

T.C.  
ERZİNCAN BİNALİ YILDIRIM ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS

BİLGİSAYARLI TOMOGRAFİ (BT) GÖRÜNTÜLERİNDEN  
AKCİĞER KANSER HÜCRELERİNİN YAPAY ZEKÂ  
TEKNİKLERİ İLE BULUNMASI

Muhittin GENÇ

Danışman: Dr. Öğr. Üyesi Funda AKAR

YAPAY ZEKA VE ROBOTİK  
ANABİLİM DALI

ERZİNCAN  
2024  
Her Hakkı Saklıdır.

## ÖZET

Yüksek Lisans Tezi

### **BİLGİSAYARLI TOMOGRAFİ (BT) GÖRÜNTÜLERİNDEN AKCİĞER KANSER HÜCRELERİNİN YAPAY ZEKÂ TEKNİKLERİ İLE BULUNMASI**

Muhittin GENÇ

Erzincan Binali Yıldırım Üniversitesi  
Fen Bilimleri Enstitüsü  
Yapay Zekâ ve Robotik Anabilim Dalı

Danışman: Dr. Öğr. Üyesi Funda AKAR

Akciğer kanseri, dünya genelinde yüksek ölüm oranlarına sahip ölümcül bir hastalık olarak öne çıkmaktadır. Erken teşhis, hastalığın etkili bir şekilde tedavi edilebilmesi açısından kritik bir öneme sahiptir. Bu çalışma, akciğer kanserinin erken teşhisinde yapay zekâ tekniklerinin rolünü incelemekte ve sağladığı avantajları vurgulamaktadır. Bu bağlamda, yapay zekâ destekli teşhis sistemlerinin, radyologların iş yükünü azaltarak doğruluk oranlarını artırma potansiyeli, akciğer kanseri teşhisindeki yöntemleri önemli ölçüde iyileştirebileceği öngörülmektedir.

Bu çalışmada, Evrişimli Sinir Ağları (CNN) ve YOLO algoritması kullanılarak gerçekleştirilen akciğer kanseri teşhisinde elde edilen sonuçlar değerlendirilmiştir. Hem CNN hem de YOLO modelinin medikal görüntüler üzerindeki başarısı, 6 farklı veri seti üzerinden karşılaştırılarak analiz edilmiştir. Tüm veri setleri arasında, CNN modeli için en yüksek F1-Skoru %99,85 ile histogram eşitleme ve kontrast sınırlı uyarlanabilir histogram eşitlemesi yapılan veri seti üzerinde elde edilmiştir. YOLO modeli için ise yine aynı ön işleme tekniği uygulanan veri setinde en yüksek F1-Skoru %96 olarak elde edilmiştir.

**2024, 91 Sayfa**

**Anahtar Kelimeler:** Akciğer kanseri, Derin öğrenme, Erken teşhis, Evrişimli sinir ağları (CNN), YOLO algoritması, Yapay zekâ

## **ABSTRACT**

MSc Thesis

### **DETECTION OF LUNG CANCER FROM COMPUTED TOMOGRAPHY (CT) SCANS USING ARTIFICIAL INTELLIGENCE TECHNIQUES**

Muhittin GENC

Erzincan Binali Yıldırım University  
Graduate School of Natural and Applied Sciences  
Department of Artificial Intelligence and Robotics

Supervisor: Asist. Prof. Dr. Funda AKAR

Lung cancer stands out as a deadly disease with high mortality rates worldwide. Early diagnosis is critical for effective treatment of the disease. This study investigates the role of artificial intelligence techniques in early diagnosis of lung cancer and highlights the advantages they provide. In this context, it is predicted that AI-assisted diagnostic systems can significantly improve the methods in lung cancer diagnosis by reducing the workload of radiologists and increasing accuracy rates.

In this study, results obtained in lung cancer diagnosis using Convolutional Neural Networks (CNN) and YOLO algorithm have been evaluated. The success of both CNN and YOLO model on medical images was compared and analyzed over 6 different datasets. Among all datasets, the highest F1-Score for the CNN model was obtained on the dataset that was subjected to histogram equalization and contrast limited adaptive histogram equalization (CLAHE) with 99.85%. For the YOLO model, the highest F1-Score was obtained at 96% on the dataset where the same preprocessing technique was applied.

**2024, 91 Pages**

**Keywords:** Artificial intelligence, Convolutional neural networks (CNN), Deep learning, Early diagnosis, Lung cancer, YOLO algorithm

## TEŞEKKÜR

Bu tezin hazırlanmasında bana büyük destek sağlayan herkese minnettarım. Öncelikle, yüksek lisans eğitimim süresince değerli rehberliği, desteği ve sabrıyla yol gösteren tez danışmanım Dr. Öğretim Üyesi Funda AKAR'a en içten teşekkürlerimi sunarım. Bilgi ve deneyimlerini benimle paylaştığı ve beni her zaman cesaretlendirdiği için kendisine minnettarım.

Hayatım boyunca bana verdiği değerli öğütler, koşulsuz sevgi ve anlayışı için çok sevdiğim anneme, aileme ve arkadaşlarıma sonsuz teşekkürlerimi sunarım. Onların desteği ve sevgisi, bu zorlu yolculuğu tamamlamamda bana güç verdi.

Bu tez çalışmasını, akciğer kanserinden aramızdan ayrılan danışman hocamın babası Yılmaz VAZGEÇER'e ithaf etmek istiyorum.

Muhittin GENÇ

Temmuz, 2024

## İÇİNDEKİLER

Sayfa

|                                                                        |            |
|------------------------------------------------------------------------|------------|
| <b>ÖZET.....</b>                                                       | <b>i</b>   |
| <b>ABSTRACT .....</b>                                                  | <b>ii</b>  |
| <b>TEŞEKKÜR .....</b>                                                  | <b>iii</b> |
| <b>İÇİNDEKİLER .....</b>                                               | <b>iv</b>  |
| <b>ŞEKİLLER LİSTESİ.....</b>                                           | <b>vii</b> |
| <b>TABLolar LİSTESİ.....</b>                                           | <b>xi</b>  |
| <b>SİMGELER VE KISALTMALAR .....</b>                                   | <b>xii</b> |
| <b>1. GİRİŞ.....</b>                                                   | <b>1</b>   |
| 1.1. Akciğer Kanseri Türleri .....                                     | 4          |
| 1.2. Akciğer Kanseri Teşhisinde Kullanılan Görüntüleme Yöntemleri..... | 5          |
| <b>2. KAYNAK ÖZETLERİ .....</b>                                        | <b>9</b>   |
| <b>3. KURAMSAL TEMELLER.....</b>                                       | <b>17</b>  |
| 3.1. Yapay Zekâ .....                                                  | 17         |
| 3.2. Makine öğrenimi (ML) .....                                        | 18         |
| 3.2.1. Makine öğrenmesi algoritmaları .....                            | 19         |
| 3.2.2. Makine öğrenmesinin uygulamaları .....                          | 19         |
| 3.2.3. Makine öğrenmesinin zorlukları .....                            | 19         |
| 3.3. Yapay sinir ağları (ANN).....                                     | 20         |
| 3.3.1. ANN uygulama alanları .....                                     | 21         |
| 3.4. Derin öğrenme (DL) .....                                          | 22         |
| 3.4.1. Derin öğrenmenin temel özellikleri .....                        | 22         |
| 3.4.2. Derin öğrenme uygulama alanları.....                            | 22         |
| 3.4.3. Derin öğrenmenin zorlukları.....                                | 23         |
| 3.5. Evrişimli sinir ağları (CNN) .....                                | 23         |
| 3.6. YOLO (You only look once) .....                                   | 25         |
| 3.6.1. YOLOv8'in temel özellikleri: .....                              | 25         |
| 3.7. Doğal dil işleme (NLP) .....                                      | 28         |
| 3.7.1. NLP'nin temel görevleri.....                                    | 28         |
| 3.7.2. NLP uygulamaları.....                                           | 28         |
| 3.7.3. NLP'nin zorlukları.....                                         | 29         |
| 3.8. Bilgisayarlı görü (Computer vision) .....                         | 29         |

|                                                                                 |           |
|---------------------------------------------------------------------------------|-----------|
| 3.8.1. Bilgisayarlı görünün temel görevleri .....                               | 29        |
| 3.8.2. Bilgisayarlı görü uygulamaları .....                                     | 30        |
| 3.8.3. Bilgisayarlı görünün zorlukları .....                                    | 30        |
| 3.9. Aktivasyon Fonksiyonları .....                                             | 30        |
| 3.9.1. Sigmoid .....                                                            | 31        |
| 3.9.2. Softmax .....                                                            | 31        |
| 3.9.3. ReLu .....                                                               | 32        |
| 3.9.4. Leaky ReLu .....                                                         | 33        |
| 3.9.5. PReLU .....                                                              | 34        |
| 3.9.6. ELU .....                                                                | 35        |
| 3.9.7. Tanh .....                                                               | 36        |
| 3.10. Optimizasyon Fonksiyonları .....                                          | 37        |
| 3.10.1. Adaptive gradient (AdaGrad) .....                                       | 38        |
| 3.10.2. Root mean square propagation (RMSprop) .....                            | 38        |
| 3.10.3. Stochastic gradient descent (SGD) .....                                 | 38        |
| 3.10.4. Adaptive moment estimation (Adam) .....                                 | 38        |
| 3.10.5. Adamax .....                                                            | 39        |
| 3.11. Derin Öğrenme Modellerinde Kullanılan Başarı Parametreleri .....          | 39        |
| 3.11.1. Sınıflandırma problemleri için kullanılan metrikler .....               | 39        |
| 3.11.2. Regresyon problemleri için kullanılan metrikler .....                   | 42        |
| 3.11.3. Genel metrikler .....                                                   | 43        |
| 3.11.4. Nesne tespiti için kullanılan metrikler .....                           | 44        |
| <b>4. MATERYAL ve YÖNTEM .....</b>                                              | <b>46</b> |
| 4.1. Veri Setlerinin Hazırlanması .....                                         | 46        |
| 4.1.1. YOLO veri setleri .....                                                  | 48        |
| 4.1.2. CNN veri setleri .....                                                   | 48        |
| 4.2. Filtreleme .....                                                           | 50        |
| 4.3. Modellerin Uygulanması .....                                               | 54        |
| 4.3.1. CNN modeli .....                                                         | 54        |
| 4.3.2. YOLO modeli .....                                                        | 55        |
| <b>5. ARAŞTIRMA BULGULARI .....</b>                                             | <b>57</b> |
| 5.1. Set A'ya Ait Çalışma Bulguları .....                                       | 57        |
| 5.1.1. CNN modelinin CNN_Set A veri setine ait performans değerlendirmesi ..... | 57        |

|                                                                             |           |
|-----------------------------------------------------------------------------|-----------|
| 5.1.2. YOLO modelinin YOLO_Set A veri setine ait performans deęerlendirmesi | 62        |
| 5.2. Set B'ye Ait alıřma Bulguları .....                                   | 70        |
| 5.2.1. CNN modelinin CNN_Set B veri setine ait performans deęerlendirmesi . | 70        |
| 5.2.2. YOLO modelinin YOLO_Set B veri setine ait performans deęerlendirmesi | 75        |
| <b>6. SONUÇ .....</b>                                                       | <b>82</b> |
| <b>7. TARTIřMA .....</b>                                                    | <b>86</b> |
| <b>KAYNAKLAR .....</b>                                                      | <b>87</b> |



## ŞEKİLLER LİSTESİ

### Sayfa

|                                                                                                                                                                                                                |    |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| Şekil 1.1. 2022 verilerine göre dünya geneli kanser vakaları (GLOBOCAN, 2024a) .....                                                                                                                           | 1  |
| Şekil 1.2. 2022 verilerine göre Türkiye geneli kanser vakaları (GLOBOCAN, 2024b) ..                                                                                                                            | 2  |
| Şekil 1.3. Dünyada ve ülkemizde görülen kanser türlerinin mortalite oranları<br>(GLOBOCAN, 2024b, 2024a) .....                                                                                                 | 2  |
| Şekil 1.4. Türkiye’de görülen kanser vakalarının cinsiyete göre dağılımları<br>(GLOBOCAN, 2024b) .....                                                                                                         | 3  |
| Şekil 1.5. Göğüs radyografisi (röntgen) .....                                                                                                                                                                  | 6  |
| Şekil 1.6. Bilgisayarlı tomografi görüntüsü .....                                                                                                                                                              | 6  |
| Şekil 1.7. Manyetik rezonans görüntüsü .....                                                                                                                                                                   | 6  |
| Şekil 1.8. Pozitron emisyon tomografi görüntüsü .....                                                                                                                                                          | 7  |
| Şekil 1.9. Kemik sintigrafisi .....                                                                                                                                                                            | 7  |
| Şekil 3.1. Yapay zekâ bileşenleri .....                                                                                                                                                                        | 18 |
| Şekil 3.2. Yapay sinir ağları .....                                                                                                                                                                            | 20 |
| Şekil 3.3. CNN Mimarisi .....                                                                                                                                                                                  | 23 |
| Şekil 3.4. YOLO v8 mimarisi (GitHub user RangeKing, 2023) .....                                                                                                                                                | 26 |
| Şekil 3.5. YOLO ızgara sistemi (Redmon vd., 2015) .....                                                                                                                                                        | 27 |
| Şekil 3.6. YOLO tespit sistemi (Redmon vd., 2015) .....                                                                                                                                                        | 28 |
| Şekil 3.7. Sigmoid fonksiyonu .....                                                                                                                                                                            | 31 |
| Şekil 3.8. Softmax fonksiyonu .....                                                                                                                                                                            | 32 |
| Şekil 3.9. ReLu fonksiyonu .....                                                                                                                                                                               | 33 |
| Şekil 3.10. Leaky ReLu fonksiyonu .....                                                                                                                                                                        | 34 |
| Şekil 3.11. PReLU fonksiyonu .....                                                                                                                                                                             | 34 |
| Şekil 3.12. ELU fonksiyonu .....                                                                                                                                                                               | 35 |
| Şekil 3.13. ROC eğrisi ve AUC alanı .....                                                                                                                                                                      | 41 |
| Şekil 3.14. Karmaşıklık Matrisinin Gösterimi .....                                                                                                                                                             | 43 |
| Şekil 4.1. Uygulamanın akış şeması .....                                                                                                                                                                       | 47 |
| Şekil 4.2. CNN ve YOLO modeli için kullanılan Set A veri setine ait örnek görüntüler,<br>(a) Orijinal görüntü (b) Gabor filtresi uygulanmış görüntü (c) Histogram eşitleme +<br>CLAHE uygulanmış görüntü ..... | 50 |

|                                                                                                                                                                                                                       |    |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 4.3.</b> CNN ve YOLO modeli için kullanılan Set B veri setine ait örnek görüntüler,<br>(a) Orijinal görüntü (b) Gabor filtresi uygulanmış görüntü (c) Histogram eşitleme +<br>CLAHE uygulanmış görüntü ..... | 50 |
| <b>Şekil 4.4.</b> a) Orijinal görüntü, b) Gabor filtresi uygulanmış görüntü .....                                                                                                                                     | 51 |
| <b>Şekil 4.5.</b> a) Orijinal görüntü, b) Histogramı eşitlenen görüntü .....                                                                                                                                          | 52 |
| <b>Şekil 4.6.</b> a) Orijinal görüntü, b) CLAHE filtresi uygulanmış görüntü .....                                                                                                                                     | 53 |
| <b>Şekil 4.7.</b> a) Orijinal görüntü, b) Histogram eşitleme+CLAHE filtresi uygulanan<br>görüntü. ....                                                                                                                | 54 |
| <b>Şekil 4.8.</b> Akciğer tümörü tespiti için geliştirilmiş CNN sınıflandırıcısı .....                                                                                                                                | 55 |
| <b>Şekil 5.1.</b> CNN_Set A veri seti %60-%20-%20 bölme durumunda (a) ORJ_V1, (b)<br>GAB_V2 ve (c) HE+CLH_V3 doğruluk eğrileri.....                                                                                   | 57 |
| <b>Şekil 5.2.</b> CNN_Set A veri seti %70-%20-%10 bölme durumunda (a) ORJ_V1, (b)<br>GAB_V2 ve (c) HE+CLH_V3 doğruluk eğrileri.....                                                                                   | 57 |
| <b>Şekil 5.3.</b> CNN_Set A veri seti %60-%20-%20 bölme durumunda (a) ORJ_V1, (b)<br>GAB_V2 ve (c) HE+CLH_V3 kayıp eğrileri .....                                                                                     | 58 |
| <b>Şekil 5.4.</b> CNN_Set A veri seti %70-%20-%10 bölme durumunda (a) ORJ_V1, (b)<br>GAB_V2 ve (c) HE+CLH_V3 kayıp eğrileri .....                                                                                     | 58 |
| <b>Şekil 5.5.</b> CNN_Set A veri seti %60-%20-%20 bölme için (a) ORJ_V1, (b) GAB_V2 ve<br>(c) HE+CLH_V3 karmaşıklık matrisleri.....                                                                                   | 61 |
| <b>Şekil 5.6.</b> CNN_Set A veri seti 70-20-10 bölme için (a) ORJ_V1, (b) GAB_V2 ve (c)<br>HE+CLH_V3 karmaşıklık matrisleri .....                                                                                     | 61 |
| <b>Şekil 5.7.</b> YOLO_Set A veri seti %60-%20-%20 bölme için ORJ_V1 doğruluk ve kayıp<br>eğrileri .....                                                                                                              | 63 |
| <b>Şekil 5.8.</b> YOLO_Set A veri seti %60-%20-%20 bölme için GAB_V2 doğruluk ve<br>kayıp eğrileri .....                                                                                                              | 64 |
| <b>Şekil 5.9.</b> YOLO_Set A veri seti %60-%20-%20 bölme için HE+CLH_V3 doğruluk ve<br>kayıp eğrileri .....                                                                                                           | 64 |
| <b>Şekil 5.10.</b> YOLO_Set A veri seti %70-%20-%10 bölme için ORJ_V1 doğruluk ve<br>kayıp eğrileri .....                                                                                                             | 65 |
| <b>Şekil 5.11.</b> YOLO_Set A veri seti %70-%20-%10 bölme için GAB_V2 doğruluk ve<br>kayıp eğrileri .....                                                                                                             | 65 |

|                                                                                                                                     |    |
|-------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 5.12.</b> YOLO_Set A veri seti %70-%20-%10 bölme için HE+CLH_V3 doğruluk ve kayıp eğrileri .....                           | 66 |
| <b>Şekil 5.13</b> YOLO_Set A veri seti %60-%20-%20 bölme için (a) ORJ_V1, (b) GAB_V2 ve (c) HE+CLH_V3 karmaşıklık matrisleri .....  | 69 |
| <b>Şekil 5.14.</b> YOLO_Set A veri seti %70-%20-%10 bölme için (a) ORJ_V1, (b) GAB_V2 ve (c) HE+CLH_V3 karmaşıklık matrisleri ..... | 69 |
| <b>Şekil 5.15.</b> CNN_Set B veri seti %60-%20-%20 bölme için (a) ORJ_V1, (b) GAB_V2 ve (c) HE+CLH_V3 doğruluk eğrileri .....       | 70 |
| <b>Şekil 5.16.</b> CNN_Set B veri seti %70-%20-%10 bölme için (a) ORJ_V1, (b) GAB_V2 ve (c) HE+CLH_V3 doğruluk eğrileri .....       | 70 |
| <b>Şekil 5.17.</b> CNN_Set B veri seti %60-%20-%20 bölme için (a) ORJ_V1, (b) GAB_V2 ve (c) HE+CLH_V3 kayıp eğrileri .....          | 71 |
| <b>Şekil 5.18.</b> CNN_Set B veri seti %70-%20-%10 bölme için (a) ORJ_V1, (b) GAB_V2 ve (c) HE+CLH_V3 kayıp eğrileri .....          | 71 |
| <b>Şekil 5.19.</b> CNN_Set B veri seti %60-%20-%20 bölme için (a) ORJ_V1, (b) GAB_V2 ve (c) HE+CLH_V3 karmaşıklık matrisleri .....  | 74 |
| <b>Şekil 5.20.</b> CNN_Set B veri seti %70-%20-%10 bölme için (a) ORJ_V1, (b) GAB_V2 ve (c) HE+CLH_V3 karmaşıklık matrisleri .....  | 74 |
| <b>Şekil 5.21.</b> YOLO_Set B veri seti %60-%20-%20 bölme için ORJ_V1 doğruluk ve kayıp eğrileri .....                              | 75 |
| <b>Şekil 5.22.</b> YOLO_Set B veri seti %60-%20-%20 bölme için GAB_V2 doğruluk ve kayıp eğrileri .....                              | 75 |
| <b>Şekil 5.23.</b> YOLO_Set B veri seti %60-%20-%20 bölme için HE+CLH_V3 doğruluk ve kayıp eğrileri .....                           | 76 |
| <b>Şekil 5.24.</b> YOLO_Set B veri seti %70-%20-%10 bölme için ORJ_V1 doğruluk ve kayıp eğrileri .....                              | 76 |
| <b>Şekil 5.25.</b> YOLO_Set B veri seti %70-%20-%10 bölme için GAB_V2 doğruluk ve kayıp eğrileri .....                              | 77 |
| <b>Şekil 5.26.</b> YOLO_Set B veri seti %70-%20-%10 bölme için HE+CLH_V3 doğruluk ve kayıp eğrileri .....                           | 77 |
| <b>Şekil 5.27.</b> YOLO_Set B veri seti %60-%20-%10 bölme için (a) ORJ_V1, (b) GAB_V2 ve (c) HE+CLH_V3 karmaşıklık matrisleri ..... | 81 |

|                                                                                                                                       |    |
|---------------------------------------------------------------------------------------------------------------------------------------|----|
| <b>Şekil 5.28.</b> YOLO_Set B veri seti %70-%20-%10 bölme için (a) ORJ_V1, (b) GAB_V2<br>ve (c) HE+CLH_V3 karmaşıklık matrisleri..... | 81 |
| <b>Şekil 6.1.</b> CNN HE+CLH_V3'ün görüntüleri sınıflandırma süreleri.....                                                            | 83 |
| <b>Şekil 6.2.</b> Örnek YOLO çıktıları.....                                                                                           | 85 |



## TABLÖLAR LİSTESİ

|                                                        | Sayfa |
|--------------------------------------------------------|-------|
| <b>Tablo 4.1.</b> Veri setlerinin adlandırılması.....  | 49    |
| <b>Tablo 4.2.</b> CNN ve YOLO veri seti bilgileri..... | 49    |
| <b>Tablo 4.3.</b> Yöntemlerin adlandırılması.....      | 49    |
| <b>Tablo 4.4.</b> CNN ve YOLO eğitim süreleri .....    | 55    |
| <b>Tablo 5.1.</b> CNN_Set A model sonuçları.....       | 59    |
| <b>Tablo 5.2.</b> YOLO_Set A model sonuçları.....      | 67    |
| <b>Tablo 5.3.</b> CNN_Set B model sonuçları.....       | 72    |
| <b>Tablo 5.4.</b> YOLO_Set B model sonuçları .....     | 79    |
| <b>Tablo 6.1.</b> Modellerin sonuçları .....           | 82    |
| <b>Tablo 6.2.</b> CNN HE+CLH_V3 test sonuçları.....    | 83    |

## SİMGELER VE KISALTMALAR


|          |                                                  |
|----------|--------------------------------------------------|
| Adagrad  | Adaptive Gradient Algorithm                      |
| Adam     | Adaptive Moment Estimation                       |
| ANN      | Artificial Neural Network                        |
| AP       | Average Precision                                |
| BiFPN    | Bi-directional Feature Pyramid Network           |
| BT       | Bilgisayarlı Tomografi                           |
| CLAHE    | Contrast Limited Adaptive Histogram Equalization |
| CNN      | Convolutional Neural Network                     |
| CPU      | Central Processing Unit                          |
| CSIP     | Class Selective Image Processing                 |
| DNN      | Deep Neural Network                              |
| DenseNet | Densely Connected Convolutional Network          |
| DVM      | Destek Vektör Makineleri                         |
| IGWA     | Doğaçlama Gri Kurt Algoritması                   |
| ELU      | Exponential Linear Unit                          |
| XGBoost  | Extreme Gradient Boosting                        |
| Xception | Extreme Inception                                |
| GPU      | Graphics Processing Unit                         |
| ICSA     | Incremental Crow Search Algorithm                |
| IoU      | Intersection over Union                          |
| KHAK     | Küçük Hücreli Akciğer Kanseri                    |
| KHDAK    | Küçük Hücreli Dışı Akciğer Kanseri               |
| K-NN     | K-Nearest Neighbors                              |
| LDA      | Local Discriminant Analysis                      |
| LSTM     | Long Short-Term Memory                           |
| mAP      | Mean Average Precision                           |
| MRG      | Manyetik Rezonans Görüntüleme                    |
| PET      | Pozitron Emisyon Tomografisi                     |
| PreLU    | Parametric Rectified Linear Unit                 |
| RAM      | Random Access Memory                             |

|         |                                            |
|---------|--------------------------------------------|
| RCNN    | Regions with Convolutional Neural Networks |
| ReLu    | Rectified Linear Unit                      |
| ResNet  | Residual Neural Network                    |
| RMSprop | Root Mean Square Propagation               |
| RNA-Seq | RNA Sequencing                             |
| RNN     | Recurrent Neural Network                   |
| SAE     | Stacked Autoencoder                        |
| SDS     | Stochastic Diffusion Search                |
| SGD     | Stochastic Gradient Descent                |
| SSA     | Salp Swarm Algorithm                       |
| SSD     | Single Shot MultiBox Detector              |
| TCGA    | The Cancer Genome Atlas                    |
| VGG-19  | Visual Geometry Group                      |
| WHO     | World Health Organization                  |
| YZ      | Yapay Zekâ                                 |
| YOLO    | You Only Look Once                         |

## 1. GİRİŞ

Akciğer kanseri, akciğer dokusundaki hücrelerin kontrol dışı bir şekilde çoğalması sonucunda ortaya çıkan ve hastanın normal nefes almasını zorlaştıran ciddi bir hastalıktır. Bu kanser türü, DNA yapısındaki bozulmaların oluşmasıyla başlar ve bu hasar, tümör adı verilen anormal bir kütlenin oluşmasına neden olarak hücrelerin aşırı çoğalmasına yol açar (Yan ve Razmjoooy, 2023).


Her yıl milyonlarca insanı etkileyen bu hastalık hem gelişmiş hem de gelişmekte olan ülkeler için önemli bir halk sağlığı sorunudur. Akciğer kanseri, dünya genelindeki tüm kanser türleri arasında en ölümcül olanıdır. Şekil 1.1’de görüldüğü gibi Dünya Sağlık Örgütü’nün (WHO) açıkladığı verilere göre 2022 yılında dünya çapında 1,8 milyon kişi akciğer kanseri sebebiyle hayatını kaybetmiş ve 2,5 milyon yeni akciğer kanseri vakası görülmüştür (GLOBOCAN, 2024a).



**Şekil 1.1.** 2022 verilerine göre dünya geneli kanser vakaları (GLOBOCAN, 2024a)


Şekil 1.2’de Türkiye’de 2022 yılında görülen kanser vakalarının insidans ve ölüm oranları gösterilmiştir. Ülkemizde görülen kanser türleri içinde akciğer kanserinin görülme oranı %17,1 olarak belirlenmiş ve 38.505 kişi hayatını kaybetmiştir. Yine 2022 yılında 5 yıllık zaman zarfında akciğer kanserinin görülme sıklığı yüz binde sekiz olarak tespit edilmiştir. Dünya genelinde ise bu zaman zarfında kanserin görülme olasılığı yüz binde altı olarak saptanmıştır.

2020 verileri baz alındığında erkeklerde dünyada akciğer kanserinin en sık görüldüğü ülke Türkiye olarak belirlenmiştir (GLOBOCAN, 2021).



Şekil 1.2. 2022 verilerine göre Türkiye geneli kanser vakaları (GLOBOCAN, 2024b)


Şekil 1.3'te dünyada ve Türkiye'de en yaygın görülen kanser türlerinin ölüm oranlarını gösteren sütun grafikleri yer almaktadır.



Şekil 1.3. Dünyada ve ülkemizde görülen kanser türlerinin mortalite oranları (GLOBOCAN, 2024b, 2024a).

Dünya genelinde en ölümcül kanser türü %34,90 ile akciğer kanseriyken, onu %17,37 ile kolorektal kanser izlemektedir, Türkiye genelinde de en ölümcül kanser türü %49,12 ile akciğer kanseridir. Bunu %14,90 ile kolorektal kanser takip etmektedir. Genel olarak, her iki grafikte de akciğer kanseri en ölümcül kanser türü olarak yer almaktadır. Türkiye'de akciğer kanserinin ölüm oranı, dünya genelinden daha yüksektir. Bu durum, Türkiye'de sigara kullanımı oranlarının yüksek olması ve hava kirliliğinin daha yoğun olmasıyla ilişkilendirilebilir.

Ülkemizde 2022 yılında raporlanan kanser türlerinin cinsiyete göre görülme oranları ve ölüm oranları Şekil 1.4'te belirtilmiştir. Grafikteki değerler incelendiğinde kanser vakalarında akciğer kanseri, erkeklerde en sık görülen ve en ölümcül kanser türü olarak öne çıkmaktadır. 33.039 insidans ve 32.119 ölüm sayısı ile diğer kanser türlerinden önemli ölçüde daha yaygındır. Bu durum, sigara içme gibi risk faktörlerinin kontrol altına alınması ve akciğer kanseri taraması programlarının önemini vurgulamaktadır. 17.274 insidans sayısı ile prostat kanseri ikinci sırada yer almaktadır. Ancak, ölüm sayısı (5.428) akciğer kanserine göre oldukça düşüktür. Bu, prostat kanseri için daha etkili tedavi seçeneklerinin mevcut olduğunu gösterir. 11.168 insidans ve 3.359 ölüm sayısı ile mesane kanseri, erkekler için diğer önemli bir sağlık sorunudur.



**Şekil 1.4.** Türkiye’de görülen kanser vakalarının cinsiyete göre dağılımları (GLOBOCAN, 2024b).

Kadınlarda ise en sık görülen kanser türü meme kanseridir. 25.249 insidans sayısı ile diğer kanser türlerinden çok daha yüksek bir orana sahiptir. 12.425 insidans sayısı ile tiroid kanseri ikinci sırada yer almaktadır. Ancak, ölüm sayısı (583) diğer kanser türlerine göre oldukça düşüktür. Kadınlarda sıklıkla görülen bir diğer kanser türü ise 10.054 insidans ve 5.560 ölüm sayısı ile kolorektal kanserdir. Kadınlarda akciğer kanseri insidans olarak dördüncü sırada yer almasına rağmen, ölüm sayısı (6.386) diğer kanser türlerine göre oldukça yüksektir. Bu durum, akciğer kanserinin genellikle geç evrede teşhis edildiğini ve daha kötü bir prognoza sahip olduğunu göstermektedir.

Amerika Birleşik Devletleri’nde yapılan bir çalışma ile, bir kişinin akciğer kanserine yakalanma olasılığı %6,1 olarak tahmin edilmiştir. Bununla birlikte, sigara içenlerin içmeyenlere göre akciğer kanserine yakalanma olasılığının 15 ile 30 kat daha yüksek olduğu belirlenmiştir. Türkiye Kanser İstatistikleri 2018 raporuna göre, en sık görülen

kanser türü akciğer kanseri olup, prevalansı %21 olarak saptanmıştır. Akciğer kanserinin başlıca nedeninin tütün ve tütün mamulleri olduğu bilinmektedir. Dünya genelinde akciğer kanserine yakalanan kişilerin %80'inin sigara içtiği veya yaşamlarının belli dönemlerinde tütün ürünlerini kullandıkları bilinmektedir. Ülkemizde ise bu oran %90 olarak tespit edilmiştir. Akciğer kanserine neden olan diğer faktörler arasında pasif sigara içiciliği, asbest, genetik faktörler ve radyasyon bulunmaktadır. Kadınlarda akciğer kanserine yakalanma oranı giderek artmaktadır. 1987 yılından sonra kadınlarda akciğer kanserinden ölme sıklığının meme kanserinden yaklaşık 1,4 kat daha fazla olduğu belirlenmiştir. Hastalara mümkün olan en erken evrede tedavi şansı sunulduğunda, hastalar genellikle daha uzun bir yaşam süresine sahip olmaktadır. Araştırmalarda, tanı gecikmelerinin özellikle ilgili kanser merkezine ulaşmada zorluk yaşayan, sosyoekonomik düzeyi düşük ve kırsal kesimlerde ikamet eden gruplarda daha belirgin olduğu ve bu durumun mortalitenin artışıyla ilişkilendirildiği gösterilmiştir (Türk Toraks Derneği, 2023).

### 1.1. Akciğer Kanseri Türleri

Akciğer kanseri, genellikle mikroskop altında kanser hücrelerinin görünümüne ve davranışlarına göre iki ana gruba ayrılır: Küçük Hücreli Akciğer Kanseri (KHAK) ve Küçük Hücreli Dışı Akciğer Kanseri (KHDAK). Bu iki ana tür, farklı özelliklere, tedavi seçeneklerine ve prognozlara sahiptir.

- **Küçük hücreli dışı akciğer kanseri (KHDAK)**

KHDAK, tüm akciğer kanseri vakalarının yaklaşık %80-85'ini oluşturur. Genellikle sigara içenlerde görülür, ancak sigara içmeyenlerde de gelişebilir. KHDAK, KHAK'a göre daha yavaş büyür ve vücudun diğer bölgelerine yayılma (metastaz yapma) eğilimi daha azdır. KHDAK, hücre tipine göre daha da alt gruplara ayrılır. En yaygın alt türleri şunlardır:

- ✓ **Adenokarsinom:** Akciğerlerin dış kısımlarında, mukus üreten hücrelerde başlar.
- ✓ **Skvamöz hücreli karsinom:** Akciğerlerin merkezinde, dış yüzeyinde bulunan hücrelerde başlar.

- ✓ **Büyük hücreli karsinom:** Akciğerlerin herhangi bir yerinde başlayabilir ve mikroskop altında büyük, yuvarlak hücrelere sahiptir.

- **Küçük hücreli akciğer kanseri (KHAK)**

KHAK, tüm akciğer kanseri vakalarının yaklaşık %10-15'ini oluşturur. Neredeyse her zaman sigara içenlerde görülür ve KHAK'a göre daha agresif bir seyir izler. KHAK, hızla büyür ve vücudun diğer bölgelerine kolayca yayılır. KHAK'ın iki ana alt türü vardır:

- ✓ **Yulaf hücreli karsinom:** En yaygın KHAK türüdür.
- ✓ **Orta hücreli karsinom:** Daha nadir görülen bir KHAK türüdür.

Yukarıda bahsedilen iki ana grubun dışında, daha nadir görülen bazı akciğer kanseri türleri de vardır:

- ✓ **Karsinoid tümörler:** Genellikle yavaş büyüyen ve nadiren yayılan tümörlerdir.
- ✓ **Lenfoma:** Lenf sistemini etkileyen bir kanser türü olmakla beraber bazen akciğerlerde de başlayabilir.
- ✓ **Sarkom:** Akciğerlerdeki bağ dokusunda başlayan nadir bir kanser türüdür.

## 1.2. Akciğer Kanseri Teşhisinde Kullanılan Görüntüleme Yöntemleri


Pulmoner karsinom (akciğer kanseri), günümüzde küresel çapta en yaygın görülen ve en ölümcül kanser türleri arasında yer almaktadır. Bu bağlamda, hastalığın başarılı bir şekilde tedavi edilebilmesi ve hastanın yaşam süresinin uzatılabilmesi için erken tanının hayati önem taşıdığı aşikardır. Pulmoner karsinom teşhisi, genellikle bir dizi tanısal test ve prosedürler aracılığıyla gerçekleştirilir. Bu yaklaşımlar, hastalığın varlığını, histopatolojik tipini, evresini ve metastatik yayılımını belirlemeyi amaçlamaktadır.

- **Göğüs radyografisi (Röntgen):** Göğüs radyografisi, akciğer kanseri şüphesinde başvurulmuş ilk basamak görüntüleme yöntemlerinden biridir (Şekil 1.5). Tümörleri, sıvı birikimini veya diğer anormalliklerin ortaya çıkarılmasını sağlar.




Şekil 1.5. Göğüs radyografisi (röntgen)

- **Bilgisayarlı tomografi (BT):** BT taraması, akciğerlerin ve çevresindeki dokuların daha detaylı görüntülenmesini sağlar (Şekil 1.6). Küçük nodüllerin tespitinde göğüs radyografisinden daha hassastır.



Şekil 1.6. Bilgisayarlı tomografi görüntüsü

- **Manyetik rezonans görüntüleme (MRG):** MRG, özellikle beyin ve omurilik gibi yumuşak dokuların görüntülenmesinde diğer yöntemlere göre daha iyi sonuçlar verir (Şekil 1.7). Kanserin santral sinir sistemi veya diğer uzak metastazlarının değerlendirilmesinde kullanılır.




Şekil 1.7. Manyetik rezonans görüntüsü

- **Pozitron emisyon tomografisi (PET):** PET taraması, kanser hücrelerinin metabolik aktivitesini gösterir ve malignite şüphesini güçlendirerek hastalığın evrelendirilmesinde ve tedaviye yanıtın değerlendirilmesinde yardımcı olur (Şekil 1.8).



**Şekil 1.8.** Pozitron emisyon tomografi görüntüsü

- **Kemik sintigrafisi:** Akciğer kanserinin sebep olduğu kemik metastazlarının tespiti için kullanılır (Şekil 1.9).



**Şekil 1.9.** Kemik sintigrafisi

Akciğer kanseri teşhisinde kullanılan yöntemlerin seçimi, hastanın belirtilerine, tıbbi geçmişine ve diğer testlerin sonuçlarına bağlı kompleks bir süreçtir ve birden fazla tanısal yöntemin kombinasyonunu gerektirebilir.

Erken tanı, tedavi başarısı ve yaşam süresini artırmada kritik öneme sahiptir. Risk faktörleri taşıyan bireylerin düzenli tarama programlarına katılımı ve semptomlara karşı duyarlı olması büyük önem arz etmektedir.

Ölüm oranının diğer kanser türlerine oranla daha yüksek olması sebebiyle akciğer kanserinin erken teşhisinin çok önemli olduğu açıktır. Gelişen bilişim çağında yapay zekâ tekniklerinin kullanımı ile bu konu üzerine çözüm arayışına yoğunlaşan çalışmalar yapılmaktadır. Özellikle sağlık alanında yapay zekânın kullanımı ile hekimlerin hastalıklara tanı koymasını kolaylaştırmak ve iş verimliliklerini artırmak amaçlanmaktadır.

Derin öğrenme algoritmalarının karmaşık veri setlerinden anlamlı özellikler çıkarma yeteneği, akciğer kanserinin erken evrelerini tespit etme konusunda önemli bir potansiyele işaret etmektedir. Görüntüleme tekniklerinde ve büyük veri analizinde kullanılan derin öğrenme yöntemleri, hastalığın erken teşhisinde umut verici sonuçlar sunmaktadır. Bu amaca yönelik yapılan bu çalışmada; derin öğrenme yöntemleri kullanılarak, Bilgisayarlı Tomografi (BT) taramalarından elde edilen görüntülerde akciğerdeki kanserli bölgenin tespiti yapılmıştır.

## 2. KAYNAK ÖZETLERİ

Akciğer kanserinin teşhisine yardımcı olmak üzere derin öğrenme yöntemlerinden faydalanılarak yapılan çalışmalar incelendiğinde özellikle 2019 yılından sonra çalışmaların giderek arttığı ve farklı yapay zekâ yöntemleri kullanılarak çözüm sunan çalışmaların yoğunlaştığı dikkati çekmektedir. Keshani vd. yaptıkları çalışmada BT görüntülerini kullanarak kanserli akciğeri, aktif kontur modelleme ile bölütlere ayırmışlardır. Bu bölütlere çeşitli maskeleme teknikleri uygulanmış ve nodüller 2B stokastik ve 3B anatomik özellikler kullanılarak Destek Vektör Makineleri (DVM) ile sınıflandırma yapmışlardır. Nodülleri %89'luk bir başarımla tespit etmişlerdir (Keshani vd., 2013).

Kuruvilla ve Gunavathi BT görüntülerinden akciğer bölümlenmesi yapıp bu sayede standart sapma, çarpıklık, basıklık, ortalama, beşinci merkezi moment ve altıncı merkezi moment gibi çeşitli istatistiksel parametreleri ortaya çıkarmışlardır. Bu parametreleri kullanarak yapay sinir ağlarından ileri beslemeli ve ileri beslemeli geri yayımlı algoritmalar ile sınıflandırma işlemi gerçekleştirmişlerdir. Yapılan çalışma sonucunda elde edilen sonuçlar, birinci yöntem ile %91,1 ikinci yöntem ile de %93,3'lük bir doğruluk saptamışlardır (Kuruvilla vd Gunavathi, 2014). De Carvalho Filho vd. görüntü tanıma ve görüntü işleme teknikleri yardımıyla BT görüntülerinden akciğer kanserli nodüllerinin tespiti üzerine bir metodoloji geliştirerek; görüntüleri bölümlere ayırıştırıp akciğere benzeyen yapıların kümeleme algoritmaları ile sınıflandırılmasını sağlamışlardır. Son sınıflandırma işleminde DVM'ye ek olarak bir genetik algoritma olan Mikro-Genetik Algoritmayı kullanmışlardır. %85,91 duyarlılık, %97,70 özgüllük ve %97,55 doğruluk ile sonuçlar elde etmişlerdir (De Carvalho Filho vd., 2014).

Song vd. akciğer BT görüntülerini kullanarak iyi ve kötü huylu nodülleri tespit etmek için üç çeşit derin öğrenme yönteminden Evrişimli Sinir Ağları (CNN), Derin Sinir Ağları (DNN) ve Yığılmış Otomatik Kodlayıcıdan (SAE) faydalanmışlardır. Bu modeller eğitildiğinde CNN için %84,15 doğruluk, DNN için %82,37 doğruluk ve SAE için de %82,59'luk bir doğruluk ölçmüşlerdir (Song vd., 2017). Bir başka araştırmaya göre bağırsak ve akciğer adenokarsinomlarını, doku mikro dizilerinden elde edilen protein desenleri üzerinden tespit etmişlerdir. Analizlerde Linear Diskriminant Analiz (LDA)

algoritması kullanılmış ve bu algoritmanın bağırsak ve akciğer adenokarsinomlarını %95 oranında doğrulukla ayırt edebildiği görülmüştür. Ayrıca analizlerde tümör örneklerindeki proteinlerin kimliği de belirlenmiştir (Kriegsmann vd., 2017).

Lustberg vd. akciğer kanseri riski altındaki organların bölütlenmesinde bilgisayar yardımıyla oluşturulan şekillendirmenin bu süreçte zaman kazandırıp kazandırmadığını tespit etmek için çalışma yapmışlardır. Manuel olarak yapılan şekillendirme ortalama 20 dakika sürerken atlas tabanlı yazılım ile bu süre 7-8 dakikaya, derin öğrenme tabanlı yazılım ile 10 dakikaya kadar indiğini tespit etmişlerdir (Lustberg vd., 2018) .

Bir başka çalışmada, BT görüntüleri üzerine birtakım görüntü işleme teknikleri uygulanıp görüntülerin kalitesi arttırılmış, daha sonra görüntüdeki fazlalık ifade edecek gereksiz ayrıntılar kırılmıştır. Bu şekilde elde edilen görüntüler katman sayısı arttırılan bir DNN algoritması tarafından modellenmiştir. Elde edilen sonuçlara göre doğruluk %94,56, hassaslık %96,2 ve özgüllük %94,2 olarak ölçülmüştür (Lakshmanaprabu vd., 2019). BT görüntülerindeki kanserli bölgenin belirginleştirilmesini sağlamak için histogram eşitleme yapılarak çeşitli spektral özellikler elde edilen başka bir çalışmada ise, Geliştirilmiş Bol Kümeleme Tekniği (IPCT) ve Anında Eğitilmiş Sinir Ağları (DITNN) teknikleriyle bir derin öğrenme yöntemi geliştirilmiş ve yapılan eğitim sonucunda %98,42 oranında bir doğruluk elde edilmiştir (Shakeel vd., 2019). 2019'da yapılan bir çalışmada da BT görüntüleri kullanılarak KOAH ve Fibrozis gibi hastalıkların tespiti ve sınıflandırılması yapılmıştır. Öznitelikleri belirlemek için yeni ortaya çıkan üç algoritma Doğaçlama Karga Arama Algoritması (ICSA), Doğaçlama Gri Kurt Algoritması (IGWA) ve Doğaçlama Mürekkepbalığı Algoritması (ICFA) kullanılmıştır. Sınıflandırma için DVM, K-en Yakın Komşu (K-NN) ve Karar Ağacı kullanılmış olup sınıflandırma modelleri ve öznitelik çıkarma yöntemlerinin kombinasyonlarından en iyi sonucu IGWA + K-NN'nin %99,4 verdiği gözlemlenmiştir (Gupta vd., 2019). Kasinathan vd. tarafından yapılan çalışmada BT görüntüleri kullanılarak akciğer, segmentasyon işlemine tabi tutularak alt bölgelere ayrılmıştır. Öznitelikleri belirlemek için Gauss dağılımı uygulanmış ve CNN ile sınıflandırma yapılmıştır. Sınıflandırma sonucu %97 doğruluk elde edilmiştir (Kasinathan vd., 2019).

Pacal vd. tarafından gerçekleştirilen bir çalışma ile, kolon kanseri analizinde derin öğrenme uygulamalarının kapsamlı bir incelemesi sunulmaktadır. Makale, öncelikle

popüler derin öğrenme mimarilerinin genel bir özetini sunmakta ve ardından kolon kanseri analizinde derin öğrenme çalışmalarını; tespit etme, sınıflandırma, segmentasyon, sağkalım tahmini ve iltihabi bağırsak hastalıkları şeklinde beş kategoriye ayırarak incelenmektedir. Her kategori altındaki çalışmalar özetlenmektedir. Ayrıca, mevcut zorluklar ve gelecek araştırmalar için öneriler tartışılmaktadır (Pacal vd., 2020). 2020 yılında yapılan bir çalışmada, CNN kullanılarak Irak hastanelerinden toplanan bir akciğer BT veri seti üzerinde çalışma gerçekleştirilmiş, AlexNet mimarisine sahip bir teknik kullanılarak BT taramalarında hedef kitlenin iyi huylu veya kötü huylu olduğu tespit edilmeye çalışılmıştır. %93,5 'e varan bir tespit başarısı elde etmişlerdir (Al-Yasriy vd., 2020). Abbas vd. yazdıkları makalede, akciğerin skuamöz hücreli karsinomu ve adenokarsinomu teşhisinde CNN'lerin etkinliğini değerlendirmişlerdir. LC2500 veri kümesinden elde edilen 15.000 dijital histopatolojik görüntü, altı farklı CNN mimarisi ile analiz edilmiş ve elde edilen sonuçlara göre tüm modellerin %97'nin üzerinde yüksek F-1 skorlarına ulaşarak bu kanser türlerinin teşhisinde CNN'lerin başarılı olduğunu vurgulamışlardır (Abbas vd., 2020).

Akciğer ve kolon kanseri teşhisinde derin öğrenme tabanlı ve bilgisayar destekli tanı sistemini konu alan makalede LC25000 veri kümesindeki dijital patoloji görüntüleri, sık bir CNN mimarisi kullanılarak analiz edilmiştir. Sonuçlar, akciğer kanseri için %97'nin üzerinde ve kolon kanseri için %96'nın üzerinde bir doğruluk elde edildiğini göstermiştir. Bu bulgular neticesinde, CNN'lerin kanser teşhisinde umut vadeden bir araç olduğu ve yapay zekanın gelecekteki tıbbi uygulamalar için potansiyeli vurgulanmaktadır (Mangal vd., 2020). Bukhari vd. 2020 yılında yaptıkları bir araştırmada, kolon adenokarsinomunun histopatolojik teşhisinde derin öğrenme modellerinin, özellikle de ResNet mimarisinin etkinliğini değerlendirmişlerdir. ResNet-18, ResNet-34 ve ResNet-50 modelleri önce LC25000 veri setiyle, ardından CRAG veri setiyle eğitilmiştir ve ResNet-50 modelinin diğer modellere göre daha iyi bir doğruluğa (%93,91) ulaştığı tespit edilmiştir (Bukhari vd., 2020).

Kolon kanseri sınıflandırması için derin öğrenme ve makine öğrenmesi tekniklerini birleştiren bir yöntemde ise ResNet-50 ve DenseNet-121 modelleri, kolon doku görüntülerinden özellik çıkarmak için kullanılırken, SVM, Random Forest, KNN ve XGBoost gibi çeşitli makine öğrenmesi algoritmaları sınıflandırma için kullanılmıştır.

DenseNet-121 ve KNN sınıflandırıcısı kombinasyonu, %98,53'lik doğruluk ve %98,63'lik duyarlılık ile en iyi performansı göstermiştir (Sarwinda vd., 2020). 2020 yılında yapılan başka bir çalışmada ise, akciğer ve kolon kanserinin erken teşhisini iyileştirmek için derin öğrenme tabanlı bir yaklaşım sunulmaktadır. Beş farklı doku türünü (akciğer skuamöz hücreli karsinom, akciğer adenokarsinom, benign akciğer dokusu, kolon adenokarsinom ve benign kolon dokusu) sınıflandırmak için beş sınıflı bir CNN modeli geliştirilmiştir. Model %90,29 doğruluk oranı elde etmiştir (Tori Sugden, 2020).

Nanglia vd. yaptıkları çalışmalarında hibrit bir sınıflandırma algoritması uygulayarak sınıflandırma doğruluğunu arttırmayı amaçlamışlardır. Bu bağlamda, Destek vektör makineleri ile ileri beslemeli geri yayılım algoritmasını birleştirmişlerdir. Oluşturdukları model ile %98,08 doğruluk değeri saptamışlardır (Nanglia vd., 2021). Surendar P. Ve Ponni Bala M. öncelikle akciğer görüntülerini ön işleme tabi tutup ardından kanserli nodülleri Salp Sürü Algoritması (SSA) ile tespit etmişlerdir. Bu işlemten sonra Çekirge Optimizasyon Algoritması ile özneteliklerin seçimi yapılmıştır. Son olarak, CNN ve Uyarlamalı Sinüs Kosinüs Karga Arama Algoritması (ASKA) ile hibrit bir sınıflandırıcı kullanılarak kanser teşhisi konulmuştur. Bu yöntem ile %99,17 gibi bir doğruluk oranına ulaşmışlardır (P. ve M., 2021). BT görüntüleri üzerinde Yapay Sinir Ağları (ANN), CNN ve Tekrarlayan Sinir Ağları (RNN) yöntemlerinin birbirlerine kıyaslarını yapan bir başka çalışmada ANN modelinin, RNN ve CNN modellerinden marjinal olarak daha yüksek (%71,18) bir doğruluk gösterdiği saptanmıştır (Doppalapudi vd., 2021).

Chen vd. BT görüntülerinden akciğer kanseri tanısını kolaylaştırmak amacıyla bu görüntülere Segnet yaklaşımını uygulayarak iyi huylu ve kötü huylu tümörleri tespit etmeye çalışmışlardır. Çalışmada Segnet Deeplab v3 ve VGG-19 modelleri oluşturulmuş ve manuel olarak yapılan işlemlerle kıyaslamalar yapılmıştır. Manuel olarak yapılan tespitte akciğer kanseri için doğruluk %86,25, SegNet modeli için doğruluk %92,50, Deeplab v3 yaklaşımının doğruluk oranı %80,41 ve VGG 19 için doğruluk %79,58 olarak ölçülmüştür (Chen vd., 2021). 2021 yılında akciğer kanserinin yapay zekâ teknikleriyle tespit edilmesine yönelik bir araştırmada LC25000 Akciğer ve kolon histopatolojik görüntü veri seti ile ResNet 50, VGG-19 ve Inception\_ResNet\_V2 olmak üzere üç farklı CNN model yapısıyla eğitim gerçekleştirilmiştir. Sonuç olarak Inception\_ResNet\_V2

%99,7, VGG-19 %92,99 ve ResNet-50 ise %99,4 oranında doğruluk elde etmiştir (Baranwal vd., 2021).

Jing Hu vd. akciğer kanserini tespit etmek amacıyla derin öğrenme yöntemlerini kullanarak Hematoxylin and Eosin (H&E) boyanmış doku kesitlerinden elde edilen görüntüler ile anti-PD-1 yanıtını tahmin etmeye çalışmışlardır. Xception modeli kullanarak transfer öğrenme gerçekleştirilmiş ve son olarak destek vektör makineleri ile sınıflandırma yapılmıştır. Yapılan sınıflandırma neticesinde %77,8'lik bir başarı elde etmişlerdir (Hu vd., 2021). Akciğer ve kolon kanserinin beş farklı doku türünü (üç malign, iki benign) sınıflandırmak için derin öğrenme ve dijital görüntü işleme tekniklerini kullanan bir yöntem sunan başka bir çalışmada ise LC25000 veri kümesi kullanılarak geliştirilen model, %96,33'lük bir doğruluk oranı elde etmiştir (Masud vd., 2021).

Talukder vd. yaptıkları çalışmada kolon ve akciğer kanserinin erken tespiti için hibrit bir özellik çıkarma yöntemi üzerinde durmuşlardır. VGG16 MobileNet ve DenseNet201 modelleri kullanılmış ve kanser hücrelerini tespit oranı akciğer kanseri için %99,05 kolon kanseri için %100 olarak ölçülmüştür (Talukder vd., 2022). Akciğer kanseri üzerine yapılan bir çalışmada BT görüntülerinin yanı sıra nesnelerin interneti (IoT) teknolojisinden de faydalanılmıştır. Hem BT hem de giyilebilen teknolojilerden alınan veriler birleştirilerek Genişletilmiş Konvolüsyonlu Sinir Ağı (ECNN) modelinden geçirilmiş ve %96,8'lik bir doğruluk elde edilmiştir (Pawar vd., 2022).

Haznedar ve Simsek yaptıkları çalışmada Kanser Genomu Atlasından (TCGA) alınan akciğer ve renal hücre kanseri RNA-Seq veri kümelerini analiz etmek için hem klasik makine öğrenme yöntemlerini hem de derin öğrenme yöntemlerini kullanmışlardır. Klasik makine öğrenme yöntemleri olan karar ağaçları, random forest ve DVM arasından en iyi sonucu Random Forest vermiştir (%93,51-%91,83). Derin öğrenme yöntemlerinden DNN-Adadelta yöntemiyle doğruluk oranları ise %95,54 ve %96,15 olarak ölçülmüştür (Haznedar ve Simsek, 2022). Yapılan başka bir araştırmada akciğerlere metastaz yapan Osteosarkom nodüllerini tespit etmek amacıyla VGG16 omurgası Tek Atış Tespiti (SSD) yöntemi ile birleştirilerek bir model oluşturulmuş ve %75,97'lik bir doğruluk elde edilmiştir (Loraksa vd., 2022).

BT görüntüleri kullanılarak akciğer ve kolon kanserlerinin hızlı ve doğru teşhisi için histogram eşitleme yaklaşımı (CSIP) uygulanmış ve AlexNet sinir ağı modeli ile eğitim gerçekleştirilmiştir. CSIP uygulanmadan önce doğruluk %89,8 iken CSIP uygulandıktan sonra doğruluğun ve %98,8'e çıktığı tespit edilmiştir (Mehmood vd., 2022). Dodia vd. derin öğrenme algoritmalarını kullanarak, akciğer kanserinin tıbbi görüntü analizinde gerçekleştirilen son araştırmalar, verimlilik, avantajlar ve sınırlamalar gibi çeşitli teknik yönler açısından karşılaştırmalar yapmışlardır. Tartışılan bu yaklaşımlar, akciğer kanserinin saptanması ve sınıflandırılmasını gerçekleştirmek için kullanılabilecek teknikler hakkında bilgi vermektedir. Görüntülerin elde edilmesinde, ilgili özelliklerin çıkarılmasında, etkilenen bölgenin segmentasyonunda, optimal özelliklerin seçiminde ve sınıflandırmada uyarlanan çok sayıda teknik de tartışılmaktadır (Dodia vd., 2022).

Akciğer nodüllerinin anormalliklerini sınıflandırmak için Geliştirilmiş Kapuçin Arama Algoritması (ICSA) ile optimize edilmiş hibrit CNN tabanlı Uzun ve Kısa Süreli Bellek (LSTM) yöntemlerini birleştirerek bir model ortaya koyan bir çalışmada simülasyon sonuçları, önerilen yöntemin doğruluk oranını %98 olarak saptamıştır (Kanipriya vd., 2022). 2022 yılında yapılan başka bir araştırmada ise, akciğer BT görüntülerinden nodül tespiti için geliştirilmiş bir YOLO-v5 algoritması olan STBi-YOLO tanıtılmaktadır. YOLO-v5'in küçük hedefleri tespit etmedeki yetersizliği, üç önemli iyileştirme ile ele alınmıştır. Maksimum havuzlama yerine stokastik havuzlama kullanılmış olup çift yönlü özellik piramidi ağı (BiFPN) ile küçük hedeflerin algılanma kabiliyeti geliştirilmiştir. Bunun yanında eğitim modelinin optimizasyonu için EIOU kayıp fonksiyonu kullanılmıştır. Bu iyileştirmeler sayesinde STBi-YOLO ile %96,1 gibi bir doğrulukla akciğer nodülleri tespit edilmiştir (Liu, 2022). Shanthi vd. yaptıkları çalışmada akciğer kanser hücrelerini saptamak ve sınıflandırmayı iyileştirmek için Naïve Bayes, Karar ağacı ve ANN sınıflandırıcılarını kullanarak Stokastik Difüzyon Arama (SDS) tabanlı özellik seçimine sahip yeni bir hibrit algoritma oluşturmuşlardır. Sonuçlar, önerilen TABU-SDS-NN yönteminin %94,07'lik bir doğruluğa eriştiğini göstermiştir (Shanthi vd., 2022).

2023 yılında yapılan bir çalışmada ise BT görüntülerinden akciğer kanser hücrelerinin tespiti için üç farklı CNN modeli oluşturup bunlarla ayrı ayrı eğitim gerçekleştirilmiştir. Bu üç modelin sonuçlarının ortalaması alınarak yeni bir yaklaşımda bulunulmuştur. Bu üç CNN modelinin ortalama doğruluğu %95 olarak ölçülmüştür (Shah vd., 2023).

Talib vd. yaptıkları çalışmada, histopatolojik görüntülerde akciğer kanserinin tespiti için iki derin öğrenme modelini önermişlerdir. Bu modellerden ilki TransSegNet adı verilen bir segmentasyon modelidir. Bu model, özel olarak seçilmiş hiper parametrelerle eğitilerek, kanserli bölgeleri doğru bir şekilde segmentasyon yapmayı amaçlar. Diğer bir model olan MinClassNet (sınıflandırma modeli) ise yedi katmanlı bir CNN mimarisine sahiptir ve sağlıklı ve anormal hücreleri sınıflandırmak için eğitilmiştir. TransSegNet, %99,62 doğruluk ve 0,0067 kayıp ile başarılı bir segmentasyon performansı sergilemiştir. MinClassNet ise %98,39 doğrulukla sağlıklı ve anormal hücreleri etkili bir şekilde sınıflandırmıştır (Talib vd., 2024). Akciğer kanserinin erken teşhisinde bilgisayar destekli tanı sistemlerinin doğruluğunu artırmak amacıyla yapılan bu çalışmada Mitscherlich fonksiyonu tabanlı bir topluluk modeli olan MENet önerilmektedir. MENet, üç derin öğrenme modelinin (Xception, InceptionResNetV2 ve MobileNetV2) tahmin olasılıklarının birleştirilmesinden oluşmaktadır. Önerilen MENet modelinde IQ-OTH/NCCD ve LIDC-IDRI veri setleri ile sırasıyla %99,54 ve %95,75 doğruluk elde edilmiştir (Majumder vd., 2024).

2024 yılında yapılan başka bir çalışmada ise, gaz sensörü dizisi ve derin öğrenme algoritması kullanılarak akciğer kanserinin erken teşhisi için bir nefes analiz sistemi geliştirilmiştir. Nefes analiz sistemi, on adet yarı iletken metal oksit (SMO), bir foto iyonizasyon dedektörü (PID) ve dokuz elektrokimyasal (EC) gaz sensörü kullanarak nefes içerisindeki çoklu uçucu organik bileşikler (VOC) tespit etmek üzere tasarlanmıştır. Sistem, sağlıklı bireyleri ve akciğer kanseri hastalarını sınıflandırmada %97,8'lik genel bir doğruluk elde etmiştir (Lee vd., 2024). Önceden eğitilmiş evrişimli sinir ağı modellerinin akciğer kanserini tespit etmedeki performansını değerlendirmek amacıyla yapılan bir çalışmada LIDC-IDRI veri seti kullanılmıştır. ResNet-50, VGG-16, Xception ve MobileNet gibi önceden eğitilmiş CNN modellerine, ek katmanlar ve optimize edilmiş hiper parametreler eklenmiştir. Bu şekilde oluşturulmuş CNN modelleri, akciğer kanseri tespitinde %78 ila %86 arasında değişen doğruluk oranıyla sonuçlar elde etmiştir. En iyi performans VGG-16 modeli tarafından %86,71 doğrulukla elde edilmiştir (Chai vd., 2024).

Jothi ve Murugaiyan yaptıkları çalışmada, akciğer kanserini teşhis etmek için şempanze optimizasyon algoritmasıyla birlikte bir evrişimli sinir ağı içeren bir derin öğrenme

teknikini önermektedirler. Tespit ettikleri sonuçlara göre, önerilen sistem %100 doğruluk, %99 duyarlılık, %99 recall ve %98 F1 skoru elde etmiştir (Jothi ve Murugaiyan, 2024).



### 3. KURAMSAL TEMELLER


#### 3.1. Yapay Zekâ

Yapay zekâ (YZ), bilgisayarların çeşitli görevleri yerine getirmek, karmaşık problemleri çözmek, öğrenmek ve kararlar almak gibi insan zekasına özgü aktiviteleri gerçekleştirebilme kabiliyetini ifade eder. Yapay zekânın tarihçesi oldukça köklü bir geçmişe sahiptir ve birçok dönemi kapsayan bir evrimi ifade eder. Bu teknolojinin temelleri 1950 yılında, ünlü matematikçi ve bilgisayar bilimcisi Alan Turing'in "Bilgisayarlarla Düşünme" adlı makalesinde atılmıştır. Turing, "bir makine düşünebilir mi?" sorusuna odaklanarak, yapay zekanın teorik temellerini atmış oldu, takip eden yıllarda bu alanda gelişmeler giderek artmış ve bu teknoloji ile ilgili konferanslar düzenlenmeye başlanmıştır. 1955 yılında Dartmouth Konferansı'nda, John McCarthy "yapay zekâ" terimini ilk kez burada kullanmıştır. Böylelikle bu konferans yapay zekânın resmi başlangıcı olarak kabul edilmiştir. McCarthy, 1959 yılında Lisp programlama dilini geliştirdi. Lisp, yapay zekâ programlarını yazmak için kullanılan en önemli dillerden biridir ve günümüzde de hala kullanılmaktadır.

Yapay zekânın geçmişi, teorik temellerin atıldığı 1950'lerden günümüze kadar sürekli bir evrimi yansıtmaktadır. O günden bugüne geçen her zaman diliminde, belirli yaklaşımlar, algoritmalar ve teknikler öne çıkmıştır. Bugün, yapay zekâ hızla gelişmekte olup, teknolojinin birçok alanında etkilerini göstermektedir. Bu alandaki hızlı gelişmeler, bir dizi disiplinde derin etkiler yaratmış ve birçok sektörde devrim niteliğinde değişikliklere öncülük etmiştir.

YZ, geniş bir teknik yelpazeye sahiptir. Makine öğrenimi, yapay sinir ağları, derin öğrenme, doğal dil işleme ve görüntü analizi gibi alt alanlar, bilgisayar sistemlerine çeşitli yetenekler kazandırmak üzere geliştirilen algoritmalar ve teknikler içerir. Sağlık, finans, otomotiv, eğitim ve sanayi gibi sektörlerde yapay zekâ uygulamaları, veri analizi, tahmin modelleri, otonom sistemler ve kişisel asistanlar gibi birçok alanda etkili bir şekilde kullanılmaktadır. Bu uygulamalar, iş süreçlerini optimize etmek, karar alma süreçlerini iyileştirmek ve yeni fırsatlar yaratmak için kullanılmaktadır. Bu devrim niteliğinde değişikliklerle birlikte, günlük yaşantımıza derinlemesine entegre olmuştur. Ancak, bu teknolojinin etik, güvenlik ve toplumsal etkileri konusundaki sorumlulukları göz ardı

etmemek ve bu konularda dengeli bir yaklaşım benimsemek, yapay zekâ uygulamalarının sürdürülebilir ve topluma fayda sağlayan bir şekilde geliştirilmesi için kritik önem taşımaktadır. Yapay zekâyı oluşturan temel bileşenler Şekil 3.1’de gösterilmiştir.



Şekil 3.1. Yapay zekâ bileşenleri

### 3.2. Makine Öğrenimi (ML)

Makine öğrenimi, bilgisayar sistemlerinin deneyimlerinden öğrenerek performanslarını artırmalarına imkân tanıyan bir yapay zekâ dalıdır. Veri analizi, desen tanıma ve tahminleme gibi görevlerde kullanılan bir dizi algoritma ve teknik içerir.

- **Denetimli öğrenme (Supervised learning):** Etiketli veri setleri üzerinde çalışan bir öğrenme türüdür. Algoritma, giriş verilerini kullanarak çıkış değerini tahmin etmeyi öğrenir.
- **Denetimsiz öğrenme (Unsupervised learning):** Etiketlenmemiş veri setleri üzerinde çalışır ve desenleri tanımlamak için kullanılır. Kümeleme ve boyut azaltma gibi uygulamalara sahiptir.
- **Yarı denetimli öğrenme (Semi-supervised learning):** Hem etiketli hem de etiketsiz veri setlerini kullanarak, bir modelin eğitildiği bir makine öğrenimi paradigmasıdır. Bu yaklaşım, genellikle etiketlenmiş veri setinin sınırlı veya maliyetli olduğu durumlarda kullanılırken, büyük miktarda etiketlenmemiş veriye erişim sağlama ihtiyacını karşılamak üzere tasarlanmıştır.

- **Pekiştirmeli öğrenme (Reinforcement learning):** Bir ajanın çevresiyle etkileşimde bulunarak öğrendiği bir tür öğrenme şeklidir. Ajan, çevresine yönlendirdiği eylemlerin sonuçlarından geri bildirim alır. Bu durum, insanların keşfetme ve geliştirme sürecini yansıtarak, problem çözme sürecinde deneme-yanılma metodunu kullanır.

### 3.2.1. Makine öğrenmesi algoritmaları

- **Regresyon:** Bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi analiz etmekte kullanılır (örn. ev, araba fiyat tahmini).
- **Sınıflandırma:** Kategorik çıktılar tahmin etmek için kullanılır (örn. görüntü sınıflandırma).
- **Kümeleme:** Benzer özelliklere sahip veri öğelerini gruplandırmak için kullanılır (örn. müşteri segmentasyonu).
- **Boyut indirgeme:** Verilerin karmaşıklığını azaltmak ve görselleştirmek için kullanılır.
- **Derin öğrenme:** Çok katmanlı yapay sinir ağları kullanarak karmaşık kalıpları öğrenmek için kullanılır.

### 3.2.2. Makine öğrenmesinin uygulamaları

- **Görüntü tanıma:** Nesneleri, yüzleri ve sahneleri tanımak için kullanılır.
- **Doğal dil işleme:** Metinleri anlamak, çevirmek ve üretmek için kullanılır.
- **Öneri sistemleri:** Kişiselleştirilmiş ürün veya içerik önerileri sunmak için kullanılır.
- **Finansal tahmin:** Hisse senedi fiyatları, risk değerlendirmesi ve dolandırıcılık tespiti gibi finansal tahminlerde kullanılır.
- **Sağlık hizmetleri:** Hastalık teşhisi ve tedavi planlaması gibi uygulamalarda kullanılır.

### 3.2.3. Makine öğrenmesinin zorlukları


- **Veri kalitesi:** Makine öğrenmesi modellerinin performansı, kullanılan verilerin kalitesine bağlıdır.

- **Aşırı uydurma:** Modelin eğitim verilerine çok fazla uyum sağlaması ve yeni verilere genelleme yapamaması.
- **Model açıklanabilirliği:** Bazı modellerin karar verme süreçleri karmaşık ve anlaşılması zordur.
- **Etik hususlar:** Makine öğrenmesi modellerinin önyargılı veya ayrımcı olmaması için dikkatli bir şekilde tasarlanması gerekir.

Makine öğrenmesi, günümüzde sürekli olarak gelişmektedir. Daha gelişmiş algoritmalar, hesaplama gücündeki artış ve büyük veriye erişim, makine öğrenmesinin yeteneklerini ve uygulama alanlarını genişletmektedir. Gelecekte, makine öğrenmesinin birçok sektörde devrim yaratması ve insanların hayatını önemli ölçüde etkilemesi beklenmektedir.

### 3.3. Yapay Sinir Ağları (ANN)

Yapay sinir ağları, makine öğrenimi ve yapay zekâ uygulamalarının temel bir bileşenidir. Bu, insan beynindeki biyolojik sinir ağlarının çalışma şekline ilham alan bir hesaplama modelidir. Bir ANN, nöron adı verilen bağlantılı düğümlerden oluşur. Bu nöronlar, bir giriş katmanı, bir veya daha fazla gizli katman ve bir çıkış katmanı şeklinde düzenlenir. Nöronlar arasındaki her bağlantının bir ağırlığı vardır. Şekil 3.2’de nöronlar arası ilişkinin gösterimi yapılmıştır.



Şekil 3.2. Yapay sinir ağları

**Giriş katmanı (Input layer):** Giriş katmanı, sistemin gözlemlediği veya öğrenmeye çalıştığı verileri temsil eder. Her bir düğüm, bir özellik veya giriş değişkenini temsil etmektedir.

**Gizli katmanlar (Hidden layers):** Gizli katmanlar, ANN'nin öğrenme yeteneğini sağlayan ve veriler arasındaki karmaşık ilişkileri sağlamaya yardımcı olan katmanlardır. Her bir düğüm, önceki katmandaki düğümlerin çıkışlarına dayalı olarak belirlenen ağırlıkları ve aktivasyon fonksiyonlarını kullanarak bir çıktı üretir. Birden fazla gizli katman olabilir ve bu katmanlar genellikle problemin karmaşıklığına bağlı olarak değişkenlik gösterir.

**Çıkış katmanı (Output layer):** Çıkış katmanı, ANN'nin bir sonucu veya tahminini üretir. Örneğin, bir sınıflandırma probleminde her düğüm bir sınıfa karşılık gelir ve bu düğümlerden biri veya birkaçı, sistemin tahmin ettiği sınıfı temsil eder. Çıkış katmanı, ANN'nin problemine bağlı olarak farklı yapılandırmalara ve bir veya daha fazla nörona sahip olabilir.

Düğümdeki ağırlıklar, ANN'nin öğrenme sürecinde uyum sağlanan parametrelerdir. Aktivasyon fonksiyonları, düğümün çıkışını sınırlayarak ve ağırlık öğrenme kapasitesini artırarak kullanılmaktadırlar. ANN'nin genel performansını etkileyen mimari tasarım, bu katmanların sayısı ve düğümlerin düzenlemesi gibi faktörlere bağlıdır.

### 3.3.1. ANN uygulama alanları

- **Görüntü işleme:** Nesne tanıma, görüntü sınıflandırma, yüz tanıma
- **Doğal dil işleme:** Makine çevirisi, metin özetleme, duygu analizi
- **Konuşma tanıma:** Sesli asistanlar, konuşmadan metne dönüştürme
- **Finansal tahmin:** Hisse senedi fiyatları, risk değerlendirmesi
- **Tıbbi teşhis:** Hastalık teşhisi, tıbbi görüntü analizi
- **Otonom sürüş:** Nesne algılama, yol takibi

### 3.4. Derin Öğrenme (DL)

Derin öğrenme, makine öğreniminin bir alt kümesidir. DL, bilgisayar bilimindeki en popüler konulardan biridir. Bu, veri dağılımları arasındaki ilişkileri keşfetmek amacıyla canlı sinir ağları yapısını taklit eden bir algoritmadır. Sinir ağları, çok katmanlı düğümlerden oluşan matematiksel modellerdir. Veri bu düğümlerden geçirildiğinde, her biri bir ağırlıkla çarpılır ve bir sapma ile eklenir. Sonunda, veri ayarlanır ve çıkış üretilir (Gu vd., 2018).

#### 3.4.1. Derin öğrenmenin temel özellikleri

- **Çok katmanlı mimari:** Derin öğrenme modelleri, birbiriyle bağlantılı birçok katmandan oluşmaktadır. Her katman, girdi verilerini işleyerek daha soyut ve karmaşık temsiller üretir. Bu çok katmanlı yapı, modelin verilerdeki hiyerarşik ilişkileri öğrenmesine olanak tanır.
- **Öznitelik öğrenimi:** Geleneksel makine öğrenmesinde, öznitelik çıkarımı genellikle uzman kişiler tarafından yapılır. Derin öğrenme modelleri ise, verilerden otomatik olarak öznitelikler çıkarabilir. Bu, özellikle görüntü ve ses işleme gibi alanlarda büyük bir avantaj sağlar.
- **Doğrusal olmayan işlevler:** Derin öğrenme modelleri, doğrusal olmayan aktivasyon fonksiyonlarını kullanarak karmaşık ve doğrusal olmayan ilişkileri modelleyebilirler. Bu, gerçek dünyadaki problemleri daha doğru bir şekilde temsil etmelerini sağlar.

#### 3.4.2. Derin öğrenme uygulama alanları

Derin öğrenme, günümüzde birçok alanda karşımıza çıkmaktadır. Bu alanlar şunlardır:

- **Görüntü işleme:** Nesne tanıma, görüntü sınıflandırma, yüz tanıma, tıbbi görüntü analizi
- **Doğal dil işleme:** Makine çevirisi, metin özetleme, duygu analizi, sohbet robotları
- **Konuşma tanıma:** Sesli asistanlar, konuşmadan metne dönüştürme
- **Öneri sistemleri:** Kişiselleştirilmiş ürün önerileri, içerik önerileri
- **Otonom sürüş:** Nesne algılama, yol takibi, karar verme


### 3.4.3. Derin öğrenmenin zorlukları

- **Veri gereksinimi:** Derin öğrenme modelleri, etkili bir şekilde öğrenmek için büyük miktarda veriye ihtiyaç duyarlar.
- **Hesaplama gücü:** Eğitim süreci, yüksek hesaplama gücü ve zaman gerektirir.
- **Kara kutu problemi:** Modelin karar verme süreci, tam olarak açıklanamaz, bu da bazı alanlarda güvenilirliği etkilemektedir.

Araştırmacılar derin öğrenme konusunda, daha etkili ve açıklanabilir modeller geliştirmek, hesaplama maliyetlerini azaltmak ve yeni uygulama alanları keşfetmek için çalışmaktadırlar. Derin öğrenmenin, yapay zekanın gelişiminde ve birçok sektörde büyük bir potansiyele sahip olduğu açıktır.

### 3.5. Evrişimli Sinir Ağları (CNN)

Evrişimli sinir ağları, girdi görüntülerini alan ve özellikleri ayıklamak için çeşitli filtrelerden geçiren ve çekirdeklerle birleştirerek sonuçlar üreten derin öğrenme algoritmalarıdır (Chauhan vd., 2018). CNN'lerin görüntü sınıflandırma, nesne tanıma ve yüz tanıma gibi alanların yanı sıra tıp alanında da kullanımı yoğunlaşmakta ve bu gelişmeler hastalıkların tanısını kolaylaştırarak sağkalım oranını artırmaktadır. Şekil 3.3'te bir CNN mimarisi sunulmuştur.



Şekil 3.3. CNN Mimarisi

Bir CNN modeli temelde 3 katmandan oluşmaktadır. Bu katmanlar evrişim (convolution), ortaklama (pooling) ve tam bağlantı (fully connected) katmanlarıdır.

**Evrişim katmanı (Convolution):** Konvolüsyon, CNN'lerin temel bileşenidir. Görüntülerdeki önemli özellikleri çıkarmak ve analiz etmek için kullanılır. Bu işlem, bir filtre matrisinin görüntü üzerinde kaydırılması ve her piksel için filtre ile görüntü değerlerinin çarpılmasıyla gerçekleştirilir. Bir CNN'de birden fazla konvolüsyon katmanı kullanılabilir. Her katman farklı bir özelliğe odaklanabilir (örneğin, kenarlar, dokular, nesneler). Katmanlar ardışık olarak uygulanarak daha karmaşık özelliklerin öğrenilmesi sağlanır. Bu katmanda kenarlar, dokular, nesneler gibi önemli görsel özellikler algılanır, giriş görüntüsündeki gürültüler filtrelenerek görüntünün netleştirilmesi sağlanır.

**Ortaklama katmanı (Pooling):** Ortaklama katmanı, CNN'lerin performansını ve verimliliğini artırmada önemli bir rol oynar. Görüntü boyutunu küçültmek, hesaplama karmaşıklığını azaltmak ve aşırı uyumu önlemek amacıyla kullanılmaktadır. Ortaklama katmanları genellikle konvolüsyon katmanlarından sonra kullanılır. Görüntünün boyutunu küçülterek hesaplama karmaşıklığını ve bellek ihtiyacını azaltır. Farklı görüntülerde benzer özelliklerin algılanmasını sağlayarak aşırı uyumu önler. Modeli daha sağlam ve farklı görüntülere karşı daha genelleştirilebilir hale getirir.

**Tam bağlantı katmanı (Fully connected):** Tam bağlantı katmanı, genellikle önceki konvolüsyon ve diğer katmanlarından elde edilen özellikleri kullanarak sınıflandırma veya regresyon gibi görevleri gerçekleştirmek için kullanılır. Bu katman kendisine gelen birden fazla girdiyi işleyerek çıkış katmanı için olasılık skorları üretir. Bu skorlar bir aktivasyon fonksiyonundan geçirilerek sınıflandırma için olasılık dağılımına dönüştürülür. Tam bağlantı katmanı diğer katmanlara göre daha fazla parametre ve hesaplama karmaşıklığına sahiptir.

**Batch normalization:** Yapay sinir ağlarının her katmanındaki girdileri normalize etmek için kullanılır. Eğitim sırasında her mini grup için, BatchNorm, her katmanın aktivasyonlarını, gruptaki ortalamayı çıkararak ve grup standart sapmasına bölecek şekilde normalize eder. Bu şekilde eğitim süreci hızlandırılır. BatchNorm, dropout gibi bir düzenleyici olarak da işlev görür. Eğitim sürecine gürültü ekleyerek, aşırı uyumun (overfitting) azaltılmasına ve genelleştirmenin iyileştirilmesine yardımcı olur.

**Dropout:** CNN'lerde aşırı uyumu önlemek için kullanılan bir tekniktir. Eğitim sırasında, rastgele seçilen nöronlar belirli bir olasılıkla geçici olarak devre dışı bırakılır. Bu, modelin belirli bir nörona veya nöron grubuna bağımlı hale gelmesini önler ve daha sağlam ve genelleştirilebilir bir model oluşturmaya yardımcı olur.

### 3.6. YOLO (You Only Look Once)

Günümüzde nesne tespiti, otonom araçlardan artırılmış gerçeklik uygulamalarına kadar birçok alanda kritik bir rol oynamaktadır. Bu alandaki çeşitli algoritmalar arasında öne çıkanlardan biri de "You Only Look Once" veya kısaca YOLO'dur. YOLO, hız ve doğruluğu bir araya getirerek, görüntülerdeki nesnelerin hızlı ve güvenilir bir şekilde tespit edilmesini sağlamaktadır.


YOLO 2015 de ilk sürümünü yayınlamış, takip eden yıllarda YOLOv2, YOLOv3, YOLOv4, YOLOv5, YOLOv6, YOLOv7 ve son olarak YOLOv8 modellerini duyurmuştur. İlk sürümünden bu yana bir dizi iterasyon geçirmiş ve her yeni sürüm, öncekilerin üzerine koyarak performansı artırmıştır. Bu evrim sürecinde, algoritmanın hızını ve doğruluğunu optimize etmek için çeşitli teknikler ve inovasyonlar eklenmiştir. Şekil 3.4'te YOLO v8 mimarisinin temel yapısı verilmiştir.

#### 3.6.1. YOLOv8'in temel özellikleri:

YOLOv8, nesne tespiti alanında son dönemde geliştirilen ve dikkat çeken bir derin öğrenme mimarisidir. YOLO ailesinin bir üyesi olarak, gerçek zamanlı performans ve yüksek doğruluk sunma amacını taşır. Bu amaca ulaşmak için, YOLOv8 mimarisi üç temel bileşenden oluşur: omurga (backbone), boyun (neck) ve baş (head).

**Backbone (Omurga):** Giriş görüntüsünden anlamlı özellikler çıkarmak için kullanılan temel yapıdır. Genellikle, önceden eğitilmiş bir CNN mimarisi omurga olarak kullanılır. YOLOv8, CSPDarknet53 ve EfficientNet gibi farklı omurga ağları kullanabilir. Bu ağlar, derin yapıları ve atlama bağlantıları (skip connections) sayesinde, hem düşük seviyeli (kenarlar, dokular) hem de yüksek seviyeli (nesne parçaları, şekiller) özellikleri etkili bir şekilde tespit eder.

**Neck (Boyun):** Boyun, omurga ve kafa arasında bir köprü görevi görür. Omurga ağından gelen özellikleri işleyerek farklı ölçeklerde ve çözünürlüklerde özellik haritaları oluşturur. Bu, modelin farklı boyutlardaki nesneleri tespit etme yeteneğini artırır. YOLOv8, PANet (Path Aggregation Network) gibi yapılar kullanarak özelliklerin daha iyi bir şekilde birleştirilmesini sağlar.




Şekil 3.4. YOLO v8 mimarisi (GitHub user RangeKing, 2023)

**Head (Baş):** Baş, sınır kutuları ve nesne algılama için güven puanları gibi ağır çıktıları oluşturmaktan sorumlu olan ağın son bölümüdür. Nesne tespiti için tahminler yapar.


YOLOv8 mimarisinin temel bileşenleri, girdi görüntüsünden anlamlı özellikler çıkarma, farklı ölçeklerde ve çözünürlüklerde özellik haritaları oluşturma ve nesne tespiti için tahminler yapma görevlerini yerine getirerek, yüksek performanslı ve gerçek zamanlı nesne tespiti yapmayı sağlar.

YOLO, tespit sürecini bir tek adımda gerçekleştiren bir nesne tespit çerçevesidir. Bu durum hem hızlı hem de etkili bir nesne tespiti yapılmasını sağlar. Temel prensibi, görüntüyü bir ızgara hücrelerine bölmek ve her hücrenin sorumluluğunda bir nesneyi tespit etmektir (Şekil 3.5).



**Şekil 3.5.** YOLO ızgara sistemi (Redmon vd., 2015)

YOLO tespit sistemi Şekil 3.6’da sunulmuştur. Bu uçtan uca birleştirilmiş algılama tasarımı, YOLO mimarisinin daha hızlı eğitilmesini ve çıkarım sırasında gerçek zamanlı hıza ulaşmasını sağlarken aynı zamanda yüksek ortalama hassasiyet sağlar. Geleneksel nesne tespit yöntemleri kayan pencere yaklaşımını kullanmaktadır. Ancak, sınıflandırıcı tüm görüntü üzerinde eşit aralıklarla çalıştırılır, bu da eğitim ve test süreçlerinde oldukça yavaş ve özellikle Bölge Tabanlı Evrişimli Sinir Ağı (RCNN) mimarilerinde her aşamanın ayrı ayrı eğitilmesini zorlaştırarak optimize etmeyi zorlaştırır (Aditya Sharma, 2022).



Şekil 3.6. YOLO tespit sistemi (Redmon vd., 2015)

### 3.7. Doğal Dil İşleme (NLP)

NLP, üç temel terimin entegrasyonu ile oluşturulmuştur. Bu terimler şunlardır: nöroloji, yani zihinsel ve düşünsel süreçler; dilbilim, yani dil kullanımı ve dilin bireyleri nasıl etkilediği; programlama, yani hedeflere ulaşmak için eylemlerin sıralanma şekli (O'Connor, 2001).

#### 3.7.1. NLP'nin temel görevleri

- **Dili anlama:** Bilgisayarın metnin anlamını çıkarması, cümle yapısını analiz etmesi ve dilbilgisi kurallarını uygulaması.
- **Dil üretimi:** Bilgisayarın anlamlı ve dilbilgisi kurallarına uygun metinler oluşturması.
- **Konuşma tanıma:** İnsan konuşmasını metne dönüştürme.
- **Konuşma sentezi:** Metni insan konuşmasına dönüştürme.
- **Makine çevirisi:** Bir dilden diğerine metin çevirisi.
- **Metin özetleme:** Uzun metinleri özetleme.
- **Duygu analizi:** Metindeki duyguları ve düşünceleri belirleme.

#### 3.7.2. NLP uygulamaları

- **Sanal asistanlar:** Siri, Alexa gibi sesli asistanlar, NLP kullanarak insanlarla etkileşim kurar.
- **Makine çevirisi:** Google Translate gibi araçlar, farklı diller arasında metin çevirisi yapar.
- **Duygu analizi:** Sosyal medya analizleri, müşteri geri bildirimleri ve pazar araştırmalarında duygu analizi kullanılır.

- **Metin özetleme:** Haber özetleri, araştırma makaleleri ve raporlar gibi uzun metinleri özetlemek için kullanılır.
- **Sohbet robotları:** Müşteri hizmetleri, eğitim ve eğlence gibi alanlarda sohbet robotları insanlarla etkileşim kurar.

### 3.7.3. NLP'nin zorlukları

- **Dil belirsizliği:** İnsan dili doğal olarak belirsizdir, aynı kelime veya cümle farklı bağlamlarda farklı anlamlara gelebilir.
- **Dil değişimi:** Dil sürekli olarak gelişir ve değişir, bu da NLP modellerinin güncel kalmasını zorlaştırır.
- **Kültürel farklılıklar:** Farklı kültürler ve diller, NLP modellerinin genelleştirilmesini zorlaştırır.

Derin öğrenme ve büyük veri analitiğindeki gelişmeler, NLP modellerinin doğruluğunu ve yeteneklerini artırmaktadır. Gelecekte, NLP'nin insanlarla bilgisayarlar arasındaki etkileşimi daha da doğal ve sezgisel hale getirmesi beklenmektedir.

## 3.8. Bilgisayarlı Görü (Computer vision)

Bilgisayarlı görüş, bilgisayarların dijital görüntü ve video verilerini analiz ederek nesneleri tanıma, sahneleri anlama, hareketleri izleme ve hatta insan benzeri özellikleri tespit etme yeteneğini içerir. Bu teknoloji genellikle karmaşık veri setleri üzerinde derin öğrenme ve diğer makine öğrenimi tekniklerini kullanarak başarıyla uygulanmaktadır.

### 3.8.1. Bilgisayarlı görünün temel görevleri

- **Görüntü sınıflandırma:** Görüntüdeki nesneleri veya sahneleri tanımlama ve sınıflandırma (örn. kedi, köpek, araba).
- **Nesne tespiti:** Görüntüdeki nesnelerin yerini ve sınırlarını belirleme (örn. sınırlayıcı kutular ile nesneleri işaretleme).
- **Görüntü segmentasyonu:** Görüntüyü anlamlı bölgelere ayırma (örn. ön plan ve arka plan ayrımı).
- **Hareket analizi:** Görüntülerdeki hareketleri izleme ve analiz etme.

- **3D görüntü işleme:** 3 boyutlu nesneleri ve sahneleri analiz etme.

### 3.8.2. Bilgisayarlı görü uygulamaları

- **Otonom araçlar:** Nesneleri, yayaları ve yolu algılamak ve güvenli sürüş kararları almak için kullanılır.
- **Tıbbi görüntüleme:** X-ray, MR ve BT taramalarını analiz ederek hastalıkları teşhis etmek ve tedavileri planlamak için kullanılmaktadır.
- **Yüz tanıma:** Güvenlik sistemleri, biyometrik kimlik doğrulama ve fotoğraf etiketleme gibi uygulamalarda kullanılır.
- **Robotik:** Robotların etraflarındaki dünyayı algılamasını ve etkileşim kurmasını sağlamak için kullanılır.
- **Üretim:** Kalite kontrol, ürün sınıflandırma ve otomatik inceleme gibi görevlerde kullanılır.

### 3.8.3. Bilgisayarlı görünün zorlukları

- **Görsel belirsizlik:** Aynı nesne farklı açılardan, ışıklandırma koşullarında veya arka planlarda farklı görünebilir.
- **Görsel karmaşıklık:** Gerçek dünya görüntüleri çok sayıda nesne ve ayrıntı içerir, bu da işlemeyi zorlaştırır.
- **Hesaplama maliyeti:** Bilgisayarlı görü algoritmaları, özellikle derin öğrenme modelleri, yüksek hesaplama gücü ve kaynak gerektirir.

Derin öğrenme ve büyük veri analitiğindeki gelişmeler, bilgisayarlı görü modellerinin doğruluğunu ve yeteneklerini artırmaktadır. Gelecekte, bilgisayarlı görünün insan görsel sistemini aşan yeteneklere sahip olması ve birçok sektörde devrim yaratması beklenmektedir.

## 3.9. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonu, bir yapay sinir ağı veya derin öğrenme modelinde bulunan nöronların çıkışını belirleyen matematiksel bir işlevdir. Bu fonksiyon, nöronun çıkışını

oluşturan girdi toplamının (ağırlıklı toplam) bir doğrusal olmayan dönüşümünü gerçekleştirir. CNN yapılarında kullanılan başlıca aktivasyon fonksiyonları şunlardır:


### 3.9.1. Sigmoid

Sigmoid fonksiyonu, herhangi bir girişi 0 ile 1 arasına sıkıştırır. İkili sınıflandırma problemlerinin çıkış katmanında sıklıkla kullanılan bir aktivasyon fonksiyonudur (Şekil 3.7). Formülü aşağıda gibidir.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.1)$$

#### Dezavantajları:

- Derin ağlarda, girdi değerleri çok büyük veya çok küçük olduğunda gradyanlar sifıra yakın değerler alabilir. Bu durum, ağıın öğrenmesini yavaşlatabilir veya tamamen durdurabilir.
- Üstel fonksiyon içerdiği için diğer aktivasyon fonksiyonlarından daha yavaş hesaplanır.



Şekil 3.7. Sigmoid fonksiyonu

#### Kullanımı:


Çıkış katmanında ikili sınıflandırma problemleri için kullanılır.

### 3.9.2. Softmax

CNN yapılarındaki son katmanlarda sıklıkla kullanılan diğer bir aktivasyon fonksiyonu da softmaxtır. Bu fonksiyon çoklu sınıflandırma problemlerinde sınıfların olasılık

dağılımlarını hesaplamada kullanılır (Şekil 3.8). Softmax fonksiyonu (3.2) nolu denkleme göre hesaplanır.

$$S(x_i) = \frac{e^{x_i}}{\sum_{j=1}^n e^{x_j}} \quad (3.2)$$



Şekil 3.8. Softmax fonksiyonu

#### Avantaj ve dezavantajları:

- Çıkışlar, her sınıf için bir olasılık dağılımını temsil eder.
- Çok sınıflı sınıflandırma problemleri için idealdir.
- Büyük giriş değerleri için üstel fonksiyonun taşmasına neden olabilir.
- Farklı girişler için aynı çıktıları üretebilir, bu da öğrenmeyi yavaşlatabilir.

#### Kullanımı:

- Softmax, birden fazla olası sınıf olduğunda kullanılır. Örneğin, bir görüntü sınıflandırma modelinde, softmax fonksiyonu, girdi görüntüsünün her bir sınıf için olasılığını verir.
- Softmax, genellikle derin öğrenme modellerinin çıkış katmanında kullanılır, özellikle de CNN'lerde ve RNN'lerde.


### 3.9.3. ReLu

ReLu (Rectified Linear Unit), en yaygın kullanılan aktivasyon fonksiyonlarından biridir. Negatif değerleri 0'a eşitler, pozitif değerleri olduğu gibi korur. Hızlı ve hesaplama açısından verimlidir (Denk. 3.3). Basit ve etkili olması nedeniyle tercih edilir. ReLu fonksiyon grafiği Şekil 3.9'da gösterilmiştir.

#### Avantaj ve dezavantajları:

- Basit bir eşikleme işlemi olduğu için sigmoid ve tanh'dan çok daha hızlı hesaplanır.
- Pozitif girdiler için gradyan sabittir (1), bu da gradyanların daha iyi yayılmasını ve ağıın daha hızlı öğrenmesini sağlar.
- Negatif değerleri 0'a eşitleyerek ağıın daha seyrek olmasını sağlar. Bu da daha hızlı eğitim ve daha iyi genelleme yeteneği sağlar.
- Büyük negatif değerler için gradyan 0 olur. Bu durum, ilgili nöronların öğrenmeyi durdurmasına ve ağıın performansının düşmesine neden olur.

$$f(x) = \max(0, x) \quad (3.3)$$



Şekil 3.9. ReLu fonksiyonu

#### Kullanımı:

ReLU, yaygın olarak derin öğrenme modellerinde, özellikle de görüntü sınıflandırması ve nesne tanıma gibi bilgisayarlı görme görevlerinde kullanılır.

#### 3.9.4. Leaky ReLu

Negatif değerleri 0'a eşitlemez, küçük bir eğimle korur. Bu, ReLu'nun negatif bölgesindeki problemleri azaltmaya ve ReLU'ya göre daha sağlam bir model oluşturmaya yardımcı olur (Denk. 3.4). Leaky ReLu grafiği Şekil 3.10'da gösterilmiştir.

$$f(x) = \max(0.01x, x) \quad (3.4)$$


#### Avantaj ve dezavantajları:

- Negatif girdiler için 0 olmayan bir gradyan sağlayarak "ölü ReLU" problemini azaltmaya çalışır.

- Bazı durumlarda ReLU'dan daha iyi performans gösterse de bu garanti değildir.

#### Kullanımı:

- ReLU'nun performansını artırmak için kullanılır.
- Özellikle "ölü ReLU" probleminin yaşandığı durumlarda faydalı olabilir.




Şekil 3.10. Leaky ReLU fonksiyonu

#### 3.9.5. PReLU

PReLU (Parametric ReLU), ReLU aktivasyon fonksiyonunun bir çeşididir ve negatif girdiler için sabit bir eğim yerine öğrenilebilir bir parametre kullanır. Bu sayede, ReLU'nun "ölü ReLU" problemini ele alırken aynı zamanda ağı daha fazla esneklik sağlar (Denk 3.5). PReLU grafiği Şekil 3.11'de gösterilmiştir.

$$x \geq 0 \text{ ise } PReLU(x) = x, x < 0 \text{ ise } PReLU(x) = \alpha * x \quad (3.5)$$



Şekil 3.11. PReLU fonksiyonu

#### Avantaj ve dezavantajları:

- Negatif girdiler için sıfır olmayan bir gradyan sağlayarak "ölü ReLU" problemini ele alır.
- Öğrenilebilir  $\alpha$  parametresi sayesinde, ağ, veriler için en uygun doğrusal olmayanlığı öğrenme esnekliğine sahip olur.
- Bazı durumlarda, PReLU, ReLU ve Leaky ReLU'dan daha iyi performans gösterebilir.
- $\alpha$  parametresi, ağa ek bir parametre ekler. Bu da aşırı öğrenme riskini artırabilir, özellikle de veri kümesi küçükse.


#### Kullanımı:

Daha fazla esneklik sağlamak ve Leaky ReLU'nun performansını iyileştirmek için kullanılabilir. Genellikle ReLU'nun performansını artırabileceği durumlarda tercih edilir.

#### 3.9.6. ELU

ELU (Exponential Linear Unit), ReLU aktivasyon fonksiyonunun bazı sınırlarını ele almayı hedefleyen ve genellikle daha hızlı öğrenme ve daha iyi genelleme yeteneği sunan bir aktivasyon fonksiyonudur (Şekil 3.12). Formülü (3.6) nolu denklemde sunulmuştur.

$$x \geq 0 \text{ ise } ELU(x) = x, \quad x < 0 \text{ ise } ELU(x) = \alpha(e^x - 1) \quad (3.6)$$



Şekil 3.12. ELU fonksiyonu

#### Avantaj ve dezavantajları:

- ELU, ReLU gibi hesaplama açısından verimlidir ve gradyan yok olma problemini hafifletmeye yardımcı olur.
- ReLU'nun aksine, ELU negatif değerler için sıfır olmayan bir gradyana sahiptir, bu da "ölü ReLU" problemini önler ve ağıın tüm girdi aralığında öğrenmesini sağlar.
- Düzgün türevi sayesinde ELU, daha hızlı yakınsama ve daha iyi bir çözüme ulaşma potansiyeli sunar.
- ELU, gürültülü verilere karşı ReLU ve Leaky ReLU'dan daha dayanıklı olabilir.
- Üstel fonksiyonun varlığı, ReLU'ya kıyasla ELU'yu hesaplama açısından biraz daha maliyetli hale getirir, ancak fark genellikle ihmal edilebilir düzeydedir.


#### Kullanımı:

Daha iyi performans için ReLU yerine kullanabilir. Gürültülü verilerle çalışırken fayda sağlar.

#### 3.9.7. Tanh

Tanh fonksiyonu, sigmoid'e benzer ancak çıkışı -1 ile 1 arasına sıkıştırır. Regresyon problemlerinde kullanılır (Denk 3.7). Merkezi eğilimli olması, girişlerin ortalamasını sıfıra getirir, bu da eğitim sürecini kolaylaştırır (Şekil 3.13).

$$\tanh(x) = \frac{(e^x - e^{-x})}{(e^x + e^{-x})} \quad (3.7)$$



Şekil 3.13. Tanh fonksiyonu

### **Avantaj ve dezavantajları:**

- Gradyanların daha düzgün yayılmasını sağlar, bu da öğrenmeyi hızlandırır.
- Bazı durumlarda daha hızlı bir şekilde optimum sonuçlara ulaşabilir.
- Sigmoid gibi, tanh da gradyan yok olma problemine karşı hassastır.

### **Kullanımı:**

- Özellikle RNN'lerde (Tekrarlayan Sinir Ağları) ve LSTM'lerde (Uzun Kısa Süreli Bellek) yaygın olarak kullanılır.
- Gizli katmanlarda kullanılabilir ancak ReLU kadar popüler değildir.

**Aktivasyon fonksiyonu seçimi:** Aktivasyon fonksiyonları CNN modelinizin başarısı üzerinde önemli bir etkiye sahiptir. Genel bir kural olarak:

ReLU, genellikle başlangıç noktası olarak iyi bir seçimdir. Basit, hızlı ve genellikle iyi performans gösterir.

Leaky ReLU, "ölü ReLU" problemini azaltmak için kullanılabilir.

PReLU, Leaky ReLU'ya göre daha fazla esneklik sağlar.

ELU, daha hızlı yakınsama sağlayabilir ancak hesaplama açısından daha maliyetlidir.

Sigmoid, genellikle ikili sınıflandırma problemlerinin çıkış katmanında kullanılır.

Tanh, RNN'lerde ve LSTM'lerde yaygın olarak kullanılır.

En iyi aktivasyon fonksiyonu, probleme ve veri kümesine bağlı olarak değişecektir. Genellikle deneme yanılma yoluyla en iyi performans gösteren aktivasyon fonksiyonunu bulmak gerekir.

### **3.10. Optimizasyon Fonksiyonları**

Derin öğrenmede, modeller karmaşık ve çok boyutlu parametrelere sahip olduğu için, bu parametrelerin en uygun şekilde ayarlanması büyük önem taşır. Optimizasyon fonksiyonları, bu parametreleri iteratif olarak güncelleyerek, modelin kayıp fonksiyonunu (loss function) yani model tahminlerinin gerçek değerlerden ne kadar uzak olduğunu gösterir. Optimizasyon fonksiyonları modelin daha doğru sonuçlar üretmesini sağlar, modelin eğitim süresini kısaltır ve genelleme yeteneğini artırır. Derin öğrenmede sıkça kullanılan bazı optimizasyon fonksiyonları aşağıda açıklanmıştır.

### **3.10.1. Adaptive gradient (AdaGrad)**

Derin öğrenme modellerini eğitmek için kullanılan bir optimizasyon algoritmasıdır. Özellikle seyrek veriler ve doğal dil işleme gibi uygulamalarda tercih edilir. Her parametre için ayrı bir öğrenme oranı kullanarak, parametrelerin güncellenmesini optimize eder. Seyrek ve farklı ölçeklerdeki parametre güncellemeleri gereken durumlarda kullanılır.

### **3.10.2. Root mean square propagation (RMSprop)**

AdaGrad algoritmasının bir modifikasyonudur ve parametre güncellemelerinde daha dengeli bir yaklaşım sunar. AdaGrad'ın problemi olan öğrenme hızının zaman içinde çok küçük olmasını çözmeye yönelik olarak geliştirilmiştir. Özellikle görüntü işleme ve tekrarlayan sinir ağları gibi alanlarda yaygın olarak kullanılır.

### **3.10.3. Stochastic gradient descent (SGD)**

Genel amaçlı bir optimizasyon algoritmasıdır ve çoğu derin öğrenme modelinde kullanılabilir. Bir modelin parametrelerini, kayıp fonksiyonunu minimize ederek optimize etmeye çalışır. SGD, en basit ve en hızlı optimizasyon algoritmalarından biri olmasının yanında büyük veri setleri ile çalışmaya uygun ve daha az hesaplama kaynağına ihtiyaç duyan bir optimizasyon fonksiyonudur. Basit ve büyük veri setlerinde başlangıç olarak tercih edilebilir.

### **3.10.4. Adaptive moment estimation (Adam)**

SGD ve RMSProp algoritmalarının bir kombinasyonudur ve her ikisinin de avantajlarını birleştirmeye çalışır. Hem öğrenme oranını adaptif olarak ayarlamak hem de momentum kullanarak daha hızlı ve kararlı yakınsama sağlamak için kullanılır. Çoğu uygulama ve veri setinde tercih edilen genel amaçlı bir optimizasyon algoritmasıdır. Büyük veri setleri ve derin ağlarda yaygın olarak kullanılır.

### 3.10.5. Adamax

Adam'ın bir genişletmesidir. Özellikle büyük veri setleri veya yüksek boyutlu parametre uzaylarında etkilidir. Adamax, Adam'a göre daha istikrarlı bir eğitim, daha az parametre güncellemesi ve daha iyi genelleme sağlar. Adamax, adaptif öğrenme oranı ve momentum özelliklerini korurken, büyük gradyan adımlarına karşı daha dayanıklı bir optimizasyon sağlar. Bu, belirli durumlarda stabilite ve performans açısından avantaj sağlayabilir. Ancak, diğer optimizasyon algoritmaları gibi, veri setine ve probleme bağlı olarak performansı değişebilir ve hiper parametrelerin dikkatli bir şekilde ayarlanması gerekebilir.

Her optimizasyon fonksiyonunun avantajları ve dezavantajları vardır. Hangi fonksiyonun kullanılacağı, veri setinin büyüklüğüne, modelin karmaşıklığına, öğrenme hızına ve aşırı uyum riskine göre belirlenmelidir. Çoğu durumda Adam ve Adamax, iyi bir başlangıç noktası olarak tercih edilir. Ancak, özel durumlarda diğer optimizasyon algoritmaları daha uygun olabilir.

## 3.11. Derin Öğrenme Modellerinde Kullanılan Başarı Parametreleri

Derin öğrenme yöntemlerinde kullanılan başarı parametreleri, modelin performansını değerlendirmek ve iyileştirmek için kullanılır. Bu parametreler, modelin doğruluğunu, genelleme yeteneğini ve eğitim sürecinin etkinliğini ölçer. Derin öğrenmede yaygın olarak kullanılan başarı metrikleri aşağıda açıklanmıştır.

### 3.11.1. Sınıflandırma problemleri için kullanılan metrikler

#### Doğruluk (Accuracy)

Oluşturulan modelin ne kadar doğru olduğunun ölçütüdür. Modelin doğru tahmin ettiği örneklerin sayısının, toplam örnek sayısına oranı olarak ifade edilir. Hesaplanması kolay ve anlaşılması basit olmasına rağmen dengesiz veri kümeleri için yanıltıcı olabilir, çünkü azınlık sınıfındaki hataları görmezden gelebilir (Denk. 3.8).

$$ACC = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.8)$$

### Kesinlik (Precision)

Kesinlik (hassasiyet), doğru şekilde pozitif olarak sınıflandırılan pozitif örnek sayısının, pozitif olarak sınıflandırılan (doğru veya yanlış) toplam örnek sayısına oranı olarak hesaplanır. Hassasiyet, modelin bir örneği pozitif olarak sınıflandırmadaki doğruluğunu ölçer (Denk 3.9).

Model birçok yanlış pozitif sınıflandırma yaptığında veya birkaç doğru pozitif sınıflandırma yaptığında, bu paydayı artırır ve hassasiyeti küçültür. Öte yandan, hassasiyet yüksek olduğunda:

Model birçok doğru pozitif sınıflandırma yapar ve böylelikle daha az yanlış pozitif sınıflandırma yapar.

$$P = \frac{TP}{TP+FP} \quad (3.9)$$

### Duyarlılık (Recall)

Duyarlılık, doğru şekilde pozitif olarak sınıflandırılan pozitif örnek sayısının, toplam pozitif örnek sayısına oranı olarak hesaplanmaktadır. Bu metrik, modelin pozitif örnekleri tespit etme kapasitesini değerlendirmektedir. Duyarlılığın değeri ne kadar yüksek olursa, model o kadar fazla pozitif örneği doğru bir şekilde tespit eder (Denk 3.10).

$$R = \frac{TP}{TP+FN} \quad (3.10)$$

### F1 skor

F1 skoru, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan önemli bir ölçüttür. Özellikle dengesiz veri kümeleri için faydalıdır çünkü hem hassasiyeti hem de duyarlılığı hesaba katar. Basitçe söylemek gerekirse, F1 skoru modelin ne kadar "dengeli" performans gösterdiğini ölçer.

Formülü aşağıdaki gibidir.

$$F1\ Score = 2 * \frac{Precision*Recall}{Precision+Recall} \quad (3.11)$$

### F1 skorun temel özellikleri:

- **0 ile 1 arasında bir değer alır:** 1 mükemmel bir skor iken, 0 en düşük skordur.

- **Hassasiyet ve duyarlılığın harmonik ortalamasıdır:** Bu, her iki metriği de eşit olarak değerlendirdiği anlamına gelir.
- **Dengesiz veri kümeleri için idealdir:** Bu tür veri kümelerinde, bir sınıfın örnek sayısı diğerlerinden çok daha fazladır ve bu durum geleneksel doğruluk ölçütlerini yanıltıcı hale getirebilir.


### ROC eğrisi ve AUC

ROC eğrisi ve AUC, bir sınıflandırma modelinin performansını değerlendirmek için kullanılan güçlü metriklerdir. AUC, dengesiz veri kümeleri için özellikle kullanışlıdır ve modelin tüm olası eşik değerleri için performansını gösterir. Ancak, tek bir metrik olarak kullanıldığında yanıltıcı olabilir ve dengesiz veri kümeleri için güvenilirliği sınırlı olabilir. Şekil 3.14'te ROC eğrisi ve AUC alanı grafiği gösterilmiştir.

ROC eğrisi, bir sınıflandırma modelinin farklı eşik değerlerindeki performansını gösteren bir grafikdir. Eğrinin x eksenini yanlış pozitif oranını (FPR), y eksenini ise doğru pozitif oranını (TPR) temsil eder.

**Yanlış pozitif oran (FPR):** Gerçekte negatif olan örneklerin pozitif olarak sınıflandırıldığı orandır.

**Doğru pozitif oran (TPR):** Gerçekte pozitif olan örneklerin pozitif olarak sınıflandırıldığı orandır (aynı zamanda geri çağırma olarak da bilinir).



Şekil 3.13. ROC eğrisi ve AUC alanı

ROC eğrisi, farklı eşik değerleri kullanılarak oluşturulur. Eşik değeri ne kadar yüksek olursa, model o kadar az örnek sınıflandırır, dolayısıyla daha az yanlış pozitif ve daha az doğru pozitif elde edilir.

AUC, ROC eğrisinin altında kalan alanın ölçüsüdür. AUC, 0 ile 1 arasında değişen bir değerdir. Bu değerlerin anlamları aşağıdaki gibidir.

AUC = 1: Model mükemmeldir ve tüm pozitif örnekleri doğru bir şekilde sınıflandırır.

AUC = 0.5: Model rastgele tahminlerde bulunur ve performansı rastgele tahminlerden daha iyi değildir.

AUC = 0: Model tamamen tersine çevrilmiştir ve tüm pozitif örnekleri yanlış bir şekilde sınıflandırır.

### 3.11.2. Regresyon problemleri için kullanılan metrikler

**Mean absolute error (MAE):** Modelin tahminleri ile gerçek değerler arasındaki mutlak farkların ortalamasıdır. Her tahmin-hata arasındaki farkın büyüklüğünü ölçer. Formülü aşağıda görülmektedir:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.12)$$

Burada  $n$  veri noktası sayısını,  $y_i$  gerçek değeri,  $\hat{y}_i$  tahmini değeri ifade eder.

Aykırı değerlere karşı daha az hassas olmasına karşın Mean Squared Error (MSE) metriğine göre daha az bilgi sağlar.

**Mean squared error (MSE):** Modelin tahminleri ile gerçek değerler arasındaki karesel farkların ortalamasıdır. Büyük hataların daha fazla vurgulanmasını sağlar. Formülü Denk. 3.13'teki gibidir.

$$MSE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2 \quad (3.13)$$

Hesaplanması kolay ve anlaşılması basittir. Hatalara karşı hassasiyet sağlar. Dezavantajı ise aykırı değerlerden etkilenebilmesidir.

**Root mean squared error (RMSE):** RMSE, MSE'nin karekökü alınarak hesaplanır. Gerçek ve tahmini değerler arasındaki farkın standart sapmasını ifade eder. Daha yüksek hata değerleri nedeniyle daha fazla ağırlık taşır. MSE'ye benzer, ancak hataları orijinal ölçekte ifade eder. Buna karşın aykırı değerlerden etkilenebilir. RMSE (3.14) eşitliği ile hesaplanır.


$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2} \quad (3.14)$$

Hangi metriğin kullanılacağı, çözülmek istenen spesifik regresyon probleminin doğasına ve veri kümesinin özelliklerine bağlıdır. Örneğin, aykırı değerlerden etkilenmeyen bir metrik mi yoksa gerçek değerlerin orijinal ölçekte ifade edildiği bir metrik mi kullanmak istediğiniz sorularını cevaplamanız gerekir.

### 3.11.3. Genel metrikler

#### Karmaşıklık matrisi (Confusion matrix)

Karmaşıklık (karışıklık) matrisi, makine öğrenmesi modellerinin performansını değerlendirmek için kullanılan metriklerden biridir. Bu matris, modelin tahminlerini gerçek değerlerle karşılaştırır ve her sınıf için doğru ve yanlış tahminlerin sayısını gösterir (Şekil 3.15).



Şekil 3.14. Karmaşıklık Matrisinin Gösterimi

Karışıklık matrisinde kullanılan temel kavramlar şunlardır:

- **Doğru pozitif (TP):** Modelin doğru bir şekilde pozitif olarak sınıflandırdığı örneklerin sayısıdır.
- **Doğru negatif (TN):** Modelin doğru bir şekilde negatif olarak sınıflandırdığı örneklerin sayısıdır.
- **Yanlış pozitif (FP):** Modelin yanlışlıkla pozitif olarak sınıflandırdığı örneklerin sayısıdır.
- **Yanlış negatif (FN):** Modelin yanlışlıkla negatif olarak sınıflandırdığı örneklerin sayısıdır.

Bu değerler, modelin doğruluk, hassasiyet, duyarlılık oranı ve F1 skoru gibi ölçütleri hesaplamak için kullanılır.

#### **Kayıp fonksiyonu (Loss function)**

Kayıp fonksiyonu (Loss Function), bir makine öğrenmesi modelinin performansını değerlendirmek için kullanılan bir matematiksel fonksiyondur. Modelin yaptığı tahminlerin gerçek değerlerden ne kadar uzak olduğunu ölçer. Bu fonksiyon, model eğitimi sırasında modelin parametrelerini optimize etmek için kullanılır. Görevi modelin yaptığı tahminler ile gerçek değerler arasındaki farkı (hata) ölçmektir.

#### **3.11.4. Nesne tespiti için kullanılan metrikler**

Nesne tespitinde derin öğrenmede kullanılan ve yukarıda açıklamalarını yaptığımız metriklere ek olarak aşağıdaki metrikler de kullanılmaktadır.

#### **Ortalama hassasiyet (AP)**

AP, nesne tespiti modellerinin performansını değerlendirmek için hassasiyet ve güveni birleştiren önemli bir ölçüttür. Kesinlik-duyarlılık eğrisinin altındaki alanı hesaplar ve modelin farklı eşik değerlerinde ne kadar iyi performans gösterdiğini özetler. Daha yüksek AP, daha doğru ve güvenilir nesne tespiti anlamına gelir. Ortalama hassasiyet (3.15) nolu eşitlikteki gibi tespit edilir.

$$AP = \int_0^1 p(r)dr \cong \sum_{k=1}^n p(k) \cdot \Delta r(k) \quad (3.15)$$

### Genel ortalama hassasiyet (mAP)

mAP, nesne tespit modellerinin performansını ölçmek için kullanılan önemli bir metriktir. mAP, modelin tespit ettiği nesnelerin doğruluğunu değerlendirmek için hassasiyet-duyarlılık eğrisinin altında kalan alanı ölçer. Bu eğri, farklı güven eşiklerindeki model performansını gösterir. mAP50, güven eşiği olarak 0,5 kullanılarak hesaplanan mAP'dir. Bu, modelin en az %50 güvenle doğru bir şekilde tespit ettiği nesnelerin doğruluğunu yansıtır. mAP50-95 ise 0,5 ile 0,95 arasındaki farklı güven eşiklerinde hesaplanan mAP'lerin ortalamasıdır. Bu, modelin farklı güven düzeylerindeki genel performansını gösterir. mAP değeri ne kadar yüksek olursa, modelin nesneleri o kadar doğru bir şekilde tespit ettiği anlamına gelir (Tarık Aslan ve Mustafa Yagımlı, 2023) . Formülü (3.16) nolu denklemde verilmiştir.

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (3.16)$$

### Intersection over union (IoU)

Nesne algılama modellerinin performansını değerlendirmek için kullanılan önemli bir metriktir. Modelin tahmin ettiği nesne kutusu ile gerçek nesne kutusu arasındaki örtüşme oranını ölçer, yani modelin nesneleri ne kadar doğru konumlandırıldığını belirtir. IoU, iki kutunun kesişim alanının, iki kutunun birleşim alanına oranı olarak hesaplanır. IoU (3.17) nolu denkleme göre hesaplanır.

$$IoU = \frac{\text{Kesişim Alanı}}{\text{Birleşim Alanı}} \quad (3.17)$$

İki kutu birbirine çok benziyorsa, kesişim alanı büyük, birleşim alanı ise küçük olur. Bu durumda IoU yüksek olur, yani modelin tahmini gerçek nesneye yakın demektir.

#### **4. MATERİYAL ve YÖNTEM**

Bu çalışma, incelenen konunun önemi göz önünde bulundurularak literatürdeki çalışmalardan farklı bir metodolojik yaklaşım benimsemektedir. Çalışmada, veri seti orijinal haliyle kullanılmasının yanı sıra, çeşitli ön işleme teknikleri uygulanarak üç farklı veri seti elde edilmiştir. Bu yaklaşımın temel amacı, uygulanan ön işleme yöntemlerinin model başarısı üzerindeki etkisini incelemektir.

Model performansını artırmak amacıyla, görüntülere gabor filtresi uygulanarak ikinci bir veri seti oluşturulmuştur. Ek olarak, orijinal veri setindeki görüntülere öncelikle histogram eşitleme, ardından ise kontrast sınırlı uyarlanabilir histogram eşitleme (CLAHE) uygulanarak üçüncü bir veri seti oluşturulmuştur. Veri setleri, iki farklı ayrıştırma yöntemi kullanılarak oluşturulmuştur. İlk ayrıştırmada, veri setinin %70'i eğitim, %20'si doğrulama ve %10'u test amacıyla kullanılmıştır. İkinci ayrıştırmada ise bu oranlar sırasıyla %60 eğitim, %20 doğrulama ve %20 test olarak belirlenmiştir. Veri seti genişletme işleminin ardından, evrişimli sinir ağları ve son yıllarda popüleritesi artan YOLO algoritmasının 8. versiyonu kullanılarak modellerin başarı metrikleri açısından karşılaştırmalı bir analizi gerçekleştirilmiştir. Çalışmanın akış şeması Şekil 4.1'de gösterilmiştir.

##### **4.1. Veri Setlerinin Hazırlanması**


Veri setini hazırlamak, makine öğrenmesi modellerinin başarısında çok önemli bir rol oynamaktadır. İyi hazırlanmış bir veri seti, modelin performansını artırır, doğru tahminler yapmasını sağlar ve genelleme yeteneğini iyileştirir.

YOLO ve CNN modellerinde kullanılmak üzere hazırlanan veri setleri ve bunlar üzerinde yapılan işlemler aşağıda açıklanmıştır.

##### **Veri ön işleme:**

Veri ön işleme, makine öğrenmesi modellerinin performansını artırmak ve daha doğru sonuçlar elde etmek için verileri hazırlama sürecidir. Ham veriler genellikle düzensiz, eksik, farklı ölçeklerde veya doğrudan modelin anlamayacağı formatlarda olabilir. Veri

ön işleme, bu sorunları ele alarak veriyi modelin etkili bir şekilde kullanabileceği bir hale getirir.



Şekil 4.1. Uygulamanın akış şeması

#### Boyutlandırma:

Veri setini boyutlandırma (data scaling) veya veri normalizasyonu, makine öğrenmesi modellerinde verilerin tüm özelliklerin benzer bir ölçekte olması için dönüştürülmesidir. Bu, farklı ölçeklerde olan görüntülerin modelin performansını olumsuz etkilemesini önlemek için önemlidir. Kullanılan veri kümelerindeki görüntülerin boyutları farklı olduğu için bu kümelerdeki görüntüler aynı ölçeğe getirilmek amacıyla küçültülmüştür.

CNN modellerinde kullanılan görüntülere boyut azaltımı yapılarak, görüntüler 64x64 piksel boyutuna indirgenmiştir.

CNN modelleri için yapılan bu boyut azaltımı, model eğitiminde kaynak kullanımından ve zamandan tasarruf sağlamayı amaçlamaktadır. YOLO modeli, büyük ölçekli görüntülerde daha yüksek başarı elde ettiği için, YOLO veri setinde herhangi bir boyut azaltımı yapılmamıştır. Fakat veri setinde aynı ölçekte olmayan görüntülere boyutlandırma yapılarak görüntüler aynı ölçüye getirilmiştir.

#### **4.1.1. YOLO veri setleri**

İlk veri seti (YOLO\_Set A), "Lung Image Dataset" adlı veri setidir ve Roboflow platformunda yayınlanmıştır (Rodney, 2023). Toplamda 1557 adet 512x512 piksel boyutundaki BT görüntüsünden oluşmaktadır. Bu veri setindeki görüntülere veri artırma yöntemleri (döndürme, çevirme, parlaklık/kontrast, çarpıtma) uygulanarak veri seti, 3910 adet görüntüye çıkarılmıştır.

İkinci veri seti (YOLO\_Set B): Bu veri setindeki BT görüntüleri "Cancer Imaging Archive (TCIA)" kaynağından elde edilmiştir (Clark vd., 2013; AKCA, 2021). Bu set toplamda 4968 adet 512x512 piksel boyutundaki BT görüntüsünden oluşmaktadır.

#### **4.1.2. CNN veri setleri**

CNN modelinin eğitimi için kullanılan ilk veri seti (CNN\_Set A), kaggle.com sitesinde yayınlanan "Large COVID-19 CT Scan Slice Dataset" isimli veri kümesindeki sağlıklı akciğer BT görüntüleri ile YOLO algoritması için hazırladığımız ilk veri setinin birleştirilmesi ile oluşturulmuştur. Bu iki veri kümesinden de eşit sayıda BT görüntüsü alınmış olup toplam 7474 görüntü ile CNN modeli eğitime tabii tutulmuştur (Maftouni, 2021; Rodney, 2023).

CNN için kullanılan ikinci veri seti (CNN\_Set B) ise, "TCIA" kaynağından elde edilen kanserli BT görüntüleri ile roboflow.com platformundan elde edilen normal akciğer BT görüntülerinin birleştirilmesi ile oluşturulmuştur. Bu veri seti toplam 7940 adet BT görüntüsünden oluşmaktadır (Clark vd., 2013; Mehmet Fatih AKCA, 2021; Normalset Computer Vision Project, 2023).

CNN ve YOLO modellerinde kullanılan veri setleri aşağıdaki biçimde adlandırılmıştır (Tablo 4.1).

**Tablo 4.1.** Veri setlerinin adlandırılması

|             |                      |            |
|-------------|----------------------|------------|
| <b>YOLO</b> | 1. Veri seti (Set A) | YOLO_Set A |
|             | 2. Veri seti (Set B) | YOLO_Set B |
| <b>CNN</b>  | 1. Veri seti (Set A) | CNN_Set A  |
|             | 2. Veri seti (Set B) | CNN_Set B  |

Oluşturulan YOLO ve CNN veri setlerine ait bilgiler Tablo 4.2’ de gösterilmiştir.

**Tablo 4.2.** CNN ve YOLO veri seti bilgileri


| Model       | Veri seti  | Görüntü Adeti | Piksel Değerleri | Görüntü Formatı | Çözünürlük |
|-------------|------------|---------------|------------------|-----------------|------------|
| <b>YOLO</b> | YOLO_Set A | 3910          | 512x512          | jpg             | 96 dpi     |
|             | YOLO_Set B | 4968          | 512x512          | jpg             | 96 dpi     |
| <b>CNN</b>  | CNN_Set A  | 7474          | 512x512          | jpg             | 96 dpi     |
|             | CNN_Set B  | 7940          | 512x512          | jpg             | 96 dpi     |

Her iki model (CNN ve YOLO) için hazırlanan veri setlerine, gabor filtresi ve histogram eşitleme + CLAHE filtreleri uygulanarak yeni veri setleri elde edilmiştir. Uygulanan bu yöntemler bundan sonra Tablo 4.3’teki gibi isimlendirilecektir.


**Tablo 4.3.** Yöntemlerin adlandırılması

| Yöntem Adı | Yöntemin Açıklaması                                     |
|------------|---------------------------------------------------------|
| ORJ_V1     | Orijinal veri setine herhangi bir işlem yapılmadı       |
| GAB_V2     | Gabor filtresinin uygulanması ile oluşturulan yöntem    |
| HE+CLH_V3  | Histogram Eşitleme + CLAHE yapılarak elde edilen yöntem |

Şekil 4.2 ve Şekil 4.3’te her veri setine ait örnek görüntüler verilmiştir.



**Şekil 4.2.** CNN ve YOLO modeli için kullanılan Set A veri setine ait örnek görüntüler, (a) Orijinal görüntü (b) Gabor filtresi uygulanmış görüntü (c) Histogram eşitleme + CLAHE uygulanmış görüntü




**Şekil 4.3.** CNN ve YOLO modeli için kullanılan Set B veri setine ait örnek görüntüler, (a) Orijinal görüntü (b) Gabor filtresi uygulanmış görüntü (c) Histogram eşitleme + CLAHE uygulanmış görüntü

#### 4.2. Filtreleme

Her iki model için hazırlanan veri setlerine ait görüntülere netlik, keskinlik ve parlaklık özelliklerinin iyileştirilmesi amacıyla, çeşitli filtreler uygulanmıştır. Bu filtreler, görüntü işleme teknikleri kullanılarak, piksel yoğunluğunu ve kontrastı ayarlayarak, düşük frekanslı gürültüyü azaltarak ve kenarları belirginleştirerek görüntülerin görsel kalitesini artırmıştır. Uygulamada kullanılan filtre türleri, veri setinin özelliğine ve hedeflenen iyileştirme seviyesine göre belirlenmiştir. Bu sayede, analiz ve yorumlama için daha net ve daha ayrıntılı görüntüler elde edilmiş, veri setinin bilgi içeriği zenginleştirilmiştir.

**Gabor filtresi:** Gabor filtresi, doku analizi ve görüntü işlemede kullanılan bir filtreleme yöntemidir. Özellikle kenar tespiti, özellik çıkarma ve nesne tanıma gibi görevlerde

kullanılır. Gabor filtresi, gauss fonksiyonu ile cosinus ya da sinus fonksiyonunun çarpımı şeklinde matematiksel olarak tanımlanır. Bu filtre, belirli bir frekansta ve belirli bir yönde değişen yoğunluklarla birlikte görüntüdeki desenleri tespit etmeye yöneliktir. Gabor filtresinden geçirilmiş örnek görüntü Şekil 4.4'te gösterilmiştir.



**Şekil 4.4.** a) Orijinal görüntü, b) Gabor filtresi uygulanmış görüntü

Gabor filtresinin uygulanması (4.1) nolu denkleme göre yapılır.

$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp \left( -\frac{x'^2 + y'^2}{2\sigma^2} \right) \cos \left( 2\pi \frac{x'}{\lambda} + \psi \right) \quad (4.1)$$

$$x' = x \cos \theta + y \sin \theta$$

$$y' = -x \sin \theta + y \cos \theta$$

Bu denklemden:

$\lambda$ , kosinüsün dalga boyu faktörünü temsil eder ve frekansı belirtir.

$\theta$ , Gabor fonksiyonunun yönünü belirtir.

$\psi$ , fazın ofset değerini belirtir.

$\gamma$ , uzamsal görüş açısını belirtir.

$\sigma$ , Gauss bileşeni için standart sapma değerini belirtir.

$x'$  ve  $y'$ , filtre boyutuna göre normalize edilmiş koordinatlardır.

**Histogram eşitleme:** Bir görüntünün histogramını kullanarak kontrastını ve parlaklığını ayarlayan bir görüntü işleme tekniğidir. Bu teknik, görüntünün dinamik aralığını genişletmek ve görüntünün daha ayrıntılı görünmesini sağlamak için kullanılır. Histogram eşitleme işlemi, histogramı dönüştürerek, piksel yoğunluklarının daha geniş bir aralığa dağılmasını sağlar. Histogram eşitleme (4.2) nolu denkleme göre yapılır.

$$s_i = (L - 1) \cdot \sum_{j=0}^i \frac{n_j}{n} \quad (4.2)$$

Histogram eşitleme yapılırken ilk adım olarak görüntünün yoğunluk histogramı hesaplanır.

$$p(i) = \frac{n_i}{n} \quad (4.3)$$

Burada:

$p(i)$ ,  $i$  yoğunluk seviyesinin olasılığını (yoğunluk histogramını) temsil eder.

$n_i$ ,  $i$  yoğunluk seviyesindeki piksel sayısını ifade eder.

$n$ , toplam piksel sayısını ifade eder.

İkinci adımda ise kümülatif dağılım fonksiyonu (CDF) hesaplanır.

$$CDF(i) = \sum_{j=0}^i p(j) \quad (4.4)$$

$CDF(i)$ ,  $i$  yoğunluk seviyesine kadar olan yoğunluk değerlerinin kümülatif olasılığını ifade eder.

$j$ , yoğunluk seviyesinin indisidir (0'dan 255'e kadar).

$p(j)$ , yoğunluk histogramını ifade eder.


Son adımda ise yeni yoğunluk değeri ile eşleme yapılır.

$$s_i = (L - 1) \cdot CDF(i) \quad (4.5)$$

$s_i$ ,  $i$  yoğunluk seviyesinin eşitlendiği yeni yoğunluk değerini verir.

$L$ , yoğunluk seviyelerinin toplam sayısını (genellikle 256'dır) ifade eder.


Tüm bu formül ve adımlar, histogram eşitlemenin temelini oluşturur ve görüntülerin kontrastını artırmada yaygın olarak kullanılır. Histogram eşitleme yönteminin uygulandığı görüntü örneği Şekil 4.5'te gösterilmiştir.



Şekil 4.5. a) Orijinal görüntü, b) Histogramı eşitlenen görüntü

**CLAHE (Kontrast Sınırlı Adaptif Histogram Eşitleme):** Geleneksel histogram eşitleme yöntemlerine bir iyileştirme sunan bir görüntü işleme tekniğidir. Standart histogram eşitleme tekniği, tüm görüntü üzerinde aynı eşitleme işlemi uygularken, CLAHE, görüntüyü küçük bölgelere bölerek daha adaptif bir yaklaşım sunar. Şekil 4.6’da CLAHE filtresi uygulanmış bir örnek görüntü verilmiştir.

CLAHE'nin temel amacı, her bir küçük bölge üzerinde histogram eşitleme yaparak yerel kontrastı artırmaktır. Böylece, homojen olmayan aydınlatma koşullarına sahip görüntülerde bile detayları daha iyi koruyarak daha iyi bir kontrast sağlar. CLAHE tekniği (4.6) nolu denkleme göre yapılır.



**Şekil 4.6.** a) Orijinal görüntü, b) CLAHE filtresi uygulanmış görüntü

$$s(x, y) = \text{Clip} \left( \frac{CDF_{norm}(r(x, y)) \times (L-1)}{N_s \times N_r} \right) \quad (4.6)$$

Burada:

$s(x, y)$ , işlenmiş görüntüdür.

$r(x, y)$ , orijinal görüntüdür.

$CDF_{norm}(r(x, y))$ , piksel yoğunluklarının normleştirilmiş kümülatif dağılım fonksiyonudur.


$N_s \times N_r$ , bölgenin boyutudur.

$L$ , piksel değerlerinin aralığıdır (genellikle 0 ile 255 arasında).

$\text{Clip}(x)$ , tepkisel kestirme işlemidir.  $x$  değeri belirli bir aralığın dışındaysa, onu bu aralığa sığdırır.

**Histogram eşitleme+CLAHE filtresi:** Bu yöntemde öncelikle görüntünün histogramı eşitlenir ve ardından bu eşitlenmiş histograma sahip yeni görüntü, kontrast sınırlı adaptif

histogram eşitleme işlemine tabi tutulur. Bu süreç ile hem görüntünün genel parlaklığı artırılır hem de görüntüdeki ayrıntılar daha belirgin hale getirilir (Şekil 4.7).




**Şekil 4.7.** a) Orijinal görüntü, b) Histogram eşitleme+CLAHE filtresi uygulanan görüntü.

### 4.3. Modellerin Uygulanması

Orijinal veri setine (ORJ\_V1) ek olarak, başarı üzerindeki etkisini araştırmak amacıyla her veri setine öncelikle Gabor filtresi uygulanmıştır (GAB\_V2). Daha sonra, orijinal veri setine histogram eşitleme + CLAHE işlemi uygulanarak yeni bir veri seti oluşturulmuştur (HE+CLH\_V3). Sonuç olarak, YOLO ve CNN için her biri farklı ön işleme yöntemleri uygulanmış altı farklı veri seti elde edilmiş ve bu veri setleri üzerinde sınıflandırma ve tespit işlemleri gerçekleştirilmiştir.

#### 4.3.1. CNN modeli

Giriş görüntüsü üzerinde 3 farklı konvolüsyon işlemi gerçekleştirilmiştir. Her konvolüsyon işleminden sonra, modele pooling uygulanarak görüntünün yüksekliği ve genişliği azaltılmıştır. Ayrıca, modelde iç katmanlarda normalizasyonu sağlamak için her konvolüsyondan sonra batch normalizasyon uygulanmış olup aşırı öğrenme ve ezberleme yapmaması için de tam bağlantı katmanından sonra dropout parametresi kullanılmıştır. Son olarak, model sigmoid aktivasyon fonksiyonundan geçirilerek sonuçlar elde edilmiştir. Bu işlemler, giriş görüntüsünden çeşitli özelliklerin çıkarılmasını sağlamak ve modelin daha genel bir şekilde öğrenme yapmasını desteklemek amacını taşımaktadır. Şekil 4.8’de önerilen CNN modeli sunulmuştur.



**Şekil 4.8.** Akciğer tümörü tespiti için geliştirilmiş CNN sınıflandırıcısı

Model, Intel Core i5 7200U 2.5 GHz işlemci ve 8 GB RAM'e sahip bir bilgisayarda 50 epoch süresince çalıştırılmıştır. Bu süreç, 6 farklı veri seti ve 2 farklı bölme işlemi için gerçekleştirilmiştir. Eğitim süreleri Tablo 4.4'te detaylı olarak sunulmuştur.

**Tablo 4.4.** CNN ve YOLO eğitim süreleri

| CNN       |              |              |              |              |
|-----------|--------------|--------------|--------------|--------------|
|           | CNN_Set A    |              | CNN_Set B    |              |
| Yöntem    | 70-20-10     | 60-20-20     | 70-20-10     | 60-20-20     |
| ORJ_V1    | 3 saat 11 dk | 3 saat 15 dk | 3 saat 23 dk | 3 saat 28 dk |
| GAB_V2    | 3 saat 22 dk | 3 saat 24 dk | 3 saat 37 dk | 3 saat 36 dk |
| HE+CLH_V3 | 2 saat 57 dk | 2 saat 51 dk | 3 saat 05 dk | 3 saat 02 dk |
| YOLO      |              |              |              |              |
|           | YOLO_Set A   |              | YOLO_Set B   |              |
| Yöntem    | 70-20-10     | 60-20-20     | 70-20-10     | 60-20-20     |
| ORJ_V1    | 2 saat 18 dk | 2 saat 44 dk | 2 saat 27 dk | 2 saat 57 dk |
| GAB_V2    | 2 saat 09 dk | 2 saat 38 dk | 2 saat 19 dk | 2 saat 50 dk |
| HE+CLH_V3 | 2 saat 22 dk | 2 saat 41 dk | 2 saat 31 dk | 2 saat 54 dk |

#### 4.3.2. YOLO modeli

YOLO v8 mimarisini baz alarak 60 epoch süresince gerçekleştirilen eğitim, Python programlama dili ve Google Colaboratory ile Google Drive kullanılarak gerçekleştirilmiştir. Eğitim sürecini hızlandırmak ve kolaylaştırmak amacıyla Google'ın sağladığı Tesla T4 GPU kullanılmıştır. Veri setinin işlenmesi ve eğitim süresi, Tablo 4.4'te gösterilmiştir. Bu çalışmada Tesla T4 GPU'nun tercih edilme sebebi, CPU ile birkaç gün sürecektir olan eğitim işlemini GPU kullanılarak birkaç saatte tamamlayabilmek

olmuştur. Bu seçim, zamandan tasarruf sağlamak ve eğitim sürecini daha verimli hale getirmek amacını taşımaktadır.




## 5. ARAŞTIRMA BULGULARI


### 5.1. Set A'ya Ait Çalışma Bulguları

#### 5.1.1. CNN modelinin CNN\_Set A veri setine ait performans değerlendirmesi

Şekil 5.1 ve Şekil 5.2'de CNN modellerinin doğruluk eğrileri verilmektedir.




**Şekil 5.1.** CNN\_Set A veri seti %60-%20-%20 bölme durumunda (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 doğruluk eğrileri




**Şekil 5.2.** CNN\_Set A veri seti %70-%20-%10 bölme durumunda (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 doğruluk eğrileri

Verilen doğruluk eğrileri incelendiğinde her iki bölme durumu için HE+CLH\_V3'ün, hem eğitim hem de doğrulama grafiklerinin diğer yöntemlere göre daha az dalgalanma gösterdiği ve daha kararlı bir yapıda olduğu görülmektedir. Bu analiz, CNN modeli için HE+CLH\_V3'ün daha etkili bir performans sergilediğini ve daha güvenilir sonuçlar verdiğini göstermektedir.

Şekil 5.3 ve Şekil 5.4'te CNN modellerine ait kayıp grafiği görülmektedir.



**Şekil 5.3.** CNN\_Set A veri seti %60-%20-%20 bölme durumunda (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 kayıp eğrileri



**Şekil 5.4.** CNN\_Set A veri seti %70-%20-%10 bölme durumunda (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 kayıp eğrileri

Her iki bölme durumunda da bu kayıp grafikleri incelendiğinde ORJ\_V1 ve GAB\_V2'nin eğitim kaybı, doğrulama kaybından daha hızlı azalmakta ve 30. epoch'tan sonra doğrulama kaybı artmaya başlamaktadır. Bu, modelin eğitim verilerine aşırı uyum sağladığını ve doğrulama verilerinde kötüleşmeye başladığını göstermektedir.

HE+CLH\_V3 incelendiğinde ise eğitim kaybı ve doğrulama kaybının benzer şekilde azaldığı ve 20. epoch'tan sonra sabitlendiği görülmektedir. Bu, modelin eğitim verilerine aşırı uyum sağlamadığını ve iyi bir performans gösterdiği sonucunu doğurmaktadır. Bu da bu yöntemin diğer yöntemlerden daha kararlı olduğunu göstermektedir.

Tablo 5.1'de CNN\_Set A model sonuçları verilmiştir. Bu tabloya göre HE+CLH\_V3'ün, her iki veri seti ve neredeyse tüm metrikler açısından en iyi performansı gösterdiği tespit edilmiştir. Özellikle Test Accuracy ve F1-Score değerleri oldukça yüksek çıkmıştır ayrıca eğitim süresi de diğer yöntemlere göre daha düşük seyretmektedir. Bu, HE+CLH\_V3'ün modelin öğrenme kapasitesini önemli ölçüde artırdığını göstermektedir.

**Tablo 5.1.** CNN\_Set A model sonuçları

| CNN | Bölme Durumu | Yöntemler | Train Acc     | Train Loss    | Val Acc      | Val Loss     | Test Acc     | Test Loss    | F1-Score-Kanser/ Normal | Precision-Kanser/ Normal | Recall-Kanser/ Normal |
|-----|--------------|-----------|---------------|---------------|--------------|--------------|--------------|--------------|-------------------------|--------------------------|-----------------------|
|     |              |           |               |               |              |              |              |              |                         |                          |                       |
|     | 60-20-20     | ORJ_V1    | 0,9850        | 0,0610        | 0,894        | 0,480        | 0,890        | 0,470        | 0,89-0,90               | 0,97-0,84                | 0,81-0,98             |
|     |              | GAB_V2    | <b>0,9980</b> | <b>0,0040</b> | 0,920        | 0,250        | 0,950        | 0,290        | 0,92-0,93               | 0,98-0,87                | 0,86-0,98             |
|     |              | HE+CLH_V3 | 0,9960        | 0,0100        | <b>0,989</b> | <b>0,241</b> | <b>0,992</b> | <b>0,024</b> | <b>0,99-0,99</b>        | <b>0,98-1,00</b>         | <b>1,00-0,98</b>      |
|     | 70-20-10     | ORJ_V1    | 0,9847        | 0,6850        | 0,935        | 0,307        | 0,800        | 0,670        | 0,93 0,94               | 0,98-0,90                | 0,89-0,98             |
|     |              | GAB_V2    | <b>1,0000</b> | <b>0,0027</b> | 0,925        | 0,256        | 0,980        | 0,082        | 0,92 0,93               | 1,00-0,87                | 0,85-1,00             |
|     |              | HE+CLH_V3 | 0,9985        | 0,0590        | <b>0,995</b> | <b>0,182</b> | <b>0,993</b> | <b>0,020</b> | <b>0,99-0,99</b>        | <b>0,99-1,00</b>         | <b>1,00-0,99</b>      |


GAB\_V2 de iyi bir performans sergilemektedir, ancak HE+CLH\_V3 kadar tutarlı olmadığı görülmektedir. Train Accuracy değeri yüksek olmasına rağmen, bu durum Validation Accuracy ve Test Accuracy değerlerine tam olarak yansımamaktadır. Bu durum, modelin overfitting (aşırı öğrenme) olabileceğine işaret etmektedir.

ORJ\_V1 ise diğer yöntemlere göre daha düşük performans ortaya koymaktadır. Özellikle Validation Loss ve Test Loss değerleri yüksek, bu da modelin genelleme yeteneğinin daha zayıf olduğunu göstermektedir.


%70-%20-%20 bölme durumundaki veri seti, %60-%20-%20 bölme durumundaki veri setine göre genel olarak daha iyi sonuçlar vermiştir. Bu durum, daha fazla eğitim verisinin modelin performansını etkilediği sonucunu çıkarmaktadır. Ancak, ORJ\_V1 için %70-%20-%10 bölme durumundaki veri setinde Test Accuracy değerinin düştüğü gözlemlenmiştir. Bu durum, veri setindeki değişikliğin bazı durumlarda olumsuz etki yaratabileceğini göstermektedir.

HE+CLH\_V3'ün başarısı, doğru önışleme yönteminin model performansı için kritik olduğunu vurgulamaktadır. GAB\_V2'nin aşırı öğrenme problemi, önışleme veya model mimarisinde iyileştirme yapılması gerektiğini göstermektedir. ORJ\_V1'in düşük performansı, bu yöntemin veri setine veya probleme uygun olmadığı anlamına gelmektedir.

Bir diğer başarı metriği olan karmaşıklık matrisi, modellerin yaptığı tahminlerin ne kadarının doğru olduğunu göstermektedir. Şekil 5.5 ve Şekil 5.6'te CNN modelinin %60-%20-%20 ve %70-%20-%10 bölme durumu için ORJ\_V1, GAB\_V2 ve HE+CLH\_V3'e ait karmaşıklık matrisleri görülmektedir. Bu grafikler incelendiğinde, her iki bölme durumu için HE+CLH\_V3'ün diğer yöntemlere göre daha başarılı tahminlerde bulunduğu, GAB\_V2'nin ORJ\_V1'e yakın olmakla beraber ORJ\_V1'den daha iyi tahminler yaptığı gözlemlenmiştir. Ayrıca bölme durumunun da bu matrisler üzerinde etkili olduğu sonucuna varılmıştır.



**Şekil 5.5.** CNN\_Set A veri seti %60-%20-%20 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 karmaşıklık matrisleri



**Şekil 5.6.** CNN\_Set A veri seti 70-20-10 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 karmaşıklık matrisleri

### 5.1.2. YOLO modelinin YOLO\_Set A veri setine ait performans deęerlendirmesi

YOLO grafiklerini anlayabilmek için bu grafiklerde kullanılan metriklerin ne anlama geldiğini bilmek gerekmektedir. YOLO grafiklerinde kullanılan temel performans metriklerini aşığıda açıklanmıştır.

**metrics/precision(B):** Modelin doğru olarak tahmin ettięi nesnelerin, tüm tahmin edilen nesneler içindeki oranını gösterir.

**metrics/recall(B):** Modelin doğru olarak tahmin ettięi nesnelerin, gerçekte var olan tüm nesneler içindeki oranını gösterir.

**metrics/mAP50(B) ve metrics/mAP50-95(B):** Genel ortalama hassasiyet (mAP) metrikleri, modelin genel performansını deęerlendirmek için kullanılır. mAP50, %50 eşik deęerinde, mAP50-95 ise %50 ile %95 arasındaki eşik deęerlerinde hesaplanan ortalama hassasiyeti temsil eder. Bu deęerlerin yüksek olması, modelin nesne tespitinde başarılı olduğunu gösterir.

**train/box\_loss:** Nesnelerin konumunu (bounding box) tahmin etmedeki hata oranını gösterir. Başlangıçta yüksek olan bu deęer, eğitim ilerledikçe düşer ve model nesnelerin yerini daha doğru tahmin etmeye başlar.

**train/cls\_loss:** Nesnelerin sınıfını tahmin etmedeki hata oranını gösterir. Benzer şekilde, bu deęer de eğitim boyunca düşerek modelin sınıflandırma yeteneğinin geliştiğini gösterir.


**train/dfl\_loss:** Nesne olup olmadığını tahmin etmedeki hata oranını gösterir. Bu deęer de eğitim boyunca düşer ve modelin nesneleri arka plandan ayırt etme yeteneğini artırır.

**val/box\_loss, val/cls\_loss, val/dfl\_loss:** Bu grafikler, eğitim kayıplarına benzer şekilde, doğrulama seti üzerindeki modelin performansını gösterir.

**val/box\_loss:** Bu metrik, modelin tahmin ettięi sınırlayıcı kutular ile gerçek sınırlayıcı kutular arasındaki farkı ölçer. Bu deęerin düşük olması, modelin nesnelerin konumunu ve boyutunu daha doğru bir şekilde tahmin ettiğini gösterir.

**val/cls\_loss:** Modelin nesneleri doğru sınıflara atama yeteneğini değerlendirir. Daha düşük bir val/cls\_loss, modelin nesneleri daha doğru bir şekilde sınıflandırdığını gösterir.

YOLO modeli için %60-%20-%20 bölme durumunda ORJ\_V1, GAB\_V2 ve HE+CLH\_V3'e ait doğruluk ve kayıp eğrileri performans parametrelerindeki değişim, epoch sayısındaki artışa bağlı olarak sırasıyla Şekil 5.7, Şekil 5.8 ve Şekil 5.9'da gösterilmiştir. %70-%20-%10 bölme durumu için ise doğruluk ve kayıp eğrileri sırasıyla Şekil 5.10, Şekil 5.11 ve Şekil 5.12'de gösterilmiştir




**Şekil 5.7.** YOLO\_Set A veri seti %60-%20-%20 bölme için ORJ\_V1 doğruluk ve kayıp eğrileri


%60-%20-%20 bölünmesine sahip yöntemlerde, özellikle ORJ\_V1 ve GAB\_V2'de, doğrulama kaybında belirgin dalgalanmalar görülmektedir. Bu durum, modelin eğitim verisine overfit olabileceğini ve görülmemiş verilere genelleme yeteneğinin düşük olabileceğini göstermektedir.

%70-%20-%10 bölünmesine sahip yöntemlerde, özellikle HE+CLH\_V3'te, eğitim ve doğrulama kaybı daha istikrarlı bir şekilde azalmaktadır. Bu, modelin daha dengeli bir öğrenme sürecine sahip olduğunu ve overfitting riskinin daha düşük olduğunu gösteriyor.

Grafiklerdeki dalgalanmalar, modelin doğrulama setinde bazı zorluklar yaşadığını ve olası overfitting (aşırı öğrenme) sorununu işaret edebilir. Bu durumu daha iyi analiz etmek için eğitim ve doğrulama kayıpları karşılaştırılmalıdır.



**Şekil 5.8.** YOLO\_Set A veri seti %60-%20-%20 bölme için GAB\_V2 doğruluk ve kayıp eğrileri




**Şekil 5.9.** YOLO\_Set A veri seti %60-%20-%20 bölme için HE+CLH\_V3 doğruluk ve kayıp eğrileri


Precision ve Recall değerleri tüm yöntemlerde genel olarak artış göstermektedir. Bu durumda, modelin nesneleri doğru bir şekilde tespit etme ve sınıflandırma yeteneğinin geliştiği sonucu çıkarmaktadır.

mAP (mean Average Precision) değerleri dalgalanma göstermekle birlikte, en yüksek mAP değerlerine GAB\_V2 (%70-%20-%10) ve HE+CLH\_V3 (%70-%20-%10)


yöntemlerinde ulaşılmıştır. Bu yöntemler genel nesne tespit performansı açısından daha iyi performans göstermektedir.



**Şekil 5.10.** YOLO\_Set A veri seti %70-%20-%10 bölme için ORJ\_V1 doğruluk ve kayıp eğrileri



**Şekil 5.11.** YOLO\_Set A veri seti %70-%20-%10 bölme için GAB\_V2 doğruluk ve kayıp eğrileri



**Şekil 5.12.** YOLO\_Set A veri seti %70-%20-%10 bölme için HE+CLH\_V3 doğruluk ve kayıp eğrileri

Grafiklerdeki bu bilgiler göz önüne alındığında HE+CLH\_V3 (%70-%20-%10), istikrarlı eğitim ve doğrulama kaybı, yüksek mAP değerleri ve düşük overfitting riski ile en başarılı yöntem olarak öne çıkmaktadır. %70-%20-%10 bölünme oranı, %60-%20-%20 bölünmesine kıyasla daha dengeli bir öğrenme ve daha iyi genelleme yeteneği sağlamaktadır.

YOLO'nun YOLO\_Set A veri setine ait model sonuçları Tablo 5.2'de gösterilmiştir. Buna göre; mAP (50) değerleri hem eğitim hem de doğrulama setlerinde %98'e kadar çıkmaktadır, bu durum, modelin nesnelerin konumlarını doğru bir şekilde tahmin etmede başarılı olduğunu, mAP (50-95) değerlerinin %61 civarında olması ise modelin nesnelerin sınırlayıcı kutularını daha hassas bir şekilde tahmin etmekte zorlandığını göstermektedir.

F1-Skor değerleri, modelin 0,471-0,512 eşik değerleri arasında daha dengeli bir performans sergilediğini göstermektedir.

Precision değerleri oldukça yüksek (1,0 civarında) ancak Recall değerleri daha düşük (%98) olarak ölçülmüştür. Bu, modelin çok az yanlış pozitif tahmin yaptığını ancak bazı nesneleri kaçırdığını göstermektedir.

**Tablo 5.2.** YOLO\_Set A model sonuçları

| YOLO V8 | Bölme Durumu | Yöntemler | Train mAP (50) | Train mAP (50-95) | Val mAP (50) | Val mAP (50-95) | F1-Skor-Eşik Değer | Precision-Eşik Değer | Recall |
|---------|--------------|-----------|----------------|-------------------|--------------|-----------------|--------------------|----------------------|--------|
|         | 60-20-20     | ORJ_V1    | 0,980          | <b>0,621</b>      | 0,980        | <b>0,621</b>    | <b>0,96/0,471</b>  | 1,0/0,862            | 0,98   |
|         |              | GAB_V2    | 0,978          | 0,601             | 0,978        | 0,602           | 0,96/0,478         | 1,0/0,837            | 0,98   |
|         |              | HE+CLH_V3 | <b>0,981</b>   | 0,616             | <b>0,981</b> | 0,615           | 0,96/0,512         | <b>1,0/0,831</b>     | 0,98   |
|         | 70-20-10     | ORJ_V1    | 0,976          | <b>0,612</b>      | 0,975        | <b>0,611</b>    | 0,95/0,492         | 1,0/0,836            | 0,98   |
|         |              | GAB_V2    | 0,974          | 0,604             | 0,973        | 0,603           | 0,96/0,361         | 1,0/0,838            | 0,97   |
|         |              | HE+CLH_V3 | <b>0,977</b>   | 0,610             | <b>0,977</b> | 0,610           | <b>0,96/0,249</b>  | <b>1,0/0,831</b>     | 0,98   |


60-20-20 ve 70-20-10 şeklinde bölünen veri setleri arasında performans açısından önemli bir fark gözlemlenmemekle beraber %60-%20-%20 bölme işlemi ile 3 yöntemde de daha yüksek başarı elde edildiği görülmektedir.

Şekil 5.13 ve Şekil 5.14'te YOLO modelinin sırasıyla %60-%20-%20 ve %70-%20-%10 bölme durumları için ORJ\_V1, GAB\_V2 ve HE+CLH\_V3'e ait karmaşıklık matrisleri sunulmaktadır.


Karmaşıklık matrisleri incelendiğinde, HE+CLH\_V3'ün Şekil 5.13'te nodül1'i %96, nodül2'yi %100; Şekil 5.14'te ise nodül1'i %98 ve nodül2'yi %97 ile doğru tahmin ederek diğer yöntemlere göre daha iyi bir sonuç elde ettiği gözlemlenmektedir. Ayrıca, modelin görüntülerde herhangi bir tespit yapamadığı durumlarda, görüntüleri arka plan olarak algılayıp etiketlediği belirlenmiştir. Bu durum, modelin tespit yeteneğini ölçme açısından önemli bir gözlem sunmaktadır.

Her üç ön işleme yönteminin de benzer performans göstermesi modelin ön işleme yöntemine karşı göreceli olarak duyarsız olduğunu veya veri setinin zaten iyi bir şekilde hazırlanmış olduğunu göstermektedir. Tüm parametreler değerlendirildiğinde HE+CLH\_V3'ün, diğer yöntemlerden çok farklı olmasa da daha iyi sonuçlar ürettiği gözlemlenmiştir.

Veri setindeki görüntüler üzerinde yapılan ön işlemlerin YOLO modelinin başarısı üzerine CNN modelinde olduğu kadar etkili olmadığı da gözlemlenmiştir.



Şekil 5.13 YOLO\_Set A veri seti %60-%20-%20 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 karmaşıklık matrisleri




Şekil 5.14. YOLO\_Set A veri seti %70-%20-%10 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 karmaşıklık matrisleri


## 5.2. Set B'ye Ait Çalışma Bulguları

### 5.2.1. CNN modelinin CNN\_Set B veri setine ait performans değerlendirmesi

Şekil 5.15 ve Şekil 5.16'da doğruluk eğrileri verilen modellerden GAB\_V2 ile HE+CLH\_V3'nin artan epoch sayısına göre daha istikrarlı bir şekilde eğitildiği görülmektedir. Buna karşın ORJ\_V1 eğrisinin kararsız yapısı bu veri setinde ön işlemenin ne kadar gerekli olduğunu göstermektedir. Elde edilen sonuçlar, eğitim verisi miktarı ile öğrenme performansı arasında pozitif bir korelasyon olduğunu göstermektedir. Özellikle, %70-%20-%10 veri bölme oranı, daha dengeli bir veri dağılımı sağlayarak modelin öğrenme kapasitesini artırmıştır. Bu durum, modelin daha fazla örneklem üzerinde eğitilerek daha geniş bir özellik uzayı öğrenmesine ve genelleme yeteneğini geliştirmesine olanak tanımaktadır.



**Şekil 5.15.** CNN\_Set B veri seti %60-%20-%20 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 doğruluk eğrileri




**Şekil 5.16.** CNN\_Set B veri seti %70-%20-%10 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 doğruluk eğrileri

Şekil 5.17 ve Şekil 5.18'de bu modelin kayıp grafikleri gösterilmiştir. Grafikler incelendiğinde ORJ\_V1'de eğitim kaybının sürekli olarak azaldığı, ancak doğrulama kaybının onuncu epoch civarında çok dalgalanmaya başladığı ve kararsız bir yapıya


ulaştığı görülmektedir. Bu, modelin eğitim verilerine aşırı uyum sağlamaya başladığının ve genelleyci kapasitesini kaybettiğinin bir işaretidir.

GAB\_V2, ORJ\_V1'e göre daha iyi bir performans göstermektedir. Eğitim ve doğrulama kaybı daha az dalgalanmış ve yirminci epoch civarında nispeten aynı hızda azalmıştır. Bu, modelin eğitim verilerine aşırı uyum sağlamadan iyi bir şekilde genelleştiğini göstermektedir.

HE+CLH\_V3, diğer iki yöntemle karşılaştırıldığında en iyi performansı göstermektedir. Eğitim kaybı epoch sayısına bağlı olarak daha hızlı bir şekilde azalmış ve doğrulama kaybı daha düşük ve daha stabil olmuştur. Bu, modelin verilerden daha iyi yararlanabildiğini ve genelleyci performansını en üst düzeye çıkardığını göstermiştir.



**Şekil 5.17.** CNN\_Set B veri seti %60-%20-%20 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 kayıp eğrileri



**Şekil 5.18.** CNN\_Set B veri seti %70-%20-%10 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 kayıp eğrileri

CNN\_Set B veri seti kullanılarak eğitilen CNN modelinin parametrik değerleri Tablo 5.3'te gösterilmiştir. Her üç yöntemde benzer Train Accuracy, Validation Accuracy ve Test Accuracy değerlerine sahip olduğu gözlenmiştir. Bu durum, modelin veri setine ve

**Tablo 5.3.** CNN\_Set B model sonuçları

|     | Bölme Durumu | Yöntemler | Train Acc    | Train Loss   | Val Acc      | Val Loss     | Test Acc     | Test Loss    | F1-Score-<br>Kanser/ Normal | Precision-<br>Kanser/ Normal | Recall-<br>Kanser/ Normal |
|-----|--------------|-----------|--------------|--------------|--------------|--------------|--------------|--------------|-----------------------------|------------------------------|---------------------------|
|     |              |           |              |              |              |              |              |              |                             |                              |                           |
| CNN | 60-20-20     | ORJ_V1    | 0,969        | <b>0,074</b> | 0,963        | <b>0,098</b> | <b>0,968</b> | <b>0,083</b> | 0,96-0,96                   | 0,98-0,94                    | 0,94-0,98                 |
|     |              | GAB_V2    | 0,966        | 0,093        | 0,954        | 0,119        | 0,960        | 0,100        | 0,95-0,95                   | 0,95-0,96                    | 0,96-0,95                 |
|     |              | HE+CLH_V3 | <b>0,975</b> | 0,076        | <b>0,963</b> | 0,100        | 0,965        | 0,100        | <b>0,96-0,96</b>            | <b>0,94-0,99</b>             | <b>0,99-0,94</b>          |
|     | 70-20-10     | ORJ_V1    | 0,978        | <b>0,055</b> | <b>0,979</b> | <b>0,050</b> | <b>0,974</b> | <b>0,078</b> | <b>0,98 0,98</b>            | <b>0,99-0,97</b>             | <b>0,97-0,99</b>          |
|     |              | GAB_V2    | <b>0,980</b> | 0,061        | 0,974        | 0,068        | 0,970        | 0,092        | 0,97 0,97                   | 0,97-0,98                    | 0,98-0,97                 |
|     |              | HE+CLH_V3 | 0,976        | 0,085        | 0,966        | 0,100        | 0,959        | 0,121        | 0,97-0,97                   | 0,94-1,00                    | 1,00-0,94                 |

önişleme yöntemine karşı daha az duyarlı olduğunu ve daha robust (sağlam) bir yapıda olduğunu göstermektedir. Train Loss, Validation Loss ve Test Loss değerleri de CNN\_Set A'daki değerlere göre daha düşük ve birbirine yakın. Bu durum, modelin overfitting probleminin azaldığını ve genelleme yeteneğinin geliştiğini göstermektedir. F1-Score, Precision ve Recall değerleri de oldukça dengeli ve yüksek. Bu durum, modelin hem kanserli hem de normal örnekleri doğru bir şekilde sınıflandırabildiğini göstermektedir.


%70-%20-%10 bölme durumundaki veri seti, %60-%20-%20 bölme durumundaki veri setine göre hala hafif bir üstünlük sağlamakta ancak fark önemsizmeyecek derecededir. Bu durum, modelin daha fazla eğitim verisinden faydalanabildiğini ancak önceki duruma göre daha az bağımlı olduğunu göstermektedir.

Her üç önişleme yönteminin de benzer performans göstermesi, veri setinin iyi bir şekilde temizlenmiş olabileceğini veya model mimarisinin önişleme yöntemine karşı daha az duyarlı olduğunu göstermektedir.


HE+CLH\_V3, Precision ve Recall değerlerinde hala biraz daha yüksek değerlere sahip olduğu görülmekte, bu da bu ön işlemenin daha etkili olduğu göstermektedir.

Şekil 5.19 ve Şekil 5.20'de karmaşıklık matrisleri verilen CNN modelinin %60-%20-%20 ve %70-%20-%10 bölme durumu için ORJ\_V1, GAB\_V2 ve HE+CLH\_V3 incelendiğinde, her iki bölme durumu için HE+CLH\_V3'ün diğer yöntemlere göre daha başarılı tahminlerde bulunduğu görülmektedir. GAB\_V2'nin ORJ\_V1'e göre daha iyi bir tahmin oranına sahip olduğu da gözlemlenmiştir.

Sonuç olarak, oluşturduğumuz CNN modelinin farklı veri setleri ile yapılan çalışmalarda ürettiği çıktıları bakılarak modelimizin dengeli, tutarlı ve sağlam olduğu kanaatine varılmıştır.




**Şekil 5.19.** CNN\_Set B veri seti %60-%20-%20 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 karmaşıklık matrisleri




**Şekil 5.20.** CNN\_Set B veri seti %70-%20-%10 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 karmaşıklık matrisleri

### 5.2.2. YOLO modelinin YOLO\_Set B veri setine ait performans deęerlendirmesi


%60-%20-%20 bölme durumunda ORJ\_V1, GAB\_V2 ve HE+CLH\_V3'e ait doęruluk ve kayıp grafikleri Şekil 5.21, Şekil 5.22 ve Şekil 5.23'te gösterilmiştir.



Şekil 5.21. YOLO\_Set B veri seti %60-%20-%20 bölme için ORJ\_V1 doęruluk ve kayıp eğrileri




Şekil 5.22. YOLO\_Set B veri seti %60-%20-%20 bölme için GAB\_V2 doęruluk ve kayıp eğrileri




**Şekil 5.23.** YOLO\_Set B veri seti %60-%20-%20 bölme için HE+CLH\_V3 doğruluk ve kayıp eğrileri


%70-%20-%10 bölme durumu için doğruluk ve kayıp eğrileri sırasıyla Şekil 5.24, Şekil 5.25 ve Şekil 5.26’da gösterilmiştir.



**Şekil 5.24.** YOLO\_Set B veri seti %70-%20-%10 bölme için ORJ\_V1 doğruluk ve kayıp eğrileri



**Şekil 5.25.** YOLO\_Set B veri seti %70-%20-%10 bölme için GAB\_V2 doğruluk ve kayıp eğrileri



**Şekil 5.26.** YOLO\_Set B veri seti %70-%20-%10 bölme için HE+CLH\_V3 doğruluk ve kayıp eğrileri

Her üç yöntem ve her iki veri seti bölme durumu incelendiğinde eğitim kayıpları ve doğrulama kayıpları genel olarak düşüş eğilimindedir, bu da modelin eğitim boyunca öğrenmeye devam ettiğini göstermektedir.

Doğrulama kayıplarındaki dalgalanmalar overfitting riskini işaret ediyor olabilir. Bu sorun veri büyütme veya düzenleme teknikleri ile düzeltilebilir. Precision ve Recall değerlerinin yüksek olması, modelin nesneleri doğru bir şekilde tespit etme ve

sınıflandırma yeteneğinin iyi olduğunu gösterir. mAP değerleri, modelin genel performansının iyi olduğunu göstermektedir. HE+CLH\_V3 ön işlemesine tabii tutulan veri setindeki eğitim sürecinin epoch sayısına bağlı olarak diğer yöntemlere göre daha tutarlı bir şekilde devam ettiği sonucu gözlemlenebilmektedir.

Tablo 5.4'te YOLO modelinin YOLO\_Set B veri seti için performans metrik değerleri verilmiştir. Bu değerler göz önüne alındığında hem eğitim hem de doğrulama kümeleri için mAP değerlerinin oldukça yüksek olduğu (çoğunlukla 0,90'ın üzerinde) gözlemlenmiş olup, modelin nesneleri doğru bir şekilde tespit etme ve sınıflandırma konusunda genel olarak başarılı olduğunu göstermektedir. F1-Skoru da tüm senaryolarda 0,85'in üzerinde olup, modelin Precision ve Recall arasında iyi bir denge sağladığını ortaya koymaktadır.

%70-%20-%10 oranında bölünen veri seti, %60-%20-%20 oranına göre biraz daha yüksek mAP değerlerine sahiptir. Bu durum, daha büyük eğitim setlerinin modelin performansını artırabileceğini göstermektedir. GAB\_V2 diğer yöntemlere göre daha düşük bir doğrulukta sonuçlar üretmiştir. Bu da bu ön işleme yönteminin bu veri seti için uygun olmadığı sonucunu çıkarmaktadır.

**Tablo 5.4.** YOLO\_Set B model sonuçları

| YOLO V8 | Bölme Durumu | Yöntemler | Train mAP (50) | Train mAP (50-95) | Val mAP (50) | Val mAP (50-95) | F1-Skor-Eşik Değer | Precision-Eşik Değer | Recall      |
|---------|--------------|-----------|----------------|-------------------|--------------|-----------------|--------------------|----------------------|-------------|
|         | 60-20-20     | ORJ_V1    | <b>0,927</b>   | <b>0,666</b>      | <b>0,926</b> | <b>0,667</b>    | <b>0,89/0,234</b>  | 1,0/0,911            | <b>0,93</b> |
|         |              | GAB_V2    | 0,877          | 0,624             | 0,878        | 0,623           | 0,86/0,238         | 1,0/0,910            | 0,89        |
|         |              | HE+CLH_V3 | 0,918          | 0,665             | 0,905        | 0,654           | 0,87/0,412         | <b>1,0/0,884</b>     | 0,92        |
|         | 70-20-10     | ORJ_V1    | 0,951          | 0,718             | 0,951        | 0,718           | 0,92/0,556         | 1,0/0,894            | <b>0,96</b> |
|         |              | GAB_V2    | 0,928          | 0,693             | 0,928        | 0,694           | 0,89/0,475         | 1,0/0,899            | 0,95        |
|         |              | HE+CLH_V3 | <b>0,953</b>   | <b>0,721</b>      | <b>0,953</b> | <b>0,720</b>    | <b>0,92/0,198</b>  | <b>1,0/0,888</b>     | 0,95        |

Şekil 5.27’de %60-%20-%20 bölme durumunda oluşan karmaşıklık matrisleri verilmiştir. Buna göre üç yöntem de nodülü iyi bir şekilde tespit etmiş olmakla beraber diyagonaldeki yüksek değerler (0,86; 0,82; 0,85) modelin nodülleri doğru bir şekilde tanıdığını göstermiştir.


Arka plan sınıfı da genellikle doğru bir şekilde tanımlanmış, ancak bazı yanlış pozitif örnekler de mevcuttur. Nodüllerin bir kısmı her üç yöntemde de arka plan olarak yanlış sınıflandırılmış.

ORJ\_V1, diğer yöntemlere kıyasla daha yüksek bir doğruluk oranına sahiptir (%86) ve arka planı nispeten iyi bir şekilde tanımlamaktadır. HE+CLH\_V3, GAB\_V2’ye göre daha başarılı bir sonuç göstermiştir, ancak ORJ\_V1’e yakın olmasına rağmen daha düşük bir başarı seviyesindedir. Arka plan sınıfında da benzer bir performansa sahiptir.


%70-%20-%10 bölme durumunda elde edilen karmaşıklık matrisleri (Şekil 5.28) göz önüne alındığında ise tüm yöntemlerin nodülleri önceki bölme durumuna göre daha yüksek bir doğrulukla tespit ettiği görülmektedir (0,92; 0,89;0,90). Nodüllerin arka plan olarak yanlış sınıflandırılma oranı da öncekine göre düşmüştür. Bu durum, modelin öğrenme sürecinin veri miktarına bağlı olduğunu göstermektedir. Model, daha fazla veriyle beslendiğinde genellikle daha iyi öğrenme sağlamaktadır. ORJ\_V1 nodülleri %92 doğruluk oranıyla tespit ederek diğer yöntemlerden daha yüksek bir başarı göstermiştir.

Bununla beraber arka planı da düşük bir yanlış pozitif oranıyla tespit etmiştir. Diğer yöntemlerden HE+CLH\_V3, GAB\_V2’ye göre daha iyi durumdadır.

Her iki bölme yöntemi de dikkate alındığında, ORJ\_V1’in nodülleri sınıflandırmada en yüksek doğruluk oranına sahip olduğu görülmektedir. Ancak, HE+CLH\_V3’te oldukça başarılı sonuçlara sahip ve aralarında çok büyük farklar oluşmamıştır.



Şekil 5.27. YOLO\_Set B veri seti %60-%20-%10 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 karmaşıklık matrisleri



Şekil 5.28. YOLO\_Set B veri seti %70-%20-%10 bölme için (a) ORJ\_V1, (b) GAB\_V2 ve (c) HE+CLH\_V3 karmaşıklık matrisleri

## 6. SONUÇ

Akciğer kanseri, tüm kanser türleri arasında en yüksek ölümcüllük oranına sahip olup, erken teşhis bu tehlikeli hastalığın etkilerini azaltmada hayati bir rol oynamaktadır. Bu yüksek lisans tezi çalışmasında, akciğer kanser hücrelerinin BT görüntülerinden yapay zekâ teknikleri ile otomatik olarak tespit edilmesi amaçlanmıştır. Bu amaçla, CNN ve YOLO algoritması olmak üzere iki farklı derin öğrenme modeli kullanılmıştır. Modellerin performansını değerlendirmek ve karşılaştırmak amacıyla, farklı ön işleme teknikleri uygulanmış 6 farklı veri seti üzerinde deneyler gerçekleştirilmiş ve bu algoritmaların etkinliğini değerlendirilmiştir. Oluşturulan modellerin sonuçları Tablo 6.1’de gösterilmiştir.

**Tablo 6.1.** Modellerin sonuçları


| Set A Veri Seti |              |              |              |              |              |              |              |              |
|-----------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
|                 | CNN          |              |              |              | YOLO         |              |              |              |
|                 | 60-20-20     |              | 70-20-10     |              | 60-20-20     |              | 70-20-10     |              |
|                 | Train<br>Acc | F1-<br>Score | Train<br>Acc | F1-<br>Score | Train<br>Acc | F1-<br>Score | Train<br>Acc | F1-<br>Score |
| ORJ_V1          | %98,5        | %90          | %98,5        | %94          | %98          | %96          | %97,6        | %95          |
| GAB_V2          | <b>%99,8</b> | %93          | <b>%100</b>  | %93          | %97,8        | %96          | %97,4        | %96          |
| HE+CLH_V3       | %99,6        | <b>%99</b>   | %99,8        | <b>%99</b>   | <b>%98,1</b> | %96          | %97,7        | %96          |
| Set B Veri Seti |              |              |              |              |              |              |              |              |
|                 | CNN          |              |              |              | YOLO         |              |              |              |
|                 | 60-20-20     |              | 70-20-10     |              | 60-20-20     |              | 70-20-10     |              |
|                 | Train<br>Acc | F1-<br>Score | Train<br>Acc | F1-<br>Score | Train<br>Acc | F1-<br>Score | Train<br>Acc | F1-<br>Score |
| ORJ_V1          | %96,9        | %96          | %97,8        | <b>%98</b>   | <b>%92,7</b> | <b>%89</b>   | %95,1        | %92          |
| GAB_V2          | %96,6        | %95          | <b>%98</b>   | %97          | %87,7        | %86          | %92,8        | %89          |
| HE+CLH_V3       | <b>%97,5</b> | %96          | %97,6        | %97          | %91,8        | %87          | <b>%95,3</b> | %92          |

Veri setleri, farklı ön işleme teknikleri ile ayrıştırılmış ve bu tekniklerin modellerin başarılarına olan etkisi detaylı bir şekilde incelenmiştir.

### CNN Modeli





GAB\_V2 (gabor filtresi) ve HE+CLH\_V3 (histogram eşitleme + CLAHE) ön işlemleri, ORJ\_V1 (orijinal veri seti) ile karşılaştırıldığında daha yüksek Train ve F1-Skoru değerlerine ulaşmıştır. Bu durum, ön işleme tekniklerinin CNN modelinin performansını artırmada etkili olduğunu göstermektedir.

CNN modeli HE+CLH\_V3 ile yapılan test sonuçları Şekil 6.1 ve Tablo 6.2’de sunulmuştur.



Şekil 6.1. CNN HE+CLH\_V3’ün görüntüleri sınıflandırma süreleri

Tablo 6.2. CNN HE+CLH\_V3 test sonuçları

| Test verisi                                                                         | Gerçek   | Tahmin   | Test verisi                                                                          | Gerçek   | Tahmin   |
|-------------------------------------------------------------------------------------|----------|----------|--------------------------------------------------------------------------------------|----------|----------|
|  | Normal   | Normal   |  | Normal   | Kanserli |
|  | Kanserli | Normal   |  | Kanserli | Kanserli |
|  | Normal   | Normal   |  | Kanserli | Kanserli |
|  | Kanserli | Kanserli |  | Kanserli | Kanserli |

%70-%20-%10 veri bölünmesi, %60-%20-%20 bölünmesine göre genel olarak daha yüksek F1-Skoru değerlerine sahip olmuştur. Bu, daha fazla eğitim verisinin modelin genelleme yeteneğini ve dolayısıyla performansını iyileştirdiğini göstermektedir.

### **YOLO Modeli**


YOLO modelinde de GAB\_V2 ve HE+CLH\_V3'te yapılan ön işlemler, ORJ\_V1'e göre daha yüksek Train ve F1-Skoru değerlerine ulaşmasını sağlamıştır

Veri bölünme oranlarının YOLO modelinin performansı üzerinde belirgin bir etkisi gözlemlenmemiştir.

CNN modeli, YOLO modeline göre genel olarak daha yüksek F1-Skoru değerlerine ulaşmıştır. Bu, CNN modelinin akciğer kanser hücrelerinin tespitinde daha başarılı olduğunu göstermektedir. YOLO modeli ise veri bölünme oranlarına karşı daha az duyarlılık göstermiş ve daha sağlam bir performans sergilemiştir.

Sonuç itibarıyla, bu çalışma ön işleme tekniklerinin ve veri bölünme oranlarının hem CNN hem de YOLO modelleri için önemli olduğunu göstermektedir. Gabor filtresi ve histogram eşitleme + CLAHE gibi teknikler, model performansını artırmada etkili olmuştur. Ayrıca, CNN modelinin akciğer kanseri hücrelerinin tespitinde YOLO modeline göre daha başarılı olduğu görülmüştür.

YOLO v8 ile tahmin edilen örnek görüntüler Şekil 6.2'de sunulmuştur.



Şekil 6.2. Örnek YOLO çıktıları

## 7. TARTIŞMA

Çalışma sonuçları, derin öğrenme modellerinin akciğer kanseri hücrelerinin BT görüntülerinden otomatik olarak tespit edilmesinde etkili bir şekilde kullanılabileceğini göstermektedir. Özellikle CNN modeli, yüksek doğruluk ve F1-Skoru değerlerine ulaşarak umut verici sonuçlar ortaya koymuştur. YOLO modeli ise nesne tespit görevinde başarılı bir performans sergilemiştir.

Ön işleme tekniklerinin model performansı üzerinde önemli bir etkiye sahip olduğu görülmüştür. Histogram eşitleme ve CLAHE teknikleri, görüntülerdeki kontrast ve parlaklığı iyileştirerek modelin öğrenme yeteneğini artırmıştır. Gabor filtresi ise kenar ve doku bilgisini vurgulayarak modelin performansını iyileştirmiştir. Veri bölünme oranının da model performansını etkilediği görülmüştür. %70-%20-%10 oranında bölünen veri setleri, daha fazla eğitim verisi sağlayarak modelin öğrenme kapasitesini artırmış ve daha iyi sonuçlar elde edilmesini sağlamıştır.

Bu çalışma, derin öğrenme modellerinin tıbbi görüntü analizinde kullanımı konusunda önemli bir adım olup, ileriye yönelik çalışmalar için sağlam bir temel oluşturmaktadır. Bu alanda yapılacak daha fazla araştırma, akciğer kanseri gibi ölümcül hastalıkların erken teşhisinde devrim niteliğinde gelişmelere yol açabilir.

Bu çalışmaya dayanarak, gelecekteki araştırmalara yönelik çeşitli öneriler sunulabilir. Öncelikle, modelin genelleme yeteneğini artırmak ve daha geniş bir popülasyonu temsil eden sonuçlar elde etmek amacıyla daha kapsamlı ve çeşitli veri setlerinin kullanılması önem arz etmektedir. Bununla birlikte, farklı derin öğrenme model mimarilerinin ve optimizasyon tekniklerinin araştırılması, model performansını daha da iyileştirebilir. Özellikle transfer öğrenme tekniklerinin kullanımı, sınırlı veri kümeleriyle çalışırken bile yüksek performans elde edilmesini sağlayabilir. Ayrıca, derin öğrenme modellerinin diğer makine öğrenmesi algoritmalarıyla entegrasyonu, tespit ve teşhis performansını arttıracakları öngörülmektedir. Hibrit modeller oluşturularak, farklı algoritmaların güçlü yönlerinden faydalanılabilir ve daha sağlam ve doğru sonuçlar elde edilebilir.

## KAYNAKLAR

- Abbas, M. A., Bukhari, S. U. K., Syed, A., ve Shah, S. S. H. (2020). The Histopathological Diagnosis of Adenocarcinoma ve Squamous Cells Carcinoma of Lungs by Artificial intelligence: A comparative study of convolutional neural networks. *MedRxiv*. <https://doi.org/10.1101/2020.05.02.20044602>
- Aditya Sharma. (2022, April 12). *Understanding a Real-Time Object Detection Network: You Only Look Once (YOLOv1)*.
- Al-Yasriy, H. F., Al-Husieny, M. S., Mohsen, F. Y., Khalil, E. A., ve Hassan, Z. S. (2020). Diagnosis of Lung Cancer Based on CT Scans Using CNN. *IOP Conference Series: Materials Science and Engineering*, 928(2). <https://doi.org/10.1088/1757-899X/928/2/022035>
- Baranwal, N., Doravari, P., ve Kachhoria, R. (2021). *Classification of Histopathology Images of Lung Cancer Using Convolutional Neural Network (CNN)*. <https://orcid.org/0000-0002-1113-7884>
- Bukhari, S. U. K., Syed, A., Bokhari, S. K. A., Hussain, S. S., Armaghan, S. U., ve Shah, S. S. H. (2020). The Histological Diagnosis of Colonic Adenocarcinoma by Applying Partial Self Supervised Learning. *MedRxiv*. <https://doi.org/10.1101/2020.08.15.20175760>
- Chai, C. C., Khoh, W. H., Pang, Y. H., ve Yap, H. Y. (2024). A Lung Cancer Detection with Pre-Trained CNN Models. *Journal of Informatics and Web Engineering*, 3(1), 41–54. <https://doi.org/10.33093/jiwe.2024.3.1.3>
- Chauhan, R., Ghanshala, K. K., ve Joshi, R. C. (2018). Convolutional Neural Network (CNN) for Image Detection and Recognition. *2018 First International Conference on Secure Cyber Computing and Communication (ICSCCC)*, 278–282. <https://doi.org/10.1109/ICSCCC.2018.8703316>
- Chen, X., Duan, Q., Wu, R., ve Yang, Z. (2021). Segmentation of lung computed tomography images based on SegNet in the diagnosis of lung cancer. *Journal of Radiation Research and Applied Sciences*, 14(1), 396–403. <https://doi.org/10.1080/16878507.2021.1981753>
- Clark, K., Vendt, B., Smith, K., Freymann, J., Kirby, J., Koppel, P., Moore, S., Phillips, S., Maffitt, D., Pringle, M., Tarbox, L., ve Prior, F. (2013, December 25). The Cancer Imaging Archive (TCIA): Maintaining and Operating a Public Information Repository. *Journal of Digital Imaging*. <https://doi.org/10.1007/s10278-013-9622-7>
- De Carvalho Filho, A. O., De Sampaio, W. B., Silva, A. C., de Paiva, A. C., Nunes, R. A., ve Gattass, M. (2014). Automatic detection of solitary lung nodules using quality threshold clustering, genetic algorithm and diversity index. *Artificial Intelligence in Medicine*, 60(3), 165–177. <https://doi.org/10.1016/j.artmed.2013.11.002>
- Dodia, S., B., A., ve Mahesh, P. A. (2022). Recent advancements in deep learning based lung cancer detection: A systematic review. *Engineering Applications of Artificial Intelligence*, 116, 105490. <https://doi.org/https://doi.org/10.1016/j.engappai.2022.105490>

- Doppalapudi, S., Qiu, R. G., ve Badr, Y. (2021). Lung cancer survival period prediction and understanding: Deep learning approaches. *International Journal of Medical Informatics*, 148, 104371. <https://doi.org/https://doi.org/10.1016/j.ijmedinf.2020.104371>
- GitHub user RangeKing. (2023, January). *YOLOv8 Architecture*. 2023.
- Global Cancer Observatory. (2021). *Dünya geneli kanser görülme oranları*.
- GLOBOCAN. (2024a). *2022 Dünya Kanser İstatistikleri*. <https://gco.iarc.who.int/media/globocan/factsheets/populations/900-world-fact-sheet.pdf>
- GLOBOCAN. (2024b). *2022 Türkiye Kanser İstatistikleri*. <https://gco.iarc.who.int/media/globocan/factsheets/populations/792-turkiye-fact-sheet.pdf>
- Gu, D., Shen, J., Wang, X., ve Beck, J. E. (2018). *Deep Learning Project Report*.
- Gupta, N., Gupta, D., Khanna, A., Rebouças Filho, P. P., ve de Albuquerque, V. H. C. (2019). Evolutionary algorithms for automatic lung disease detection. *Measurement*, 140, 590–608. <https://doi.org/https://doi.org/10.1016/j.measurement.2019.02.042>
- Haznedar, B., ve Simsek, N. Y. (2022). A Comparative Study on Classification Methods for Renal Cell and Lung Cancers Using RNA-Seq Data. *IEEE Access*, 10, 105412–105420. <https://doi.org/10.1109/ACCESS.2022.3211505>
- Hu, J., Cui, C., Yang, W., Huang, L., Yu, R., Liu, S., ve Kong, Y. (2021). Using deep learning to predict anti-PD-1 response in melanoma and lung cancer patients from histopathology images. *Translational Oncology*, 14(1), 100921. <https://doi.org/https://doi.org/10.1016/j.tranon.2020.100921>
- Jothi, J., ve Murugaiyan, C. (2024). A combined deep CNN with a chimp optimization approach for lung cancer diagnosis. *Journal of Intelligent ve Fuzzy Systems*, 46, 1–16. <https://doi.org/10.3233/JIFS-237339>
- Kanipriya, M., Hemalatha, C., Sridevi, N., SriVidhya, S. R., ve Jany Shabu, S. L. (2022). An improved capuchin search algorithm optimized hybrid CNN-LSTM architecture for malignant lung nodule detection. *Biomedical Signal Processing and Control*, 78, 103973. <https://doi.org/https://doi.org/10.1016/j.bspc.2022.103973>
- Kasinathan, G., Jayakumar, S., Gandomi, A. H., Ramachandran, M., Fong, S. J., ve Patan, R. (2019). Automated 3-D lung tumor detection and classification by an active contour model and CNN classifier. *Expert Systems with Applications*, 134, 112–119. <https://doi.org/10.1016/j.eswa.2019.05.041>
- Keshani, M., Azimifar, Z., Tajeripour, F., ve Boostani, R. (2013). Lung nodule segmentation and recognition using SVM classifier and active contour modeling: A complete intelligent system. *Computers in Biology and Medicine*, 43(4), 287–300. <https://doi.org/10.1016/j.combiomed.2012.12.004>
- Kriegsmann, M., Longuespée, R., Wandernoth, P., Mohanu, C., Lisenko, K., Weichert, W., Warth, A., Dienemann, H., De Pauw, E., Katzenberger, T., Aust, D., Baretton, G., Kriegsmann, J., ve Casadonte, R. (2017). Typing of colon and lung adenocarcinoma by high throughput imaging mass spectrometry. *Biochimica et*

- Biophysica Acta (BBA) - Proteins and Proteomics*, 1865(7), 858–864.  
<https://doi.org/https://doi.org/10.1016/j.bbapap.2016.11.018>
- Kuruvilla, J., ve Gunavathi, K. (2014). Lung cancer classification using neural networks for CT images. *Computer Methods and Programs in Biomedicine*, 113(1), 202–209. <https://doi.org/10.1016/j.cmpb.2013.10.011>
- Lakshmanaprabu, S. K., Mohanty, S. N., Shankar, K., Arunkumar, N., ve Ramirez, G. (2019). Optimal deep learning model for classification of lung cancer on CT images. *Future Generation Computer Systems*, 92, 374–382. <https://doi.org/10.1016/j.future.2018.10.009>
- Lee, B., Lee, J., Lee, J. O., Hwang, Y., Bahn, H. K., Park, I., Jheon, S., ve Lee, D. S. (2024). Breath analysis system with convolutional neural network (CNN) for early detection of lung cancer. *Sensors and Actuators B: Chemical*, 409. <https://doi.org/10.1016/j.snb.2024.135578>
- Liu, K. (2022). STBi-YOLO: A Real-Time Object Detection Method for Lung Nodule Recognition. *IEEE Access*, 10, 75385–75394. <https://doi.org/10.1109/ACCESS.2022.3192034>
- Loraksa, C., Mongkolsomlit, S., Nimsuk, N., Uscharapong, M., ve Kiatisevi, P. (2022). Development of the Osteosarcoma Lung Nodules Detection Model Based on SSD-VGG16 and Competency Comparing With Traditional Method. *IEEE Access*, 10, 65496–65506. <https://doi.org/10.1109/ACCESS.2022.3183604>
- Lustberg, T., van Soest, J., Gooding, M., Peressutti, D., Aljabar, P., van der Stoep, J., van Elmpt, W., ve Dekker, A. (2018). Clinical evaluation of atlas and deep learning based automatic contouring for lung cancer. *Radiotherapy and Oncology*, 126(2), 312–317. <https://doi.org/10.1016/j.radonc.2017.11.012>
- Maftouni, M. , L. A. C. S. B. , Z. Y. , Y. N. , and K. Z. J. (2021, May 22). A Robust Ensemble-Deep Learning Model for COVID-19 Diagnosis based on an Integrated CT Scan Images Database. *IIE annual conference. Proceedings* (pp. 632-637). *Institute of Industrial and Systems Engineers (IISE)*.
- Majumder, S., Gautam, N., Basu, A., Sau, A., Geem, Z. W., ve Sarkar, R. (2024). MENet: A Mitscherlich function based ensemble of CNN models to classify lung cancer using CT scans. *PLoS ONE*, 19(3 March). <https://doi.org/10.1371/journal.pone.0298527>
- Mangal, S., Chaurasia, A., ve Khajanchi, A. (2020). *Convolution Neural Networks for diagnosing colon and lung cancer histopathological images*. <http://arxiv.org/abs/2009.03878>
- Masud, M., Sikder, N., Nahid, A. Al, Bairagi, A. K., ve Alzain, M. A. (2021). A machine learning approach to diagnosing lung and colon cancer using a deep learning-based classification framework. *Sensors (Switzerland)*, 21(3), 1–21. <https://doi.org/10.3390/s21030748>
- Mehmet Fatih AKCA. (2021). *Veri seti*. <https://universe.roboflow.com/mehmet-fatih-akca/yolotransfer/dataset/2>
- Mehmood, S., Ghazal, T. M., Khan, M. A., Zubair, M., Naseem, M. T., Faiz, T., ve Ahmad, M. (2022). Malignancy Detection in Lung and Colon Histopathology

- Images Using Transfer Learning With Class Selective Image Processing. *IEEE Access*, 10, 25657–25668. <https://doi.org/10.1109/ACCESS.2022.3150924>
- Nanglia, P., Kumar, S., Mahajan, A. N., Singh, P., ve Rathee, D. (2021). A hybrid algorithm for lung cancer classification using SVM and Neural Networks. *ICT Express*, 7(3), 335–341. <https://doi.org/https://doi.org/10.1016/j.ict.2020.06.007>
- Normalset Computer Vision Project*. (2023).
- O'Connor, J. (2001). *The NLP workbook: a practical guide to achieving the results you want*.
- P., S., ve M., P. B. (2021). Diagnosis of lung cancer using hybrid deep neural network with adaptive sine cosine crow search algorithm. *Journal of Computational Science*, 53, 101374. <https://doi.org/https://doi.org/10.1016/j.jocs.2021.101374>
- Pacal, I., Karaboga, D., Basturk, A., Akay, B., ve Nalbantoglu, U. (2020). A comprehensive review of deep learning in colon cancer. *Computers in Biology and Medicine*, 126, 104003. <https://doi.org/https://doi.org/10.1016/j.combiomed.2020.104003>
- Pawar, A. B., Jawale, M. A., William, P., Chhabra, G. S., Rakshe, D. S., Korde, S. K., ve Marriwala, N. (2022). Implementation of blockchain technology using extended CNN for lung cancer prediction. *Measurement: Sensors*, 24, 100530. <https://doi.org/https://doi.org/10.1016/j.measen.2022.100530>
- Redmon, J., Divvala, S., Girshick, R., ve Farhadi, A. (2015). *You Only Look Once: Unified, Real-Time Object Detection*. <http://pjreddie.com/yolo/>
- Rodney. (2023, March). *Lung Image Dataset*.
- Sarwinda, D., Bustamam, A., Paradisa, R. H., Argyadiva, T., ve Mangunwardoyo, W. (2020, November 10). Analysis of Deep Feature Extraction for Colorectal Cancer Detection. *ICICoS 2020 - Proceeding: 4th International Conference on Informatics and Computational Sciences*. <https://doi.org/10.1109/ICICoS51170.2020.9298990>
- Shah, A. A., Malik, H. A. M., Muhammad, A., Alourani, A., ve Butt, Z. A. (2023). Deep learning ensemble 2D CNN approach towards the detection of lung cancer. *Scientific Reports*, 13(1), 2987. <https://doi.org/10.1038/s41598-023-29656-z>
- Shakeel, P. M., Burhanuddin, M. A., ve Desa, M. I. (2019). Lung cancer detection from CT image using improved profuse clustering and deep learning instantaneously trained neural networks. *Measurement: Journal of the International Measurement Confederation*, 145, 702–712. <https://doi.org/10.1016/j.measurement.2019.05.027>
- Shanthi, S., Akshaya, V. S., Smitha, J. A., ve Bommy, M. (2022). Hybrid TABU search with SDS based feature selection for lung cancer prediction. *International Journal of Intelligent Networks*, 3, 143–149. <https://doi.org/https://doi.org/10.1016/j.ijin.2022.09.002>
- Song, Q. Z., Zhao, L., Luo, X. K., ve Dou, X. C. (2017). Using Deep Learning for Classification of Lung Nodules on Computed Tomography Images. *Journal of Healthcare Engineering*, 2017. <https://doi.org/10.1155/2017/8314740>

- Talib, L. F., Amin, J., Sharif, M., ve Raza, M. (2024). Transformer-based semantic segmentation and CNN network for detection of histopathological lung cancer. **Biomedical Signal Processing and Control**, 92, 106106. <https://doi.org/https://doi.org/10.1016/j.bspc.2024.106106>
- Talukder, Md. A., Islam, Md. M., Uddin, M. A., Akhter, A., Hasan, K. F., ve Moni, M. A. (2022). Machine learning-based lung and colon cancer detection using deep feature extraction and ensemble learning. **Expert Systems with Applications**, 205, 117695. <https://doi.org/https://doi.org/10.1016/j.eswa.2022.117695>
- Tarık Aslan, ve Mustafa Yagımlı. (2023). **The Journal of International Scientific Researches** 2023, 8(2). <https://orcid.org/0000-0003->
- Tori Sugden. (2020). **CNN classification model for lung and colon cancer images**. Tori Sugden.
- Türk Toraks Derneği. (2023, November). **Türk Toraks Derneği Akciğer Kanseri Farkındalık Bülteni**.
- Yan, C., ve Razmjoo, N. (2023). Optimal lung cancer detection based on CNN optimized and improved Snake optimization algorithm. **Biomedical Signal Processing and Control**, 86, 105319. <https://doi.org/https://doi.org/10.1016/j.bspc.2023.105319>