0,3)

| Clip_limit    | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|---------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| CLAHE olmadan |             | 1142/286        | 0,95455        | 0,95489        | 0,95455        | 0,95419        |
| <b>0,1</b>    | <b>4</b>    | <b>1142/286</b> | <b>0,96154</b> | <b>0,96177</b> | <b>0,96154</b> | <b>0,96153</b> |
| <b>0,1</b>    | <b>8</b>    | <b>1142/286</b> | <b>0,96154</b> | <b>0,96213</b> | <b>0,96154</b> | <b>0,96171</b> |
| 0,1           | 16          | 1142/286        | 0,94025        | 0,94022        | 0,94025        | 0,94034        |
| 0,1           | 28          | 1142/286        | 0,93706        | 0,93770        | 0,93706        | 0,93594        |
| 0,1           | 32          | 1142/286        | 0,93706        | 0,93650        | 0,93706        | 0,93655        |
| 0,1           | 56          | 1142/286        | 0,94056        | 0,94122        | 0,94056        | 0,94073        |
| 0,1           | 112         | 1142/286        | 0,93007        | 0,92972        | 0,93007        | 0,92985        |
| <b>0,2</b>    | <b>4</b>    | <b>1142/286</b> | <b>0,96154</b> | <b>0,96147</b> | <b>0,96154</b> | <b>0,96148</b> |
| 0,2           | 8           | 1142/286        | 0,94755        | 0,94923        | 0,94755        | 0,94653        |
| 0,2           | 16          | 1142/286        | 0,95105        | 0,95080        | 0,95105        | 0,95070        |
| 0,2           | 28          | 1142/286        | 0,93706        | 0,93709        | 0,93706        | 0,93629        |
| 0,2           | 32          | 1142/286        | 0,94406        | 0,94433        | 0,94406        | 0,94327        |
| 0,2           | 56          | 1142/286        | 0,94406        | 0,94370        | 0,94406        | 0,94366        |
| 0,2           | 112         | 1142/286        | 0,92657        | 0,92657        | 0,92657        | 0,92657        |
| 0,3           | 4           | 1142/286        | 0,95804        | 0,95920        | 0,95804        | 0,95756        |
| 0,3           | 8           | 1142/286        | 0,93357        | 0,93345        | 0,93357        | 0,93335        |
| 0,3           | 16          | 1142/286        | 0,93706        | 0,93694        | 0,93706        | 0,93649        |
| 0,3           | 28          | 1142/286        | 0,92657        | 0,92584        | 0,92657        | 0,92586        |
| 0,3           | 32          | 1142/286        | 0,94056        | 0,94029        | 0,94056        | 0,94008        |
| 0,3           | 56          | 1142/286        | 0,93706        | 0,93729        | 0,93706        | 0,93622        |
| 0,3           | 112         | 1142/286        | 0,93007        | 0,92956        | 0,93007        | 0,92965        |

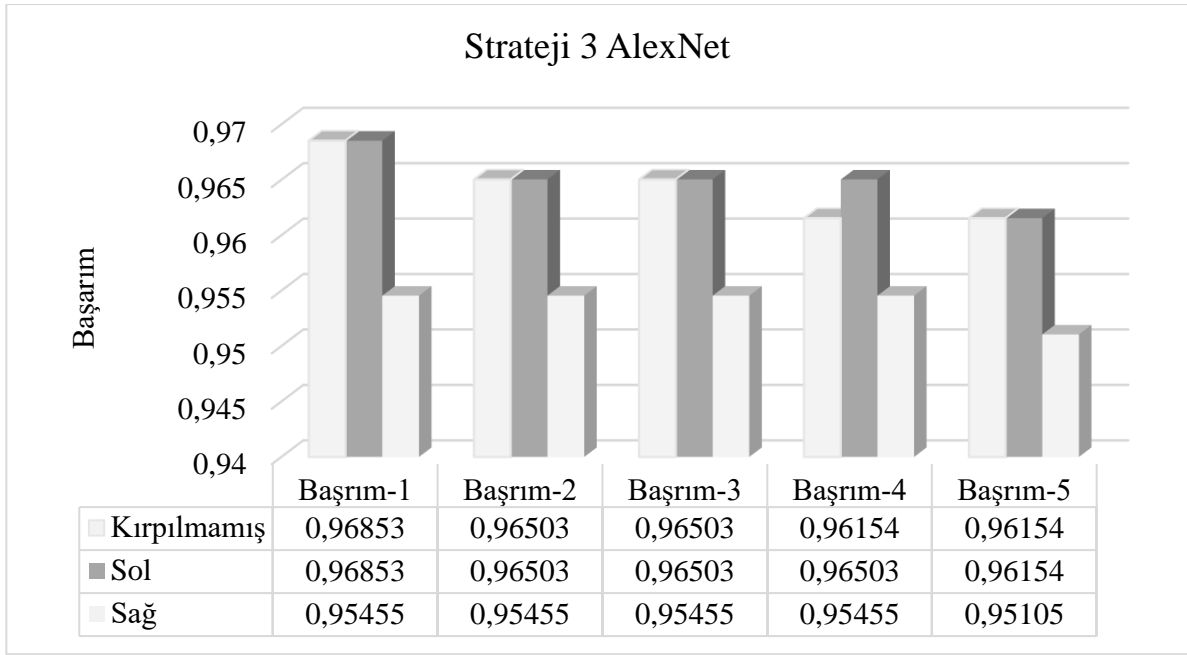


Çizelge 4.44. VGG16 Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,4 - 0,6)

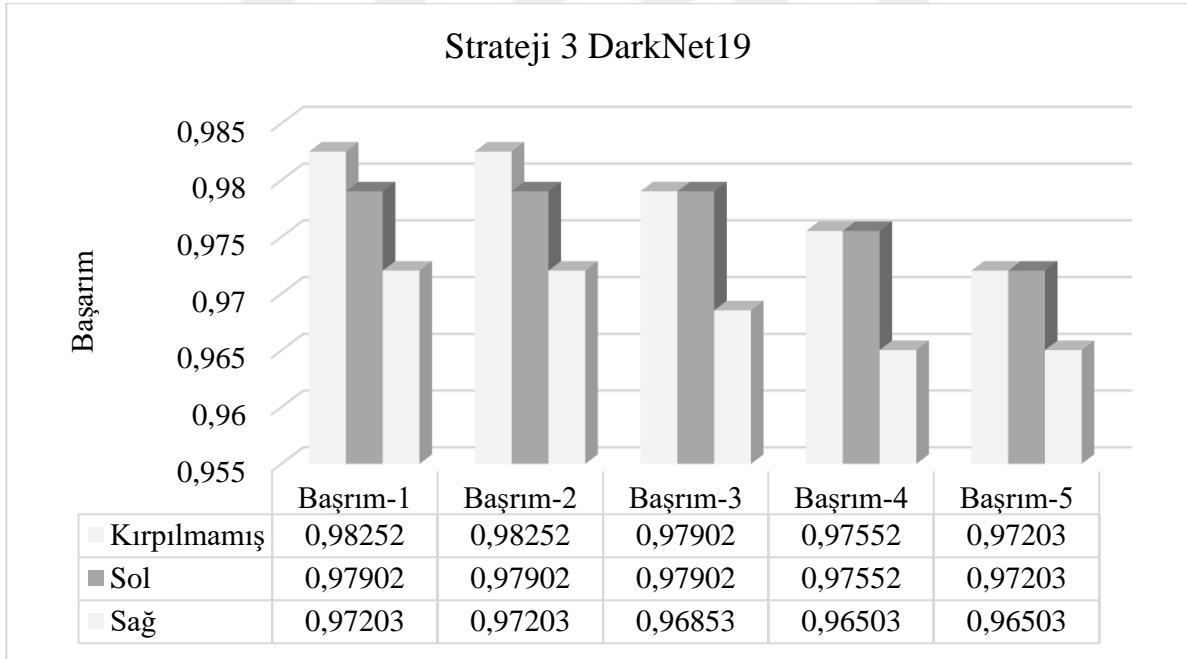
| Clip_limit | Kernel_size | Eğitim/Test | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|------------|-------------|-------------|----------|----------|------------|---------|
| 0,4        | 4           | 1142/286    | 0,94755  | 0,94773  | 0,94755    | 0,94691 |
| 0,4        | 8           | 1142/286    | 0,93007  | 0,92952  | 0,93007    | 0,92972 |
| 0,4        | 16          | 1142/286    | 0,94755  | 0,94720  | 0,94755    | 0,94725 |
| 0,4        | 28          | 1142/286    | 0,94056  | 0,94017  | 0,94056    | 0,94013 |
| 0,4        | 32          | 1142/286    | 0,93706  | 0,93667  | 0,93706    | 0,93630 |
| 0,4        | 56          | 1142/286    | 0,95804  | 0,95803  | 0,95804    | 0,95779 |
| 0,4        | 112         | 1142/286    | 0,93706  | 0,93706  | 0,93706    | 0,93706 |
| 0,5        | 4           | 1142/286    | 0,96154  | 0,96171  | 0,96154    | 0,96161 |
| 0,5        | 8           | 1142/286    | 0,95455  | 0,95430  | 0,95455    | 0,95420 |
| 0,5        | 16          | 1142/286    | 0,94406  | 0,94377  | 0,94406    | 0,94370 |
| 0,5        | 28          | 1142/286    | 0,94056  | 0,94013  | 0,94056    | 0,93999 |
| 0,5        | 32          | 1142/286    | 0,93706  | 0,93687  | 0,93706    | 0,93646 |
| 0,5        | 56          | 1142/286    | 0,94056  | 0,94024  | 0,94056    | 0,94027 |
| 0,5        | 112         | 1142/286    | 0,91608  | 0,91545  | 0,91608    | 0,91526 |
| 0,6        | 4           | 1142/286    | 0,95105  | 0,95153  | 0,95105    | 0,95035 |
| 0,6        | 8           | 1142/286    | 0,94755  | 0,94766  | 0,94755    | 0,94749 |
| 0,6        | 16          | 1142/286    | 0,94755  | 0,94759  | 0,94755    | 0,94719 |
| 0,6        | 28          | 1142/286    | 0,93357  | 0,93306  | 0,93357    | 0,93319 |
| 0,6        | 32          | 1142/286    | 0,93007  | 0,92969  | 0,93007    | 0,92983 |
| 0,6        | 56          | 1142/286    | 0,92657  | 0,92596  | 0,92657    | 0,92559 |
| 0,6        | 112         | 1142/286    | 0,94755  | 0,94824  | 0,94755    | 0,94777 |

Çizelge 4.45. VGG16 Sağ Lob CXR strateji 3 sonuçları (clip\_limit: 0,7 - 1)


| Clip_limit | Kernel_size | Eğitim/Test     | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-----------------|----------------|----------------|----------------|----------------|
| 0,7        | 4           | 1142/286        | 0,94406        | 0,94517        | 0,94406        | 0,94416        |
| 0,7        | 8           | 1142/286        | 0,93007        | 0,92949        | 0,93007        | 0,92940        |
| 0,7        | 16          | 1142/286        | 0,94406        | 0,94370        | 0,94406        | 0,94366        |
| 0,7        | 28          | 1142/286        | 0,94406        | 0,94370        | 0,94406        | 0,94371        |
| 0,7        | 32          | 1142/286        | 0,93357        | 0,93326        | 0,93357        | 0,93273        |
| 0,7        | 56          | 1142/286        | 0,94056        | 0,94038        | 0,94056        | 0,93995        |
| 0,7        | 112         | 1142/286        | 0,92657        | 0,92598        | 0,92657        | 0,92604        |
| 0,8        | 4           | 1142/286        | 0,92657        | 0,93060        | 0,92657        | 0,92753        |
| 0,8        | 8           | 1142/286        | 0,95105        | 0,95119        | 0,95105        | 0,95060        |
| 0,8        | 16          | 1142/286        | 0,94056        | 0,94047        | 0,94056        | 0,94036        |
| 0,8        | 28          | 1142/286        | 0,93357        | 0,93329        | 0,93357        | 0,93274        |
| 0,8        | 32          | 1142/286        | 0,93357        | 0,93329        | 0,93357        | 0,93274        |
| 0,8        | 56          | 1142/286        | 0,93007        | 0,92953        | 0,93007        | 0,92930        |
| 0,8        | 112         | 1142/286        | 0,93007        | 0,93013        | 0,93007        | 0,92915        |
| 0,9        | 4           | 1142/286        | 0,95455        | 0,95456        | 0,95455        | 0,95450        |
| 0,9        | 8           | 1142/286        | 0,96154        | 0,96167        | 0,96154        | 0,96159        |
| 0,9        | 16          | 1142/286        | 0,94406        | 0,94367        | 0,94406        | 0,94379        |
| 0,9        | 28          | 1142/286        | 0,94056        | 0,94007        | 0,94056        | 0,94015        |
| 0,9        | 32          | 1142/286        | 0,93706        | 0,93663        | 0,93706        | 0,93662        |
| 0,9        | 56          | 1142/286        | 0,91958        | 0,91295        | 0,91958        | 0,91969        |
| 1          | 4           | 1142/286        | 0,94056        | 0,94127        | 0,94056        | 0,93995        |
| 1          | 8           | 1142/286        | 0,67832        | 0,82769        | 0,67832        | 0,61458        |
| 1          | 16          | 1142/286        | 0,96154        | 0,96218        | 0,96154        | 0,96154        |
| <b>1</b>   | <b>28</b>   | <b>1142/286</b> | <b>0,94755</b> | <b>0,94744</b> | <b>0,94755</b> | <b>0,94729</b> |
| 1          | 32          | 1142/286        | 0,96503        | 0,96592        | 0,96503        | 0,96472        |
| <b>1</b>   | <b>56</b>   | <b>1142/286</b> | <b>0,95455</b> | <b>0,95610</b> | <b>0,95455</b> | <b>0,95397</b> |
| 1          | 112         | 1142/286        | 0,96503        | 0,96497        | 0,96503        | 0,96493        |



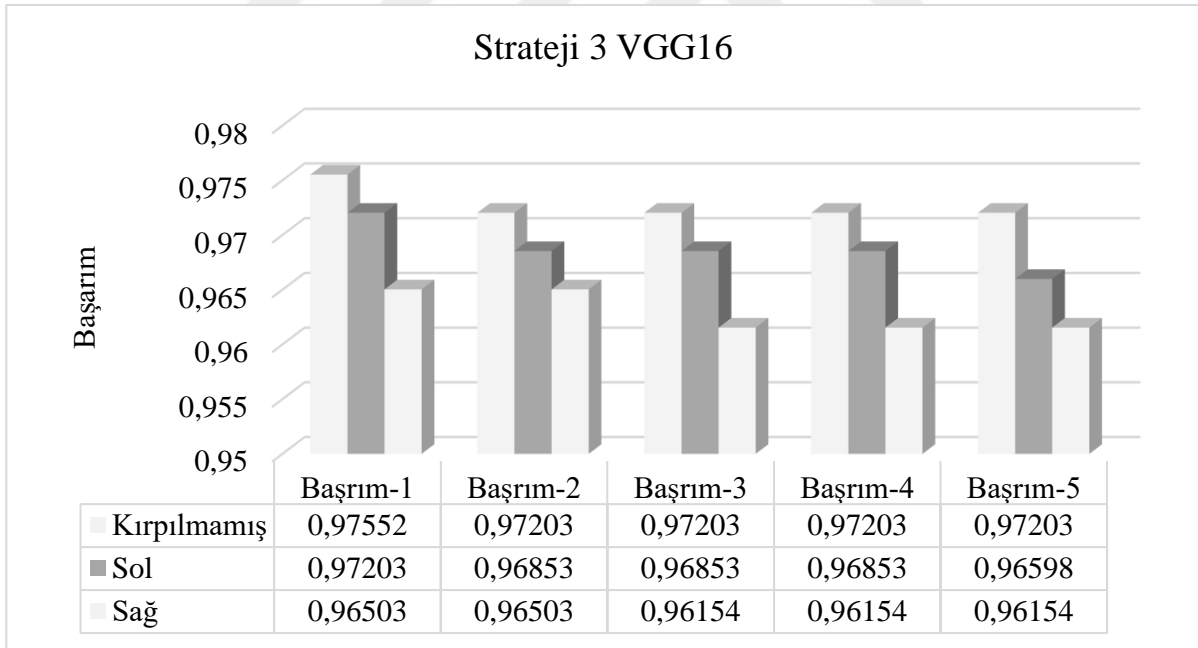
Şekil 4.1. Strateji 3 AlexNet en iyi sonuçları



Şekil 4.2. Strateji 3 DarkNet19 en iyi sonuçları



Şekil 4.3. Strateji 3 MobileNet en iyi sonuçları



Şekil 4.4. Strateji 3 VGG16 en iyi sonuçları

#### 4.4. Strateji 4 ile Elde Edilen Sonuçlar

Strateji 3'te elde edilen en iyi 5 sonuca göre ağırlıklar kaydedilip, Covidx veri seti için 3615 Covid-19, 250 Pnömoni ve 250 Sağlıklı CXR görüntüsü için kaydedilen ağırlıklara öğrenme aktarımı metodu ile test işlemi uygulanmıştır.

Çizelge 4.46. AlexNet strateji 4 için test sonuçları

| Clip_limit | Kernel_size | Test        | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        | İşlem Süresi(s) |
|------------|-------------|-------------|----------------|----------------|----------------|----------------|-----------------|
| 0,1        | 4           | 4115        | 0,45541        | 0,88835        | 0,45541        | 0,56145        | 3,187           |
| 0,1        | 8           | 4115        | 0,40243        | 0,89603        | 0,40243        | 0,48762        | 2,484           |
| 0,1        | 56          | 4115        | 0,50838        | 0,90591        | 0,50838        | 0,60958        | 2,937           |
| <b>0,5</b> | <b>28</b>   | <b>4115</b> | <b>0,56501</b> | <b>0,91263</b> | <b>0,56501</b> | <b>0,66216</b> | <b>2,109</b>    |
| 0,8        | 56          | 4115        | 0,47825        | 0,91869        | 0,47825        | 0,58067        | 2,203           |

Çizelge 4.47. DarkNet19 strateji 4 için test sonuçları


| Clip_limit | Kernel_size | Test        | Doğruluk      | Kesinlik       | Duyarlılık     | F1-Skor        | İşlem Süresi(s) |
|------------|-------------|-------------|---------------|----------------|----------------|----------------|-----------------|
| 0,1        | 8           | 4115        | 0,65877       | 0,79953        | 0,65877        | 0,68431        | 8,015           |
| 0,4        | 4           | 4115        | 0,60267       | 0,78237        | 0,60267        | 0,63281        | 7,515           |
| 0,6        | 8           | 4115        | 0,67088       | 0,79599        | 0,67088        | 0,69941        | 7,765           |
| <b>0,7</b> | <b>16</b>   | <b>4115</b> | <b>0,7252</b> | <b>0,78810</b> | <b>0,72520</b> | <b>0,74546</b> | <b>7,859</b>    |
| 1          | 112         | 4115        | 0,66073       | 0,72942        | 0,66073        | 0,68557        | 7,468           |

Çizelge 4.48. MobileNet strateji 4 için test sonuçları

| Clip_limit | Kernel_size | Test        | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        | İşlem Süresi(s) |
|------------|-------------|-------------|----------------|----------------|----------------|----------------|-----------------|
| 0,4        | 28          | 4115        | 0,24836        | 0,86524        | 0,24836        | 0,27961        | 7,234           |
| 0,6        | 28          | 4115        | 0,35626        | 0,85978        | 0,35626        | 0,42691        | 4,890           |
| 0,7        | 32          | 4115        | 0,36622        | 0,86992        | 0,36622        | 0,44046        | 4,578           |
| 0,5        | 28          | 4115        | 0,31470        | 0,86484        | 0,31470        | 0,38255        | 5,015           |
| <b>0,9</b> | <b>8</b>    | <b>4115</b> | <b>0,41385</b> | <b>0,85043</b> | <b>0,41385</b> | <b>0,49747</b> | <b>5,093</b>    |

Çizelge 4.49. VGG16 strateji 4 için test sonuçları

| Clip_limit | Kernel_size | Test        | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        | İşlem Süresi(s) |
|------------|-------------|-------------|----------------|----------------|----------------|----------------|-----------------|
| 0,1        | 4           | 4115        | 0,48214        | 0,87706        | 0,48214        | 0,59075        | 6,000           |
| 0,1        | 28          | 4115        | 0,4469         | 0,90505        | 0,44690        | 0,54880        | 3,921           |
| 0,2        | 8           | 4115        | 0,43767        | 0,88886        | 0,43767        | 0,53230        | 3,500           |
| <b>0,2</b> | <b>56</b>   | <b>4115</b> | <b>0,48360</b> | <b>0,91351</b> | <b>0,48360</b> | <b>0,58213</b> | <b>3,546</b>    |
| 0,3        | 8           | 4115        | 0,44885        | 0,8949         | 0,44885        | 0,54670        | 3,734           |



Şekil 4.5. Strateji 4 en iyi test sonuçları

#### 4.5. Strateji 5 ile Elde Edilen Sonuçlar

Bu kısımda, strateji 3 sonucunda her model için seçilen en iyi 5 sonucun ağırlıkları kullanılarak öğrenim aktarma metodu kullanılarak Covidx CXR görüntülerinin eğitilmesi gerçekleştirilmiştir. 3615 Covid-19, 3500 Pnömoni ve 3500 Sağlıklı CXR görüntüsünden oluşan bu veri çerçevesine, seçilen en iyi 5 sonucun CLAHE parametreleri uygulanarak modellerin tekrardan eğitilmesi sağlanmıştır ve sonuçlar sunulmuştur.

Çizelge 4.50. AlexNet strateji 5 için eğitim/test sonuçları

| Clip_limit | Kernel_size | Eğitim/Test       | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-------------------|----------------|----------------|----------------|----------------|
| 0,1        | 4           | 10615/3185        | 0,91743        | 0,92028        | 0,91743        | 0,91695        |
| 0,1        | 8           | 10615/3185        | 0,88320        | 0,90266        | 0,88320        | 0,87867        |
| 0,1        | 56          | 10615/3185        | 0,84678        | 0,86805        | 0,84678        | 0,84063        |
| 0,5        | 28          | 10615/3185        | 0,91272        | 0,91675        | 0,91272        | 0,91451        |
| <b>0,8</b> | <b>56</b>   | <b>10615/3185</b> | <b>0,92433</b> | <b>0,92601</b> | <b>0,92433</b> | <b>0,92414</b> |

Çizelge 4.51. DarkNet19 strateji 5 için eğitim/test sonuçları


| Clip_limit | Kernel_size | Eğitim/Test       | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-------------------|----------------|----------------|----------------|----------------|
| 0,1        | 8           | 10615/3185        | 0,71554        | 0,81150        | 0,71554        | 0,69033        |
| <b>0,4</b> | <b>4</b>    | <b>10615/3185</b> | <b>0,93218</b> | <b>0,93689</b> | <b>0,93218</b> | <b>0,93245</b> |
| 0,6        | 8           | 10615/3185        | 0,90487        | 0,91334        | 0,90487        | 0,90167        |
| 0,7        | 16          | 10615/3185        | 0,84301        | 0,88260        | 0,84301        | 0,84627        |
| 1          | 112         | 10615/3185        | 0,88320        | 0,90315        | 0,88320        | 0,88407        |

Çizelge 4.52. MobileNet strateji 5 için eğitim/test sonuçları

| Clip_limit | Kernel_size | Eğitim/Test       | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-------------------|----------------|----------------|----------------|----------------|
| 0,4        | 28          | 10615/3185        | 0,74066        | 0,73990        | 0,74066        | 0,73937        |
| 0,6        | 28          | 10615/3185        | 0,74097        | 0,74015        | 0,74097        | 0,74046        |
| <b>0,7</b> | <b>32</b>   | <b>10615/3185</b> | <b>0,75887</b> | <b>0,75647</b> | <b>0,75887</b> | <b>0,75694</b> |
| 0,5        | 28          | 10615/3185        | 0,74411        | 0,74581        | 0,74411        | 0,74397        |
| 0,9        | 8           | 10615/3185        | 0,73438        | 0,73116        | 0,73438        | 0,73189        |

Çizelge 4.53. VGG16 strateji 5 için eğitim/test sonuçları

| Clip_limit | Kernel_size | Eğitim/Test       | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|-------------------|----------------|----------------|----------------|----------------|
| 0,1        | 4           | 10615/3185        | 0,93155        | 0,93596        | 0,93155        | 0,93211        |
| <b>0,1</b> | <b>28</b>   | <b>10615/3185</b> | <b>0,95039</b> | <b>0,95114</b> | <b>0,95039</b> | <b>0,95052</b> |
| 0,2        | 8           | 10615/3185        | 0,93626        | 0,93758        | 0,93626        | 0,93648        |
| 0,2        | 56          | 10615/3185        | 0,94976        | 0,94981        | 0,94976        | 0,94950        |
| 0,3        | 8           | 10615/3185        | 0,90801        | 0,90950        | 0,90801        | 0,90650        |



Şekil 4.6. Strateji 5 en iyi test sonuçları

## 4.6. Strateji 6 ile Elde Edilen Sonuçlar

### 4.6.1. Covid-19 ve Sağlıklı CXR Eğitim Sonuçları

Strateji 3 ile elde edilen en iyi sonuçlara göre CLAHE parametreleri uygulanarak büyük ölçekli Covid-19 3615 adet CXR ve Sağlıklı 3500 CXR görüntüleri eğitilmiştir. 2'li sınıflandırma işlemi AlexNet, DarkNet19, MobileNet ve VGG19 modelleri kullanılarak yapılmıştır.



Çizelge 4.54. AlexNet 2'li sınıflandırma sonuçları (Covid-19 ve Sağlıklı)

| Clip_limit | Kernel_size | Eğitim/Test      | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|------------------|----------------|----------------|----------------|----------------|
| 0,1        | 4           | 7115/2135        | 0,91216        | 0,91581        | 0,91216        | 0,91194        |
| 0,1        | 8           | 7115/2135        | 0,84118        | 0,87389        | 0,84118        | 0,83777        |
| 0,1        | 56          | 7115/2135        | 0,85151        | 0,87877        | 0,85152        | 0,84903        |
| <b>0,5</b> | <b>28</b>   | <b>7115/2135</b> | <b>0,93724</b> | <b>0,93770</b> | <b>0,93724</b> | <b>0,93723</b> |
| 0,8        | 56          | 7115/2135        | 0,83794        | 0,87431        | 0,83794        | 0,83360        |

Çizelge 4.55. DarkNet19 2'li sınıflandırma sonuçları (Covid-19 ve Sağlıklı)

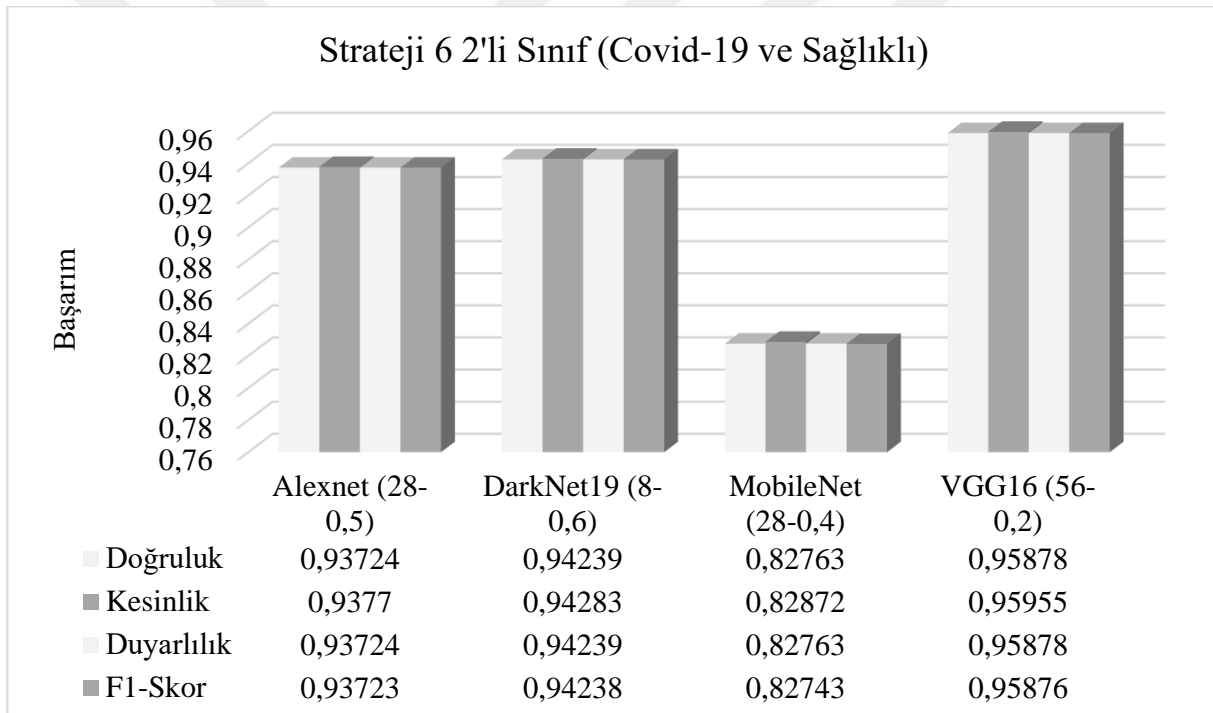
| Clip_limit | Kernel_size | Eğitim/Test      | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|------------------|----------------|----------------|----------------|----------------|
| 0,1        | 8           | 7115/2135        | 0,92319        | 0,92849        | 0,92319        | 0,92299        |
| 0,4        | 4           | 7115/2135        | 0,89227        | 0,90162        | 0,89227        | 0,89155        |
| 0,6        | 8           | 7115/2135        | 0,94239        | 0,94283        | 0,94239        | 0,94238        |
| 0,7        | 16          | 7115/2135        | 0,90070        | 0,91511        | 0,90070        | 0,89993        |
| <b>1</b>   | <b>112</b>  | <b>7115/2135</b> | <b>0,95176</b> | <b>0,95447</b> | <b>0,95176</b> | <b>0,95166</b> |

Çizelge 4.56. MobileNet 2'li sınıflandırma sonuçları (Covid-19 ve Sağlıklı)

| Clip_limit | Kernel_size | Eğitim/Test      | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|------------------|----------------|----------------|----------------|----------------|
| <b>0,4</b> | <b>28</b>   | <b>7115/2135</b> | <b>0,82763</b> | <b>0,82872</b> | <b>0,82763</b> | <b>0,82743</b> |
| 0,6        | 28          | 7115/2135        | 0,80468        | 0,80570        | 0,80468        | 0,80444        |
| 0,7        | 32          | 7115/2135        | 0,81827        | 0,82020        | 0,81827        | 0,81790        |
| 0,5        | 28          | 7115/2135        | 0,81358        | 0,81701        | 0,81358        | 0,81320        |
| 0,9        | 8           | 7115/2135        | 0,77986        | 0,78647        | 0,77986        | 0,77835        |

Çizelge 4.57. VGG16 2'li sınıflandırma sonuçları (Covid-19 ve Sağlıklı)

| Clip_limit | Kernel_size | Eğitim/Test      | Doğruluk       | Kesinlik       | Duyarlılık     | F1-Skor        |
|------------|-------------|------------------|----------------|----------------|----------------|----------------|
| 0,1        | 4           | 7115/2135        | 0,95550        | 0,95619        | 0,95550        | 0,95550        |
| 0,1        | 28          | 7115/2135        | 0,95410        | 0,95460        | 0,95410        | 0,95408        |
| 0,2        | 8           | 7115/2135        | 0,89602        | 0,90940        | 0,89602        | 0,89506        |
| <b>0,2</b> | <b>56</b>   | <b>7115/2135</b> | <b>0,95878</b> | <b>0,95955</b> | <b>0,95878</b> | <b>0,95876</b> |
| 0,3        | 8           | 7115/2135        | 0,88852        | 0,90031        | 0,88852        | 0,88780        |



Şekil 4.7. Strateji 6 2'li sınıf sonuçları (Covid-19 ve Sağlıklı)

#### 4.6.2. Covid-19 ve Pnömoni CXR Eğitim Sonuçları

Strateji 3 ile elde edilen en iyi sonuçlara göre CLAHE parametreleri uygulanarak büyük ölçekli Covid-19 3615 adet CXR ve Pnömoni 3500 CXR görüntüleri eğitilmiştir. 2'li sınıflandırma işlemi AlexNet, DarkNet19, MobileNet ve VGG19 modelleri kullanılarak yapılmıştır.

Çizelge 4.58. AlexNet 2'li sınıflandırma sonuçları (Covid-19 ve Pnömoni)

| Clip_limit | Kernel_size | Eğitim/Test      | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|------------|-------------|------------------|----------|----------|------------|---------|
| 0,1        | 4           | 7115/2135        | 0.96393  | 0.96621  | 0.96393    | 0.96388 |
| 0,1        | 8           | 7115/2135        | 0.98876  | 0.9889   | 0.98876    | 0.98876 |
| 0,1        | 56          | 7115/2135        | 0.98642  | 0.9866   | 0.98642    | 0.98641 |
| <b>0,5</b> | <b>28</b>   | <b>7115/2135</b> | 0.99438  | 0.99438  | 0.99438    | 0.99438 |
| 0,8        | 56          | 7115/2135        | 0.99297  | 0.99301  | 0.99297    | 0.99297 |

Çizelge 4.59. DarkNet19 2'li sınıflandırma sonuçları (Covid-19 ve Pnömoni)


| Clip_limit | Kernel_size | Eğitim/Test      | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|------------|-------------|------------------|----------|----------|------------|---------|
| 0,1        | 8           | 7115/2135        | 0.99672  | 0.99672  | 0.99672    | 0.99672 |
| 0,4        | 4           | 7115/2135        | 0.98876  | 0.989    | 0.98876    | 0.98876 |
| 0,6        | 8           | 7115/2135        | 0.99625  | 0.99625  | 0.99625    | 0.99625 |
| 0,7        | 16          | 7115/2135        | 0.99578  | 0.9958   | 0.99578    | 0.99578 |
| <b>1</b>   | <b>112</b>  | <b>7115/2135</b> | 0.99625  | 0.99625  | 0.99625    | 0.99625 |

Çizelge 4.60. MobileNet 2'li sınıflandırma sonuçları (Covid-19 ve Pnömoni)

| Clip_limit | Kernel_size | Eğitim/Test      | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|------------|-------------|------------------|----------|----------|------------|---------|
| <b>0,4</b> | <b>28</b>   | <b>7115/2135</b> | 0.95176  | 0.95357  | 0.95176    | 0.95172 |
| 0,6        | 28          | 7115/2135        | 0.93208  | 0.93641  | 0.93208    | 0.93188 |
| 0,7        | 32          | 7115/2135        | 0.96159  | 0.9616   | 0.96159    | 0.96159 |
| 0,5        | 28          | 7115/2135        | 0.94707  | 0.94722  | 0.94707    | 0.94707 |
| 0,9        | 8           | 7115/2135        | 0.90023  | 0.90024  | 0.90023    | 0.90024 |

Çizelge 4.61. VGG16 2'li sınıflandırma sonuçları (Covid-19 ve Pnömoni)

| Clip_limit | Kernel_size | Eğitim/Test      | Doğruluk | Kesinlik | Duyarlılık | F1-Skor |
|------------|-------------|------------------|----------|----------|------------|---------|
| 0,1        | 4           | 7115/2135        | 0.99344  | 0.99347  | 0.99344    | 0.99344 |
| 0,1        | 28          | 7115/2135        | 0.99297  | 0.99298  | 0.99297    | 0.99297 |
| 0,2        | 8           | 7115/2135        | 0.99344  | 0.99345  | 0.99344    | 0.99344 |
| <b>0,2</b> | <b>56</b>   | <b>7115/2135</b> | 0.99344  | 0.99347  | 0.99344    | 0.99344 |
| 0,3        | 8           | 7115/2135        | 0.99391  | 0.99392  | 0.99391    | 0.99391 |



Şekil 4.8. Strateji 6 2'li sınıf sonuçları (Covid-19 ve Pnömoni)

## 4.7. Farklı Stratejiler için Grad-CAM Gösterimi


### 4.7.1. Strateji 1 için Grad-CAM

Strateji 1’de AlexNet, VGG16 ve MobileNet modelleri kullanılarak farklı LHE parametreleri için sağ ve sol lob birlikte eğitilerek sonuçlar elde edilmiştir.

Şekil 4.9.’da görüldüğü üzere AlexNet (a), VGG16 (b) ve MobileNet (c) modelleri için farklı Grad-CAM gösterimleri elde edilmiştir. Her model için son evrişim katmanı ve sonrası sınıflandırma katmanları alınarak görüntüler üzerinde öğrenilen bölgeler ön plana çıkarılmıştır.

### 4.7.2. Strateji 3 ve 4 için Grad-CAM

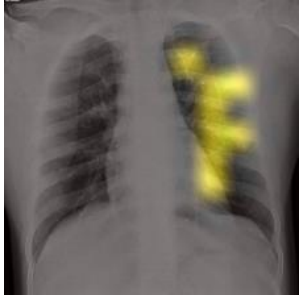


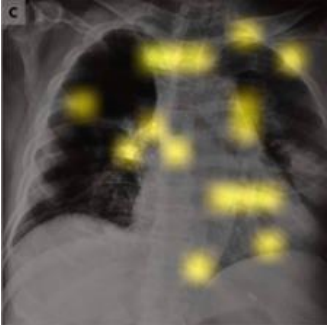
Bu kısımda Strateji 3 ve 4 için farklı Grad-CAM gösterimleri yer almaktadır. Strateji 3’te



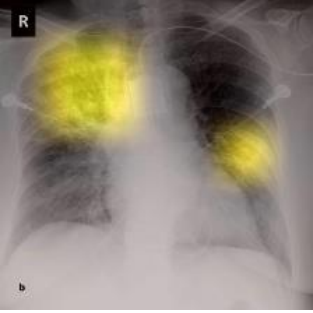

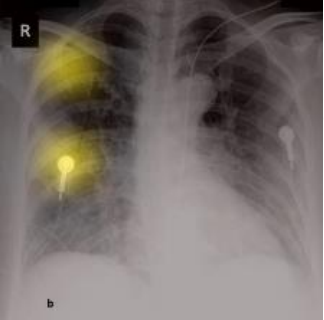

Şekil 4.9. Strateji 1 için farklı Grad-CAM görüntüleri

seçilen model elde edilen en iyi başarımlar parametrelerine göre seçilerek Grad-CAM gösterimleri elde edilmiştir. Strateji 4’te test edilen CXR görüntüleri için en iyi başarımlı parametreler seçilerek Grad-CAM sonuçları elde edilmiştir. Grad-CAM görüntüleri Çizelge 4.62. ve Çizelge 4.63.’te sunulmuştur.

Çizelge 4.62. Strateji 3 ve 4 için AlexNet ve VGG16 Grad-CAM gösterimleri

| Model   | Strateji | Clip_limit | Kernel_size | Grad-CAM gösterimi   |
|---------|----------|------------|-------------|--|
| AlexNet | 3        | 0,5        | 28          |    |
| AlexNet | 4        | 0,5        | 28          |    |
| VGG16   | 3        | 0,1        | 4           |  |
| VGG16   | 4        | 0,1        | 4           |  |

Çizelge 4.63. Strateji 3 ve 4 için MobileNet ve DarkNet19 Grad-CAM gösterimleri

| Model     | Strateji | Clip_limit | Kernel_size | Grad-CAM gösterimi   |
|-----------|----------|------------|-------------|--|
| MobileNet | 3        | 0,5        | 28          |    |
| MobileNet | 4        | 0,9        | 8           |   |
| DarkNet19 | 3        | 0,1        | 8           |  |
| DarkNet19 | 4        | 0,7        | 16          |  |

## 5. SONUÇ VE ÖNERİLER

Bu çalışmada modellerin eğitimi için Python yazılım dili kullanılmıştır, Tensorflow ve Keras kütüphaneleri kullanılmıştır. Bu süreçte Anaconda'nın Spyder arayüzü tercih edilmiştir<sup>7</sup>. Donanımsal olarak Intel Core İ7-10750H CPU (2.60 GHZ) ve Nvidia RTX 2060 Anakartı kullanılarak eğitimler gerçekleştirilmiştir.

Literatürdeki çalışmaların büyük çoğunluğu az veri ile eğitildiğinde yüksek test başarımları verirken, aynı modeller daha önce modele verilmeyen yüksek sayıdaki veri ile test edildiğinde genelleme kapasitesinin düşük olduğu görülmüştür. Genel olarak %41 ile %72 aralığında başarıma ulaşılmıştır, bu durumda klinik geçerliliğe sahip bir modelin önerilmesi için eğitimlerin büyük miktarda veri ile eğitilmesine ihtiyaç duyulduğu kanaatine varılmıştır.

Derin öğrenme algoritmalarında başarımlar farklı görüntü türleri için yüksek çıkmakla beraber güncel çalışmalarda bu yüksek başarımların sabit tutularak daha basit modellerle, daha az öznelik öğrenme işlemi gerektiren modellerle yapılması temel odak noktası olmuştur. Buna bağlı olarak mobil yapılar ve düşük parametre sayısına sahip ön eğitilmiş modellerin kullanımı yaygınlaşmıştır. Literatürdeki en basit modeller olan AlexNet, DarkNet19, MobileNet ve VGG16 temelde görüntü işleme algoritmaları birleştirilerek çok daha yalın yaklaşımlarla modellemeler gerçekleştirilmiştir. Denenen modeller içerisinde en az sayıdaki parametreye sahip MobileNet ile yüksek sınıflandırma başarımları elde edilmiş olmasına rağmen istenilen seviyede yüksek başarımlar yine parametre sayısı düşük olan DarkNet19 (yaklaşık 16 milyon) ile elde edilmiştir.

Birçok araştırma alanında COVID-19 analizi, bir pandemi için hastalığın teşhis ve tespit oranını kolaylaştırmak için önem kazanmıştır. Sonuç olarak, gelişen görüntü işleme teknikleri ve sağlam CADx sistemleri önermek, araştırmacıların ana odak noktasıdır. COVID-19'un değerlendirilmesine yönelik el yazmaları ve çeşitli teşhis araçları içinde anormallik tespiti için otomatikleştirilmiş tekniklerin kullanılması, alanın 2020'deki popülerliğini göstermektedir. Oysa karmaşık Derin öğrenme mimarilerine sahip Derin modeller kullanılarak COVID-19 teşhisi için yüksek sınıflandırma performansları rapor edilmiştir. Basit ön işleme aşamalarını değerlendirme sürecine uygulayarak, basit derin mimarileri kullanarak yeterince yüksek başarımlara ulaşılmıştır. Ana fikir, birçok evrişim katman yerine oluşturulan temsilleri kullanmak, CLAHE ile benzer örnekler içinde özellik öğrenmeyi iletme ve göğüs röntgenlerini sağlıklı,

<sup>7</sup> <https://anaconda.org/anaconda/spyder>



COVID 19 ve pnömoni patolojisi ile tanımlamak için bitişik katmanlar arasında özellik aktarma kabiliyetini uyarlamaktır.

Bu çalışma, CNN'nin sığ mimarilerle genelleme kabiliyetini artırarak benzer temsiller oluşturmak için CLAHE'nin uygulanmasındaki yeniliği içermektedir. Pek çok çalışma, denetimli eğitim ve modelleme özelliği öğrenme aşamalarında sadece sınıflandırma performanslarına odaklanırken, öneri; tıbbi görüntüler üzerinde yaygın bir kullanıma sahip olan CLAHE ile öncü bir çalışmadır. CNN mimarilerinin eğitimi için büyük verinin gerekliliği, orta ölçekli bir göğüs röntgeni veri seti kullanılarak giderilmesi denenmiştir, sonrasında öğrenme aktarımı kullanılarak veri setine CLAHE uygulanmıştır ve büyük ölçekli veri seti üzerinde test (Strateji 4) işlemi uygulanarak sonuçlar elde edilmiştir. Büyük ölçekli verilerin eğitilmesi için Strateji 3'te küçük ölçekli verilerin eğitilmesinden elde edilen en iyi 5 modelin ağırlıkları kullanılmıştır, böylece büyük ölçekli verilerin eğitilmesi öğrenme aktarımı ile gerçekleştirilmiştir. Öğrenme aktarımı ile eğitilen büyük ölçekli verilerde modelin eğitilmesi ortalama 15 eğitim turu sayısı sonucunda en iyi başarımlar elde edilmiştir. Önerilen stratejilerde, ön eğitilmiş mimariler kullanılarak çok sınıflı hastalıklar için yüksek sınıflandırma başarımlarına ulaşılmıştır. Çeşitli tıbbi görüntü analizi türleri için entegre edilmesi kolay bir mimariler tercih edilmiştir. Göğüs röntgenlerinde yeni görselleştirme teknikleri ve lokalizasyon algoritmalarının kullanılması Derin Öğrenme algoritmalarına olası bir katkıya sahiptir. CNN mimarileri ek özellik çıkarma ve ön işleme prosedürlerine ihtiyaç duymasa da düşük genelleştirme yetenekleri olan küçük patolojileri tespit etmede sınırlamaları vardır. CNN'deki modelleme mimarileri için sınıflandırma atamalarının, göğüs röntgenleri üzerindeki COVID-19 analizindeki varyans değerinin sınırladığı görüşünde, mimarileri üretken temsillerle beslemek, kaybı en aza indirmek ve sığ modeller için bile performansı artırmak için yeni bir yaklaşımdır. Daha fazla analizde, çeşitli lokalizasyon parametrelerinin değerlendirilmesi ve çeşitli hafif mimarilerle denemeler yapılması hem sol hem sağ hem de her iki akciğerde ayrı ayrı performans yeteneklerini arttırmıştır. Görüntü iyileştirmede sınırlı parametre aralığı ve çok sayıda katman içeren CNN mimarileri nedeniyle son teknoloji ürünü klinik uygunluk ve klinik geçerlilik açısından dezavantajlara sahipken, sunduğumuz CNN ile çok çeşitli CLAHE parametrelerinde denemeler yapılmıştır. 32 ve 112 kernel\_size boyutuna sahip CLAHE, DarkNet19 için en sorumlu özellik haritalarını sunarken, CLAHE için 28 kernel\_size boyutu VGG16 mimarisinde büyük ölçekli veriler için en başarılı sınıflandırma özelliklerine sahiptir.

Strateji 5 kapsamındaki büyük ölçekli COVID-19 veri kümesi için sınıflandırma performansları, doğruluk, kesinlik, duyarlılık ve f1-skor için sırasıyla %95.04, %95,11, %94,99 ve 0.9505 oranlarıyla VGG16 mimarisi kullanılarak ulaşılmıştır. En sorumlu CLAHE parametreleri

sırasıyla CLAHE kernel\_size boyutu ve klip limiti için 28 ve 0,1'dir. Grad-CAM, aktivasyon haritalarının sorumluluk seviyesini görselleştirmek için bir ısı haritası oluştururken, COVID-19 için en yüksek sorumluluğa sahip daha net bir görünüm sağlamak için eşik oranından daha az öğrenilen aktivasyon haritalarını ve tek renkli sunumu hariç tutuldu. Çizelge 4.58.'de, COVID-19 ile rastgele göğüs röntgenleri için Grad-CAM'de özelleştirilmiş yaklaşımı göstermektedir. Sarı bölümler, her Strateji için eşik oranı 0,75 olan yüksek düzeyde sorumlu bölümlerdir. Göğüs röntgenlerindeki dağılımın çoğunluğu, akciğer segmentasyonu kullanılsa bile çoğunlukla akciğerlerde meydana gelmektedir. Semptomların çeşitliliği ve hasta bazlı durumlar nedeniyle, sağlıkçılar COVID-19 tahmininden ziyade göğüs röntgeninde patolojik bölgelerin lokalizasyonunu ve görselleştirilmesini istemektedir. Bu gibi durumlarda, daha belirgin ve net bir görünüm elde etmek için COVID-19 tabanlı patolojileri geliştirmek, CNN mimarileri tarafından klinik alaka düzeyine sahip yüksek düzeyde sorumlu özellik haritalarının tahmin edilmesini sağlayacaktır. Deneyimli bir klinik çalışanı, COVID-19'lu sorumlu akciğer bölgeleri önerisinin Grad-CAM görüntülerini değerlendirdi. Klinik çalışmasının değerlendirilmesine göre, Strateji 5'teki öneri şiddetli COVID-19 patolojisini belirlemede oldukça başarılı olmasına rağmen, hafif düzeyde anormallikleri tespit etmede hala sınırlamaları vardır. Bununla birlikte, akciğer dışı ve kardiyak bölgelerde oldukça sorumlu özellik haritaları bulunabilir. Bu değerlendirme, CNN mimarilerinin klinik kullanım kazanmadan önce daha fazla sayıda COVID-19 vakasıyla desteklenmesi gerektiğini açıkça göstermektedir. Genel olarak, her Stratejide en iyi modeller için en sorumlu patolojik aktivasyon haritaları akciğer bölgelerindedir. Başarılar, akciğer patolojileri için tekrarlanabilir sunum sergileyen yerel bir ön işleme olarak CNN ile CLAHE kullanmanın, pnömoni ve COVID-19 gibi çok benzer patolojik öznelikleri ayırt etmek için çoklu vaka modelleri tasarlama yeteneklerine sahip olduğunu kanıtıyor. Göğüs röntgenlerindeki CLAHE geliştirmesi, doğru çoklu vaka sınıflandırma performanslarından yararlandı. CNN mimarileri, ön işlemede göğüs röntgeni iyileştirmelerinin ve eğitimde düz parametre optimizasyon tekniklerinin avantajları ile doğru tahminler gerçekleştirme yeteneğine sahiptir. CNN'lerin hafif kavramları, öğrenme aktarımını kullanarak sağlam modellerin önceden tanımlanması için bir avantaj sağlar. Bu nedenle, büyük ölçekli ilgili bir veri setinde Strateji 5 için Strateji 3'ün ağırlıkları kullanılmıştır. Ortak ağırlıklar kullanılarak yeni COVID-19 vakalarının yeniden eğitilmesi sağlanmıştır. Önceden eğitilmiş CNN mimarisi için en yüksek sınıflandırma performanslarına uygun olarak DarkNet19, Strateji 3 ve 4 için en yüksek çoklu durum tanımlama performanslarını elde etmiştir. VGG16, Strateji 3'teki en yüksek performans modelidir. Strateji 5, ilgili küçük ölçekli bir veri kümesi kullanılarak eğitilen model üzerinde öğrenme aktarımı ile eğitim süresini azaltmıştır.

Daha önceki stratejilerde 3 sınıflı etiketler kullanılırken, Strateji 6 için iki farklı eğitim yapılarak birincisinde Covid-19 ve Sağlıklı etiketleri kullanılmıştır. İkinci eğitimde ise Covid-19 ve Pnömoni etiketleri kullanılarak farklı sınıflar için ön eğitilmiş popüler modellerin Covid-19'un patolojik benzerlikleri ayırt etmedeki başarımları ölçülmüştür.

Bu çalışmanın temel üstünlükleri;

- COVID-19'un tanımlanması için göğüs röntgenlerinde gelecek stratejiler için en sorumlu CLAHE parametreleri belirlenmiştir.
- Çoklu testler için sol akciğer, sağ akciğer ve tam göğüs röntgenlerinin etkisi ortaya çıkarılmıştır.
- Klinik uygunluk açısından bir klinisyen tarafından en sorumlu bölgelerin değerlendirilmesi ve genişletilmiş veri seti kullanılarak küçük ölçekli COVID-19 veri kümeleri kullanılarak eğitilmiş CNN modellerinin ağırlıkları üzerinde aktarım öğreniminin uygulanması sonucunda performansların değerlendirilmesi.
- Öngörülen patoloji üzerinde klinik doğrulamanın gerekliliği, çalışmanın zayıflığını oluşturmaktadır. Bu nedenle, farklı özelliklere sahip tıbbi cihazların ve hastaya özgü vakaların çeşitliliği nedeniyle, COVID-19 için erken tanı aracı yerine göğüs röntgenlerinin yol gösterici bir değerlendirme veya destekleyici görselleştirme tekniği olarak kullanılması daha uygundur.

Bilgisayar destekli teknikler, bu sınırlamanın üstesinden gelmek için tekliflerin klinik olarak uygulanabilirliği için COVID-19'un neden olduğu patolojik bölgelerin ek açıklamaları ve lokalizasyonu ile daha ayrıntılı bir COVID-19 veri tabanına ihtiyaç duyar. Bu nedenle, DL destekli bilgisayar destekli teknikler, pnömoni ve COVID-19 vakalarının teşhisi için patolojilerin tanımlanması ve görselleştirilmesinde önemli bir rol oynamaktadır.

Literatürde yapılmış 3 sınıf etiketli farklı çalışmalara ait ön işleme, model ve doğruluk değerleri karşılaştırmaları Çizelge 5.1.'de verilmiştir. Bu çalışma ile farklı stratejiler için ön eğitilmiş modeller ile elde edilen en başarılı sonuçlar Çizelge 5.2.'de sunulmuştur.

Çizelge 5.1. Literatürde bulunan benzer çalışmaların karşılaştırılması

| Yayın                    | Önişleme                      | Model               | Covid-19 Sayısı | Sağlıklı Sayısı | Pnömoni Sayısı | Doğruluk |
|--------------------------|-------------------------------|---------------------|-----------------|-----------------|----------------|----------|
| Singh (2021)             | AHE, GANs                     | VGG19               | 473             | 8851            | 6041           | 98,67    |
| Wang, Lin ve Wong (2020) | Kırpma, Çevirme               | COVID-Net           | 358             | 8066            | 5538           | 93,34    |
| Oh, Park, ve Ye (2020)   | HE, Segmentasyon              | ResNet18            | 180             | 191             | 54             | 88,90    |
| Ozturk (2020)            | -                             | DarkNet             | 127             | 500             | 500            | 87,02    |
| El Asnaoui (2020)        | AHE                           | Inception, ResNetV2 | 231             | 1583            | 2780           | 92,18    |
| Chowdhury (2020)         | -                             | DenseNet201         | 423             | 1485            | 1579           | 97,94    |
| Haghanifar (2020)        | HE, AHE, Segmentasyon (U-NET) | DenseNet121         | 780             | 5000            | 4600           | 87,21    |
| Apostolopoulos (2020)    | Bozulma Sabitleme             | MobileNetV2         | 224             | 700             | 504            | 96,78    |
| Luz (2020)               | Veri Çoğaltma                 | EfficientNet        | 183             | 8066            | 5538           | 93,94    |
| Jain (2021)              | Veri Çoğaltma                 | Xception            | 576             | 1583            | 4273           | 97,97    |

Çizelge 5.2. Tüm stratejiler için elde edilen en başarılı sonuçlar

| Strateji                    | Önişleme                                    | Model     | Covid-19 Sayısı | Sağlıklı Sayısı | Pnömoni Sayısı | Doğruluk |
|-----------------------------|---|-----------|-----------------|-----------------|----------------|----------|
| 1                           | LHE (Kırılmış)<br>60, 100, 120, 140         | MobileNet | 856             | 1000            | 1000           | 0,98     |
| 2                           | LHE (Kırılmış)<br>40                        | DarkNet19 | 856             | 1000            | 1000           | 0,99     |
| 3                           | CLAHE<br>(Kırılmamış)<br>8 - 0,1 ve 8 - 0,6 | DarkNet19 | 428             | 500             | 500            | 0,98252  |
| 4                           | CLAHE<br>(Kırılmamış)<br>16 - 0,7           | DarkNet19 | 3615            | 250             | 250            | 0,72520  |
| 5                           | CLAHE<br>(Kırılmamış)<br>28 - 0,1           | VGG16     | 3615            | 3500            | 3500           | 0,95039  |
| 6<br>(Covid19-<br>Sağlıklı) | CLAHE<br>(Kırılmamış)<br>56 - 0,2           | VGG16     | 3615            | 3500            | -              | 0,95878  |
| 6<br>(Covid19-<br>Pnömoni)  | CLAHE<br>(Kırılmamış)<br>8 - 0,1            | DarkNet19 | 3615            | -               | 3500           | 0,99672  |

## KAYNAKLAR

- Ai, Tao ve diğerleri 2020. “Correlation of Chest CT and RT-PCR Testing for Coronavirus Disease 2019 ( COVID-19 ) in China : A Report of 1014 Cases.” *Radiologic clinics of North America* 296(2).
- Apostolopoulos, Ioannis D., ve Tzani A. Mpesiana. 2020. “Covid-19: Automatic Detection from X-Ray Images Utilizing Transfer Learning with Convolutional Neural Networks.” *Physical and Engineering Sciences in Medicine* 43(2): 635–40. <https://doi.org/10.1007/s13246-020-00865-4>.
- Ashizawa, MD Kazuto ve diğerleri 1999. “Artificial Neural Networks in Chest Radiography: Application to the Differential Diagnosis of Interstitial Lung Disease.” *Academic Radiology* 6(1): 2–9.
- El Asnaoui, Khalid, ve Youness Chawki. 2020. “Using X-Ray Images and Deep Learning for Automated Detection of Coronavirus Disease.” *Journal of Biomolecular Structure and Dynamics*: 1–12. <https://www.tandfonline.com/doi/full/10.1080/07391102.2020.1767212>.
- Avenash, R, ve P Viswanath. 2019. “Semantic Segmentation of Satellite Images Using a Modified CNN with Hard-Swish Activation Function.” *VISIGRAPP*: 413–20.
- Bengio, Yoshua. 2009. “Learning Deep Architectures for AI.” *Foundations and Trends® in Machine Learning*.
- CARUANA, RICH. 1997. “Multitask Learning \*.” 28(1): 41–75.
- Caselles, Vicent, Jose-luis Lisani, Jean-Michel Morel, ve Guillermo Sapiro. 1999. “Shape Preserving Local Histogram Modification.” *IEEE Transactions on Image Processing* 8(2): 220–30.
- Cernazanu-glavan, Cosmin Holban, ve Stefan Holban. 2013. “Segmentation of Bone Structure in X-Ray Images Using Convolutional Neural Network.” *Adv. Electr. Comput. Eng.* 13(1): 87–94.
- Chapelle, O., B. Schölkopf, ve A. Zien. 2009. “Semi-Supervised Learning.” In , 508.
- Chowdhury, Muhammad E.H. ve diğerleri 2020. “Can AI Help in Screening Viral ve COVID-19 Pneumonia?” *arXiv* 8: 132665–76.
- Cireşan, Dan C ve diğerleri 2011. “Flexible , High Performance Convolutional Neural Networks for Image Classification.” *Twenty-second international joint conference on artificial intelligence*.
- Das, Dipayan, K. C. Santosh, ve Umapada Pal. 2020. “Truncated Inception Net: COVID-19 Outbreak Screening Using Chest X-Rays.” *Physical and Engineering Sciences in Medicine* 43(3): 915–25. <https://doi.org/10.1007/s13246-020-00888-x>.
- Deng, Jia ve diğerleri 2009. “ImageNet : A Large-Scale Hierarchical Image Database.” *In 2009 IEEE conference on computer vision and pattern recognition*: 248–55.
- El-solh, Ali A ve diğerleri 1999. “Tuberculosis Using an Artificial Neural Network.” *CHEST*

116(4): 968–73.

- Er, Orhan, Nejat Yumusak, ve Feyzullah Temurtas. 2010. “Chest Diseases Diagnosis Using Artificial Neural Networks. Expert Systems with Applications.” *Expert Systems with Applications* 37(12): 7648–55.
- Gatys, Leon A, Alexander S Ecker, Matthias Bethge, ve C V Sep. 2015. “A Neural Algorithm of Artistic Style.” *arXiv preprint*: 3–7.
- Gonzalez, Rafael C, Richard E Woods, ve Pearson Prentice Hall. 2008. *Digital Image Processing Third Edition Pearson International Edition Prepared by Pearson Education*.
- Gupta, Aman, ve Haohan Wang. 2015. “Learning Structure in Gene Expression Data Using Deep Architectures , with an Application to Gene Clustering.” *Bioinformatics and Biomedicine (BIBM)*: 1328–1335.
- Haghanifar, Arman, Mahdiyaz Molahasani Majdabadi, ve Seokbum Ko. 2020. “COVID-CXNet: Detecting Covid-19 in Frontal Chest x-Ray Images Using Deep Learning.” *arXiv*.
- Han, Song, Huizi Mao, ve William J Dally. 2015. “Deep Compression: Compressing Deep Neural Networks with Pruning, Trained Quantization and Huffman Coding.” *arXiv preprint*: 1–14.
- Hastie, Tj, Rj Tibshirani, ve Jh Friedman. 2009. “Unsupervised Learning. In The Elements of Statistical Learning.” : 485–585.
- He, Kaiming, Xiangyu Zhang, Shaoqing Ren, ve Jian Sun. 2016. “Deep Residual Learning for Image Recognition.” In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, IEEE, 770–78. <http://ieeexplore.ieee.org/document/7780459/>.
- Hemdan, Ezz El-din, Marwa A. Shouman, ve Mohamed Esmail Karar. 2020. “COVIDX-Net : A Framework of Deep Learning Classifiers to Diagnose COVID-19 in X-Ray Images.” *arXiv preprint*.
- Hinton, G E ve diğerleri 2012. “Improving Neural Networks by Preventing Co-Adaptation of Feature Detectors.” *arXiv preprint*: 1–18.
- Hinton, Geoffrey E, Simon Osindero, ve Yee-Whye Teh. 2006. “Communicated by Yann Le Cun A Fast Learning Algorithm for Deep Belief Nets 500 Units 500 Units.” 18(7): 1527–54.
- Horry, Michael ve diğerleri 2020. “X-Ray Image Based COVID-19 Detection Using Pre-Trained Deep Learning Models.”
- Howard, Andrew G ve diğerleri 2017. “MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications.” *arXiv*.
- Hu, Jie, Li Shen, ve Gang Sun. 2018. “Squeeze-and-Excitation Networks.” *Proceedings of the IEEE conference on computer vision and pattern recognition*: 7132–41.
- Hummel, ve Robert A. 1975. “Histogram Modification Techniques.” *Computer Graphics and Image Processing* 4(3): 209–24.

- Hummel, Robert. 1977. "Image Enhancement by Histogram Transformation." *Computer Graphics and Image Processing* 6(2): 184–95. <https://linkinghub.elsevier.com/retrieve/pii/S0146664X77800117>.
- Ioffe, Sergey, ve Christian Szegedy. 2015. "Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift." *International conference on machine learning*. PMLR: 448–56.
- Jaeger, Stefan ve diğerleri 2014. "Automatic Tuberculosis Screening Using Chest Radiographs." *IEEE Transactions on Medical Imaging* 33(2): 233–45.
- Jaehne, Bernd. 1991. "Digital Image Processing: Concepts, Algorithms, and Scientific Applications." In *Springer*.
- Jain, Rachna, Meenu Gupta ve diğerleri. 2021. "Deep Learning Based Detection and Analysis of COVID-19 on Chest X-Ray Images." *Applied Intelligence* 51(3): 1690–1700. <http://link.springer.com/10.1007/s10489-020-01902-1>.
- Jordan, M I, ve T M Mitchell. 2015. "Machine Learning: Trends, Perspectives, and Prospects." 349(6245).
- Kalinovsky, Alexander, ve Vassili Kovalev. 2016. "Lung Image Segmentation Using Deep Learning Methods and Convolutional Neural Networks Deep Learning for Image Analysis View Project UAV: Back to Base Problem View Project Lung Image Segmentation Using Deep Learning Methods and Convolutional Neural Network." *International Conference on Pattern Recognition and Information Processing* (July 2017): 21–24. <http://imlab.grid.by/>.
- Ketcham, ve David J. 1976. "Real-Time Image Enhancement Techniques." *Image processing. International Society for Optics and Photonics* 74: 120–25.
- Kim, Young-Youn, Lee-Sup Kim, ve Seung-Ho Hwang. 2001. "An Advanced Contrast Enhancement Using Partially Overlapped Sub-Block Histogram Equalization." *IEEE transactions on circuits and systems for video technology* 11(4): 475–84.
- Kingma, Diederik P, ve Jimmy Lei Ba. 2014. "ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION." *arXiv preprint*: 1–15.
- Krizhevsky, Alex, Ilya Sutskever, ve Geoffrey E Hinton. 2012. "ImageNet Classification with Deep Convolutional Neural Networks." *Communications of the ACM* 60(6): 84–90. <https://dl.acm.org/doi/10.1145/3065386>.
- Lecun, Y., L. Bottou, Y. Bengio, ve P. Haffner. 1998. "Gradient-Based Learning Applied to Document Recognition." *IEEE* 86(11): 2278–2324.
- LeCun, Yann, Yoshua Bengio, ve Geoffrey Hinton. 2015. "Deep Learning." *Nature* 521: 436–444.
- Li, Yunqing, Wenjun Wang, ve Daoyin Yu. 1994. "Application of Adaptive Histogram Equalization to X-Ray Chest Images." In *Second International Conference on Optoelectronic Science and Engineering '94*, eds. Wang Da-Heng, Anna Consortini, and James B Breckinridge, 513. <http://proceedings.spiedigitallibrary.org/proceeding.aspx?doi=10.1117/12.182056>.



- Lin, Min, Qiang Chen, ve Shuicheng Yan. 2013. "Network In Network." *arXiv preprint*.
- Litjens, Geert ve diğerleri 2017. "A Survey on Deep Learning in Medical Image Analysis." *Medical Image Analysis* 42: 60–88.
- Luz, Eduardo J.S. ve diğerleri. 2020. "Towards an Effective and Efficient Deep Learning Model for COVID-19 Patterns Detection in X-Ray Images." *arXiv*.
- McCulloch, Warren S., ve Walter H. Pitts. 1948. "Originally Published in: Bulletin of Mathematical Biophysics, Vol. 5, 1943, p. 115-133." 5: 115–33.
- Minsky, M., ve S. Papert. 1969. "Perceptrons." *MIT Press, Cambridge, MA*.
- Nair, Vinod, ve Geoffrey E Hinton. "Rectified Linear Units Improve Restricted Boltzmann Machines." *Icml*.
- Osako, Keiichi ve diğerleri 2015. "COMPLEX RECURRENT NEURAL NETWORKS FOR DENOISING SPEECH SIGNALS." : 16–20.
- Ozturk, Tulin ve diğerleri 2020. "Automated Detection of COVID-19 Cases Using Deep Neural Networks with X-Ray Images." *Computers in Biology and Medicine* 121: 103792. <https://linkinghub.elsevier.com/retrieve/pii/S0010482520301621>.
- Pan, Sinno Jialin, ve Qiang Yang. 2010. "A Survey on Transfer Learning IEEE Transactions on Knowledge and Data Engineering." 22(10): 1345–59.
- Patel, Vishal M, Raghuraman Gopalan, Ruonan Li, ve Rama Chellappa. 2015. "Visual Domain Adaptation: A Survey of Recent Advances." *IEEE Signal Processing Magazine* 32(3): 53–69.
- Patil, S. A., ve M. Kuchanur. 2012. "Lung Cancer Classification Using Image Processing." *International Journal of Engineering and Innovative Technology*.
- PaulJ., Werbos. 1974. "Beyond Regression : "New Tools for Prediction and Analysis in the Behavioral Sciences." *Ph. D. dissertation, Harvard University*.
- Pizer, Stephen M. 1986. "Psychovisual Issues in the Display of Medical Images." *Pictorial information systems in medicine, Springer*: 211–33.
- R.Senthilkumar, ve M. Senthilmurugan. 2014. "TRIAD HISTOGRAM TO ENHANCE CHEST X-RAY IMAGE." *International Journal of Advanced Research in Computer and Communication Engineering* 3(11): 8577–80.
- Ramachandran, Prajit, Barret Zoph, ve Quoc V Le. 2017. "SEARCHING FOR ACTIVATION FUNCTIONS." *arXiv preprint*: 1–13.
- Redmon, Joseph, ve Ali Farhadi. "YOLO9000: Better, Faster, Stronger."
- Rosenblatt, F. 1958. "The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain." *Psychological review* 65(6): 386–408.
- Rosenblatt, Frank. 1962. "Principles of Neurodynamics." *Spartan, New York* 15: 27.
- Russakovsky, Olga ve diğerleri 2015. "ImageNet Large Scale Visual Recognition Challenge." *International Journal of Computer Vision (IJCV)* 115(3): 211–252.

- Saha, Prottoy, Muhammad Sheikh Sadi, ve Md Milon Islam. 2021. "EMCNet: Automated COVID-19 Diagnosis from X-Ray Images Using Convolutional Neural Network and Ensemble of Machine Learning Classifiers." *Informatix in Medicine Unlocked* 22: 100505. <https://doi.org/10.1016/j.imu.2020.100505>.
- Selvaraju, Ramprasaath R. ve diğerleri 2017. "Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization." *Proceedings of the IEEE international conference on computer vision*: 1–23.
- Shipp, Margaret Ann ve diğerleri 2002. "Diffuse Large B-Cell Lymphoma Outcome Prediction by Gene-Expression Profiling and Supervised Machine Learning." *Nature Medicine* 8: 68–74.
- Simard, Patrice Y, Dave Steinkraus, ve John C Platt. 2003. "Best Practices for Convolutional Neural Networks Applied to Visual Document Analysis." *Icdar* 3: 1–6.
- Simonyan, Karen, ve Andrew Zisserman. 2014. "Very Deep Convolutional Networks for Large-Scale Image Recognition." *3rd International Conference on Learning Representations, ICLR 2015 - Conference Track Proceedings*. <http://arxiv.org/abs/1409.1556>.
- Singh, Rajeev Kumar, Rohan Pandey, ve Rishie Nandhan Babu. 2021. "COVIDScreen: Explainable Deep Learning Framework for Differential Diagnosis of COVID-19 Using Chest X-Rays." *Neural Computing and Applications*. <http://link.springer.com/10.1007/s00521-020-05636-6>.
- Srivastava, Nitish ve diğerleri 2014. "Dropout : A Simple Way to Prevent Neural Networks from Overfitting." *The journal of machine learning research* 15(1): 1929–58.
- Stephen M.Pizer. 1981. "Intensity Mappings for the Display of Medical Images." *Functional Mapping of Organ Systems and Other Computer Topics*: 205–17.
- Szegedy, Christian ve diğerleri 2015. "Going Deeper with Convolutions." *IEEE conference on computer vision and pattern recognition*: 1–9.
- Tan, Mingxing ve diğerleri 2019. "MnasNet : Platform-Aware Neural Architecture Search for Mobile." *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*: 2820–28.
- Thrun, Sebastian. 1996. "Is Learning The N-Th Thing Any Easier Than Learning The First ?" *Advances in neural information processing systems. MORGAN KAUFMANN PUBLISHERS*: 640–46.
- Wang, Haohan, ve Jingkang Yang. 2016. "Multiple Confounders Correction with Regularized Linear Mixed Effect Models , with Application in Biological Processes." *bioRxiv*.
- Wang, Linda, Zhong Qiu Lin, ve Alexander Wong. 2020. "COVID-Net: A Tailored Deep Convolutional Neural Network Design for Detection of COVID-19 Cases from Chest X-Ray Images." *Scientific Reports* 10(1): 19549. <http://www.nature.com/articles/s41598-020-76550-z>.
- Wang, Shuai ve diğerleri 2021. "Deep Learning Algorithm Using CT Images to Screen for Corona Virus Disease ( COVID-19 )." *IMAGING INFORMATICS AND ARTIFICIAL*

*INTELLIGENCE.*

Yang, Yang ve diğlerleri 2020. "Evaluating the Accuracy of Different Respiratory Specimens in the Laboratory Diagnosis and Monitoring the Viral Shedding of 2019-NCov Infections." *medRxiv*.

Zeiler, Matthew D, ve Rob Fergus. 2014. "Visualizing and Understanding Convolutional Networks." In *Computer Vision – ECCV 2014*, , 818–33.

Zuiderveld, ve Karel. 1994. "Contrast Limited Adaptive Histogram Equalization." *Graphics gems*: 474–



## DİZİN

### A

ADAPTİF · 1, 2, iv  
AHE · xiv, 29, 30, 39, 100  
AlexNet · iv, v, vii, viii, x, xi, xii,  
2, 6, 22, 34, 35, 36, 37, 38, 39,  
42, 43, 44, 45, 47, 48, 49, 50,  
51, 52, 53, 54, 55, 83, 85, 87,  
88, 89, 90, 91, 93, 94, 96  
ARDS · xiv, 8

### B

Bilgisayar Destekli Teşhis · xiv,  
7  
Biyolojik Sinir Ağı Yapısı · xii,  
15  
Bölgesel Histogram Eşitleme · xv

### C

CAD · xiv, 7  
CLAHE · viii, xiv, 10, 12, 13, 29,  
30, 33, 36, 37, 38, 47, 50, 53,  
56, 59, 62, 65, 68, 71, 74, 77,  
80, 86, 88, 90, 96, 97, 99, 101  
CNN · xii, xiv, 6, 7, 8, 10, 14, 16,  
19, 20, 30, 33, 37, 38, 97, 98,  
99, 102  
COVID-19 · 1, 2, iv, v, vii, xiv,  
1, 2, 8, 9, 10, 31, 32, 96, 97,  
99, 102, 103, 104, 105, 106  
COVID-Net · 9, 100, 106  
Covidx · xii, 32, 33, 38, 39, 85,  
86  
CXR · viii, ix, x, xi, xii, xiv, 6, 7,  
8, 10, 27, 28, 30, 31, 32, 33,  
34, 35, 37, 38, 39, 40, 42, 43,

44, 45, 46, 47, 48, 49, 50, 51,  
52, 53, 54, 55, 56, 57, 58, 59,  
60, 61, 62, 63, 64, 65, 66, 67,  
68, 69, 70, 71, 72, 73, 74, 75,  
76, 77, 78, 79, 80, 81, 82, 85,  
86, 88, 90, 93

### Ç

Çok Katmanlı Algılayıcı · xv

### D

DarkNet19 · iv, v, viii, ix, x, xi,  
xii, 2, 24, 25, 35, 36, 37, 38,  
39, 43, 45, 46, 56, 57, 58, 59,  
60, 61, 62, 63, 64, 83, 85, 87,  
88, 89, 90, 91, 95, 96, 97, 98,  
101  
DenseNet121 · 100  
DenseNet201 · 12, 100  
Derin Öğrenme · iv, vii, xiv, 5,  
14, 22, 97  
Derin Sinir Ağları · xiv  
DL · iv, v, xiv, 1, 6, 14, 15, 99  
DNN · xiv, 5

### E

EfficientNet · 100  
Evrişimsel Sinir Ağları · vii, xiv,  
6, 16

### G

GHE · xv, 26  
Global Histogram Eşitleme · xv  
Göğüs Röntgen Filmi · vii, xiv, 6

Grad-CAM · viii, ix, xi, xii, xiii,  
xv, 4, 30, 31, 93, 94, 95, 98,  
106

### H

Histogram Eşitleme · iv, viii, xii,  
2, 9, 13, 25, 26, 27

### I

ILSVRC · xv, 6, 22  
ImageNet · xv, 6, 9, 11, 21, 22,  
102, 104, 105  
Inception · iv, v, 11, 12, 13, 100,  
102

### L

LHE · iv, v, viii, xii, xv, 26, 27,  
28, 29, 33, 34, 35, 42, 43, 44,  
45, 46, 93, 101  
LİTERATÜR TARAMASI · vii,  
5

### M

Makine Öğrenimi · xv, 5  
MobileNet · iv, v, viii, x, xi, xii,  
2, 9, 11, 23, 24, 34, 36, 37, 38,  
39, 42, 43, 65, 66, 67, 68, 69,  
70, 71, 72, 73, 84, 85, 87, 88,  
89, 90, 91, 93, 95, 96, 101  
Motivasyon · vii, 1

---

**Ö**

Öğrenme aktarımı · vii, 20, 21,  
97  
Öğrenme Aktarımı · xv, 11

---

**P**

Pnömoni · iv, vii, ix, xi, xii, xiii,  
2, 3, 8, 11, 31, 32, 33, 38, 85,  
86, 90, 91, 92, 99, 100, 101

---

**R**

ResNet18 · 12, 100  
Röntgen Filmi · xv

---

**S**

Stratejiler · viii, ix, x, xi, xii, xiii,  
3, 33, 34, 35, 36, 37, 38, 39,

40, 42, 43, 44, 45, 46, 47, 83,  
84, 85, 86, 88, 90, 92, 93, 94,  
95, 97, 99, 101

---

**T**

Tezin Kapsamı · vii, 2  
Tezin Önemi ve Farklılıkları · vii,  
2

---

**U**

Ulusal Sağlık Enstitüleri Klinik  
Merkezi · xv, 2  
Uyarlanabilir Histogram Eşitleme  
· iv, xiv, 2, 10

---

**V**

Veri Seti · viii, 31, 37

VGG16 · iv, v, viii, x, xi, xii, 2,  
12, 13, 22, 34, 36, 37, 38, 39,  
43, 74, 75, 76, 77, 78, 79, 80,  
81, 82, 84, 86, 88, 90, 92, 93,  
94, 96, 97, 101

VGG19 · 9, 11, 12, 13, 88, 90,  
100  
VGGNet · vii, 6, 22

---

**X**

Xception · 11, 13, 100  
X-Ray · iv, v, xv, 1, 2, 102, 103,  
104, 105, 106

---

**Y**

Yapay Sinir Ağları · xv, 5  
YOLOv2 · 24



**TEKNOVERSITE**



teknoversite **AYRICALIĞINDASINIZ**

**İSTE**

