



**DERİN ÖĞRENME MODELLERİNE DAYALI
MAMOGRAFİ GÖRÜNTÜLERİNİN
SINIFLANDIRILMASI**

**2024
YÜKSEK LİSANS TEZİ
BİYOMEDİKAL MÜHENDİSLİĞİ**

AYA ALDASHASH

**Tez Danışmanı
Doç. Dr. Eftal ŞEHİRLİ**

**DERİN ÖĞRENME MODELLERİNE DAYALI MAMOGRAFİ
GÖRÜNTÜLERİNİN SINIFLANDIRILMASI**

Aya ALDASHASH

**Tez Danışmanı
Doç. Dr. Eftal ŞEHİRLİ**

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

**KARABÜK
Temmuz 2024**

Aya ALDASHASH tarafından hazırlanan “DERİN ÖĞRENME MODELLERİNE DAYALI MAMOGRAFİ GÖRÜNTÜLERİNİN SINIFLANDIRILMASI” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Doç. Dr. Eftal ŞEHİRLİ

Tez Danışmanı, Biyomedikal Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından Oy Birliği ile Biyomedikal Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 26/06/2024

Unvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Doç. Dr. Ahmet Reşit KAVSAOĞLU (KBÜ)

Üye : Doç. Dr. Eftal ŞEHİRLİ (KBÜ)

Üye : Dr. Öğr. Üyesi Kadir İLERİ (BANÜ)

ÇEVİRİMİÇİ

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

Doç. Dr. Zeynep ÖZCAN

Lisansüstü Eğitim Enstitüsü Müdürü

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

Aya ALDASHASH

ÖZET

Yüksek Lisans Tezi

DERİN ÖĞRENME MODELLERİNE DAYALI MAMOGRAFİ GÖRÜNTÜLERİNİN SINIFLANDIRILMASI

Aya ALDASHASH

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı:

Doç. Dr. Eftal ŞEHİRLİ

Haziran 2024, 130 sayfa

Meme kanserinin yaygınlığı ve ölüm potansiyeli göz önüne alındığında, erken teşhisin hasta sonuçlarını ve hayatta kalma oranlarını iyileştirmek için oldukça önemli olduğu görülmektedir. Bu tez, meme kanserinin tespit etme sürecini iyileştirmek için, mamografi görüntülerinin sınıflandırılması için derin öğrenme modellerinin uygulanmasını araştırmaktadır. Tezin amacı, mamografi görüntüleri üzerinde kitle tespit etmek ve tespit edilen kitlelerin sınıflandırması için otomatik bir sistem oluşturmak üzere YOLO (You Only Look Once) ve evrişimli sinir ağları (CNN) kullanarak hibrit bir yaklaşım önermektir. INbreast veri setindeki 410 görüntüden 107 kitle içeren görüntü ve 62 sağlıklı görüntü kullanılmıştır. Seçilen kitle görüntüleri, iyi huylu, şüpheli ve kötü huylu kitlelerin tüm işaretlenmiş (annotated) görüntülerini temsil etmektedir. Veri artırma teknikleri kullanılarak, model esnekliğini artırmak ve daha geniş bir varyans aralığından öğrenmek için, seçilen kitle ve normal görüntülerin sayısı sırasıyla 1183 ve 1116'ya çıkarılmıştır. Bu

tezde, YOLOv7 nesne algılama algoritması, %95.9'luk Ortalama Hassasiyet (mAP) ile olası kitlelerin tespit edilmesini içeren algılama aşamasında YOLOv5'i geride bırakmıştır. Tespitin ardından, ön eğitilmiş CNN modelleri tespit edilen kitleleri iyi huylu, kötü huylu ve şüpheli olarak sınıflandırmıştır. ResNet50 %91.7 doğruluğu ile en iyi performans göstermiştir. Kitle tespiti için YOLOv7 ve sınıflandırma için ön eğitilmiş CNN'lerin kombinasyonu, önde gelen araştırmalarla karşılaştırılabilir yüksek doğruluk üreterek, radyologların meme kanserini erken ve doğru bir şekilde teşhis etmelerine yardımcı olma potansiyelini göstermektedir.

Anahtar Sözcükler : Derin öğrenme, Mamografi, Meme kanseri

Bilim Kodu : 92518

ABSTRACT

M.Sc. Thesis

CLASSIFICATION OF MAMMOGRAPHY IMAGES BASED ON DEEP LEARNING MODELS

Aya ALDASHASH

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

Thesis Advisor:

Assoc. Prof. Dr. Eftal ŞEHİRLİ

June 2024, 130 pages

Given the prevalence and potential mortality of breast cancer, early diagnosis is crucial to improve patient outcomes and survival rates. This thesis investigates the application of deep learning models for the classification of mammography images to improve the detection process of breast cancer. The aim of the thesis is to propose a hybrid approach using YOLO (You Only Look Once) and convolutional neural networks (CNN) to create an automated system for mass detection and classification of detected masses on mammography images. Out of 410 images in the INbreast dataset, 107 images containing masses and 62 normal images were used. The selected mass images represent all annotated images of benign, suspicious and malignant masses. Using data augmentation techniques, the number of selected mass and normal images was increased to 1183 and 1116, respectively, in order to increase the model flexibility and to learn from a wider range of variances. In this thesis, the YOLOv7 object detection algorithm outperforms YOLOv5 in the detection phase,

which involves the detection of possible masses with a mean average precision (mAP) of 95.9%. After detection, the pre-trained CNN models were used to classify the detected masses as benign, malignant and suspicious. ResNet50 showed the best performance in this phase with 91.7% accuracy. The combination of YOLOv7 for mass detection and pre-trained CNNs for classification produced high accuracy comparable to leading research, demonstrating the potential to assist radiologists to diagnose breast cancer early and accurately.

Key Words : Breast cancer, Deep learning, Mammography

Science Code : 92518

TEŐEKKÜR

Yüksek lisans eğitimin sürecinde ve bu tezin hazırlanmasında bilgi ve tecrübelerini esirgemeyen, tezimin bilimsel bir nitelik kazanmasında büyük katkılarda bulunan değerli danışman hocam Doç. Dr. Eftal ŐEHİRLİ'ye içten teşekkürlerimi sunarım.

Hayatımın her döneminde yanımda olan, her türlü fedakarlığı gösteren ve beni destekleyen aileme minnettarım. Onların desteęi ve inancı olmadan bu başarıyı elde etmem mümkün olmazdı.

Ayrıca, yüksek lisans eğitimin boyunca bana destek veren, yardımlarını ve teşviklerini esirgemeyen tüm arkadaşlarıma teşekkür ederim. Bu süreçteki katkılarınız ve dostluęunuz benim için çok değerliydi.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xiii
ÇİZELGELER DİZİNİ	xvi
SİMGELER VE KISALTMALAR DİZİNİ	xvii
BÖLÜM 1	1
GİRİŞ	1
1.1. TEZİN TANIMI.....	1
1.2. TEZİN AMACI.....	3
BÖLÜM 2	4
MEME VE MEME HASTALIKLARI HAKKINDA GENEL BİLGİLER	4
2.1. MEME GELİŞİMİ VE ANATOMİK YAPISI	4
2.2. MEME ANORMALLİKLERİ	6
2.2.1. Kitleler	7
2.2.2. Kalsifikasyonlar (Kireçlenme)	8
2.2.3. Yapısal Distorsiyon	10
2.2.4. Diğer Anormallikler	11
2.3. MEME KANSERİ.....	12
2.3.1. Meme Kanserin Türleri	12
2.3.1.1. Non-invazive Meme Kanseri	12
2.3.1.2. İnvaziv Meme Kanseri.....	13
2.3.2. Dünyada Meme Kanseri İstatistikleri	15
2.3.3. Türkiye’de Meme Kanseri İstatistikleri.....	17

	<u>Sayfa</u>
BÖLÜM 3	18
MEME KANSERİ GÖRÜNTÜLEME YÖNTEMLERİ.....	18
3.1. MAMOGRAFİ.....	18
3.2. ULTRASON.....	20
3.3. MANYETİK REZONANS GÖRÜNTÜLEME (MAGNETIC RESONANCE IMAGING (MRI)).....	21
3.4. TERMOGRAFİ.....	21
3.5. SİNTİMAMOGRAFİ (SM)	22
3.6. HİSTOPATOLOJİ	22
BÖLÜM 4	24
AÇIK ERİŞİMLİ MAMOGRAFİ VERİ SETLERİ	24
4.1. MAMMOGRAPHIC IMAGE ANALYSIS SOCIETY (MIAS)	24
4.2. DIGITAL DATABASE FOR SCREENING MAMMOGRAPHY (DDSM)	24
4.3. BREAST CANCER DIGITAL REPOSITORY (BCDR)	25
4.4. THE OPTIMAM MAMMOGRAPHY DATABASE (OMI-DB).....	26
4.5. BANCOWEB LAPIMO.....	26
4.6. THE VICTRE TRIAL.....	26
BÖLÜM 5	27
YAPAY ZEKA (ARTIFICIAL INTELLIGENCE (AI)).....	27
5.1. YAPAY ZEKA TANIMI	27
5.1.1. AI Tarihçesi	27
5.1.2. Yapay Zeka Alt Alanları	28
5.1.3. Sağlıkta AI.....	29
5.2. YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORKS (ANN))	30
5.3. MAKİNE ÖĞRENMESİ (MACHINE LEARNING (ML))	32
5.3.1. Gözetimli ML (Supervised ML).....	33
5.3.2. Gözetimsiz ML (Unsupervised ML)	34
5.3.3. Yarı Gözetimli ML	35
5.3.4. Pekiştirmeli ML.....	35
5.4. DERİN ÖĞRENME (DEEP LEARNING (DL)).....	35

	<u>Sayfa</u>
BÖLÜM 6	37
LİTERATÜR TARAMASI	37
BÖLÜM 7	43
MATERYAL	43
7.1. VERİ SETİ	43
7.2. PYTHON.....	44
7.3. GOOGLE COLABORATORY.....	45
7.4. LABELIMG	46
BÖLÜM 8	48
METOT	48
8.1. ÖN İŞLEME.....	49
8.1.1. Yeniden Boyutlandırma.....	49
8.1.2. Görüntü İşaretleme	50
8.1.3. Veri Artırmak	51
8.2. NESNE TANIMA	53
8.2.1. YOLO (You Only Look Once).....	54
8.2.1.1. YOLOv5	57
8.2.1.2. YOLOv7	59
8.2.1.3. YOLOv5 ve YOLOv7 Uygulaması	61
8.3. EVREŞİMLİ SİNİR AĞLARI (CONVOLUTIONAL NEURAL NETWORK (CNN))	64
8.3.1. Transfer Öğrenme (Transfer Learning) ve Ön Eğitimli CNN Modelleri 68	
8.3.1.1. VGG16.....	71
8.3.1.2. ResNet50.....	72
8.3.2. CNN Uygulaması	73
8.4. PERFORMANS DEĞERLENDİRME METRİKLERİ.....	74
BÖLÜM 9	80
BULGULAR.....	80
9.1. YOLO.....	80

	<u>Sayfa</u>
9.1.1. YOLOv5	80
9.1.2. YOLOv7	85
9.2. CNN	97
9.2.1. VGG16 Sonuları	97
9.2.2. ResNet50 Sonuları	99
BÖLÜM 10	103
TARTIŞMA	103
BÖLÜM 11	111
SONU	111
KAYNAKLAR	113
ÖZGEMİŞ	130

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1.	Memenin anatomik yapısı [9].	6
Şekil 2.2.	Mammogram görüntülerinde kalsifikasyonların görünümü [17].	9
Şekil 2.3.	2020 yılına ait dünya üzerinde meme kanserine bağlı olum ve hasta sayıları [40].	16
Şekil 3.1.	Meme kanseri görüntüleme yöntemleri: a) Mamografi, b) Ultrason, c) MRI, d) Termografi, e) SM, f) Histopatoloji [76–81].	23
Şekil 5.1.	İnsan beynindeki nöron yapısı.	30
Şekil 5.2.	Doğal nöron ve yapay nöron [105].	31
Şekil 5.3.	Yüz tanıma DL modeli [115].	36
Şekil 7.1.	LabelImg aracının arayüzü.	47
Şekil 8.1.	Tez çalışmanın iş akış diyagramı.	48
Şekil 8.2.	Kullanılan veri artıma teknikleri. a) Orjinal Görüntü, b) Yeni görüntüler.	52
Şekil 8.3.	YOLO'nun çalışma prensibi.	54
Şekil 8.4.	Input, backbone, neck ve head ile YOLO'nun mimarisi [153].	56
Şekil 8.5.	YOLOv5'in mimarisi [157].	58
Şekil 8.6.	YOLOv7'nin mimarisi [164].	60
Şekil 8.7.	YOLO uygulamasının akış diyagramı.	62
Şekil 8.8.	Konvolüsyon İşlemi [173].	65
Şekil 8.9.	Örnekleme yöntemleri [175].	67
Şekil 8.10.	CNN mimarisi [178].	68
Şekil 8.11.	Ön eğitilmiş modelden öğrenme aktarması işlemi sırasında tüm konvolüsyon katmanlarının dondurulması ve yalnızca üst katmanların eğitimi gerçekleşmektedir [179].	69
Şekil 8.12.	Dört tip transfer öğrenme yaklaşımı [183].	71
Şekil 8.13.	VGG16 mimarisi [185].	72
Şekil 8.14.	ResNet50 mimarisi [187].	73
Şekil 8.15.	CNN uygulamasının akış diyagramı.	74
Şekil 8.16.	PR eğrisi [188].	76
Şekil 8.17.	Karışıklık matrisi.	77

Şekil 8.18.	Model doğrulama halleri. a) yetersiz uyum, b) optimal uyum, c) aşırı uyum [190].	78
Şekil 8.19.	Birlik Üzerinden Kesişim [192].	79
Şekil 9.1.	Eğitim aşamanın loss ve doğruluk grafikleri.	82
Şekil 9.2.	Eğitim aşamasından elde edilen F1-skoru grafiği.	82
Şekil 9.3.	Eğitim aşamasından elde edilen PR eğrisi.	83
Şekil 9.4.	Eğitim aşamasından elde edilen karışıklık matrisi.	83
Şekil 9.5.	Test aşamasından elde edilen F1-skoru grafiği.	84
Şekil 9.6.	Test aşamasından elde edilen PR eğrisi.	84
Şekil 9.7.	Test aşamasından elde edilen karışıklık matrisi.	85
Şekil 9.8.	Eğitim aşamanın loss ve doğruluk grafikleri.	86
Şekil 9.9.	Eğitim aşamasından elde edilen F1-skoru grafiği.	87
Şekil 9.10.	Eğitim aşamanın PR eğrisi.	87
Şekil 9.11.	Eğitim aşamasından elde edilen karışıklık matrisi.	88
Şekil 9.12.	Test aşamasından elde edilen F1-skoru grafiği.	88
Şekil 9.13.	Test aşamasından elde edilen PR eğrisi.	89
Şekil 9.14.	Test aşamasından elde edilen karışıklık matrisi.	89
Şekil 9.15.	Eğitim aşamanın loss ve doğruluk grafikleri.	90
Şekil 9.16.	Eğitim aşamasından elde edilen F1-skoru grafiği.	91
Şekil 9.17.	Eğitim aşamanın PR eğrisi.	91
Şekil 9.18.	Eğitim aşamasından elde edilen karışıklık matrisi.	92
Şekil 9.19.	Test aşamasından elde edilen F1-skoru grafiği.	92
Şekil 9.20.	Test aşamasından elde edilen PR eğrisi.	93
Şekil 9.21.	Test aşamasından elde edilen karışıklık matrisi.	93
Şekil 9.22.	Kötü hulu kitle tespiti. a) Yöntem A çıktısı, b) Yöntem B çıktısı, c) Gerçek referans sınırlayıcı kutu.	94
Şekil 9.23.	Şüpheli kitle tespiti. a) Yöntem A çıktısı, b) Yöntem B çıktısı, c) Gerçek referans sınırlayıcı kutu.	94
Şekil 9.24.	İyi huylu kitle tespiti. a) Yöntem A çıktısı, b) Yöntem B çıktısı, c) Gerçek referans sınırlayıcı kutu.	95
Şekil 9.25.	Kitle veri seti. a) İyi huylu kitle, b) Şüpheli kitle, c) Kötü huylu kitle.	95
Şekil 9.26.	YOLOv5 ve YOLOv7 modellerin mAP@0.5 eğrileri. a)YOLOv5 modelleri, b) YOLOv7 modelleri.	96
Şekil 9.27.	Performans grafikleri. a) loss grafiği, b) doğruluk grafiği.	98
Şekil 9.28.	Karışıklık matrisi.	98

	Sayfa
Şekil 9.29. Performans grafikleri. a) loss grafiđi, b) dođruluk grafiđi.....	99
Şekil 9.30. Karışıklık matrisi.	99
Şekil 9.31. Performans grafikleri. a) loss grafiđi, b) dođruluk grafiđi.....	100
Şekil 9.32. Karışıklık matrisi.	100
Şekil 9.33. Performans grafikleri. a) loss grafiđi, b) dođruluk grafiđi.....	101
Şekil 9.34. Karışıklık matrisi.	102
Şekil 10.1. YOLOv5x ve YOLOv7x modellerin karşılaştıması.	104
Şekil 10.2. Modellerin tahmini. a) Gerçek referans, b) Yöntem B tahmini (FN), c) Yöntem A tahmini.	105
Şekil 10.3. Modellerin tahmini. a) Gerçek referans, b) Yöntem B tahmini (FP), c) YöntemA tahmini.	105
Şekil 10.4. Modellerin tahmini. a) Gerçek referans, b) Yöntem B tahmini (küçük kitleleri tahmin edememesi), c) Yöntem A tahmini.	106
Şekil 10.5. ResNet50'nin Yöntem A ve Yöntem B veri setleri üzerinde SGD ve Adam optimizer'larla eğitim ve test dođruluk grafikleri. a) Yöntem A, b) Yöntem B.	107
Şekil 10.6. VGG16'nın Yöntem A ve Yöntem B veri setleri üzerinde SGD ve Adam optimizer'larla eğitim ve test dođruluk grafikleri. a) Yöntem A, b) Yöntem B.	108

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 2.1. İyi huylu ve kötü huylu yapısal distorsiyon [20].	10
Çizelge 6.1. Çalışmaların özeti.	42
Çizelge 7.1. Veri setin kategorilere ayırması [133].	44
Çizelge 8.1. Veri artırma işlemi.	52
Çizelge 8.2. YOLO versiyonları arasında karşılaştırma [153,154].	57
Çizelge 9.1. YOLOv5 test sonuçları.	81
Çizelge 9.2. YOLOv7 test sonuçları.	85
Çizelge 9.3. YOLOv5 ve YOLOv7 modellerin performansı.	96
Çizelge 9.4. Yöntem A veri setinin VGG16 test sonuçları.	97
Çizelge 9.5. Yöntem B veri setinin VGG16 test sonuçları.	98
Çizelge 9.6. Yöntem A veri setinin ResNet50 test sonuçları.	100
Çizelge 9.7. Yöntem B veri setinin ResNet50 test sonuçları.	101
Çizelge 10.1. Önceki araştırma çalışmalarına genel bakış.	110

SİMGELER VE KISALTMALAR DİZİNİ

KISALTMALAR

ACR	:	American College of Radiology Reporting and Data System (Amerikan Radyoloji Koleji raporlama sistemi)
Adam	:	Adaptive Moment Estimation (Adaptif Momentum Tahmini)
AdamW	:	Adam Moment Estimation (Adaptif Momentum Tahmini)
AI	:	Artificial Intelligence (Yapay Zeka)
ANN	:	Artificial Neural Network (Yapay Sinir Ağı)
AP	:	Average Precision (Ortalama Kesinlik)
AUC	:	Area Under Curve (Eğri Altında Alan)
BCDR	:	Breast Cancer Digital Repository (Meme Kanseri Dijital Veri Seti)
BI-RADS	:	Breast Imaging Reporting and Data System (Meme Görüntüleme Raporlama ve Veri Sistemi)
BSD	:	Berkeley Software Distribution (Berkeley Yazılım Dağıtımı)
CAD	:	Computer Aided Diagnosis (Bilgisayar Destekli Tanı)
CBIS-DDSM	:	Curated Breast Imaging Subset of DDSM (DDSM'nin Küratörlü Meme Görüntüleme Alt Seti)
CC	:	Cranio Caudal (Kraniyal Kaudal)
CEDM	:	Contrast-Enhanced Digital Mammography (Kontrastlı Dijital Mamografi)
CNN	:	Convolutional Neural Network (Evrişimli Sinir Ağı)
CRF	:	Conditional Random Fields (Koşullu Rastgele Alanlar)
DBN	:	Deep Belief Network (Derin İnanç Ağı)
DCIS	:	Ductal Carcinoma In Situ (Duktal Karsinoma in Situ)
DCNN	:	Deep Convolutional Neural Network (Derin Evrişimli Sinir Ağı)

DDSM	:	Digital Database For Screening Mammography (Tarama Mamografisi İçin Dijital Veri Seti)
DICOM	:	Digital Imaging and Communications in Medicine (Tıpta Dijital Görüntüleme ve İletişim)
DL	:	Deep Learning (Derin Öğrenme)
E-ELAN	:	Extended Efficient Layer Aggregation Network (Genişletilmiş Verimli Katman Birleştirme Ağ)
Faster-RCNN	:	Faster Region-based Convolutional Neural Network (Daha Hızlı Bölge Tabanlı Evrişimsel Sinir Ağı)
FFDM	:	Full-Field Digital Mammography (Tam Alan Dijital Mamografi)
FN	:	False Negative (Yanlış Negatif)
FP	:	False Positive (Yanlış Pozitif)
FPN	:	Feature Pyramid Network (Özellik Piramit Ağı)
FPR	:	False Positive Rate (Yanlış Pozitif Oranı)
GPU	:	Graphics Processing Unit (Grafik İşleme Birimi)
IBC	:	Inflammatory Breast Cancer (İnflamatuvar Meme Kanseri)
IDC	:	Invasive Ductal Carcinoma (İnvaziv Duktal Karsinom)
IDE	:	Integrated Development Environment (Bütünleşik Geliştirme Ortamı)
ILC	:	Invasive Lobular Carcinoma (İnvaziv Lobüler Karsinom)
IoU	:	Intersection Over Union (Birleşim Üzerindeki Kesişim)
LCIS	:	Lobular Carcinoma In Situ (lobüler Karsinoma in Situ)
mAP	:	Mean Average Precision (Ortalama Hassasiyet)
MIAS	:	Mammographic Image Analysis Society (Mamografik Görüntü Analizi Derneği)
ML	:	Machine Learning (Makine Öğrenmesi)
MLO	:	Medio-Lateral Oblique (Mediolateral Oblik)
MRI	:	Magnetic Resonance Imaging (Manyetik Rezonans Görüntüleme)
NMS	:	Non-Maximum Suppression (Maksimum Olmayan Bastırma)
OMI-DB	:	The Optimam Mammography Database (Optimam Mamografi Görüntü Veritabanı)
PAN	:	Path Aggregation Network (Yol Agregasyon Ağı)

PR	:	Precision-Recall (Kesinlik-Duyarılık)
RF	:	Random Forest (Rastgele Orman)
ROI	:	Region Of Interest (İlgili Alan)
SGD	:	Stochastic Gradient Descent (Stokastik Gradyan İniş)
SM	:	Scintimammography (Sintimamografi)
SPP	:	Spatial Pyramid Pooling (Uzamsal Piramit Havuzlama)
SVM	:	Support Vector Machine (Destek Vektör Makinesi)
TN	:	True Negative (Gerçek Negatif)
TP	:	True Positive (Gerçek Pozitif)
TPR	:	True Positive Rate (Gerçek Pozitif Oranı)
TPU	:	Tensor Processing Unit (Tensor İşleme Birimi)
TÜİK	:	Türkiye İstatistik Kurumu
VGG	:	Visual Geometry Group (Görsel Geometri Grubu)
WHO	:	World Health Organization (Dünya Sağlık Örgütü)
YOLO	:	You Only Look Once (Sadece Bir Kez Bakarsın)

BÖLÜM 1

GİRİŞ

Bu tez, meme kanseri teşhisinde kullanılan mamografi görüntülerinin sınıflandırılması için derin öğrenme (Deep Learning (DL)) yaklaşımlarının kullanımını sunmaktadır. Bu tez kapsamında gerçekleştirilen çalışmalarda, DL nesne tanıma ve sınıflandırma modellerini kullanarak yüksek doğruluğa ulaşılmaya çalışılmıştır.

1.1. TEZİN TANIMI

Meme kanseri, memedeki hücrelerin hızla büyüyerek tümör oluşturduğu bir durumdur. Bu tümörler, genellikle zararsız olan iyi huylu ve tehlikeli olabilen kötü huylu olarak iki tipte sınıflandırılabilir. İyi huylu tümörler yavaş gelişir. Yakındaki dokulara yayılma şansı çok az olan hücelere benzemektedir. Öte yandan kötü huylu tümörler, buldukları yerin ötesinde vücudun diğer bölgelerine yayılma potansiyeline sahiptir [1].

Meme kanseri, kadınlarda oldukça sık görülen bir hastalıktır. Erken tanı, bu ölümcül hastalık için tedavi masraflarını azaltır ve hayatta kalma olasılığını artırmaktadır. Bu ölümcül hastalığı erken teşhis etmek için mamografi, ultrason, manyetik rezonans (Magnetic Resonance Imaging (MRI)), histopatoloji ve termografi gibi çeşitli görüntüleme yöntemleri kullanılmaktadır. Bu hastalığın erken teşhisi için en yaygın kullanılan görüntüleme yöntemi olan mamografi, hastaları tedaviden sonra radyasyona maruz bırakmadan meme anormalliklerini tespit etmek için düşük yoğunluklu x-ışınları kullanmaktadır [1].

Bununla birlikte, görüntünün yüksek çözünürlüğü ve düşük radyasyon nedeniyle iyi huylu ve kötü huylu tümörleri çıplak gözle ayırt etmek zordur. Bu durum,

radlyologların mamografi konusunda daha doğru kararlar vermelerine yardımcı olacak bir araca duyulan ihtiyaçı vurgulamaktadır. Bilgisayar destekli tanı (Computer Aided Diagnosis (CAD)), radyoloğun mikrokalsifikasyonlar ve artan yoğunluk gibi kanserli göstergeleri tespit etmesine yardımcı olmaktadır. Geleneksel CAD'in gereksiz radyasyona maruz kalmaya, biyopsilere ve hasta maliyetlerinin artmasına neden olabilecek önemli bir yanlış teşhis şansı taşıdığı unutulmamalıdır. Tıp endüstrisi, son birkaç yılda yapay zeka (Artificial Intelligence (AI)) alanındaki gelişmelere büyük ilgi göstermiştir. Retina analizi, yüz tanıma, gereksiz tıbbi faaliyetlerin robotik hale getirilmesi ve radyolojik görüntü yorumlama, yapay sinir ağları, özellikle de Evrişimli Sinir Ağları (Convolutional Neural Network (CNN'ler)) tarafından gerçekleştirilen işlevler arasındadır [2].

DL, Makine öğrenmesinin (Machine Learning (ML)) bir alt alanı, verilerden bilgi çıkarmak için hiyerarşik sistemler kullanmaktadır. CNN, özellikle görüntü sınıflandırması için en yaygın kullanılan DL yöntemlerinden biridir. CNN, bir girdi katmanı, birden fazla gizli katman ve bir çıktı katmanından oluşmaktadır. CNN'in gizli katmanları genellikle evrişimsel (Convolutional), örnekleme (Pooling) ve tam bağılı (Fully Connected) katmanları içerir. Daha karmaşık modellerde ek katmanlar kullanılabilir [3].

DL, özellikle de CNN, meme kanseri tespiti için mamografi görüntülerinin sınıflandırılmasında başarılıdır. Bu modeller, meme kanserinin ince belirtilerinin tanımlanmasına yardımcı olarak temel ayrıntıları çıkarmaktadır. Ayrıca, potansiyel anormallikleri vurgulayarak ve bunları kötü huylu veya iyi huylu olarak sınıflandırarak otomatik lezyon tespitini kolaylaştırmaktadır. Klinik verilerle entegrasyon tanısal doğruluğu artırır ve büyük ölçekli veri analizi genellemeyi geliştirmektedir. Eğitimli modellerden alınan gerçek zamanlı karar desteği teşhisleri hızlandırmaktadır. Ancak, gerçek dünyadaki uygulamalar için titiz testler, doğrulama ve sağlık uzmanlarıyla iş birliği gerekmektedir [2,3].

1.2. TEZİN AMACI

Sıklığı ve potansiyel olarak ölümcül etkileri göz önüne alındığında, meme kanseri halk sağlığı için ciddi bir tehdit oluşturmaya devam etmektedir. Tedavinin etkinliği gecikmiş teşhisten büyük ölçüde etkilenebilir, bu nedenle erken teşhis hayatta kalma oranlarını ve hastaların yaşam kalitesini artırmak için çok önemlidir. Bu sebeple, meme kanseri tespit sürecinin iyileştirilmesi büyük önem taşımaktadır.

Bu tez, mamografi görüntülerinin otomatik analizi için DL modellerinden yararlanarak meme kanseri tespit sürecini ilerletmeyi amaçlamaktadır. Araştırma özellikle, YOLO (You Only Look Once) ve CNN nesne tanıma tekniklerini kullanarak otomatik tümör tespiti ve malignite sınıflandırması için hibrit bir model geliştirmeye odaklanmaktadır. Ayrıca, tıbbi görüntüleme teknolojisini geliştirmek, meme kanserinin erken teşhisine ve etkili tedavisine yardımcı olmak ve sağlık hizmeti uygulayıcılarına değerli karar desteği sağlamak da bu tezin önemli hedeflerindedir.

BÖLÜM 2

MEME VE MEME HASTALIKLARI HAKKINDA GENEL BİLGİLER

Meme, hem endokrin hem de üreme sistemlerinde önemli rolleri olan karmaşık bir organdır. Süt üretiminden sorumlu glandüler dokuların yanı sıra yapı ve destek sağlayan yağ ve bağ dokularından oluşmaktadır [4]. Meme anatomisini ve gelişimini anlamak, bu organı etkileyebilecek çeşitli tıbbi anormallikleri anlamak için oldukça önemlidir. Bu bölümde memenin normal anatomisi ve gelişiminin yanı sıra sık görülen anormallikler de ele alınmaktadır.

2.1. MEME GELİŞİMİ VE ANATOMİK YAPISI

Meme bezi, memelilerde emzirme için süt üreten ektodermal bir organdır. Eşsiz yapısı, birçok kültürde sanata konu olan ve estetik açıdan önem taşıyan işlevini yansıtmaktadır. Kadınların göğüsleri boyut ve şekil bakımından farklılık gösterir; bazıları daha büyük, daha küçük veya farklı şekillere sahiptir. Meme bezinin iç yapısı, süt üreten lobüller ve kanallar da dahil olmak üzere epitelyal bileşenlerden oluşmaktadır. Erkek meme yapısı kadın memesine benzer, ancak süt üretimi için fizyolojik bir ihtiyaç olmadığından özelleşmiş lobüllerden yoksundur [4].

Meme dokusu, fetal yaşam sırasında tek bir ektodermal tomurcuktan başlayarak ve süt çizgileri adı verilen uzunlamasına şeritler halinde embriyonun ventral tarafı boyunca ilerleyerek gelişmektedir. İnsanlarda, gebeliğin 9. haftasına kadar süt çizgisinin pektoral bölgesinde sadece tek bir çift bez gelişmektedir. Meme ucu tomurcuğu bu bölgede çoğalan bazal hücrelerden oluşmaktadır. Skuamöz hücreler gebeliğin 12. haftasında meme ucu tomurcuğunu kaplar ve epitelyal hücreler meme kanalları olarak aşağı doğru büyümektedir. Mezenkimal hücreler meme ucu ve areolanın düz kasına farklılaşmaktadır. Bu özelleşmiş epitel, iç lümene doğru gelişen ve laktiferöz kanalları oluşturmak üzere kanalize olan 15-20 dala ayrılmaktadır.

Plasental cinsel hormonları, doğumdan sonra 4-7 gün boyunca ifade edilebilen kolostrum içeren lobulo-alveolar yapılara farklılaşan bu dalları uyarmaktadır [5]. Gebeliğin son haftalarında, meme bezinin kütlesi sürekli olarak artar ve meme ucu-areola kompleksi (Nipple-Areolar Complex (NAC)) gelişir ve pigmente olur. Bu aşamaların başarısızlığı, ektopik meme dokusu, aksesuar meme uçları, ters meme uçları, aksesuar meme bezleri ve memenin yokluğu gibi memenin doğuştan anormalliklerine neden olabilmektedir [6].

Alveol içermeyen laktiferöz kanallar doğumdan ergenliğe kadar memeyi oluşturmaktadır. Pubertenin başlangıcı stroma ve duktal epitelin genişlemesine neden olarak terminal kanal lobüler ünitelerini ve toplayıcı kanalları oluşturmaktadır. Bu tomurcuklar ek meme lobüllerinden önce gelmektedir. Yağ dokusunun yerini daha elastik ve hacimli bağ dokusu alır ve bu da kanalların oluşumunu desteklemektedir. Kızlarda memelerin büyümesi ergenlik döneminin bir göstergesidir [7].

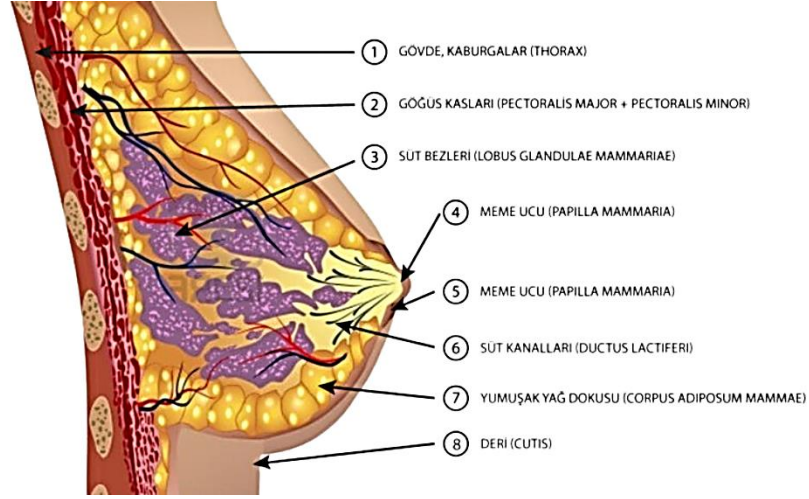
Hamilelik döneminde salgılayan alveoller gelişir ve prolaktin ile luteal ve plasental cinsel hormonları kanalların, lobüllerin ve alveollerin gelişimini desteklemektedir. Daha koyu areolar ve meme başı derisi ile birlikte memenin boyutunda önemli bir artış olmaktadır. Meme, son üç aylık dönemde kolostrum üretmeye başlar ve daha sonra lobülleri çevreleyen stroma azaldığında bunun yerini süt almaktadır. Laktasyon durduğunda glandüler doku dinlenmeye geri dönmektedir [7].

Progesteron ve östrojenin azalmasına bağlı semptomların eşlik ettiği menopoza, 40'lı yaşların sonunda ve 50'li yaşların başında gerçekleşmektedir. Memenin glandüler dokusu küçülür, bağ dokusu hücreliliğinin bir kısmını kaybeder ve genel olarak daha az kolajen vardır. Bağ dokusunun gücünü kaybetmesinin bir sonucu olarak meme tipik olarak sarkar ve hacim kaybetmektedir. Ancak atrofi değişiklikleri kadından kadına farklılık gösterir ve tutarlı değildir [7].

İnsan memesi, deri ve deri altı dokusu, meme parankimi (kanallar ve lobüller) ve destekleyici stromanın yanı sıra bağlar, sinirler, arterler, damarlar ve lenfatiklerden oluşan karmaşık bir ağ içinde konumlanmış yağdan oluşan modifiye kutanöz ekzokrin bir bezdir. Her iki cinsiyette de memenin dış sınırları normalde lateralde

midaxiller çizgi ile medialde sternum arasında, üstte ikinci kaburgadan altta altıncı kaburgaya kadar uzanmaktadır [8].

Ön yüz tabakası ve Cooper bağlarının yüzeysel fibröz uzantıları, meme derisinin altta yatan meme dokusuna bağlandığı iki yoldur. Bir ön ve arka yüz tabakası memenin derin parankimal dokularını çevrelemektedir. Üst karın oblik kasları inferiorda, serratus anterior kası lateralde ve pektoralis major kası superiorda meme tarafından örtülmektedir. Erkek memesi neredeyse tamamen yağdan oluşurken, kadın memesi tipik olarak daha büyüktür ve daha büyük hacimde fibroglandüler dokuya sahiptir [8]. Şekil 2.1, memenin anatomik yapısı göstermektedir [9].



Şekil 2.1. Memenin anatomik yapısı [9].

2.2. MEME ANORMALLİKLERİ

Meme, bir kadının hayatının her aşamasında birçok yönden farklılık gösterebilen karmaşık bir organdır. Bu değişiklikler normal olsa da, iyi huylu yumrular veya kötü huylu tümörler gibi anomaliler zaman zaman ortaya çıkabilmektedir. Etkili tedavi ve daha iyi sonuçlar için bu anormalliklerin mümkün olan en kısa sürede tespit ve teşhis edilmesi gerekmektedir. Bu anormalliklerin tespiti fiziksel muayene veya görüntüleme teknikleri kullanılarak mümkündür.

2.2.1. Kitleler

Bir kitle, en az iki projeksiyonda görülen yer kaplayan bir lezyon olarak tanımlanmaktadır [10]. Meme kitleleri, birçok görüntüleme yönteminde görülebilen ve meme dokusunun fiziksel muayenesinde tespit edilebilen küçük, ele gelen yumrular veya şişliklerdir.

Meme Kitlelerinin Türleri:

- Katı kitleler: boyutları ve şekilleri değişebilir ve mamografide ayrı beyaz lekeler olarak görülmektedir. Örnekleri şunları içermektedir:
 - Fibroadenom: En yaygın iyi huylu meme tümörleri, genellikle düzgün kenarlı ve lastik kıvamında sertliği olan kitlelerdir. Doğal kanal epitelinde bozulmaya neden olan iyi huylu stroma (fibroblastlar ve kolajen) topaklarına fibroadenom denmektedir. Her yaşta ortaya çıkabilmelerine rağmen, 30 yaşın altındaki kadınlarda görülme olasılığı daha yüksektir [11].
 - Kistler: Meme dokusunda sıklıkla görülen içi sıvı dolu keselerdir. İçi sıvı ile dolu oldukları için yumuşaktır. İçindeki sıvı arttıkça gerilmeleri nedeniyle ağrılı olabilmektedir [12].
 - Fibrokistik değişiklikler: Tipik olarak, 20 ila 50 yaş arasındaki menopoza öncesi kadınlar bu değişiklikleri yaşamaktadır. Meme rahatsızlığı ve memelerde ağrılı nodüller en sık ortaya çıkan semptomlardır. Hormonal dengesizlik, özellikle de progesterona kıyasla östrojen fazlalığı, durumun kesin patofizyolojisi bilinmese de, bu varlığın gelişiminde önemli bir etkiye sahip gibi görünmektedir [13].
 - Kötü huylu tümörler: Genellikle kanser olarak adlandırılan kötü huylu tümörler, komşu dokulara sızma ve vücudun diğer bölgelerine yayılma kapasitesine sahip anormal hücre büyümeleridir. Kanserli tümörler, genellikle sınırlı büyüme gösteren ve daha az riskli olan iyi huylu tümörlerin aksine, erken teşhis ve tedavi edilmediği takdirde bu durum hayati tehlike arz edebilmektedir [14].

- Katı Olmayan Kitleler: Bu tür kitleleri, mamogram ve ultrason gibi görüntüleme yöntemlerinde çevredeki meme dokusundan daha az yoğun olarak görülen anomalilerdir [15]. Bunlara örnek olarak:
 - Yağ kitleleri: Meme yağ dokusunun normal, homojen, düşük yoğunluklu bölgeleri, yağlı kitleler olarak bilinmektedir. Mamogramlarda pürüzsüz ve iyi tanımlanmış görünürler, genellikle ağrıya neden olmazlar ve tedavi edilmeleri gerekmez. Bu kitlelerle ilişkili herhangi bir sağlık tehlikesi yoktur; bunlar sadece yağ dağılımındaki farklılıklardır ve genellikle iyi huylu olarak kabul edilmektedir [15].
 - Karmaşık kistler: İç ekolar, ince septasyonlar, intrakistik bir kitle, fark edilebilir bir duvar veya kesin arka duvar artışının olmaması, karmaşık bir kisti kategorize etmek için kullanılabilir. Bu lezyonlar iyi tanımlanmış sınırlara sahiptir ve fark edilebilir katı bileşenler veya kist içi mural nodüller göstermemektedir [12].


2.2.2. Kalsifikasyonlar (Kireçlenme)

Meme kalsifikasyonları, meme dokusunda oluşabilen mikroskobik kalsiyum birikintileridir. Bu durum mamografik taramalarda sıklıkla görülen ve sıklığı hasta yaşıyla birlikte artmaktadır. Tümörlerin aksine, kalsifikasyonlar genelde küçüktür. Kalsifikasyonların oluşumu, iyi huylu veya kötü huylu hastalıkların göstergesi olabilmektedir. Vakaların çoğu iyi huylu olsa da, yüksek riskli lezyonlar veya kötü huylu durumlar belirli farklı kümelenmiş paternlere neden olabilmektedir [16].

Kalsifikasyonlar mamogramlarda küçük, beyaz noktalar veya lekeler olarak görünmektedir. Çeşitli görünüşleri nedeniyle - altta yatan nedenler hakkında ipuçları sağlayabilen şekil ve desendeki varyasyonlar - radyologlar bunları dikkatle yorumlamaktadır [16].

Kalsifikasyonların her zaman maligniteye işaret etmediğini anlamak önemlidir. Enflamasyon, doku hasarı, yaralanma, ameliyat kaynaklı travmalar, önceki meme kanseri tedavisi ve yaşlanmaya bağlı değişiklikler gibi iyi huylu durumlar

kalsifikasyonlara neden olabilmektedir. Niteliklerini ve potansiyel sađlık risklerini belirlemek için, belirli modellere veya özelliklere bađlı olarak kalsifikasyonların ek görüntüleme incelemeleri veya biyopsilerle daha fazla deđerlendirilmesi gerekebilmektedir. Őekil 2.2’de, mamografi görüntülerinde meme kalsifikasyon görünümü gösterilmektedir [16].



Őekil 2.2. Mammogram görüntülerinde kalsifikasyonların görünümü [17].

Meme kireçlenmelerinin iki farklı çeşidi vardır ve mamografide farklı görünümlere sahiptir.

- Makrokalsifikasyonlar: En yaygın kireçlenme türüdür. Göğüsün her yerinde büyük ve düzensiz dağılmış beyaz noktalar olarak görünmektedir. Genellikle iyi huylu olduğundan, daha fazla görüntüleme gerektirmemektedir [16].
- Mikrokalsifikasyonlar: Görünümü küçük beyaz noktalardır. Noktalar bir çizgi halinde, gruplar halinde veya rastgele dağılmış olarak görünebilmektedir. Genellikle iyi huyludur, ancak kanser belirtisi gösterme olasılıkları makrokalsifikasyonlara göre daha yüksektir. Kanser veya kanser öncesi hücreleri kontrol etmek için, doktorlar bir hastanın mamogramında bu tür kalsifikasyonları fark ederse ek testler önerebilmektedir [18].

2.2.3. Yapısal Distorsiyon

Meme Görüntüleme Raporlama ve Veri Sistemi (Breast Imaging Reporting and Data System (BI-RADS)), mimari distorsiyonu "tanımlanabilir bir kitlenin görünmediği ve memenin normal mimarisinin bozulduğu" bir görünüm olarak tanımlamaktadır. Bu, parankim sınırında fokal retraksiyon veya distorsiyonun yanı sıra bir noktadan yayılan spikülasyonları da içermektedir [19].

Yapısal distorsiyon, tarama mamografisinde bulunan anormalliklerin yaklaşık %6'sını oluşturur ve elle tutulamayan meme kanserinin üçüncü en yaygın mamografik görünümüdür. Yapısal distorsiyon mamografide kalsifikasyon veya görünür kitleden daha az yaygındır, ancak mütevazı ve çeşitli ifadesi nedeniyle tanımlanması da daha zordur. Ayrıca, mimari distorsiyon meme kanserinin ilk belirtisi olabilmektedir [20].

Yapısal distorsiyon, çeşitli nedenlere bağlı olarak ortaya çıkabilir ve bu nedenler hem iyi huylu (benign) hem de kötü huylu (malign) faktörlerden kaynaklanabilmektedir. Çizelge 2.1'de, bu anormalliklere neden olabilen faktörler ve taramalarda tespit edilen görünümler açıklanmaktadır [20].

Çizelge 2.1. İyi huylu ve kötü huylu yapısal distorsiyon [20].

Teşhis	Nedenler	Görüntüleme Bulguları
İyi Huylu	Radyal skarlar ve kompleks sklerozan lezyonlar	Fokal yapısal distorsiyon, radyolüsent merkezi çekirdek, spiküle
	Sklerozan adenozis	Mikrokalsifikasyonlar, kitle, fokal mimari distorsiyon
	Yağ nekrozu	Cilt kalınlaşması ve retraksiyonlarla birlikte spiküle lezyonlar
	Prosedür sonrası değişiklik	Mamoplasti sonrası fokal yapısal distorsiyonlu, girdaplı parankimal skar
	Nadir spiküle benign lezyonlar	Kalsifikasyon içermeyen spiküle kitleler
Kötü Huylu	Kanser	Merkezi bir kütleden yayılan spiküller
	DCIS	Fokal mimari distorsiyonlu mikrokalsifikasyonlar

2.2.4. Diğer Anormallikler

Bu kısımda, meme asimetrisi, meme ucu ve deri değişikliklere bağlı anormalliklerinin belirtiler ve nedenlerine genel bir bakış sunulmuştur.

- Meme asimetrisi: Normal kadın memeleri doğal bir asimetriye sahiptir; yine de idiyopatik, hormonal veya embriyolojik nedenler fark edilebilir bir asimetri yaratabilmektedir. Meme asimetrisi, çeşitli edinilmiş hastalıklar veya büyüme anormallikleri nedeniyle ortaya çıkabilmektedir. Bu sorunların hepsi doğumda belirgin olmadığından, bu asimetriyi doğuştan ziyade büyüme ve gelişmedeki anormallikler olarak tanımlamak teorik olarak daha doğrudur. Bu anormallikler, yapı eksikliği, yapı fazlalığı, boyut varyasyonları ve şekil varyasyonları içermektedir [21].
- Meme ucu değişiklikleri: Bunlar arasında akıntı (renkli veya kanlı, kendiliğinden veya dışarıya doğru), inversiyon (içe doğru çekilme) ve kalınlık, pullanma veya kızarıklık gibi cilt değişiklikleri yer almaktadır. Bunlar hormonlardaki değişiklikler (emzirme, hamilelik), iyi huylu durumlar (fibroadenomlar, kistler), cilt sorunları (tahrişler, enfeksiyonlar) veya Paget hastalığı adı verilen meme kanserinin nadir formlarından kaynaklanabilmektedir. Fiziksel muayene, altta yatan dokuyu değerlendirmek için mamografi ve ultrason, herhangi bir akıntının mikroskopik analizi ve potansiyel olarak bir cilt veya meme başı biyopsisi değerlendirme sürecinin bir parçasıdır [22].
- Deri değişiklikleri: Meme derisindeki değişiklikler döküntü, kalınlaşma, çukurlaşma, pullanma, soyulma veya kızarıklık şeklinde görülmektedir. Bunlar mastit gibi enfeksiyonlardan, dermatit gibi yaygın cilt rahatsızlıklarından veya daha az yaygın olarak iltihaplı meme kanseri adı verilen ve cildi etkileyen agresif bir meme kanseri türünden kaynaklanabilir. Fiziksel muayene, altta yatan dokuyu değerlendirmek için mamografi ve ultrason ve muhtemelen kesin tanı için cilt biyopsisi, değerlendirme sürecinin bir parçasıdır [23].

2.3. MEME KANSERİ

Meme kanseri, meme hücrelerinin kontrolsüz bir şekilde çoğalmasından meydana gelen bir durumdur [24]. Meme kanseri, yumru veya kalınlığa ek olarak memenin görünümünde değişiklikler olarak ortaya çıkabilmektedir. Bu, içe dönük bir meme ucunu, meme ucundaki veya göğüslerdeki derinin soyulması veya pul pul dökülmesini ve göğüs yüzeyinin kırmızımsı çukurlu ve portakal kabuğu gibi görünmesini içermektedir. Bu hastalık erkeklerde de görülebilmese rağmen, kadınlarda çok daha sık görülmektedir [25].

Bir memenin üç temel bileşeni bağ dokusu, kanallar ve lobüllerdir. Lobüller, süt üreten bezlerdir. Kanallar, sütü meme ucuna taşıyan tüplerdir. Bu bileşenler, fibröz ve yağlı bağ dokusu tarafından çevrelenir ve bir arada tutulmaktadır. Meme kanseri, kanserin başladığı hücrelere göre bu bileşenlere bağlı olarak farklı sınıflara ayrılmaktadır [26].

Çoğu meme kanseri vakası lobüllerde veya kanallarda başlar. İnvaziv meme kanseri, tümörün vücudun diğer bölgelerine yayıldığı bir kanserdir ve vakaların yaklaşık %80'i oluşturmaktadır. Kan ve lenf damarları, meme kanserinin meme dışına çıkabilmesinin iki yoludur. Meme kanseri vücudun diğer bölgelerine yayıldığında metastaz yapmış olarak kabul edilmektedir [26].

2.3.1. Meme Kanserin Türleri

Meme kanseri dokusunun birçok farklı türü ve alt türü vardır. Bu farklılıkları anlamak sadece akademik açıdan faydalı değildir; aynı zamanda olumsuz etkileri en aza indirmek için tedavileri özelleştirmelerini sağladığı düşünülmektedir. Bu kısımda meme kanserin en yaygın türleri özetlenmiştir.

2.3.1.1. Non-invazive Meme Kanseri

Noninvaziv meme kanseri, başlangıçta bulunduğu lobül veya kanalların dışına yayılmadığı anlamına gelmektedir. Ancak, anormal hücreler lobül veya kanalların

dışındaki dokulara yayılmamış olsalar bile invaziv meme kanserine dönüşebilmektedir [27]. Non-invaziv meme kanserlerinin iki histolojik tipi vardır ve bunlar biyolojileri, klinik görünüşleri ve potansiyel tedavileri açısından büyük farklılıklar göstermektedir. Bunlar Duktal karsinoma in situ ve Lobüler karsinoma in situ. "In situ", "yerinde" kelimesinin anlamına gelmektedir.

- Duktal karsinoma in situ (Ductal Carcinoma In Situ (DCIS))

İnvaziv olmayan meme kanserinin en yaygın türüdür. Bu durum Ducts denilen süt kanalları içini döşeyen hücreler kontrolsüz bir şekilde çoğalmaya başladığında oluşmaktadır. DCIS, henüz kanal dışına yayılmamış olan bu aşama için kullanılan terimdir. Bu evre meme kanserinin ilk aşamasını temsil etmektedir. Kanser ancak bu kısmın çıkarılmasıyla tam olarak tedavi edilebilmektedir. Tümör tipik olarak DCIS evresindeyken hissedilemeyecek kadar küçüktür. Mamografi, bu evredeki kanseri tanımlamak için kullanılan birincil yöntemdir [28].

- Lobüler karsinoma in situ (Lobular Carcinoma In Situ (LCIS))

Memenin içindeki süt üreten bezler olan lobüller, LCIS bölgesidir. LCIS, kanser için kullanılan bir diğer terim olan "karsinoma" kelimesini taşımasına rağmen bir meme kanseri türü değildir. Öte yandan, LCIS ileride meme kanserine yakalanma olasılığını artırmaktadır. LCIS'in herhangi bir klinik veya mamografik semptom göstermediği göz önüne alındığında, genel popülasyondaki gerçek insidansı belirsizdir. Her zaman tesadüfi ve rastgele bir keşif olduğundan, bildirilen insidansı muhtemelen düşük tahmin edilmektedir ve biyopsilerin ne sıklıkla yapıldığına bağlıdır [29].

2.3.1.2. İnvaziv Meme Kanseri

Daha önce süt kanalları veya lobülleri içinde bulunan anormal hücrelerin ayrılması ve meme dokusuna yakın başka dokulara taşınmasıyla gelişmektedir [30]. Kanser hücreleri memeden çıkarak dolaşım veya bağışıklık sistemleri yoluyla diğer vücut bölgelerine yayılabilmektedir. Tümör gelişiminin erken dönemlerinde henüz

küçükken veya daha sonra önemli ölçüde büyüdüğünde hareket edebilmektedir [31]. Kadınlarda en sık görülen genel karsinom türü invaziv meme kanseridir. Beyin, kemikler, akciğerler ve karaciğer bu hücrelerin memeden en sık yayıldığı organlardır. Bu hücreler bölünür, düzensiz bir şekilde çoğalır ve bir kez daha yeni tümörler oluşturmaktadır. Yeni oluşan hücreler vücudun diğer bölgelerinde büyüyor olsa da, meme kanseri hala varlığını sürdürmektedir [32].

- İnvaziv lobüler karsinom (Invasive Lobular Carcinoma (ILC))

ILC olarak da bilinen kanserdir. Memedeki süt bezleri veya lobüller, genellikle vücudun diğer bölgelerine yayılan ILC'nin bölgesidir. Meme kanseri vakalarının %8-14'ünden sorumlu olan bu kanser, kendine özgü biyoloji ve büyüme şekillerine sahiptir [33].

- İnvaziv duktal karsinom (Invasive Ductal Carcinoma (IDC))

IDC aynı zamanda İnfiltratif duktal karsinom olarak da tanınmaktadır. IDC tüm invaziv tümörlerin yaklaşık %85'ini oluşturan en yaygın meme kanseri türüdür [34]. Memenin süt kanallarında başlayan ve bitişik dokuya yayılan bu kanser türü, zaman içinde kan dolaşımı veya lenf düğümleri yoluyla vücudun farklı bölgelerine yayılma (metastaz yapma) potansiyeline sahiptir [35].

- Medüller karsinom

Genellikle, bu tür kanser neredeyse küresel, düzgün sınırlara sahip bir tümör halinde görülmektedir. Histolojik olarak, az farklılaşmış epitel hücreleri ve lenfositlerin heterojen bir kombinasyonundan oluşmaktadır [36].

- Tübüler karsinom

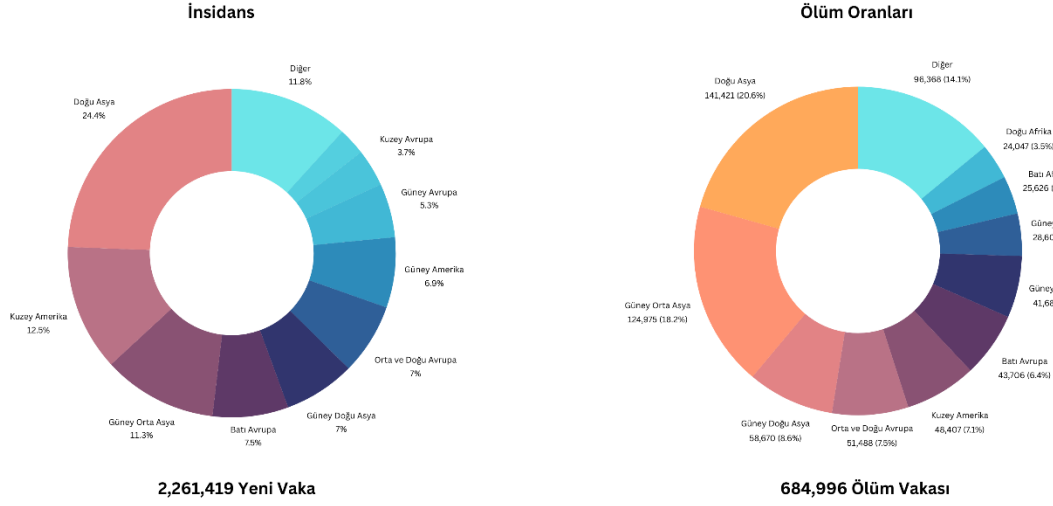
Tübüler veya iyi farklılaşmış meme adenokarsinomu yaygın değildir ve tüm meme kanseri vakalarının %1 ila %2'sini temsil etmektedir [37].

- İnflamatuvar Meme Kanseri (Inflammatory Breast Cancer (IBC))

Meme kanseri vakalarının %2.5'inde görülen IBC, invaziv meme kanserinin nadir görülen ve çok agresif varyantıdır. Kızarıklık, vücut ısısında artış ve meme dokusunda kalınlaşma şeklinde ortaya çıkmaktadır. Isınmış, kırmızımsı görünüm bir enfeksiyonun sonucu değildir; daha ziyade kanser hücrelerinin meme derisinin lenfatik kanallarına yayılmasının sonucudur [38]. Özellikleri arasında daha genç bir başlangıç yaşı, hızlı ilerleme, lokal ve uzak metastazlar ve diğer meme kanseri türlerine kıyasla daha kötü bir genel yaşam oranına sahip olmasıdır [39].

2.3.2. Dünyada Meme Kanseri İstatistikleri

2020 itibariyle meme kanseri, küresel çapta en yaygın kanser olarak akciğer kanserini geride bırakmıştır. O yıl dünya çapında yaklaşık 2.3 milyon kadın meme kanseri teşhisi konuldu ve bunların 685000'i hastalık nedeniyle hayatını kaybetmiştir (Şekil 2.3) [40]. Dünya genelinde 184 gelişmiş ve gelişmekte olan ülkenin 140'ında kadınlarda teşhis edilen en yaygın kanserdir. 2012 yılında tüm yeni kanser vakalarının yaklaşık %12'si ve kadınlardaki tüm kanserlerin %25'i bu kanserden kaynaklanmıştır. Şu anda dünya genelinde kadınlarda görülen her dört kanserden biri meme kanseridir. Meme kanseri insidansı 2008'den bu yana global olarak %20'den fazla artmıştır ve ölüm oranında ise %14'lük bir artış olmuştur [41].



Şekil 2.3. 2020 yılına ait dünya üzerinde meme kanserine bağlı olum ve hasta sayıları [40].

Erkekler meme kanseri vakalarının yalnızca %0.5-1'ini oluşturduğundan, kadın cinsiyeti hastalık için en güçlü risk faktörüdür. Yaşlanma, obezite, aşırı alkol tüketimi, radyasyona maruz kalma, ailede meme kanseri öyküsü, üreme öyküsü (ilk hamilelik ve adet başlangıcı yaşı dahil), sigara kullanımını ve menopoz sonrası hormon tedavisi meme kanseri riskini artıran faktörlerdir. 40 yaş üstü kadınlar, tüm meme kanseri vakalarının yaklaşık yarısını oluşturmaktadır [42].

1930'lardan 1970'lere kadar cerrahinin tek başına ana tedavi şekli olduğu dönemde, meme kanseri ölüm oranında (radikal mastektomi) çok az düşüş kaydedilmiştir. Ülkeler, etkili farmasötik ilaçları içeren kapsamlı tedavi planlarına bağlı olarak meme kanseri için erken teşhis programları uyguladıkça, hayatta kalma oranları 1990'larda yükselmeye başlamıştır [42].

2020 yılında Dünya Sağlık Örgütü'nün (World Health Organization (WHO)) raporlarına göre, yaklaşık 24000 meme kanseri teşhisi konulan hastalardan 7000'i yaşamını yitirmiştir. Bu durum, ölüm nedenleri arasında akciğer, mide ve pankreas kanseri türlerinin ardından dördüncü sırada yer aldığını göstermektedir [43].

2.3.3. Türkiye’de Meme Kanseri İstatistikleri

Türkiye’de meme kanseri görülme sıklığı son yıllarda artış göstermiştir. Sosyal, kültürel, eğitimsel ve ekonomik nedenlerden dolayı, meme kanserinin ortaya çıkışı, tanı aşaması ve tedavi süreci Türkiye genelinde farklılık göstermektedir. Türkiye’nin batısında meme kanseri daha erken tanı konulmakta ve insidans oranı daha yüksek olmaktadır. Erken menarş, geç menopoz, 30 yaşından sonra ilk doğum, emzirmenin azalması vb. nedenlerden dolayı, Türkiye’nin batı kesiminde (50/100000) meme kanseri insidansı, Türkiye’nin doğu kesiminin (20/100000) iki katından fazladır [44].

Meme kanseri, 2018 yılı Türkiye Sağlık Bakanlığı raporlarına göre, her iki cinsiyet ve tüm yaş grupları için akciğer kanserinden sonra ikinci sırada yer almaktadır. Kadınlarda ise, en sık görülen kanser türü olarak %26 oranında birinci sıradadır. Türkiye’deki kadınlarda meme kanseri genellikle 24 yaş ve üzerinde görülmeye başlamakta olup, en yüksek vaka dağılımı ise 25-49 yaş aralığında gerçekleşmektedir. Meme kanseri evreleri incelendiğinde, vakaların %48.2’sinin lokalize evrede tanı aldığı gözlemlenmektedir [45].

Türkiye ve diğer gelişmekte olan ülkelerde, genç/yaşlı nüfus oranı daha yüksek olup, nüfus genellikle daha gençtir. Türkiye İstatistik Kurumu (TÜİK) verilerine göre Türkiye’deki kadın nüfusunun %68’i 40 yaşın altındadır. ABD’de 40 yaş altı kadınlar nüfusun yalnızca %45’ini oluşturmaktadır. Bu farklılık, genç yaş grubunda göreceli bir nüfus fazlalığına ve bu yaş grubunda meme kanserinde göreceli bir artışa işaret etmektedir [46].

BÖLÜM 3

MEME KANSERİ GÖRÜNTÜLEME YÖNTEMLERİ

Meme kanserinin erken teşhisi tedaviyi daha kolay ve başarılı hale getirmektedir. Görüntüleme, meme kanserini incelemek ve tanımlamak için kullanılan ana yöntemdir. Hayatta kalma oranlarının iyileştirilmesi için kanserin erken teşhis edilmesi ve doğru ve kesin tanı konulması gerekmektedir. Görüntüleme teknolojilerindeki gelişmeler, meme kanserini teşhis etme becerisinde sürekli bir iyileşmeye yol açmaktadır. Hastalığın erken teşhisi hedefine ulaşmak için çok sayıda görüntüleme yöntemi sürekli olarak geliştirilmektedir. Bu yöntemlerin bir kısmı teşhis amacıyla, bir kısmı tarama amacıyla ve bir kısmı da uzmanlara ilk kararlarında daha fazla güvence sağlamak için yardımcı değerlendirme olarak kullanılmaktadır [47]. Bu bölümde meme kanseri tespiti için en yaygın kullanılan tıbbi görüntüleme yöntemlerine genel bir bakış sunulmaktadır.

3.1. MAMOGRAFİ

Meme görüntüleme alanında en yaygın kullanılan teknik, mamografidir. Bu yöntem, düşük doz genlikli X ışınları kullanarak insan memelerini incelemektedir. Mamografi, kalsiyum birikintileri ve kanserli tümörlerin daha parlak alanlar olarak görünmesini sağlamaktadır. 5-7 yıl süren takip çalışmaları, mamografi taramasının, kontrol grubuna kıyasla taranan kadınlarda ölüm oranlarında %25 ila %30 oranında bir azalmaya katkıda bulunduğunu göstermiştir [48]. Randomize kontrollü çalışmalardan elde edilen kanıtlar, mamografi taramasının meme kanserinin erken teşhisi ve tedavisi ile hastalıktan ölüm oranını önemli ölçüde düşürdüğünü desteklemektedir [49]. Yaş, aile öyküsü, enfeksiyon evresi ve meme yoğunluğu gibi değişkenler, mamografi görüntüleme hassasiyeti üzerinde etkili olabilmektedir [50].

Dijital mamografi, röntgen filminin yerine elektronik kullanarak röntgen ışınlarını bir kadının göğsünün görüntüsüne dönüştürmektedir. Bir başka tanımı da Tam Alan Dijital Mamografidir (Full-Field Digital Mammography (FFDM)). Bu teknoloji dijital kameraya benzer şekilde çalışır ve düşük ışık koşullarında bile iyi bir görüntü sağlayabilmektedir [51].

Mamografi taraması, DCIS olarak bilinen durumuyla ilişkilendirilen, kadının süt kanallarındaki mikroskopik anormal dokuların hassas tespitini sağlama avantajına sahiptir. Erken evre tümörlerin vücuttan çıkarılabilirliği, hastanın sağkalımını önemli ölçüde artırabilmektedir. Bu yöntem aynı zamanda lobüller ve invaziv duktal kanser dahil olmak üzere çeşitli meme kanseri türlerinin tanılanmasında etkin bir araçtır [52]. Ayrıca, röntgen filmleri kullanılsa bile, mamografi uygulandıktan sonra hastanın vücudu herhangi bir radyasyon retansiyonu göstermez. Bu nedenle, mamografi tabanlı tarama ve teşhis yöntemleri, tedavi sonrasında olumsuz etkilerin minimal olduğu güvenilir bir yol sunmaktadır [53].

50 yaşın altında, fibrokistik veya yoğun meme dokusuna sahip olan kadınlara mamografi çekilmek en iyi seçenek olmayabilir. Yoğun meme dokusu ve kanserli tümörler mamografilerde benzer özellikler gösterir ve bu da iki kitle arasında ayırım yapmayı zorlaştırmaktadır [53]. Kadınlarda meme yoğunluğu arttığında mamografinin anormallikleri tespit etme kapasitesi azalmaktadır. Amerikan Kanser Derneği, meme dokusu yoğunluğunu dört grupta sınıflandırmıştır. Derece 1 en düşük yoğunluğa sahip meme dokusunu belirtirken, derece 4 en yoğun meme dokusunu belirtmektedir. Bulgular, mamografi ile tespit oranlarının 4. derece için %55, 3. derece için %68 ve 2. derece için %83 olduğunu göstermiştir [54].

Mamografide güncel bir gelişme olan kontrastlı dijital mamografi (Contrast-Enhanced Digital Mammography (CEDM)), mamografi incelemesini intravenöz iyotlu kontrast madde enjeksiyonu ile birleştirmektedir [55]. Meme kanserinin tanımlanmasını kolaylaştırmak için kontrast geliştirmeyi kullanır ve mamografinin düşük maliyeti ve kullanım kolaylığının avantajlarını tümör anjiyogenezi ile birleştirmektedir [56]. Her iki memenin CEDM'si için yaklaşık on dakika gereklidir.

Bu süre, tanısal MRI'den daha azdır ve kısaltılmış bir MRI protokolünün süresiyle karşılaştırılabilmektedir [57].

Tarama amaçlı dijital mamografide her meme genellikle iki ayrı perspektif kullanılarak taranır: Kranial Kaudal (Cranio-Caudal (CC)) görünüm ve Mediolateral Oblik (Medio-Lateral Oblique (MLO)) görünüm. CC görünümü memenin üstünden alınırken, MLO görünümü göğsün ortasından dışa doğru elde edilmektedir. MLO görünümü, istatistiksel olarak patolojik değişiklikler için en olası yer olan memenin lateral tarafının en iyi görünümünü sağlarken, CC görünümü tüm memeyi göstermektedir [58].

3.2. ULTRASON

Ultrason görüntüleme, meme kanseri taraması için kullanılan bir başka tekniktir. Genellikle, düşük dozda frekanslarla memenin görüntülerini oluştururken, çok düşük kontrastlı bir görüntü sağlamaktadır. Bu nedenle, ultrason görüntüleri genellikle düşük çözünürlüklü, monokrom görüntülerdir [59].

Düzensiz şekiller, kesin olmayan ve bulanık kenarlar gösteren kanserli bölgelerin tanımlanması, çoğunlukla ultrason görüntülemeye bağlıdır. Özellikle iri göğüslü kadınlarda anormalliklerin incelenmesi söz konusu olduğunda, ultrasonografi katı kitleler ve kistler arasında mamografiden daha doğru bir ayırım yapabildiği için çok kullanışlıdır [60]. Bununla birlikte, ultrasonografi görüntülerinde benek (Speckle) gürültüsünün doğal olarak var olması, genel kalitelerinin düşmesine neden olabilmektedir [59].

Ayrıca, uygun fiyatlı olması, invaziv olmaması, yoğun memeleri incelemekte olan üstünlüğü, kullanım kolaylığı ve meme kitle düğümlerini tespit etme kapasitesi nedeniyle ultrasonografi, tarama mamografisini desteklemek için tercih edilen bir seçenektir [61].

3.3. MANYETİK REZONANS GÖRÜNTÜLEME (MAGNETIC RESONANCE IMAGING (MRI))

Hidrojen çekirdeği ya da singletonlar genellikle yağ ve suda bulunur ve MRI'da kullanılmaktadır. Hidrojen çekirdeğinin manyetik özelliği kullanılarak vücudun herhangi bir kısmı ayrıntılı olarak görüntülenebilmektedir [62]. Meme lezyonlarının boyutu, şekli ve konumu, üç boyutlu rekonstrüksiyonu desteklediği için MRI tarafından iyi bir şekilde görüntülenmektedir [63]. MRI tarafından üretilen üç boyutlu rekonstrüksiyonların kullanılmasıyla tıp uzmanları, tümörün çevresindeki yapılarla nasıl etkileşime girdiğini daha detaylı inceleyebilmektedir. MRI'ler, mamogramlar ve bilgisayarlı tomografi taramaları gibi iyonlaştırıcı radyasyon kullanmadığından, özellikle radyasyona bağlı kanser riski daha yüksek olan kadınlar için daha güvenli bir seçenektir [64].

İyi görüntü çözünürlüğü, yoğun memeleri değerlendirme yeteneği, ters meme uçlarını değerlendirme yeteneği, her iki memeyi aynı anda değerlendirme yeteneği, lumpektomi veya mastektominin en iyi tedavi yöntemi olup olmadığını değerlendirme yeteneği ile MRI, meme kanseri gelişme olasılığı daha yüksek olan kadınlar için yararlıdır. Bu yöntemin dezavantajları arasında, DCIS için düşük tanısal performansı, yüksek yanlış pozitif oranı, yavaşlığı (30 dakika ila 1 saat), yüksek maliyeti ve kalsifikasyonları gözden kaçırma potansiyeli sayılabilmektedir [64].

3.4. TERMOGRAFİ

Kanser öncesi ve kanserli dokulardaki daha yüksek metabolik oranlar, hızla çoğalan kanser hücrelerine besin sağlayan yeni kan damarlarının oluşmasına neden olmaktadır. Bu nedenle, kanser öncesi ve kanserli meme dokusunun çevresindeki doku, normal meme dokusunun çevresindeki dokudan daha yüksek bir sıcaklığa sahiptir [65]. Araştırmalar, meme derisi sıcaklığı ile meme kanseri arasındaki bağlantıyı incelemiş ve klinik olarak sağlıklı ve kötü huylu memeler arasında deri sıcaklığında tespit edilebilir farklılıklar olduğunu bulmuştur [66].

Termal Görüntüleme olarak da bilinen meme termografisi, meme kanserini teşhis etmek için kullanılan ek bir görüntüleme yöntemidir. Meme dokusundaki anormal sıcaklık değişimlerini tespit etmek için bir termal kızılötesi kamera kullanır ve daha sonra bu sinyalleri termogram olarak görüntülenen elektrik sinyallerine dönüştürmektedir [67]. Meme termografisi, diğer meme kanseri görüntüleme yöntemlerinin aksine, non-invaziv, ağrısız, temassız ve hem hasta hem de termografi uzmanı için güvenli olduğundan yıllık kontrollerde kullanılmaktadır [68]. Ancak, düşük hassasiyet, yüksek yanlış tanı oranları [69] ve oda sıcaklığına yüksek duyarlılık gibi dezavantajları bulunmaktadır [70].

3.5. SİNTİMAMOGRAFİ (SM)


Radyasyon algılayıcı bir kamera (γ -kamera) kullanılarak, Sintimamografi (Scintimammography (SM)) adı verilen işlevsel bir görüntüleme prosedürü sırasında hastanın memelerindeki radyoaktif izleyiciler tespit edilmektedir. Bugüne kadar en yaygın olarak kullanılan izleyiciler teknesyum sestamibi (Tc-99 sestamibi) ve teknesyum tetrafosmin (Tc-99 tetrafosmin)'dir. İzleyicilerin tümörlerde sağlıklı dokuya göre daha fazla birikmesi amaçlanmıştır [71]. Yoğun göğüslü kadınlara tanı koyarken Tc-99 tetrafosmin SM daha fazla hassasiyet sunmaktadır. İmplantlı memeleri görüntülemek, önemli ve hissedilebilir anormallikleri görüntülemek, yoğun memeleri görüntülemek ve şüphe duyulduğunda çok sayıda tümörü görüntülemek için kullanılabilir [71].

Multifokal meme kanserinin analizi, aksiller lenf nodlarının derecelendirilmesi ve mikrokalsifikasyonların incelenmesi gibi klinik amaçlar için SM yararlı bir tekniktir. Ancak salınan fotonların yalnızca küçük bir kısmını kullanan mekanik kolimatör, görüntülerin kalitesini sınırlayan kısıtlamalara sahiptir [72].

3.6. HİSTOPATOLOJİ

Histopatoloji, tümörleri tanımlamak amacıyla, kanserin gelişimini, genetik ilerlemesini ve hücrelerin morfolojisini araştırmak için hastadan alınan ve mikroskopik lamlara bölünen bir biyopsi örneğinin mikroskopik analizidir [73].

Meme Kanseri de dahil olmak üzere neredeyse tüm kanserleri tanımlamak için, histopatolojiden alınan bir görüntüye dayanan bir tanıdır [74]. Ancak, bu görüntülerin incelenmesini zaman alıcı, patologların deneyimine bağlı, yorgunluk ve dikkat eksikliği gibi şeylerden etkilenen bir görevdir. Bu nedenle, doğru ve otomatik histopatolojik görüntü analiz tekniklerinin geliştirilmesi alan için çok önemlidir [75]. Şekil 3.1, bu bölümde bahsedilen görüntüleme yöntemlerini göstermektedir [76–81].



Şekil 3.1. Meme kanseri görüntüleme yöntemleri: a) Mamografi, b) Ultrason, c) MRI, d) Termografi, e) SM, f) Histopatoloji [76–81]

BÖLÜM 4

AÇIK ERİŞİMLİ MAMOGRAFİ VERİ SETLERİ

Mamografi taramasının birçok avantajı arasında, meme kanseri ölüm oranında %15 ila %30 arasında değişen oranda azalma sağlaması yer almaktadır [82–84]. Ayrıca, mamografi taraması yağlı dokulara duyarlı olduğu için, hastalığın erken evrede teşhis ve tedavi edilmesine olanak tanımaktadır. Bu da, daha az mastektomi ve daha az şiddetli tedavi metotları ile ilişkilendirilmektedir [85]. Yukarıda sıralanan nedenlerden dolayı, mamografi meme kanserinin erken teşhisinde kullanılan ana görüntüleme yöntemidir ve bu tezde mamografi görüntüleri kullanılmıştır. Bununla birlikte, meme kanseriyle ilgili mamografi veri setlerinin büyük çoğunluğu açık erişime sahip değildir. En çok kullanılan ve kolay erişilebilen mamografi veri setleri aşağıda sunulmuştur.

4.1. MAMMOGRAPHIC IMAGE ANALYSIS SOCIETY (MIAS)

Mamografik Görüntü Analizi Derneği (Mammographic Image Analysis Society (MIAS)) veri setinde [86], 322 dijitalleştirilmiş görüntü vardır; 207'si iyi huylu ve 115'i kötü huyludur. Bu veri setinde anormalliğin derecesi (iyi huylu/kötü huylu), arka plan doku tipi (yoğun/yağlı) ve meme anomalisi (kitleler, asimetri) için ek açıklamalar bulunmaktadır. Lezyonlu mamogramlarda x ve y koordinatları belirlenmiştir. İnternette açık kaynaklı olması nedeniyle bu veri seti yaygın olarak kullanılmaktadır. Bununla birlikte, küçük boyut, düşük çözünürlüklü görüntüler ve yalnızca MLO görünümü içermesi gibi dezavantajları vardır.

4.2. DIGITAL DATABASE FOR SCREENING MAMMOGRAPHY (DDSM)

Araştırmacıların hastalık teşhisi için sıklıkla kullandığı bir diğer mamografi veri seti de Tarama Mamografisi için Dijital Veri Seti (Digital Database for Screening

Mammography (DDSM)) [87]. Sol ve sağ memenin iki farklı bakış açısından CC ve MLO çekilmiş iki mamogramı olan 2620 vakadan oluşmaktadır. Her vakadan, kesin referanslarla birlikte, hastanın yaşı, taramanın tarihi, uzman bir radyolog tarafından belirtilen Amerikan Radyoloji Koleji raporlama sistemi (American College of Radiology Reporting and Data System (ACR)) meme yoğunluğu gibi ek verilerle eşleştirilmiş dört mamogram alınmıştır. Sonuç olarak, bu veri seti 10480 mamografi içermektedir. Bu veri seti, 695 normal, 1784 kanser ve 141 iyi huylu vakayı içermektedir. Bu durum, sınıf dağılımının dengesiz olduğu bir dezavantajı temsil etmektedir. Ayrıca, bu veri setindeki görüntülerin çoğunluğu dijitalleştirilmiş film-ekran mamogramlarıdır ve bu da FFDM ve üç boyutlu mamografi gibi en yeni görüntüleme yöntemlerinin oldukça gerisindedir.

DDSM'nin Küratörlü Meme Görüntüleme Alt Seti (Curated Breast Imaging Subset of DDSM (CBIS-DDSM)), dikkatlice etiketlenmiş ve açıklama eklenmiş görüntülerden oluşan bir alt kümedir [88]. CBIS-DDSM, kullanım kolaylığı için düzenlenmiş 3103 mamografi görüntüsü ile DDSM'nin filtrelenmiş ve güncellenmiş bir versiyonudur.

4.3. BREAST CANCER DIGITAL REPOSITORY (BCDR)

Meme Kanseri Dijital Veri Seti (Breast Cancer Digital Repository (BCDR)), Portekiz'in kuzey kesiminde meme kanseri olan hastaların örneklerinden oluşan, internette açık kaynaklı ve kapsamlı bir veri tabanıdır[89]. Toplam 1734 BIRADS sınıflandırılmalı vaka BCDR veri setini oluşturmaktadır. Bu vakalar iki farklı bölüme ayrılmıştır: dijital mamografi ve film mamografi tabanlı bölümler. Film mamografi tabanlı bölüm, 1010 hasta vakasından (998 kadın ve 12 erkek, 20-90 yaş arası) 3703 CC ve MLO mamografi vakasından oluşmaktadır. Yaşları 27 ile 92 arasında değişen 724 hasta vakasından (723 kadın ve 1 erkek) alınan 3612 MLO ve/veya CC mamografi dijital tabanlı depoyu oluşturmaktadır.

4.4. THE OPTIMAM MAMMOGRAPHY DATABASE (OMI-DB)

OPTIMAM Mamografi Görüntü Veritabanı, Birleşik Krallık'taki meme tarama tesislerinden elde edilen mamografi görüntülerini içeren paylaşılabılır bir kaynaktır [90]. Bu veri seti, hem işlenmiş hem de işlenmemiş mamogramları, şüpheli bulgular içermeyen görüntüleri, malignitelerle ilgili klinik bilgileri ve ek açıklamaları içermektedir. OMI-DB veri seti, boyutunun her yıl büyümesi nedeniyle diğer veri tabanlarından farklıdır. Şu anda 179326 hastaya ait bilgi bulunmaktadır. Veri setinde çok az sayıda genç kadın yer almaktadır çünkü Birleşik Krallık'ta tarama 50 ila 70 yaş arasındaki kadınlara yapılan davetlere dayanmaktadır.

4.5. BANCOWEB LAPIMO

Brezilya'daki birden fazla hastaneden alınan anonimleştirilmiş mamografi görüntüleri ve ilgili klinik veriler BancoWeb LAPIMO mamografi veri setini oluşturmaktadır [91]. 2020 itibariyle, 320 hastaya ait yaklaşık 1473 dijital mamografi görüntüleri içermektedir. Görüntüler magnifikasyon görünümüleri, MLO ve CC görünümünden oluşmaktadır. Magnifikasyon görüntüleri MLO ve CC pozisyonlardan elde edilen görüntülerin belirli alanlarını büyüterek veya yakınlıştırarak detayları daha iyi görebilmek için kullanılmaktadır. Görüntüler üç kategoriye ayrılmıştır: iyi huylu, kötü huylu ve normal. Tarama geçmişi, biyopsi sonuçları ve hasta demografisi dahil olmak üzere ek klinik veriler de bulunmaktadır. CAD sistemi geliştirme ve performans değerlendirme üzerine çok sayıda araştırmada kullanılmış olmasına rağmen, diğer büyük ölçekli veri kümelerine kıyasla küçük boyutu ve kısıtlı erişimi gibi dezavantajlara sahiptir.

4.6. THE VICTRE TRIAL

Bu veri seti, sanal hastalar kullanılarak bilgisayar tarafından oluşturulan mamografi görüntüleri ve simüle edilmiş meme modellerinden oluşturulan 2986 sentetik görüntüden oluşmaktadır [92]. Yapay zeka eğitimi için faydalı olsa da, VICTRE'nin sentetik görüntüleri gerçek dünya mamografisinin inceliklerini tam olarak temsil etmeyebilir, bu nedenle gerçek hasta verisi doğrulaması gereklidir.

BÖLÜM 5

YAPAY ZEKA (ARTIFICIAL INTELLIGENCE (AI))

Dünyanın birçok yönünü deęiřtirme potansiyeline sahip olan AI, dikkate deęer bir teknolojik geliřmedir. Bu bölümde, tanımı ve tarihsel geliřimi ile bařlayıp birçok uygulamasının incelenmesine geęerek AI temel fikirlerini arařtırılmaktadır. Daha sonra, AI sistemlerinin gücünü ve karmařıklıęını büyük ölçüde artıran ML, DL ve yapay sinir aęları (Artificial Neural Networks (ANN)) olan AI'nın önemli alt alanlarından bahsedilecektir. Bu bölümde, AI'nın geliřimi ve özellikle saęlık alanları üzerindeki artan etkisi hakkında bir anlayıř saęlamayı amalanmaktadır.

5.1. YAPAY ZEKA TANIMI

AI terimi, akıllı davranıřlar sergileyebilen herhangi bir makine veya sistemi tanımlamak için kullanılmaktadır. Genellikle insan zekasına baęlı olan öęrenme, yaratıcılık ve görüntü tanıma gibi biliřsel sorunlara çözümler bulmaya odaklanan bir bilgisayar bilim dalıdır. Bilgisayarlara çok büyük miktarlarda veri ve bilgi aktarılabilir ve böylece bilgisayarlar bu verilerdeki örüntüleri bulmak üzere eęitilebilmektedir. Verilerden anlamlı sonuçlar çıkaran kendi kendine öęrenen sistemlerin oluřturulması AI'nın amacıdır. AI, daha sonra bu bilgiyi yeni sorunları insan zekasına benzer bir řekilde ele almak için kullanabilmektedir.

5.1.1. AI Tarihesi

Alan Turing, 1950 yılında yayınladıęı "Computing Machinery and Intelligence" (Hesaplama Makineleri ve Zeka) adlı arařtırma makalesinde makinelerin düřünebileceęi fikrini incelemiřtir. AI terimi ilk kez bu yayında kullanılmıř ve aynı zamanda AI'yı teorik ve felsefi bir fikir olarak tanıtmıřtır. Bilgisayar teknolojisi

1957 ve 1974 yılları arasında gelişerek bilgisayarların daha büyük miktarda veriyi daha hızlı depolamasını ve işlemlerini sağlamıştır. Savunma İleri Araştırma Projeleri Ajansı gibi ajanslar, bu sektördeki ilerlemelerin bir sonucu olarak AI araştırmaları için bir fon oluşturmuştur. İlk başlarda temel amaç, bilgisayarların konuşulan dili tercüme ve taklit edip edemeyeceğini bulmak olmuştur [93].

1980'lerde artan finansman ve daha gelişmiş bilgisayar araçları nedeniyle gelişim hız kazanmıştır. DL yaklaşımları üzerine araştırmalar David Rumelhart ve John Hopfield tarafından yayınlanmış ve bilgisayarların deneyimlerden öğrenebileceği kanıtlanmıştır. Bilim insanları 1990'larda ve 2000'lerin başında dünya satranç şampiyonunu yenmek de dahil olmak üzere önemli AI hedeflerine ulaşmışlardır. AI araştırmaları, artan bilgi işlem gücü ve veri kullanılabilirliği nedeniyle modern dönemde genişledi ve daha yaygın hale gelmiştir [93].

AI'nın tıpta kullanımı son 50 yılda önemli ölçüde ilerlemiştir. ML ve DL'nin geliştirilmesinden bu yana AI tıptaki kullanım alanları artmış ve önemli olanaklar ortaya çıkmıştır. AI, teşhis hassasiyetini artırma, sağlayıcılar için klinik iş akışını ve iş akışı verimliliğini optimize etme, daha etkili hastalık ve tedavi takibi sağlama, prosedür doğruluğunu artırma ve genel hasta sonuçlarını iyileştirme potansiyeline sahiptir [94].

5.1.2. Yapay Zeka Alt Alanları

Yıllar boyunca, AI temel bir "eğer, o zaman kuralları" setinden insan beynine benzer şekilde çalışan daha sofistike algoritmalara doğru evrimleşmiştir. AI, ML, DL, Doğal Dil İşleme (Natural Language Processing), Bilgisayarla Görü (Computer Vision), Öğrenme Kuramı (Theory of Learning), Robotik, Bilgi Temsili ve Akıl Yürütme (Knowledge Representation and Reasoning), Planlama ve Optimizasyon (Planning and Optimization), Bulanık Mantık (Fuzzy Logic), Uzman Sistemler (Expert Systems) ve Evrimsel Hesaplama (Evolutionary Computation) olmak üzere çeşitli alt alanları vardır [95,96].

5.1.3. Saęlıkta AI

Operasyonel verimlilięi ve bakım kalitesini artırmak için, özellikle gelişmiş ekonomilerdeki hastaneler ve saęlık hizmeti saęlayıcıları, AI, ML, büyük veri analitięi, akıllı sensörler ve robotlar gibi dijital teknolojileri yoğun bir şekilde kullanmaktadır [97]. Tıbbi kaynakların etkinliğini ve saęlanan bakımın kalitesini artırmak için saęlık hizmetleri ortamlarında son zamanlarda yaygın olarak kullanılan AI destekli teknolojilerden sadece bazıları ařaęıda yer almaktadır:

1. Tıbbi Kayıtların ve Tedavi Planlarının Çıkarılması:

AI, geniş tıbbi kayıt ve veri koleksiyonlarından, ilgili ve yararlı verilerin çıkarılması olan tıbbi kayıtların işleme sürecinde kullanılmaktadır. Bu, büyük veri setlerinin etkili bir şekilde incelenmesine olanak tanımaktadır. Büyük hacimli hasta verilerini analiz ederek, bireyselleştirilmiş tedavi stratejileri önerir ve tedavi programlarının oluşturulmasına yardımcı olmaktadır [98].

2. Robotik Aracılı Ameliyatlar:

AI, doğruluęu artırmak ve daha karmaşık cerrahi teknikleri mümkün kılmak için robotik aracılı ameliyatlarda kullanılmaktadır. Verilen örneklerden biri, bir cerrahın el hareketlerini doğru bir şekilde kopyalayan Da Vinci robotik cerrahi sistemidir [99].

3. Tıbbi Yönetim ve Hastane İşletmecilięi:

AI hastane işletmesine yardımcı olur ve tıbbi yönetimde önemli bir rol oynamaktadır. Saęlık tesislerinde zamanlama, kaynak tahsisi ve genel operasyonel etkinlik gibi konularda yardımcı olmaktadır [100].

4. Klinik Veri Yorumlama ve Ön Tanı:

AI, klinik verilerin yorumlanmasına yardımcı olarak tıp uzmanlarının önemli bulgular elde etmesine yardımcı olmaktadır. Tıbbi bilgilere dayalı hızlı deęerlendirmeler sunarak erken teşhise katkıda bulunmaktadır [101].

5. Görüntü Tabanlı Teşhis:

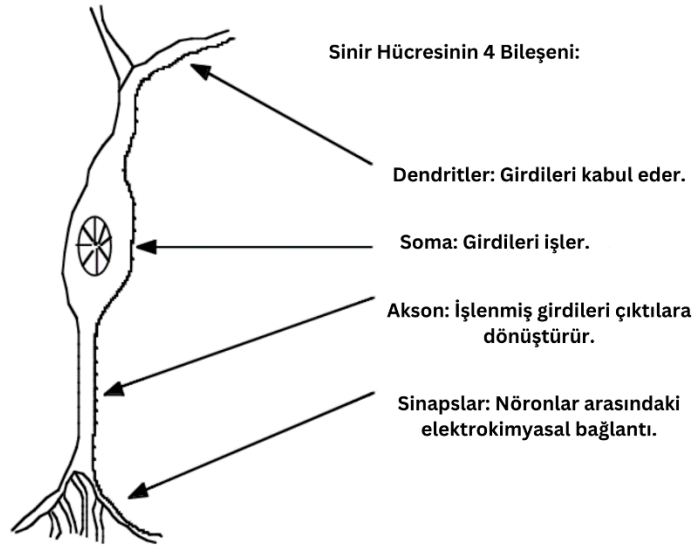
Radyolojik görüntüler ve patoloji slaytları gibi tıbbi görüntüler AI kullanılarak yorumlanabilmektedir. LYNA (lenf nodu biyopsilerinden alınan görüntüleri kullanarak meme kanserini tespit edebilen bir AI) gibi görüntü analiz sistemleri, meme kanseri gibi hastalıkların tespitinde umut verici sonuçlar göstermektedir [102].

6. Sanal Hemşirelik:

AI, sanal hemşirelik uygulamaları aracılığıyla sağlık hizmetlerinin sunumunu desteklemek ve yardımcı olmak için kullanılmaktadır. Sanal hemşirelik sistemleri iletişim ve hasta izleme özellikleri sağlamaktadır [103].


5.2. YAPAY SİNİR AĞLARI (ARTIFICIAL NEURAL NETWORKS (ANN))

ANN, verileri modellemek için kullanılan hesaplama algoritmalarıdır ve hem ML hem de DL alanında temel bileşenlerdir. "Yapay Sinir Ağı" terimi, insan beyninin yapısını oluşturan biyolojik sinir ağlarından türetilmiştir [104]. Bir nöron, beyin sinir ağının temel işlem birimi olduğu gibi, ANN'ler da verileri işleyen ve gönderen "perceptron" olarak da bilinen birkaç nörondan oluşur. Şekil. 5.1'de insan beynindeki nöron yapısını gösterilmiştir.



Şekil 5.1. İnsan beynindeki nöron yapısı.

İnsan nöronları söz konusu olduğunda, dendritler, aslında diğer nöronların çıktıları olan farklı güçlerdeki giriş sinyallerini almaktadır. Bu giriş sinyalleri daha sonra nöronun hücre gövdesinde depolanmaktadır. Biriken sinyal önceden belirlenmiş bir eşikten büyükse, bir çıkış sinyali üretilir ve akson tarafından- sinaps olarak bilinen bir bağlantı- diğer nöronlar için başka bir girdi olarak gönderilir ve süreç devam etmektedir. Doğal nöronların dört temel işlevi yapay nöronlar tarafından kopyalanmaktadır. Yapay bir nöron temel olarak Şekil 5.2’de gösterilmiştir.



Şekil 5.2. Doğal nöron ve yapay nöron [105].

Şekil 5.2’de ağa gelen çeşitli girdiler matematiksel sembol x ile gösterilmektedir. Girdiler, giriş katmanından veya diğer nöronların çıktısından alınmaktadır. Bu girdilerin her biri bir bağlantı ağırlığı ile çarpılmaktadır. Bu ağırlıklar w ile gösterilmektedir. Daha sonra, bu çarpımlar toplanır, bir sonuç üretmek için bir transfer fonksiyonundan geçirilir ve ardından çıktı alınmaktadır [106].

Her giriş sinyalinin (x_i) karşılık gelen bir ağırlığı (w_i) vardır. Giriş sinyalleri ya sonlandırılır ya da ilgili ağırlıklar tarafından güçlendirilmektedir. Net giriş sinyali nöron tarafından hesaplanmaktadır. Eşitlik 5.1’de gösterildiği gibi giriş sinyallerinin ağırlıklı toplamı net giriş sinyalidir [107].

$$Net = \sum_{i=1}^N x_i w_i \quad (5.1)$$

Net giriş sinyali daha sonra bir bias terimi (b) ile desteklenmektedir. Çıkış sinyalinin değeri de aynı şekilde bias değerinden etkilenmektedir. Elde edilen çıkış sinyali bir aktivasyon fonksiyonuna gönderilmektedir [107]. Doğrusal olmayan bir aktivasyon fonksiyonu ağırlıklı toplamı değiştirir. Eşitlik 5.2 işlemi açıklamaktadır:

$$output = a \left(\sum_{i=1}^N x_i \times w_i \right) + b \quad (5.2)$$

Bir sinir ağını eğitirken, verilerdeki örüntüleri tanımlamayı mümkün kılan ağırlıklar bulunmaya çalışılmaktadır. Prosedürde geriye yayılma (Backpropagation) ve gradyan iniş (Gradient Descent) teknikleri kullanılmaktadır. Model ağırlıklı tahminler sağlar ve tahminler daha sonra hataların hesaplanmasına uygulanmaktadır [107].

Ağ girişten çıkış yönüne doğru ilerlerken her seferinde hatayı veya üretilen çıktı ile beklenen gerçek referans değer arasındaki farkı hesaplamak için bir loss fonksiyonu (kayıp fonksiyonu) kullanılmaktadır. Geriye yayılma algoritması, bu hatanın ağırlık değişimlerine olan gradyanını belirler ve ağırlıkları buna göre güncellemektedir. Zincir kuralı ve kısmi türevler uygulanmaktadır. Gradyan iniş algoritması, sonraki değerlendirmede yanlışlığı azaltmak için ağırlık güncellemelerini sağlamaktadır [107].

5.3. MAKİNE ÖĞRENMESİ (MACHINE LEARNING (ML))

ML, insan öğrenmesini simüle etmek ve modelin doğruluğunu aşamalı olarak artırmak için veri ve algoritmaları kullanan bilgisayar bilimi ve AI'nın bir alt alanıdır. ML, bilgisayarların açık talimatlar yerine kalıplar ve çıkarımlar kullanarak belirli görevleri yerine getirmesini sağlayan istatistiksel modeller ve algoritmalar oluşturma yöntemidir. Verilerden öğrenebilen ve buna dayalı kararlar verebilen modeller oluşturmak ML'nin temel amacıdır. Bu modeller verilerdeki örüntüleri ve ilişkileri tanımlayabilse de, aşırı karmaşık görevleri yerine getiremeyebilir [108].

Belirli görevler için açık bir programlama olmadan, ML verilerden öğrenerek tahminler veya kararlar vermektedir. Uygun veri kalitesini sağlamak için süreç,

temizleme ve ön işlemeyi içeren veri toplama ve hazırlama ile başlamaktadır. Ardından, problem türüne (örneğin regresyon veya sınıflandırma) en iyi uyan model seçilir ve tahmin hatalarını azaltmak için parametreleri değiştirilerek hazırlanan veriler kullanılarak eğitilmektedir. Modelin performansını değerlendirmek için farklı bir test veri seti kullanılır ve hiper parametreler sonuçları optimize etmek için ayarlanmaktadır. Eğitim setine aşırı uyum sağlayan bir model, eğitim setinin özgün özelliklerini yakalamada aşırı uzmanlaşmış ve yeni, görülmemiş verilere iyi genelleme yapamayan bir modeldir. Bu nedenle, modelin genelleştirilebilir olması için görülmemiş test verileri kullanılmalıdır [108].

Algoritmalara aktarılan verilerin türüne göre, bu algoritmalar genellikle dört farklı şekilde öğrenilmektedir: gözetimli, gözetimsiz, yarı gözetimli veya pekiştirme yoluyla [109].

5.3.1. Gözetimli ML (Supervised ML)

Gözetimli ML ile modelin, incelenen veri setine benzer bir eğitim veri seti üzerinde eğitildiği varsayılmaktadır. Bu veri seti girdi verilerinden ve bunlara karşılık gelen çıktı verilerinden oluşmaktadır. Model, girdi ve çıktı arasındaki ilişkiyi anladıktan sonra yeni, bilinmeyen test veri setleri sınıflandırabilir ve bunlara dayalı tahminler veya değerlendirmeler yapmaktadır. Regresyon ve sınıflandırma bu tür öğrenmede kullanılan iki yöntem kategorisidir [109].

- Regresyon (Regression):

Gözetimli öğrenmenin temel bir biçimi, sayısal değerleri tahmin etmek için girdi verilerini kullanan regresyondur. Örneğin regresyon analizi, sağlık sektöründeki tıbbi maliyetleri tahmin etmek için kullanılabilir. Girdi verileri ilaç fiyatlandırması, personel maliyetleri ve gerekli tıbbi ekipman maliyetini içerirken, tedavinin tüm maliyeti çıktı olacaktır. Bu modeller girdi ve çıktı verileriyle eğitilerek yeni girdiler için toplam tedavi maliyeti tahmin edilebilmektedir [110].

- Sınıflandırma (Classification):

Modeller, gözetimli ML sınıflandırma görevlerinde bir eğitim veri setinden etiketli örnekler kullanarak giriş verilerini belirli sınıflara ayırmak için eğitilmektedir. Model, eğitildikten sonra test veri setindeki veriler için tahmin sınıfı etiketleri oluşturabilir. Spam algılama, görüntü tanıma, tıbbi teşhis ve duygu analizi gibi birçok alanda ikili sınıftan çoklu sınıfa kadar değişen sınıflandırma görevleri vardır [110].

5.3.2. Gözetimsiz ML (Unsupervised ML)

Gözetimsiz ML, daha önce algoritmalar ya da insanlar tarafından etiketlenmemiş verileri kullanması bakımından gözetimli ML'den farklıdır. Eğitim veri seti, belirtilen işin cevaplarını içermez ve model, tahmin edilen değerlere sahip olmayan girdi verilerinden öğrenmektedir. Bu algoritma, sonuçları etiketlemek veya tahmin etmek yerine verileri özelliklerine göre ilişkilendirmeye ve kümelemeye odaklanmaktadır [110]. Gözetimsiz öğrenme iki şekilde olabilir:

- İlişkilendirme (Association):

Verilerdeki değişkenler arasındaki ilişkiler veya bağlantılar, bazen ilişkilendirme kuralı öğrenimi olarak da adlandırılan ilişkilendirme yoluyla bulunmaktadır. Belirli olayların veya oluşumların sıklıkla birlikte gerçekleştiğini gösteren eğilimleri araştırmaktadır. Apriori algoritması, ilişkilendirme kuralı öğrenmenin en yaygın kullanılan yöntemidir. Pazarlama ve ürün yerleştirme stratejilerini desteklemek için pazar sepeti analizinde sıklıkla kullanılan ilişkilendirme görevlerinin amacı, düzenli olarak birlikte satın alınan ürünler arasındaki bağlantıları bulmaktır [111].

- Kümeleme (Clustering):

Kümeler içinde maksimum benzerlik ve kümeler arasında belirgin farklılık ile karakterize edilen bir veri seti içindeki doğal küme yapısını keşfetmek, kümelemenin temelidir. Bu metodoloji, önceden belirlenmiş sınıf etiketlerine dayanmadan verileri anlamlı kümelere ayırarak verilerdeki gizli örüntüleri ortaya çıkarmayı amaçlamaktadır [110]. K-ortalama ve hiyerarşik kümeleme gibi yaygın olarak

kullanılan kümeleme teknikleri bu yaklaşımı örneklendirmektedir. Kümeleme uygulamaları arasında anomali tespiti, görüntü segmentasyonu ve tüketici segmentasyonu yer almaktadır [112].

5.3.3. Yarı Gözetimli ML

Yarı gözetimli ML’de, az miktarda etiketli veri ile büyük miktarda etiketsiz veri kullanarak bir modeli eğitilmektedir. Yarı gözetimli ML’de algoritmalar, gelişimlerini yönlendirmek için ilk önce az miktarda etiketli veri aldıktan sonra modeli tamamlamak için tipik olarak önemli miktarda etiketsiz veri ile beslenmektedir. Etiketsiz verilerin mevcut olduğu ve etiketli verilerin elde edilmesinin zahmetli bir süreç gerektirdiği ML ve veri araştırması uygulamalarında faydalı olabilir [110].

5.3.4. Pekiştirmeli ML

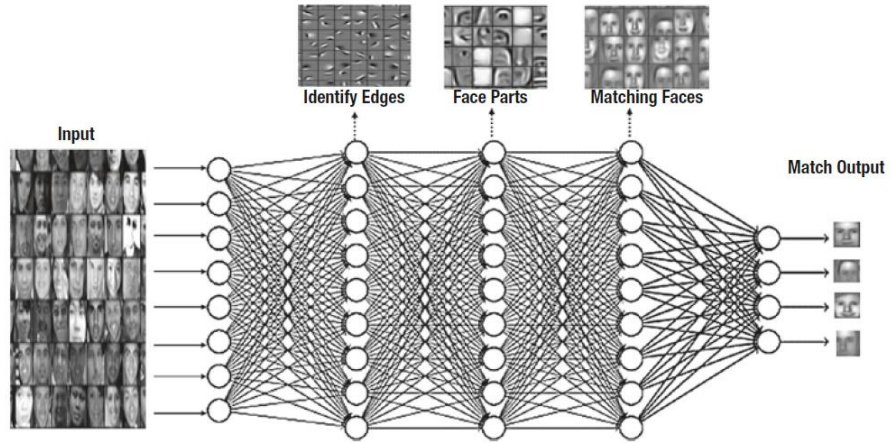
Pekiştirmeli öğrenme, makinenin çevresine yanıt olarak eylemler (a_1, a_2, \dots) üretmesini içermektedir. Bu eylemlerin çevre üzerinde bir etkisi vardır ve bu da makineye belirli skaler ödüller (veya cezalar) verilmesine neden olur r_1, r_2, \dots . Makine, yaşam boyu kazanımlarını en üst düzeye çıkaracak ve gelecekteki cezalarını en aza indirecek kararları nasıl alacağını öğrenmektedir. Kontrol teorisi (mühendislikte) ve karar teorisi (istatistik ve yönetim biliminde) alanları pekiştirmeli öğrenme ile yakından ilişkilidir [113]. Pekiştirmeli öğrenme, bir oyun oynamak veya bir metni özetlemek gibi görevleri yerine getirmek için bir dizi kararı veya eylemi verimli bir şekilde gerçekleştirilmesi gereken algoritmaları geliştirmek için sıklıkla kullanılmaktadır.

5.4. DERİN ÖĞRENME (DEEP LEARNING (DL))

DL algoritmalarını, ML algoritmalarının gelişmiş ve matematiksel olarak karmaşık bir gelişimi olarak düşünmek mümkündür. Algoritmaların katmanlı bir yapısı olan ANN, DL uygulamaları tarafından sonuca ulaşmak için kullanılmaktadır. Böyle bir ANN’nin mimarisi, insan beyninde bulunan biyolojik sinir ağından ilham alır ve

geleneksel ML modellerinden çok daha güçlü bir öğrenme süreciyle sonuçlanmaktadır [114].

DL, bir takım özellikleri doğrudan sinyal, görüntü ve video verilerinden çıkarabilen uçtan uca bir işleme yöntemidir. DL modelleri görüntü verilerinden hiyerarşik özellikler elde etmektedir. DL modelleri, bir görüntü hakkında ayrıntılı bilgi toplayan birden fazla katmandan oluşur. Şekil 5.3'teki yüz tanıma örneğinde gösterildiği gibi, DL modelinin ilk katmanları genel nitelikleri (kenarlar, lekeler ve daireler gibi) çıkarır; orta seviyeler orta seviye özellikleri (gözler, burunlar ve ağızlar gibi) çıkarır; ve son katmanlar üst seviye özellikleri (kafalar gibi nesnelere) çıkarmaktadır. DL'nin en iyi bilinen özelliği görüntüleri segmentlere ayırma ve sınıflandırma konusundaki doğruluğudur [114].



Şekil 5.3. Yüz tanıma DL modeli [115].

BÖLÜM 6

LİTERATÜR TARAMASI

Tıbbi görüntü analizi, özellikle meme kanseri teşhisi alanında DL ile büyük bir gelişme kaydetmektedir. Şüpheli lezyonları, erken evre tümörleri ve kötü huylu dokuyu hassas bir şekilde tanımlayabilmektedir. Ayrıca, ayrıntılı tümör sınırları sunmakta, doğru klinik kararları desteklemekte ve radyologlara teşhis konusunda yardımcı olmaktadır. Araştırmacılar, bu gelişmelerin bir sonucu olarak tıbbi görüntü analizinde segmentasyon, sınıflandırma, lokalizasyon ve tespit için DL'yi kullanmıştır [116]. Bu bölümde, meme kanserinin tanımlanmasına yardımcı olmak için mamografi görüntüleri kullanarak son 10 yılda yapılan ve yüksek doğruluğa sahip çalışmalar ve çözümler açıklanmakta ve özetlenmektedir.

2014 yılında Ganesan ve arkadaşları [117], mamografi görüntüleri kullanarak meme kanseri tespitini iyileştirmek için bir karar destek sistemi geliştirmeyi amaçlamıştır. Çalışmada, görüntülerden özellikler çıkarılmış ve çeşitli özellik seçim teknikleri kullanılmıştır. Daha sonra karar ağacı (Decision tree), fisher, lineer diskriminant, en yakın ortalama (Nearest Mean Classifier), Parzen ve destek vektör makinesi (Support Vector Machine (SVM)) olmak üzere altı farklı sınıflandırıcının performansını karşılaştırılmıştır. Önerilen metodoloji DDSM ve özel veri seti olan SATA CommHealth veri seti (her birinden 300 görüntü) kullanılarak değerlendirilmiştir. Karar ağacı sınıflandırıcısı, DDSM için %91.60 ve diğer veri seti için %96.80 doğruluk oranıyla en iyi performans elde etmiştir.

Dhungel ve arkadaşları [118] 2015 DL ve Rastgele Orman (Random Forest (RF)) sınıflandırıcılarının bir kombinasyonunu kullanarak mamogramlarda kitle tespiti için bir yaklaşım önermiştir. Kaskad yaklaşımı, şüpheli bölgeleri tanımlamak için bir Derin İnanç Ağı (Deep Belief Network (DBN)) ve CNN kullanmıştır. Son olarak, RF sınıflandırıcıları, kitleler ve normal doku arasında ayrı yapmak için morfolojik ve

doku özelliklerini analiz etmiştir. Bu yöntem, INbreast ve DDSM-BCRP veri seti üzerinde sırayla, %96 ve %75 duyarlılık elde etmiştir.

2016 yılında Jiao ve arkadaşları [119] tarafından yapılan çalışmada, mamografi görüntülerindeki meme kitlelerini sınıflandırmak için bir DL yaklaşımı araştırılmıştır. Görüntülerden özellikleri çıkarmak için bir CNN kullanılmıştır. Bu özellikler daha sonra iyi huylu ve kötü huylu kitleler olarak sınıflandırmak için iki farklı doğrusal SVM sınıflandırıcısını eğitmek için kullanılmıştır. Çalışmada DDSM veri setinden 600 görüntü kullanılmıştır. Önerilen yöntem %96.70'lik bir sınıflandırma doğruluğu elde etmiştir.

Aynı yıl Suzuki ve arkadaşları [120], DDSM veri setini kullanarak bir Derin Evrişimli Sinir Ağları (Deep Convolutional Neural Networks (DCNN)) oluşturmuş ve kitleleri tespit etmek için DCNN'deki transfer öğrenmeyi kullanmıştır. Çalışmanın doğruluk, duyarlılık ve özgüllük sonuçları sırasıyla %85.40, %89.90 ve %80.80 olarak elde edilmiştir.

2017 yılında Jiang [121] ön eğitilmiş CNN modelleri olan GoogLeNet ve AlexNet'i kullanmıştır. Bu çalışma, transfer öğrenmenin meme lezyonlarının sınıflandırılmasına uygulanmasını incelemektedir. Bu araştırma için üç numaralı Film Mamografi veri seti (BCDR-F03) olarak bilinen önerilen yeni veri seti kullanılmıştır. Sonuç olarak, GoogLeNet ve AlexNet sırasıyla 0.88 ve 0.83 Eğri Altındaki Alan (Area Under Curve (AUC)) elde etmiştir.

Mamogramları kullanarak meme kitlesi tanımlama, segmentasyon ve sınıflandırma için bir CAD sistemi 2017 yılında Dhungel ve arkadaşları [122] tarafından önerilmiştir. Yaklaşım, Kitle tespiti için DL ve RF modelleri kullanılırken, segmentasyon için Koşullu Rastgele Alanlar (Conditional Random Fields (CRF)) ve aktif kontur modelleri kullanılmıştır. Sınıflandırma için bir DL modeli kullanılmıştır. Sistem INbreast veri seti üzerinde test edilmiş ve kitle sınıflandırması için %98 duyarlılık ve %70 özgüllük elde edilmiştir.

2018 yılında Ribli ve arkadaşları [123], mamogramlardaki iyi huylu ve kötü huylu lezyonları tanımlamak ve sınıflandırmak için Daha Hızlı Bölge Tabanlı Evrişimsel Sinir Ağı (Faster Region-based Convolutional Neural Network (Faster-RCNN)) modelini kullanmıştır. Model, DDSM veri seti ve Semmelweis Üniversitesi'nden özel bir veri seti kullanarak eğitilmiş ve INbreast veri seti üzerinde test edilmiştir. Model nesne algılama, lokalizasyon ve sınıflandırma bileşenlerini içermektedir. Son katman, iyi huylu veya kötü huylu lezyonları görüntülerdeki nesnelere olarak tanımlamış ve tanımlanan her lezyonun sınırlayıcı kutusu ve puanı, sınıfına olan güvenini göstermiştir. Önerilen metod %90 duyarlılık, %30 Yanlış Pozitif Oranı (False Positive Rate (FPR)) ve 0.95 AUC değerlerine ulaşmıştır.

BI-RADS sınıflandırma sistemini kullanarak meme mamogramlarını sınıflandırmak için Wu ve arkadaşları 2019 yılında [124] 22 katmandan oluşan Residual Ağı (Residual Network) kullanmıştır. Veri setine dahil edilen 141473 hastanın 229426 dijital tarama mamogramı, patoloji raporlarından alınan bilgiler kullanılarak etiketlenmiştir. Çalışmanın tarama popülasyonlarının malign ve benign kitleleri için AUC değeri sırasıyla 0.886 ve 0.765'dir. Ek olarak, biyopsi uygulanmış kitleler değerlendirme için kullanılmış ve sırasıyla iyi huylu kitleler için 0.696 ve kötü huylu kitleler için 0.843 AUC elde edilmiştir.

2019 yılında Li ve arkadaşları [125] iyi huylu ve kötü huylu mamografi görüntülerini verimli bir şekilde sınıflandırmak için Inception modüllerini içeren yeni bir DenseNet-II sinir ağı modeli önermiştir. Model, 2042 görüntü içeren bir mamogram veri seti üzerinde eğitilmiş ve 10 kat çapraz doğrulama kullanılarak değerlendirilmiştir. DenseNet-II modeli ortalama %94.55 doğruluk, %95.60 duyarlılık ve %95.36 özgüllük ile AlexNet, VGGNet, GoogLeNet ve DenseNet'ten daha iyi bir performans elde etmiştir.

Rahman ve arkadaşları 2020 [126] yılında hazırladıkları makalede, önceden segmente edilmiş meme tümörü kitlelerini sınıflandırmak için DDSM veri setindeki mamografi görüntülerini kullanan derin CNN modellerinin oluşturulması ve değerlendirilmesi anlatılmaktadır. Modellerin performansını artırmak için, transfer öğrenme, veri artırma ve ön işleme yaklaşımlarını kullanılmıştır. Ön eğitilmiş

InceptionV3 modeli, %79.60 doğruluk, %75.40 kesinlik ve %89.10 duyarlılık değerlerine ulaşmıştır. Buna karşılık, ResNet50 modeli %85.70 doğruluk, %85.70 kesinlik ve %87.30 duyarlılık değerleri ile daha iyi performans sergilemiştir.

2021 yılında Saber ve arkadaşlarının hazırladıkları çalışmada [127], MIAS veri setinin iyi huylu, kötü huylu ve normal sınıflarından özellikler çıkarmak için Inception V3, ResNet50, VGG19, VGG16 ve Inception-V2 ResNet ağları kullanmıştır. SVM ve Softmax sınıflandırıcıları, sınıflandırma görevlerini uygulamak için çıkarılan özellikler kullanılarak eğitilmiştir. VGG16 modeli ile SVM sınıflandırıcısı, %98.96 doğruluk, %97.83 duyarlılık, %99.13 özgüllük, %97.35 kesinlik, %97.66 F-skoru ve 0.995 AUC değerlere ulaşarak en yüksek performansı göstermiştir.

Aynı yılda Baccouche ve arkadaşlarının gerçekleştirdikleri çalışmada [128], mamogramlardaki meme lezyonlarını eş zamanlı olarak tespit etmek ve sınıflandırmak için YOLOv3 modeline dayanan ve kitle tümörleri ile kalsifikasyonları birbirinden ayıran uçtan uca bir sistem önermiştir. Değerlendirmeler CBIS-DDSM, INbreast ve 487 mamografi görüntüsü içeren özel bir veri seti üzerinde gerçekleştirilmiştir. Sonuçlar CBIS-DDSM, INbreast ve özel veri setinde kitle lezyonları için sırasıyla %95.70, %98.10 ve %98.00 ve kalsifikasyonlar için %74.40, %71.80 ve %73.20 tespit doğruluğu göstermiştir.

Mahmood ve arkadaşlarının [129] 2022 yılında gerçekleştirdikleri çalışma, mamogramlardaki şüpheli bölgeleri iyi huylu veya kötü huylu olarak sınıflandırmak için yeni bir CNN kullanarak meme kanseri teşhisinin doğruluğunu artırmayı amaçlamaktadır. Metodoloji, MIAS'tan 322 ve özel bir veri setinden 580 mamograma uygulanan ön işleme, veri artırımı ve transfer öğrenme tekniklerini içermektedir. Ardından İlgili Alan (Region of Interest (ROI)) tespiti, özellik öğrenimi ve kitle sınıflandırması gerçekleştirilmiştir. Önerilen model %98 eğitim doğruluğu, %97 test doğruluğu, %99 duyarlılık ve 0.99 AUC elde etmiştir.

Öziç ve ark. tarafından 2023 yılında yapılan bir çalışmada YOLOv8 modeli kullanılarak VinDr-Mammo veri setindeki mamografi görüntüleri üzerinde kitle

tespiti ve lokalizasyonu gerçekleştirilmiştir [130]. Model üç farklı görüntü senaryosu ile eğitilmiş ve test edilmiştir: işlenmemiş görüntüler, meme bölgesi alanına kırpılmış görüntüler ve 1.2x oranında kırpılmış kitle alanı veriler. Üç veri senaryosu için kesinlik değerleri sırasıyla %95.70, %97.90 ve %100 olmuştur.

Prinzi ve arkadaşları tarafından 2024 yılında yapılan çalışmada mamogramlarda meme kanseri tespitinde YOLO'nun YOLOv3, YOLOv5 ve YOLOv5-Transformer mimarileri karşılaştırılmıştır [131]. Çalışmada ilk olarak, CBIS-DDSM ve INbreast veri setlerini kullanarak modeller eğitilmiştir. Ardından, bu veri setlerinden (yani eğitilmiş modelden) elde edilen ağırlıklardan yararlanarak, özel bir veri setini kullanarak modele ince ayar (Fine Tuning) yapılmıştır. Küçük YOLOv5 modeli (YOLOv5s), %62.10 mAP ile en iyi performansı göstermiştir.

Çizelge 6.1'de, bu bölümde bahsedilen çalışmaların yılı, kullandığı veri seti, görüntü sayısı, model ve sonuçlarını listeleyerek özetlenmiştir.

Çizelge 6.1. Çalışmaların özeti.

Yazar Adı ve Yıl	Kullanılan Veri Seti	Görüntü Sayısı	Model	Sonuçlar
Gansen vd. 2014 [117]	DDSM, SATA CommHealth	600	Karar Ağacı	Duyarlılık = %96.80
Dhungel vd. 2015 [118]	DDSM-BCDR, INbreast	316, 410	DBM, CNN ve RF	DDSM-BCDR: Duyarlılık = %75, INbreast: Duyarlılık = %96
Jiao vd. 2016 [119]	DDSM	600	CNN ve SVM	Doğruluk = %96.70
Suzuki vd. 2016 [120]	DDSM	1656	DCNN	Doğruluk = %85.40, Duyarlılık = %89.90, Özgüllük = %80.80
Jiang vd. 2017 [121]	BCDR-F03	736	GoogLeNet	AUC = 0.88
Dhungel vd. 2017 [122]	INbreast	107	DL, RF ve CRF	Duyarlılık = %98, Özgüllük = %70
Ribli vd. 2018 [123]	DDSM, Özel veri seti, INbreast	3467	Faster-RCNN	Duyarlılık = %90, AUC = 0.95
Wu vd. 2019 [124]	Özel veri seti	229426	ResNet	AUC = 0.90
Li vd. 2019 [125]	Özel veri seti	2042	DenseNet-II	Doğruluk = %94.55, Duyarlılık = %95.60 Özgüllük = %95.36
Rahman vd. 2020 [126]	DDSM	1167	ResNet50	Doğruluk = %85.70, Duyarlılık = %87.30 Kesinlik = %85.70
Saber vd. 2021 [127]	MIAS	322	VGG16 ve SVM	Doğruluk = %98.96, Duyarlılık = %97.83 Kesinlik = %97.35
Baccouche vd. 2021 [128]	CBIS-DDSM, INbreast, Özel veri seti	2907, 235, 487	YOLOv3	CBIS-DDSM: %95.70, INbreast: %98.10, Özel veri seti: %98
Mahmood vd. 2022 [129]	MIAS, Özel veri seti	322, 580	CNN	Doğruluk = %97, Duyarlılık = %99 AUC = 0.99
Öziç vd. 2023 [130]	VinDr-Mammo	1113	YOLOv8	Kesinlik = %100
Prinzi vd. 2024 [131]	CBIS-DDSM, INbreast, Özel veri seti	1514, 107, 278	YOLOv5s	mAP = %62.10

BÖLÜM 7

MATERYAL

Bu bölümde, tez çalışmasında kullanılan veri seti, programlama dili, DL eğitiminde kullanılan platform ve görüntülerin işaretlemesi için kullanılan araç hakkında bilgi verilmiştir.

7.1. VERİ SETİ

Bu tez çalışmasında kullanılan görüntüler INbreast veri setine aittir [132]. Veri tabanı, Porto'daki CHSJ Meme Merkezi'nde, hem Hastane Etik Kurulu'nun hem de Ulusal Veri Koruma Komitesi'nin izni altında elde edilmiştir. Bu veri seti internette herkesin erişimine açık değildir, ancak özel bir talepte bulunduktan sonra elde edilmiştir.

Toplanan 115 örnekten 90'ı her bir memenin iki görüntüsünü (MLO ve CC) içerirken, kalan 25 örnek mastektomi geçirmiş ve sadece bir memenin iki görüntüsünü içeren kadınlardır. Sonuç olarak toplamda 410 görüntü elde edilmiştir. Görüntüler DICOM (Digital Imaging and Communications in Medicine (Tıpta Dijital Görüntüleme ve İletişim)) formatında kaydedilmiştir ve 3328x4084 veya 2560x3328 piksel boyutlarındadır. Bu veri setin içerisinde çeşitli lezyon türleri (kitleler, kalsifikasyonlar, asimetri ve distorsiyonlar) dahil edilmiştir. Bu tezdeki amacın kitle tespiti ve sınıflandırması olduğu için, sadece kitle içeren görüntüler kullanılacaktır. Bununla birlikte, sağlıklı (hiç bir anormallik içermeyen) görüntüler de modelin eğitiminde kullanılmıştır. Bu veri setin içerisinde kitle içeren görüntü sayısı 107'dir, ve toplam 116 kitle bulunmaktadır. Görüntüler DICOM formatında ve BI-RADS sistemine göre sınıflandırılmıştır. Her bir anormallik için tıbbi raporlar ve radyoloji uzmanları tarafından yapılmış işaretleme dosyaları veri setine dahil edilmiştir. İşaretleme dosyaları XML ve ROI olmak üzere iki ayrı formatta

kaydedilmiştir. BI-RADS sistemi, 1986 yılında tanımlanan meme anomalileri için bir sınıflandırma sistemidir. BI-RADS, meme kanseri evrelerinin tanımlanması için mamografi bulgularını ilgili açıklamalarla birlikte sayısal kategorilere (0 ila 6 arasında) sınıflandırmaktadır. INbreast veri setinde BI-RADS 0 sınıfına ait görüntüler bulunmamaktadır. Çizelge 7.1’de BI-RADS sınıflandırmanın detaylarını ve bu tezde kullanılan sınıfların dağılımını açıklamaktadır [133].

Çizelge 7.1. Veri setin kategorilere ayırması [133].

BI-RADS	Kategori	Açıklama	Etiket	Görüntü Sayısı
0	Mamografi tamamlanmamış	Ek görüntü gerekiyor	Bulunmuyor	0
1	Negatif	Normal, görünür bir anormallik yoktur.	Sağlıklı	62
2	İyi huylu	Şüpheli bulgu yoktur, ancak iyi huylu değişiklikler olabilir	İyi huylu	24
3	Muhtemelen iyi huylu	Muhtemelen iyi huylu bir bulgu vardır, ancak stabiliteyi sağlamak için kısa süreli takip (tipik olarak 6 ay) gerekebilir.	Şüpheli	31
4	Şüpheli kötü huylu	Malignite olasılığı, Biyopsi gibi ileri tetkikler önerilir.		
5	Kötü huylu	Yüksek derecede malignite düşündürülen (>%95 malignite olasılığı), biyopsi yapılması şiddetle tavsiye edilir.	Kötü huylu	52
6	Kanıtlanmış kötü huylu	Biyopsi yoluyla kanser olduğu teyit edilmiş bulgular için kullanılır.		

Kitle içermeyen görüntüleri çıkarıldıktan sonra, her bir sınıfa ait kalan görüntü sayısı nispeten az olmuştur. Bu nedenle, altı sınıfa ait bu görüntüler, dört sınıfa indirilmiştir.

7.2. PYTHON

Bu tez çalışmasında, Python’un 3.10.12 versiyonunun kullanılmıştır. Python 1980’lerin sonlarında Guido van Rossum tarafından üretilmiş ve 1991 yılında piyasaya sürülmüş yaygın olarak kullanılan bir programlama dilidir [134]. Python,

yüksek performansı, kapsamlı kütüphaneleri, kullanım kolaylığı ve veri analizi kütüphaneleri sağlayan açık kaynaklı bir dil olup, Berkeley Yazılım Dağıtımı (Berkeley Software Distribution (BSD)) lisansına tabidir. Windows, Unix/Linux ve MacOS işletim sistemleri üzerinde çeşitli yöntemlerle çalıştırılabilir. Python, nesne yönelimli, yorumlayıcı, dinamik veri sınıfı, zengin ve güçlü sınıf kütüphanelerine sahip yüksek seviyeli bir programlama dilidir [135].

Python kodu yazmak için birçok farklı Bütünleşik Geliştirme Ortamı (Integrated Development Environment (IDE)) bulunmaktadır. Bunlar, Python'un sunduğu çok çeşitli paketlerin en iyi şekilde kullanılması için bir yazılım geliştiricisinin ihtiyaç duyduğu tüm özellikleri ve araçları bir araya getiren bir yazılım uygulaması anlamına gelir. PyCharm, Jupyter Notebooks, Visual Studio Code ve Spyder bazı IDE örnekleridir. Ayrıca, Python'un basit metin editörleri, komut satırı arayüzleri ve diğer geliştirme araçlarıyla da kullanılabilir [136].

7.3. GOOGLE COLABORATORY

Bu tez çalışmasında DL eğitim aracı olarak Google Colaboratory kullanılmıştır. Google'ın web platformlarından biri olan Google Colaboratory bulut tabanlı bir Jupyter Notebook ortamı sunmaktadır. Google Colaboratory'nin Google Drive ile uyumlu olması, veri setinin doğrudan Google Drive hesabından kolayca kaydedilip yüklenmesine olanak tanımıştır. Geleneksel, yerel donanıma bağlı ortamların kısıtlamalarının aksine, Colaboratory, ML model eğitim deneyimlerini önemli ölçüde geliştiren bir dizi avantaj sunmaktadır.

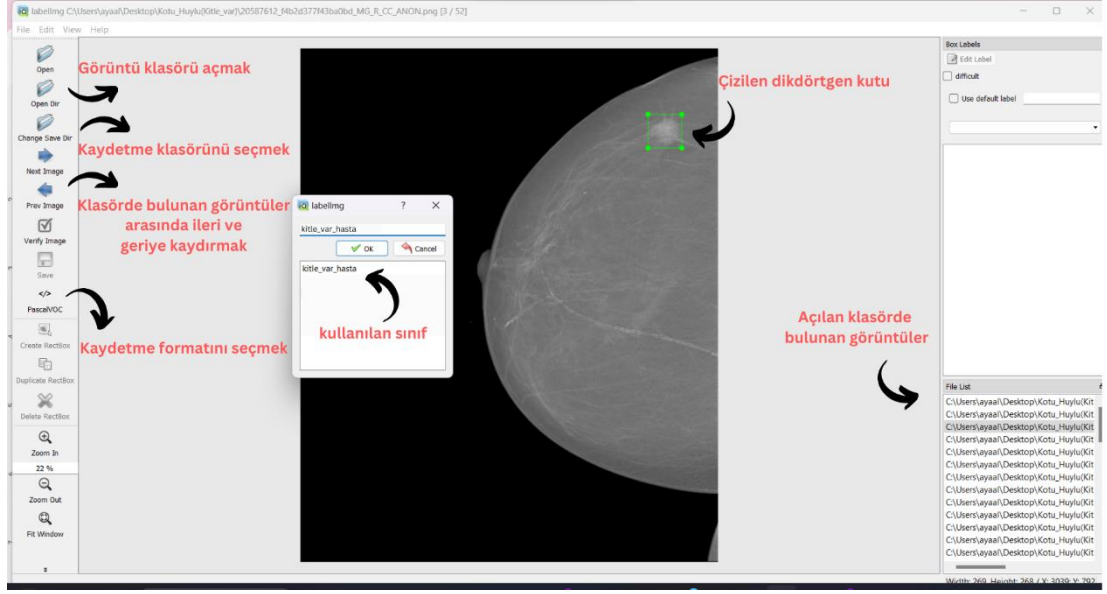
DL'nin hesaplama açısından zorlu doğasını ele almak için Colaboratory, Grafik İşleme Birimi (Graphics Processing Units (GPU)) ve Tenson İşleme Birimi (Tensor Processing Unit (TPU)) gibi yüksek performanslı bilgi işlem kaynaklarına erişim sağlamaktadır. Ayrıca, PyTorch ve TensorFlow gibi yaygın olarak kullanılan ML kütüphaneleri platforma hazır olarak yüklü gelmektedir. Ayrıca, Colaboratory'nin 12GB RAM ile geldiği ve Colaboratory Pro+ için çalışma zamanı sırasında 52GB'a kadar genişletilebildiği bilinmektedir.

Bu tez çalışmasındaki model eğitimi deneyleri Colaboratory Pro+ kullanarak yapılmıştır. Veri setinde bulunan görüntüler ve etiketleme dosyaları Google Drive'a yüklenip ardından Colaboratory'a entegre edilmiştir.

7.4. LABELIMG

Bu tez çalışmasında LabelImg aracı kullanılmıştır [137]. LabelImg, nesne algılama ve görüntü segmentasyonu gibi görevler için yaygın olarak kullanılan ücretsiz ve açık kaynaklı bir görüntü etiketleme yazılımıdır. Görüntülerdeki etiketlemesini istenilen nesnelere etrafına manuel olarak sınırlayıcı kutular çizmeye ve bunları sınıflandırmaya olanak tanımaktadır. Ardından, etiketleme verisi oluşturan çizilen sınırlayıcı kutuların koordinatları, JSON, XML ve TXT olmak üzere üç farklı uzantılı dosya halinde kaydedilme imkanı sunmaktadır. Bu da, farklı nesne algılama algoritmalarına kullanım imkanı sağlamaktadır. Farklı nesne tespit algoritmaları, farklı veri formatlarını ve etiketleme stillerini tercih edebilmektedir.

Belirtilen klasördeki görüntüleri kare kare açan "Open Dir" seçeneği kullanılarak görüntüler Labelimg'e yüklenmiştir. Etiketleme dosyaları daha sonra "Change Save Dir" seçeneği kullanılarak seçilen bir kayıt klasörüne kaydedilmiştir. Etiketleme sürecinin bir parçası olarak mamogramlarda gösterilen kitlelerin etrafına dikdörtgen kutular çizilmiştir. INbreast veri setinde bulunan kitle maskeleri ve XML uzantılı etiketleme dosyaları kullanılarak kitlelerin konumları tespit edilmiştir. Görüntülerde bulunan kitleler, "kitle_var_hasta" olarak etiketlenmiştir. Elde edilen etiketleme verisi, Labelimg'nin sunduğu ve YOLO ile uyumlu olan TXT uzantılı dosya halinde kaydedilmiştir. Şekil 7.1, LabelImg aracının arayüzünü göstermektedir.



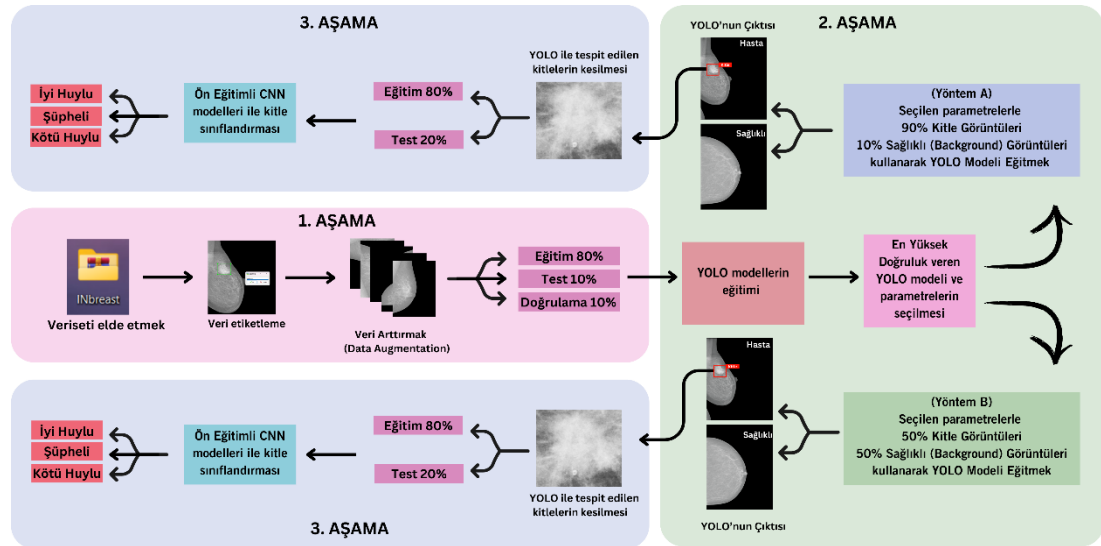
Şekil 7.1. LabelImg aracının arayüzü.

BÖLÜM 8

METOT

Bu bölüm, tezde önerilen yöntemi detaylı bir şekilde açıklamaktadır. Bu tez çalışması iki temel bölümden oluşmaktadır. İlk bölüm, mamografi görüntülerindeki kitleleri tespit etmek amacıyla YOLO modelinin kullanımını içermektedir. İkinci bölüm ise, YOLO ile tespit edilen kitleleri kesip ayırarak (cropping), CNN mimarisinin ön eğitilmiş modelleri ile iyi huylu, şüpheli ve kötü huylu olarak sınıflandırma işleminden oluşmaktadır.

Genel çerçevesi bu şekilde tasarlanan çalışmanın iş akış diyagramı Şekil 8.1'de gösterilmiştir. Bu iş akış diyagramı, çalışmanın adımlarını ve bu adımların birbirleriyle ilişkisini göstermektedir.



Şekil 8.1. Tez çalışmanın iş akış diyagramı.

8.1. ÖN İŞLEME

Ön işleme, bilgisayarla görme ve ML alanlarında kendisinden sonra gelen işlemlerin kalitesini ve performansını artırmada çok önemli bir rol oynamaktadır. En yaygın ML işlemlerinden birisi olan veri ön işleme, verilerin ML uygulamaları için uygun bir formata hazırlanmasını ve dönüştürülmesini içermektedir. Veri ön işleme, veri boyutunu en aza indirgemeyi, veri arasındaki ilişkileri tanımlamayı, verileri standartlaştırmayı, eksik verilerin tamamlanması, aykırılıkları ortadan kaldırmayı ve veri özelliklerini çıkarmayı amaçlamaktadır. Verilerin temizlenmesi, entegrasyonu, dönüştürülmesi ve indirgeme de dahil olmak üzere bir dizi teknikten faydalanmaktadır. Eksik değerlerin bulunması, verilerdeki gürültünün azaltılması, aykırı değerlerin belirlenmesi ve hatalı verilerin düzeltilmesi veri temizleme yoluyla yapılmaktadır. Entegrasyon ise, birden fazla kaynaktan gelen verileri tek bir veri setinde birleştirerek format tutarsızlıklarını gidermektedir. Dönüşüm, modelleme veya analiz için verilerin temsilinde veya biçiminde değişiklikler uygulamaktadır. Son olarak indirgeme, bir veri setinin en önemli özelliklerini korurken boyutluluğunu azaltmaya yöneliktir [138].

Bu bölümde, CNN ve YOLO modellerinin eğitimi öncesinde, yeniden boyutlandırma, görüntü işaretleme ve veri artırma olmak üzere yapılan ön işleme teknikleri incelenmektedir.

8.1.1. Yeniden Boyutlandırma

DL algoritmaları, girdi olarak sabit boyutlu görüntü veri kümelerini kabul ettiği için, modellere görüntüler yüklenmeden önce tüm görüntülerin aynı boyuta yeniden boyutlandırılması gerekmektedir. Bilgisayarla görmede, görüntülerin yeniden boyutlandırılması önemli bir ön işleme adımudur. DL modelleri öncelikle küçük görüntüler üzerinde daha hızlı eğitilmektedir. Doğru görüntü boyutunu seçerken hesaplama verimliliği ile doğruluğu dengelemek çok önemlidir [139].

Bu tezde, YOLO algoritması 640x640 boyutuna yeniden boyutlandırılmış görüntüler üzerinde çalışırken, CNN 224x224 boyutuna yeniden boyutlandırılmış görüntüleri analiz edecek şekilde tasarlanmıştır.

8.1.2. Görüntü İşaretleme

Görsel tanımanın temel işlevlerinden biri nesne algılamadır. Bir nesne dedektörü bir giriş görüntüsü alır ve ilgilenilen bir nesneyi her bulduğunda bir sınırlayıcı kutu çıktısı vermektedir. Güçlü bir dedektör geliştirmek için, büyük sayıda eğitim görüntüsü ile birlikte, onlara ait hassas işaretleme verisi (İlgili nesneyi çevreleyen sıkı dikdörtgenler) gereklidir. Nitekim, hassas sınırlayıcı kutu işaretleme, nesne tanıma modelin performansı için kritik öneme sahiptir [140].

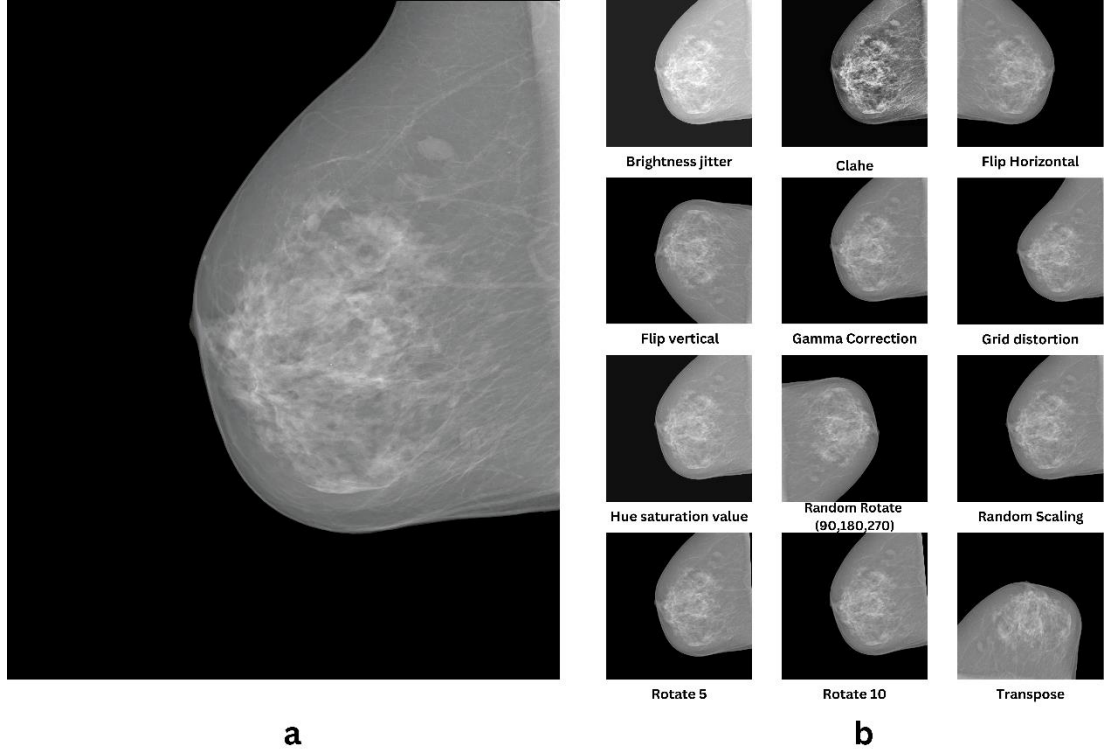
Bu tezde, daha önce de belirtildiği gibi, görüntü işaretleme işlemi gerçekleştirmek için LabelImg yazılımı kullanılmıştır. DICOM formatındaki görüntüleri açmanın LabelImg'in desteklediği bir özellik olmadığı unutulmamalıdır. Bu format CT, MRI ve X-ışınları gibi taramalardan elde edilen tıbbi görüntüler için standart bir formattır. JPEG, PNG ve BMP görüntü formatları LabelImg'nin görüntü işaretleme için kullandığı temel formatlardır. Bu nedenle, görüntü işaretleme işleminden önce, Python yardımıyla INbreast veri setinde bulunan tüm görüntüler DICOM formatından PNG formatına çevrilmiştir. Ardından, veri setinin içerdiği 107 kitle içeren görüntü üzerinde yapılan bu işlem, görüntülerin LabelImg'de açılmasını sağlamıştır. INbreast içerisinde bulunan XML uzantılı işaretleme dosyaları ve kitle maskeleri yardımı ile görüntülerde bulunan kitlelerin yeri tespit edilmiş ve etrafına dikdörtgenler çizilmiştir. Bu işlemin sonucunda elde edilen TXT uzantılı işaretleme dosyası içerisinde, beş sütun bulunmaktadır. Bu sütunların ilki nesnenin ait olduğu sınıfı temsil etmektedir. Sütunların geri kalanı sınırlayıcı kutuları [x_ merkez, y_ merkez, genişlik, yükseklik] şeklinde dört değerle temsil etmektedir. x_ merkez ve y_ merkez, sınırlayıcı kutunun merkezinin [0-1] aralığına normalize edilmiş koordinatlarıdır.

8.1.3. Veri Artırmak

Son 10 yılda, DL nesne algılama alanında büyük bir önem kazanmıştır. Bununla birlikte, güvenilir sonuçlar için, bilgisayarla görmedeki bir DL modeli önemli miktarda veriye ihtiyaç duymaktadır. Başta tıbbi görüntüleme alanında olmak üzere pratik durumlarda, yeterli veri elde etmek her zaman mümkün olmayabilir. Bir veri setinin miktarını artırmak ve görüntü kalitesini istenen ölçüde geliştirmek için "veri artırma" olarak bilinen bir takım yöntemler uygulanmaktadır. Bir modelin genelleme yeteneğini geliştirmek ve sınıf dengesizliği sorununu ele almak için veri artırımından yararlanmak önemlidir [141].

Bu tezde, veri artırma işlemleri görüntü işaretleme işleminden sonra yapılmıştır. Albumentations kütüphanesini kullanarak görüntülerle birlikte işaretleme dosyaların da artırma işlemi yapılmıştır. Albumentations, gelişmiş veri artırma gerektiren DL uygulamaları için özel olarak tasarlanmış açık kaynaklı bir kütüphanedir. Renk ayarlamaları, geometrik değişiklikler ve daha fazlası dahil olmak üzere birkaç farklı veri artırma yöntemi sunmaktadır [142].

Meme kanserin teşhisi için, tümörler meme dokusunun herhangi bir yerinde olabileceğinden dolayı, veri artırma işlemi yaparak DL modellerin genelleme yeteneği artırılmış ve daha iyi öğrenmesini sağlanmıştır. Bu tez çalışmasında, her bir görüntüden 8-12 ek yeni örnek oluşturmak üzere Şekil 8.2'de gösterilen veri artırma teknikleri kullanılmıştır [143–147].



Şekil 8.2. Kullanılan veri artırma teknikleri. a) Orjinal Görüntü, b) Yeni görüntüler.

Veri artırma işlemleri yaparken, seçilen yeni etiketler arasındaki görüntü dağılımı dikkate alınmıştır. Sınıflar arasında dengeyi sağlamak için, tüm sınıflara aynı oranda artırma yapılmamıştır. Görüntü sayısı düşük olan sınıflara daha fazla artırma oranı işlemleri uygulayıp, görüntü sayısı fazla olan sınıflarla denge sağlanmaya çalışılmıştır. Çizelge 8.1’de her bir sınıfa uygulanan veri artırma oranı ve elde edilen görüntü sayısı göstermektedir.

Çizelge 8.1. Veri artırma işlemi.

Sınıf	Veri Artırmadan Önce	Veri Artırma Oranı	Veri Artırmadan Sonra
Sağlıklı	62	X8	558
İyi Huylu	24	X12	312
Şüpheli	31	X12	403
Kötü Huylu	52	X8	468

Çizelge 8.1’de gösterilen veri artırma işleminden elde edilen sağlıklı sınıfına ait görüntüler, ilerideki YOLO (Yöntem B) eğitim aşaması gerektiğinden dolayı, 10

derece döndürme işlemini kullanarak tekrar artırma işlemi yapılmış ve toplamda sağlıklı sınıfta 1116 görüntü elde edilmiştir.

8.2. NESNE TANIMA

Nesne tanıma, bilgisayarlı görüde en önemli görevlerden biridir. Nesne tanımının temel işlevleri nesnelere bulmak ve sınıflandırmaktır. Dikdörtgen sınırlayıcı kutular bu süreçte tespit edilen nesnelere yerini belirlemek, sınıflandırmak ve nesnelere var olma güvenirliklerini göstermek için kullanılmaktadır [148]. Dolayısıyla, nesne tanıma işlemindeki iki temel görev nesne lokalizasyonu ve sınıflandırmasıdır. Nesne lokalizasyonu, bir nesne örneğini bir sınırlayıcı kutu içine alarak konumunu ve ölçüsünü belirlemektedir. Bir nesneye bir sınıf etiketi verme işlemi sınıflandırma olarak adlandırılmaktadır [149].

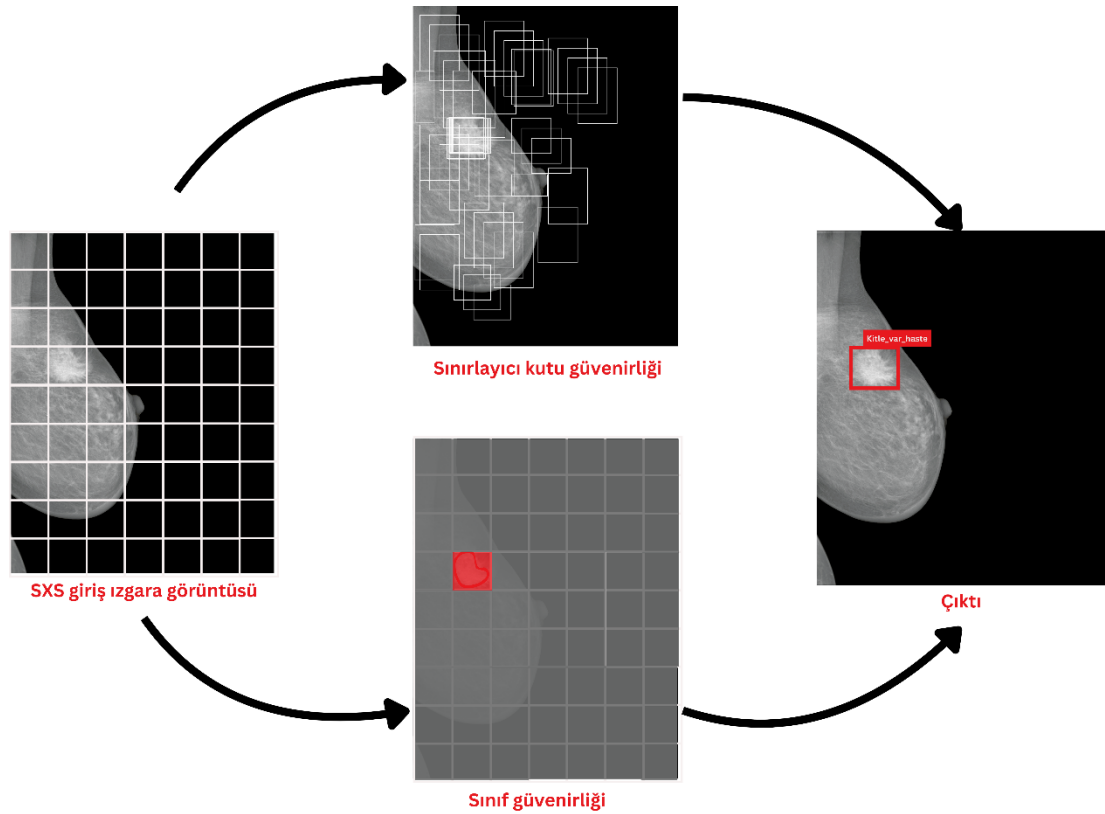
Nesne tanımının temel bileşeni, görüntülerden uzamsal bilgileri (nesne konumu) ve sınıflandırma bilgilerini (nesne sınıfı) çıkaran CNN'lerdir. Bu temel, nesnelere kareler boyunca tanındığı ve sınıflandırıldığı nesne izleme gibi diğer bilgisayarlı görme uygulamaları için kullanılmaktadır. Örnek segmentasyonu, görüntü yazısı ve nesne takibi gibi birçok bilgisayarlı görü görevi nesne tanıma üzerine kurulu olduğundan, nesne tanıma işlemindeki doğruluk çok önemlidir; bu alandaki gelişmeler, diğer birçok bilgisayarlı görü uygulamasının işlevselliğini doğrudan artırmaktadır [150].

Nesne tanıma, tıbbi görüntülerdeki anormalliklerin veya ilgili nesnelere tespit edilmesini ve tanımlanmasını olanak sağladığından, tıbbi görüntüleme için çok önemlidir. Tıbbi görüntülerdeki anomalilerin doğru bir şekilde tanımlanması ve lokalize edilmesi tıbbi teşhis için kritik öneme sahiptir. DL'de gerçek zamanlı nesne lokalizasyonu ve tespiti, doğruluk ve verimlilik açısından dikkate değer bir performans göstermiştir. YOLO, çok ilgi çeken bir nesne tanımlama tekniğidir [151].

Bu tez çalışmasında, mamografi tarama görüntülerindeki kitleleri tanımlamak için YOLO uygulanmıştır. YOLO’da tespit edilen kitleler, tezin ilk aşaması olan nesne tanımının çıktısını oluşturmaktadır.

8.2.1. YOLO (You Only Look Once)

YOLO, Joseph Redmon ve arkadaşları tarafından 2015 yılında önerilen uçtan uca tek bir sinir ağıdır. Nesne tanımını bir regresyon problemi olarak yeniden ifade ederek, her piksel için nesne kategorilerini ve sınırlayıcı kutu niteliklerini tahmin eden ilk tek aşamalı yaklaşımdır [152]. YOLO’nun temel prensibi Şekil 8.3’te gösterilmektedir.



Şekil 8.3. YOLO’nun çalışma prensibi.

Şekil 8.3’te gösterildiği gibi, YOLO, giriş görüntüsünü bir $S \times S$ ızgarasına böler ve her ızgara hücresi, o ızgara hücresinde ortalanmış nesneyi tahmin etmekten sorumludur. Bu da, geleneksel iki aşamalı yöntemlere kıyasla daha hızlı nesne tespitine olanak tanır ve özellikle gerçek zamanlı uygulamalar için kullanışlıdır. Her

ızgara hücresi, B sınırlayıcı kutularını ve bu kutular için güvenilirlik skorlarını tahmin etmektedir. Bu güvenilirlik skorları, kutunun bir nesne içerdiğinden modelin ne kadar emin olduğunu ve ayrıca tahmin ettiği kutunun ne kadar doğru olduğunu düşündüğünü yansıtmaktadır (Eşitlik 8.1) [152].

$$Pr(Object) \times IOU_{pred}^{truth} \quad (8.1)$$

Eşitlik 8.1’de, $Pr(Object)$ bir nesnenin, tahmin edilen sınırlayıcı kutu içinde bulunma olasılığını temsil etmektedir. IoU, Birleşim Üzerindeki Kesişim (Intersection over Union) anlamına gelmektedir. Tahmin edilen sınırlayıcı kutunun gerçek referans sınırlayıcı kutuya göre doğruluğunu değerlendirmek için kullanılan bir metriktir. Eğer o hücrede herhangi bir nesne yoksa, güvenilirlik skoru sıfır olur. Aksi takdirde, güvenilirlik skorunun tahmin edilen kutu ile gerçek referans sınırlayıcı kutu arasındaki IoU’ya eşit olmasını istenmektedir [152].

Her sınırlayıcı kutu tahmini beş değerden oluşur: x , y , w , h ve güvenilirlik. (x, y) koordinatları, ızgara hücresinin sınırlarına göre kutunun merkezini temsil etmektedir. Genişlik (w) ve yükseklik (h) tüm görüntüye göre tahmin edilmektedir. Son olarak güvenilirlik tahmini, tahmin edilen kutu ile herhangi bir gerçek referans sınırlayıcı kutu arasındaki IoU’yu temsil etmektedir [152].

Her bir ızgara hücresi aynı zamanda C sınıf olasılıklarını da tahmin eder, $Pr(Class_i | Object)$. Bu olasılıklar, bir nesne içeren ızgara hücresine bağlıdır. Test zamanında, bu sınıf olasılıkları ile her bir kutunun güvenilirlik tahminlerini çarparak her bir kutu için sınıfa özgü güvenilirlik skorları elde edilir (Eşitlik 8.2). Bu skorlar hem o sınıfın kutuda görünme olasılığını hem de tahmin edilen kutunun nesneye ne kadar iyi uyduğunu göstermektedir [152].


$$Pr(Class_i | Object) \times Pr(Object) \times IOU_{truth,pred} = Pr(Class_i) \times IOU_{truth,pred} \quad (8.2)$$

YOLO algoritması bağlamında, hedef kutu B^{gt} olarak gösterilirken, tahmin edilen kutu B olarak temsil edilmektedir. Olasılık (p), nesnenin tespit edilen sınırlayıcı kutu içinde var olup olmadığını göstermektedir. Eşitlik 8.3 ile tanımlanan IoU metriği,

gerçek referans sınırlayıcı kutu ile tahmin edilen sınırlayıcı kutular arasındaki kesişim alanını hesaplar. Giriş görüntüsünde tespit edilen her nesne için kabul edilebilir bir alan belirler ve buna göre karar verilmektedir. En uygun sınırlayıcı kutuyu elde etmek için tahmin sonrasında güvenilirlik değeri de hesaplanmaktadır [151].

$$IoU = \frac{B \cap B^{gt}}{B \cup B^{gt}} \quad (8.3)$$

YOLO mimarisini üç temel bileşen oluşturur: backbone, neck ve head (Şekil 8.4). Farklı YOLO versiyonları arasında bu temel bileşenlerin mimarileri farklılıklar gösterebilmektedir. Backbone, neck ve head seçimleri, belirli bir uygulamaya ve amaçlanan dengeye bağlı olarak değişir ve YOLO modelinin hızını ve doğruluğunu etkilemektedir. Backbone katmanları, Giriş görüntülerinden önemli bilgileri çıkarmaktadır. Özellik haritaları, genellikle VGG16 veya ResNet50 gibi ön eğitilmiş bir CNN olan backbone tarafından oluşturulmaktadır. Neck, Özellik Piramit Ağı (Feature Pyramid Network (FPN)) ve Uzamsal Piramit Örnekleme (Spatial Pyramid Pooling (SPP)) gibi unsurlarla çoklu backbone katmanlarından gelen bu özellik haritalarını harmanlamakta ve yumuşatmaktadır. Ağın nihai çıktısı, sınırlayıcı kutuları, nesne skorlarını ve sınıf etiketlerini tahmin etmek için birleştirilmiş bilgileri işleyen head katmanları tarafından üretilmektedir [151].



Şekil 8.4. Input, backbone, neck ve head ile YOLO'nun mimarisi [153].

YOLO'nun başarısı sadece tek adımlı sürecinden değil, aynı zamanda YOLOv1 ile başlayan ve bugüne kadar YOLOv9 ile devam eden iteratif gelişiminden de

kaynaklanmaktadır (Çizelge 8.2). Her versiyon, oluşturucu mimari atılımlarının bir araya gelişini sergileyerek YOLO'ya çok çeşitli sektörel kullanımlarda özgün bir beceri ve uyarlanabilirlik kazandırmıştır. YOLO felsefesi, hız ve doğruluk arasındaki doğal denge ile karakterize edilir, bu da onu hem endüstri uygulayıcıları hem de araştırma topluluğu için uygun bir seçenek haline getirmektedir [154,155].

Çizelge 8.2. YOLO versiyonları arasında karşılaştırma [154,155].

Versiyon	Yıl	Framework	Backbone	Mekanizma
YOLOv1	2015	Darknet	Darknet24	Izgara tabanlı yaklaşım
YOLOv2	2016	Darknet	Darknet24	Hiyerarşik sınıflandırma
YOLOv3	2018	Darknet	Darknet53	Özellik Piramidi Ağı
YOLOv4	2020	Darknet	CSPDarknet53	Geliştirilmiş Kuantizasyon, PAN, RepVGG
YOLOv5	2020	PyTorch	Modified CSPn v7	AutoAnchor, Mosaic, MixUp, EfficientNet
YOLOv6	2022	PyTorch	EfficientRep	RepVGG, PAN, EfficientRep
YOLOv7	2022	PyTorch	RepConvN	ELAN, Model scaling
YOLOv8	2023	PyTorch	YOLO v8	C2f module, EfficientRep, CIoU, DFL
YOLOv9	2024	PyTorch	GELAN	PGI

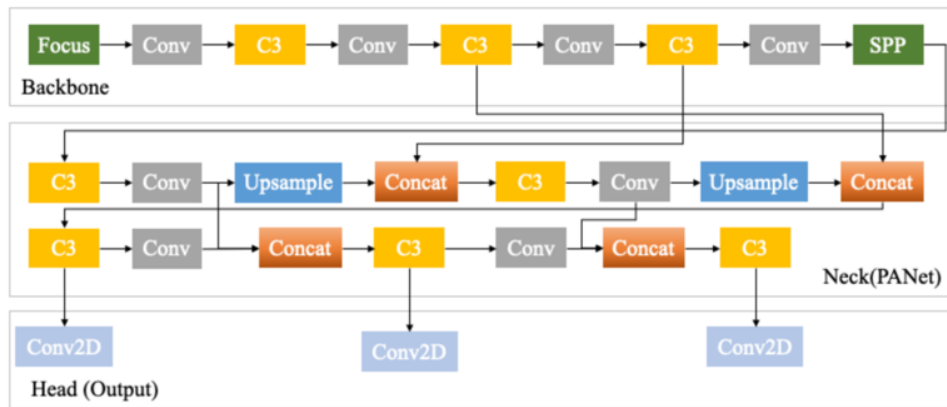
YOLO'nun tıbbi alanda uygulanması, anatomik yapıları, lezyonları, tümörleri ve klinik olarak ilgili diğer tıbbi nesnelere tespit etme ve lokalize etme kabiliyeti nedeniyle ilgi çekmiştir. Tıbbi görüntülerdeki anormallikleri tespit edebilir ve lokalize edebilir, bu da çeşitli hastalıkların erken tespitine ve teşhisine yardımcı olabilmektedir. YOLO'nun tıbbi uygulamalarda benimsenmesi, tıbbi teşhisin doğruluğunu ve verimliliğini artırma potansiyeline sahiptir ve bu da hasta sonuçları üzerinde önemli bir etkiye sahip olabilmektedir [151].

Bu tezde, meme kitlelerini tespiti için hem YOLOv5 hem de YOLOv7 kullanılmıştır.

8.2.1.1. YOLOv5

Ultralytics CEO'su ve kurucusu Glen Jocher 2020 yılında YOLOv5'i kullanıma sunmuştur [156]. YOLOv5, önceki YOLO versiyonlarına kıyasla daha az model parametresine sahiptir ve PyTorch framework üzerine kurulmuş olması, kullanım kolaylığı ve model eğitimi açısından önemli avantajlar sunmaktadır [157].

YOLOv5'in algoritma tasarımı YOLO serisinin temelindeki mantığı sürdürmektedir. Tespit edilecek görüntü bir giriş katmanı (input) aracılığıyla işlenir ve özellik çıkarımı için backbone'a gönderilmektedir. Ardından, backbone farklı boyutlarda özellik haritaları elde eder ve daha sonra bu özellikleri özellik füzyon ağı (neck) aracılığıyla birleştirerek sırasıyla görüntüdeki küçük, orta ve büyük nesnelere tespit etmek için üç özellik haritası (YOLOv5'te boyutlar 80×80 , 40×40 ve 20×20 boyutlarıyla ifade edilir) oluşturmaktadır. Elde edilen üç özellik haritası tahmin işlemini gerçekleştiren head katmanlarına gönderilmektedir. Sonra, nesne sınıfı, sınıf güveni, kutu koordinatları, genişlik ve yükseklik bilgilerini içeren çok boyutlu bir dizi (BBboxes) elde etmek için önceden ayarlanmış gerçek referans değerleri kullanılarak özellik haritasındaki her piksel için güven hesaplaması ve sınırlayıcı kutu regresyonu gerçekleştirilmektedir. Dizideki gereksiz bilgileri filtrelemek için ilgili eşikleri (Güven Eşiği, Nesnellik Eşiği) ayarlanmaktadır. Güven eşiği (Confidence Threshold) ve nesnellik eşiği (Objectness Threshold), sırayla, kutu içinde bir nesnenin bulunma olasılığını ve kutunun sınıfından bağımsız olarak herhangi bir nesne içermesi olasılığını göstermektedir. Daha sonra, Maksimum Olmayan Bastırma (Non-Maximum Suppression (NMS)) işlemi gerçekleştirilerek, nihai algılama çıktısı elde edilmektedir. Son yapılan NMS işlemin amacı, güven skorlarına dayalı olarak örtüşen kutular arasında en iyi sınırlayıcı kutuyu seçmektir. Şekil 8.5'te YOLOv5'in mimarisi gösterilmektedir [158].



Şekil 8.5. YOLOv5'in mimarisi [157].

Şekil 8.5'te gösterildiği gibi, YOLOv5 mimarisinde backbone katmanları temel olarak focus modülü, wrapped convolution modülü, C3 modülü ve SPP modülünden oluşmaktadır. Focus modülü, giriş görüntüleri üzerinde dilimleme işlemleri gerçekleştirerek ağız görüntülerden özellik çıkarma yeteneğini geliştirmektedir. Öte yandan, C3 modülü, özellik çıkarma doğruluğunu korurken ağız özellik temsil yeteneklerini geliştirmektedir. Bu, ağız ihtiyaç duyduğu bellek tüketimini ve parametre sayısını azaltarak gerçekleştirilmektedir. SPP, ağız sabit boyut kısıtlamasını ortadan kaldıran ve farklı boyutlardaki girdileri etkili bir şekilde işlemesine olanak tanıyan bir pooling katmanıdır [159]. Neck katmanlarında, YOLOv5, FPN ve Yol Agregasyon Ağı (Path Aggregation Network (PAN)) yöntemlerini kullanmaktadır. FPN'nin temel fikri, farklı ölçeklerdeki hedefleri tespit etmek için birden fazla yeni özellik haritası oluşturmak üzere backbone katmanlarında üretilen özellik haritasını sık örnekleme (up-sampling). PAN ise, farklı ölçeklerdeki nesnelerin algılanma doğruluğunu artırmak için kullanılmaktadır [158]. Head (çıkıtı), neck katmanların füzyonundan elde edilen özellik haritası aracılığıyla hedefin kategorilerini ve konumunu sınıflandırır. YOLOv5, tam bağlı katmanlar kullanmak yerine, üç farklı boyuttaki özellik haritasında nesnelerin güvenini, kategori olasılığını ve tahmin kutusu koordinatlarını tahmin etmek için üç adet 1×1 evrişimli katman kullanmaktadır [159].

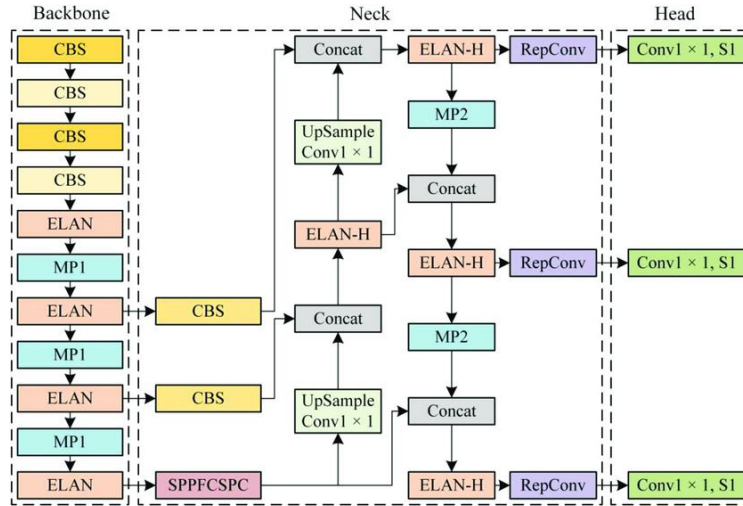
YOLOv5 tarafından YOLOv5n (nano), YOLOv5s (küçük), YOLOv5m (orta), YOLOv5l (büyük) ve YOLOv5x (ekstra büyük) olmak üzere beş ölçekli versiyon sunulmuştur. Bu versiyonlar, farklı donanım gereksinimlerini karşılamak ve farklı genişlik ve derinliklerde konvolüsyon modüllerine sahip olarak belirli uygulamalara uyacak şekilde tasarlanmıştır [160].

8.2.1.2. YOLOv7

YOLOv4 ve YOLOR'u yayınlayan yazarlar tarafından Temmuz 2022'de ArXiv'de YOLOv7 yayınlanmıştır [161]. Yayınlandığı sırada mevcut birçok nesne dedektöründen daha iyi performans göstererek 5 FPS ile 160 FPS arasında değişen hızlara ulaşmıştır. Başka veri setleri veya ön eğitilmiş ağırlıklar kullanılmadan MS COCO veri seti üzerinde tamamen sıfırdan eğitilmiş gerçek zamanlı bir nesne

dedektörüdür. Yayınlandığı zamanki güncel olan en iyi gerçek zamanlı nesne algılayıcıya göre yaklaşık %40 daha az parametre ve %50 daha az hesaplama ile YOLOv7, çıkarsama maliyetlerini artırmadan gerçek zamanlı nesne algılama doğruluğunu önemli ölçüde artırmıştır. Ayrıca, daha hızlı çıkarım hızı ve daha yüksek algılama doğruluğuna sahiptir [162].

YOLOv7 ağı modeli altı mimariyi içermektedir: Yolov7-Tiny, YOLOv7, Yolov7x, Yolov7-E6, Yolov7-D6 ve Yolov7-E6e. Temel farklılıklar evrişim katmanlarının sayısı ve yardımcı head'lerin (auxiliary head) sayısıdır. Daha fazla evrişimsel katman genellikle ağı daha karmaşık ve incelikli özellikler öğrenmesini sağlayarak doğruluğu artırabilmektedir. Bununla birlikte, katman sayısının artırılması modelin hesaplama karmaşıklığını ve bellek kullanımını da artırmaktadır. Yardımcı head yapıları, ekstra ara tahminler sağlayarak öğrenme sürecini iyileştirmek için tasarlanmış ağıdaki ek çıktı katmanlarını ifade etmektedir. Bu, eğitim sürecine yardımcı olabilir, modeli daha sağlam hale getirebilir ve potansiyel olarak genelleme yeteneklerini geliştirmektedir [163]. Şekil 8.6'da YOLOv7'nin mimarisi gösterilmiştir [164].



Şekil 8.6. YOLOv7'nin mimarisi [164].

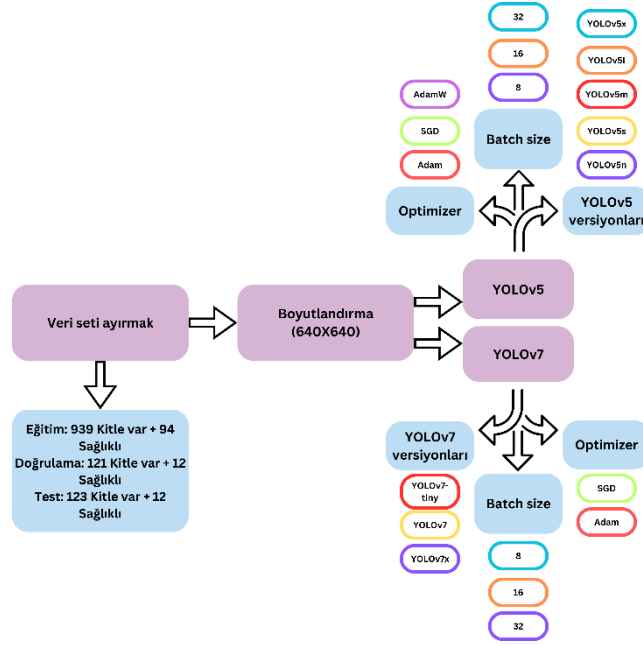
YOLOv7'de ilk olarak, giriş görüntüsü 640x640 olarak yeniden boyutlandırılmaktadır. Daha sonra, backbone katmanlarına aktarılmaktadır. YOLOv7'nin backbone katmanlarındaki hesaplama bloğu Genişletilmiş Verimli

Katman Birleştirme Ağı (Extended Efficient Layer Aggregation Network (E-ELAN)) olarak adlandırılmaktadır. Bu ağ, farklı özellik haritaları tarafından öğrenilen özellikleri geliştirebilir ve parametrelerin ve hesaplamaların kullanımını iyileştirmektedir. Neck modülü, daha önce oluşturulan etkili özellik katmanları üzerinde özellik füzyonu gerçekleştirerek önemli bir rol oynamaktadır. Son olarak, RepConv tahmin sonuçlarını vermektedir. Hem sınıflandırma hem de regresyon için temel unsurları kapsayan head katmanları, bu görevlerden sorumlu en önemli bileşen olarak görev yapmaktadır [164].

8.2.1.3. YOLOv5 ve YOLOv7 Uygulaması

Bu tezdeki YOLO uygulaması Google Colaboratory aracılığıyla gerçekleştirilmiştir. İlk adım, YOLO ortamını kurmak üzere GitHub'taki YOLOv5 ve YOLOv7 kaynaklarını klonlamaktır. Klonlama işleminin ardından hiper parametreler, model ve veriler için konfigürasyon dosyalarını içeren klasörler oluşturulmuştur. Eğitim sürecini başlatmak için işaretleme dosyaları ve görüntüler veri klasörlerine yüklenmiştir. TXT uzantılı işaretleme dosyaları, sınıf numarası, sınırlayıcı kutunun merkezinin x ve y koordinatları, genişlik ve yükseklik değerleri içermektedir. Bu tez kapsamında, YOLO aşamasında yalnızca kitle tanımlaması hedeflendiği için, yalnızca "Kitle var hasta" sınıfı mevcuttur ve bu sınıfın değeri 0 olarak belirlenmiştir.

YOLO eğitimleri, iki farklı yöntem kullanılarak gerçekleştirilmiştir: Yöntem A ve Yöntem B. Yöntem A'da, artırma işleminden sonra oluşturulan 1183 kitle içeren görüntünün %80'i eğitim, %10'u doğrulama ve %10'u test için ayrılmıştır. Ayrıca, YOLO geliştiricilerinin önerdiği gibi, kitle içermeyen sağlıklı (background) görüntüler de %10 oranında eğitim, doğrulama ve test veri setlerine eklenmiştir [165]. Yöntem B'de de veri seti %80, %10 ve %10 oranlarında eğitim, doğrulama ve test olarak ayrılmıştır. Ancak bu yöntemde, kitle içermeyen sağlıklı görüntülerle kitle içeren görüntüler eşit sayıda kullanılmıştır. Bu yöntem, YOLO eğitiminde kitle içermeyen sağlıklı görüntülerle kitle içeren hasta görüntüler arasındaki dengeyi sağlamanın model performansını nasıl etkilediğini araştırmak için kullanılmıştır. Bu iki yöntemin çıktısı sonraki CNN aşamasında kullanılıp elde edilen sonuçları karşılaştırılmıştır. Şekil 8.7 YOLO uygulamasının akış diyagramını göstermektedir.



Şekil 8.7. YOLO uygulamasının akış diyagramı.

İlk olarak, YOLOv5 modeliyle eğitim deneyleri gerçekleştirilmiştir. Bu deneylerde, farklı YOLOv5 versiyonları ve çeşitli batch size değerleri kullanılarak Stokastik gradyan inişi (Stochastic Gradient Descent (SGD)), Adaptif Momentum Tahmini (Adaptive Moment Estimation (Adam)) ve Adam Ağırlık Azalması (Adam Weight Decay (AdamW)) optimizier'ları test edilmiş ve en yüksek doğruluk hedeflenmiştir. Deneyler 50, 70 ve 90 epoch kullanılarak yapılmıştır. Ardından, YOLOv7 modelinin eğitim deneylerine geçilmiştir. Bu aşamada YOLOv7'nin YOLOv7-tiny, YOLOv7 ve YOLOv7x versiyonları değerlendirilmiştir. Deneylerde 8, 16 ve 32 batch size değerleri kullanılırken, Adam ve SGD optimizier'ları kullanılmıştır. Epoch sayıları, YOLOv5'te olduğu gibi, 50, 70 ve 90 olarak belirlenmiştir.

SGD, derin sinir ağı eğitimi için en popüler gradyan inişi optimizasyon yöntemidir. SGD, tüm eğitim örneklerini ayrıştırmak yerine parametreleri tek bir örnek üzerinde güncellemektedir [166]. Tek bir SGD iterasyonu örneği aşağıdaki Eşitlik 8.4 kullanarak ifade edilir [167]:

$$W = \omega - \eta \nabla Q_i(\omega) \quad (8.4)$$

Eşitlik 8.4'te, ω bir sinir ağının eğitimi sırasında başlangıç ağırlığını temsil eder ve η öğrenme oranını ifade etmektedir. Q_i halihazırda gözlemlenen verileri, Q ise genellikle bir hata fonksiyonunu temsil etmektedir. SGD, Q hata fonksiyonunu minimize ederek optimum W ağırlığını belirlemektedir. Daha sonra, loss fonksiyonunu elde etmek için gerçek ve tahmin edilen değerlerin türevi hesaplanmaktadır. W , sinir ağı eğitim süreci boyunca güncellemelere tabi tutulmaktadır [167].

Adam günümüzde mevcut olan en yaygın optimizasyon yöntemlerinden biridir. Adam, momentum ve gradyan inişi kavramlarını birleştirerek loss fonksiyonunu minimize ederek fonksiyonunun minimum değerini bulan stokastik bir optimizasyon tekniğidir. Adam işlemi şu şekilde özetlenebilir: ilk olarak, loss fonksiyonunun belirli bir yerindeki gradyan, büyüklüğü analiz noktasında söz konusu fonksiyonun maksimum değişim oranı olan ve bu maksimumun yönünü işaret eden bir vektör üretmek için hesaplanmaktadır [168]. Adam optimizasyon algoritmasının matematiksel gösterimi Eşitlik 8.5 ve Eşitlik 8.6'da gösterilmiştir.

$$\Delta \omega_t = -\eta \frac{x_t}{\sqrt{y_t + \epsilon}} * g_t \quad (8.5)$$

$$\omega_{t+1} = \omega_t + \Delta \omega_t \quad (8.6)$$

Eşitlik 8.5'te, η öğrenme oranını ve g_t t zamanındaki gradyanı temsil etmektedir. x_t , ω_t parametresi boyunca gradyanların üstel ortalamasını gösterirken, y_t , ω_t boyunca gradyanların karelerinin üstel ortalamasını temsil etmektedir. ϵ sayısal stabiliteyi sağlamak için sabit bir değeri temsil etmektedir [167]. Eşitlik 8.6, optimize edici içindeki dahili parametre ω 'nın ayarlanmasını göstermektedir. Bu ayarlama, $\Delta \omega_t$ olarak temsil edilen değişikliğin ω_t 'nin mevcut değerine eklenmesini gerektirmektedir [168].

AdamW optimizer'ın amacı, ağırlıkların azalmasına dayanan sinir ağı optimizasyon sürecine bir regülasyon getirmektir. Regülerizasyon, loss fonksiyonuna bir ceza ekleme işlemidir. Parametreyi bir sönüm oranı ω_t ile çarparak, ağırlık sönümleme


stratejisi, Eşitlik 8.7’de gösterildiği gibi, θ_t ağırlıklarının güncelleme süreci boyunca aşırı genişlemesini önlemektedir [169].

$$\theta_{t+1} = \theta_t - \eta(\nabla Q_i(\theta_t) + \lambda\theta_t) \quad (8.7)$$

Batch size, dahili model parametrelerini güncellemeden önce işlenecek örnek sayısını tanımlayan bir hiper parametredir. Epoch sayısı ise öğrenme algoritmasının tüm eğitim veri seti boyunca kaç kez çalışacağını belirleyen bir hiper parametredir. Bir epoch, bir veya daha fazla batch’ten oluşabilmektedir [170]. Bu tezde, kitle tanımlama işlemi için YOLOv5 ve YOLOv7 modellerini kullanırken, 8, 16 ve 32 batch size seçenekleri kullanılmıştır. Ayrıca, deneylerde epoch sayıları için de, 50, 70 ve 90 değerleri kullanılmıştır.

8.3. EVREŞİMLİ SİNİR AĞLARI (CONVOLUTIONAL NEURAL NETWORK (CNN))

CNN günümüzde oldukça yaygın olarak kullanılan bir DL mimarisidir. ConvNets olarak da adlandırılan CNN, ilk olarak 1995 yılında LeCun ve arkadaşları tarafından tanımlanmıştır [171]. İleri beslemeli (Feed Forward) çok katmanlı hiyerarşik sinir ağı tabanlı bir DL mimarisidir. Bir görüntüden özellikler çıkarmak için eğitilebilir filtreler uygulamayı mümkün kılan konvolüsyonel bir matematiksel prosedürden yararlanmaktadır [172]. Temel olarak konvolüsyon, iki veri setini birleştirmek için kullanılan matematiksel bir işlemdir. Konvolüsyon kerneli, girdiyi alır ve onu bir çıktı özellik haritasına dönüştürür. Genellikle CNN özellik dedektörü olarak bilinen konvolüsyon işlemi Şekil 8.8’de gösterilmiştir [173].



Şekil 8.8. Konvolüsyon İşlemi [173].

CNN'in iki ana parçası sınıflandırma bileşeni ve hiyerarşik özellik çıkarma bileşenidir. Hiyerarşik özellik çıkarma bileşeni, her katmanın bir önceki katmandan öğrendiği çoklu katmanlara bölünmüştür. Evrimsel özellik çıkarma katmanları, giriş görüntülerindeki yerel özellikleri tespit etmeyi amaçlamaktadır. Bunları bir aktivasyon fonksiyonu uygulayan doğrusal olmayan katmanlar takip etmektedir. Daha sonra, mimarinin her seviyesinde özellik alanını azaltmak için örnekleme katmanları kullanılmaktadır. Dropout katmanları gibi öğrenmeyi geliştirmek için belirli katmanlar da kullanılabilir. Sınıflandırma bileşeni ise, yanıt vermek için kullanılmaktadır. Bir veya daha fazla tam bağlı katmandan ve son bir Softmax katmanından oluşmaktadır [172].

CNN'ler, kenarlar, köşeler, dokular veya daha soyut şekiller gibi hedef sınıfları veya nitelikleri en iyi şekilde tanımlamak için tasarlanmıştır. Bu sinir ağı türü, katmanlar halinde düzenlenmiş nöronlardan oluşur ve diğer sinir ağı modellerinde olduğu gibi hiyerarşik temsiller öğrenme yeteneğine sahiptir. Ağırlıklar ve bias (yanlılık) farklı katmanlardaki nöronları birbirine bağlamaktadır. İlk katman, girdi katmanıdır ve sınıflandırılacak veriyi içermektedir (örneğin; mamogram verisi). Mamogram görüntülerinden kitle türlerine göre tahmini bir sınıflandırmayı içeren çıktı katmanı ise son katmandır. Girdi katmanı ile çıktı katmanı arasında, girdinin özellik uzayını çıktı ile eşleştirecek şekilde değiştiren gizli katmanlar vardır. Örüntülerden faydalanmak amacıyla, CNN'ler gizli katman olarak en az bir evrimsel katman içerir. Evrimsel olmayan ilave katmanlar da bunun bir parçası olabilir [174].

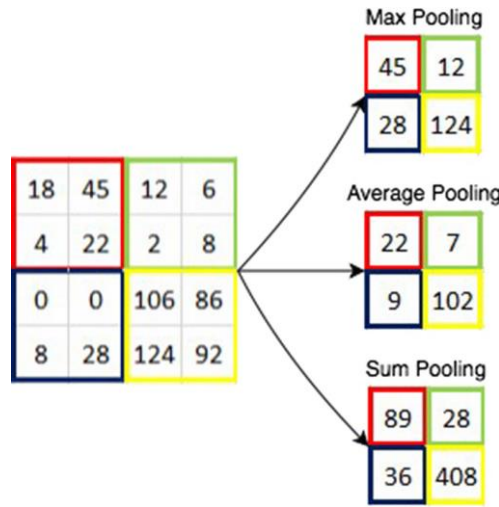
Evrişimli katmanlar, optimize edilebilir birkaç filtre ekleyerek girişi veya önceki gizli katmanları değiştirmektedir. Bir evrişimli katmanın derinliği, filtre sayısına göre belirlenmektedir. Takip eden dönüşümler, mevcut konuyla ilgili temel kalıpları vurgulamayı amaçlamaktadır. Konvolüsyon yani filtrenin katman üzerinde kaydırılması ve filtre ile katmanın değerlerinin iç çarpımının hesaplanması, önemli kalıpların yinelemeli olarak nasıl öğrenildiğini açıklamaktadır. Sonuç olarak, her filtre için yeni bir iç çarpımı katmanı olan bir özellik haritası elde edilmektedir [174].

Bir CNN'in ilk özellik haritaları kenarlar, daireler veya köşeler gibi temel, ince ölçekli örüntülere sahip olabilir. Türetilen özellik haritaları, bir sonraki katman için giriş verisi olarak kullanılmaktadır. Bu katman, başka bir evrişim katmanı olabilir veya tespit edilen özelliklere dayanarak bir sonuca ulaşan nihai bir katman olabilmektedir. Konvolüsyon genellikle bir ağın daha derin katmanlarında daha soyut kalıpları ve meme lezyonunun şekli gibi daha üst düzey kavramları ortaya çıkarır. Rastgele olarak başlatılan filtreler, model eğitim süreci sırasında ilgili görüntü özelliklerini tanımlamak için yinelemeli olarak optimize edilmektedir. Birbirini takip eden çoklu evrişim katmanlar ve bunların çeşitli filtreleri sayesinde ağ, bir sınıfın mevcut olup olmadığını belirlemek için bir görüntünün en küçük yönlerini bile tanımlayabilmektedir [174].

Tipik olarak, özellik haritaları, birçok evrişimli katman dizileri arasında uzamsal örnekleme işlemleri kullanılarak uzamsal olarak aşağı örneklenmektedir. Çeşitli hücreleri tek bir hücrede birleştirme işlemine örnekleme adı verilmektedir. Bu işlem bir görüntünün daha düşük bir uzamsal çözünürlükle yeniden örneklenmesine benzemektedir. Örneklemenin birden fazla faydası vardır: daha soyut özelliklerin ve ölçekler arasında uzamsal bağlamın tespit edilmesini sağlar, bu da anlamsal bilgileri yoğunlaştırmaktadır. Ayrıca, ayırt edici bilgileri korurken verilerin boyutunu azaltır, bu da model parametrelerinin sayısını, hesaplama yükünü ve aşırı öğrenme (overfitting) riskini azaltmaktadır [174].

Örnekleme, bir filtre boyutu, adım kaydırma (stride) (ardışık örnekleme işlemleri arasındaki mesafe) ve bir azaltma işlemi ile tanımlanır. Genellikle üç örnekleme tekniği kullanılır: "Max Pooling", "Average Pooling" ve "Sum Pooling". Maksimum

örnekleme genellikle en çok tercih edilen yöntemdir. Maksimum örnekleme, ağ içindeki güçlü aktivasyonları (kenar veya çizgi özellikleri gibi) korur ve örneğin ortalama örneklemenin aksine bunların ortalamasını almaz. Giriş özellik haritası, 2'ye 2 filtre boyutu ve 2'lik bir adımla tipik bir maksimum örnekleme işleminde 4 kat azaltılırken, çıkış hücreleri 2'ye 2 filtrenin içindeki dört giriş hücresinin maksimum değerini içermektedir [174]. Şekil 8.9'da örnekleme yöntemlerinin arasındaki farkı gösterilmiştir [175].




Şekil 8.9. Örnekleme yöntemleri [175].

CNN modellerinde, iki boyutlu özellik haritalarından oluşan bir önceki evrimsel katmanından gelen çıktıyı tek boyutlu bir diziye dönüştüren bir düzleştirme (Flatten) katmanı bulunmaktadır. Bu aşama, tam bağlı katmana geçişi kolaylaştırmak için gereklidir çünkü tam bağlı katmanlar yalnızca tek boyutlu dizilerle kullanılmaktadır [176].

Yoğun katmanlar (Dense Layers) olarak da bilinen, tam bağlı katmanlar, katmandaki her düğüm ile bir önceki katmandaki her düğüm arasında bağlantıya sahiptir. Erişimsel ve örnekleme katmanlarından çıkarılan özelliklerin sınıflandırılması, yoğun katmanların temel işlevidir. Son yoğun katmanda her hedef sınıfa ait tek bir yapay nöron bulunur ve her nöronun "Softmax" aktivasyon fonksiyonu 0 ile 1 arasında bir olasılık değeri üretmektedir [177].

CNN mimarileri büyük ölçüde çeşitlilik gösterir ve temelde görevin özelliklerine göre belirlenmektedir. Görev, görüntüleri sınıflandırmayı, segmentasyon veya bir görüntüdeki belirli nesnelere bulmayı içerebilmektedir. Sorunun karmaşıklığı, bir CNN mimarisinin uygun olup olmadığını önemli ölçüde belirlemektedir. Daha zor bir sorunu çözmek için genellikle daha derin, daha gelişmiş bir ağı ihtiyaç duyulmaktadır. Öte yandan, eğitim verilerinin sınırlı olması, aşırı uyum riskinin artması nedeniyle model karmaşıklığını kısıtlamaktadır. Gizli katmanların miktarını ve özelliklerini, örnekleme işlemlerini, regülarizasyon (regularization) yöntemlerini veya maliyet fonksiyonlarını (cost function) belirleyen bir CNN mimarisinin hiper parametreleri de ağın genel karmaşıklığını ve performansını etkilemektedir [174]. Şekil 8.10 CNN mimarisi göstermektedir [178].

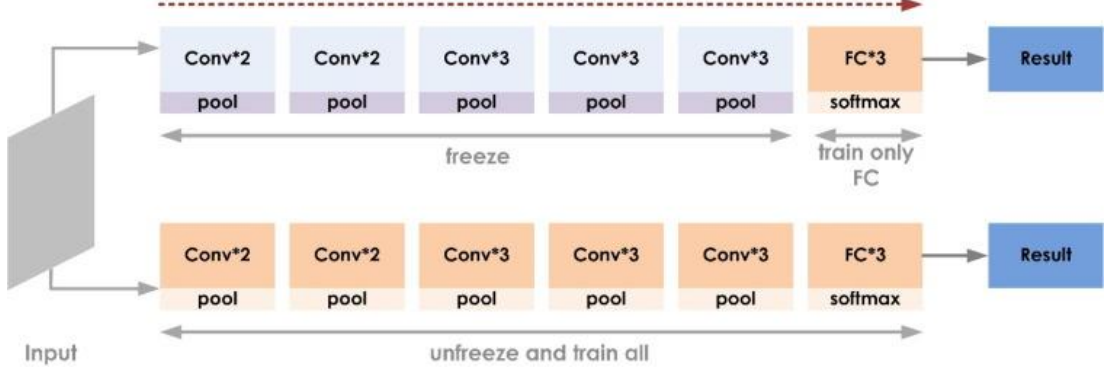


Şekil 8.10. CNN mimarisi [178].

8.3.1. Transfer Öğrenme (Transfer Learning) ve Ön Eğitimli CNN Modelleri

Bir alanda kazanılan karmaşık fikirleri kavrama ve başka bir alandaki benzer görevlere uygulama yeteneği insanların doğasında mevcuttur. Transfer öğrenme (Transfer Learning), bilgi aktarma tekniklerini simüle etmek için bilgisayar donanımını kullanma çabasıdır. Transfer öğrenme, ön eğitimli ağlara ince ayar yaparak farklı görevlerde kullanmayı amaçlamaktadır. Bu işlem teknik olarak, daha önce belirli bir amaç için belirli bir veri setiyle tamamen eğitilmiş bir ağın yeniden kullanılmasıyla gerçekleştirilmektedir. Yeniden kullanma, Şekil 8.11’de gösterildiği

gibi, ađın bazı ynlerinin yeni etki alanına uyacak Őekilde yeniden eđitilmesi Őeklinde gerŐekleŐmektedir [179].



Őekil 8.11. n eđitimi modelden đrenme aktarması iŐlemi sırasında tm konvolsyon katmanlarının dondurulmasđ ve yalnızca st katmanların eđitimi gerŐekleŐmektedir [179].

Tıbbi grnt uygulamaları iŐin eđitim verilerine eriŐim genellikle kısıtlıdır. Bu, gizlilik kaygıları ve byk miktarda veriyi etiketlemenin zorluđu nedeniyle. Bu durum, modelin eđitim sırasında karŐılaŐmadđđı verilere genelleme yapma yeteneđini olumsuz etkileyebilmektedir. Ayrıca, gerŐek eđitim, hesaplama sresi ve kaynaklar aŐısından maliyetlidir. Bu nedenle, seŐenek olarak deđerlendirilebilecek transfer đrenme teknikleri vardır. n eđitimi bir modelden zellik Őıkarma tekniđinden yararlanan transfer đrenme sayesinde geliŐtiriciler artık bir modeli eđitirken sıfırdan baŐlamak zorunda deđildir. Transfer đrenme modellerini eđitmek iŐin genellikle byk bir veri seti (ImageNet gibi) kullanılmaktadır. Eđitilen modelden elde edilen iliŐkili parametreler daha sonra zel bir sinir ađđ kullanılarak diđer ilgili uygulamalara uygulanabilmektedir. Bu tr modeller dođrudan yeni grev tahminlerine veya diđer uygulama eđitim prosedrlarına uygulanabilmektedir [180].

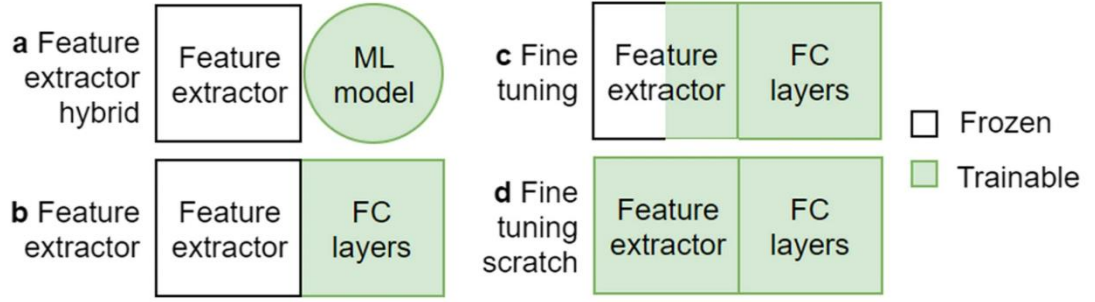
Tıbbi veri setleri tıbbi olmayan veri setlerinden farklı olsa da, transfer đrenme arkasındaki kavram, dŐk seviyeli zelliklerin (grntleri oluŐturan dz ve eđri Őizgiler gibi) grnt analizi grevlerinin Őođunda ortak olmasıdır. Bu nedenle, aktarılan parametreler (ađđrlıklar) etkili bir zellik seti olarak hizmet edebilir, bylece byk bir veri seti, eđitim sresi ve bellek harcamasđ gereksinimini

azaltılmaktadır. Transfer öğrenme genellikle iki yaklaşım kullanılır: özellik çıkarma (feature extraction) ve ince ayar (fine-tuning) [181].

Özellik çıkarma yaklaşımında, büyük bir veri seti (örn. ImageNet) üzerinde iyi eğitilmiş bir CNN modeli, tıbbi alan uygulaması için bir özellik çıkarıcı olarak kullanılmaktadır. Daha spesifik olarak, iyi eğitilmiş CNN modelinin tüm evrimsel katmanları dondurulurken, tam bağlı katmanlar kaldırılmaktadır. Evrimsel katmanları, tıbbi göreve uyum sağlamak için sabit bir özellik çıkarıcı görevi görmektedir. Çıkarılan özellikler daha sonra yeni tam bağlı katmanlar veya herhangi bir denetimli ML yöntemi olabilen bir sınıflandırıcıya beslenmektedir. Son olarak, eğitim sürecinde tüm ağ yerine yalnızca yeni sınıflandırıcı eğitilmektedir [182].

Öte yandan, ince ayarda, ön eğitilmiş CNN'in evrimsel katmanları dondurulmaz. Bunun yerine, ön eğitilmiş ağırlıklarla başlatılırken, sınıflandırıcı katmanları rastgele başlatılır. Eğitim sırasında hem evrimsel katmanlar hem de yeni sınıflandırıcı güncellenerek tüm ağın tıbbi alana adapte olması sağlanmaktadır. İnce ayar tipik olarak daha fazla esneklik ve gelişmiş performans potansiyeli sunar ancak özellik çıkarma yaklaşımına kıyasla daha fazla hesaplama kaynağı gerektirmektedir [182].

Bu yaklaşımların her biri kendi içinde iki alt kategoriye ayrılabilir. Şekil 8.12'de transfer öğrenme için kullanılan dört farklı teknik gösterilmektedir. Özellik çıkarıcı hibrit (Şekil 8.12a), diğer türlerde (Şekil 8.12b-d) bulunan ağların mimarisi korur, ancak tam bağlı katmanları kaldırır ve özellik çıkarıcıya SVM veya RF sınıflandırıcısı gibi bir ML yöntemi eklemektedir. En çok zaman alan yöntem sıfırdan ince ayar yapmaktır çünkü eğitim aşaması boyunca tüm parametreler topluluğunun güncellenmesini gerektirir [183].




Şekil 8.12. Dört tip transfer öğrenme yaklaşımı [183].

Bu tez çalışmasında, YOLO'nun çıktısı olarak elde edilen kesilmiş kitle görüntülerini sınıflandırmak için VGG16 ve ResNet50 ön eğitilmiş CNN modelleri kullanılmıştır.

8.3.1.1. VGG16

VGG16 mimarisi ilk olarak 2014 yılında Görsel Geometri Grubu (Visual Geometry Group (VGG)) tarafından ImageNet Büyük Ölçekli Görsel Tanıma Yarışması sırasında sunulmuştur. İki geliştirici Simonyan ve Zisserman'ın "Büyük Ölçekli Görüntü Tanıma için Çok Derin Konvolüsyon Ağları" adlı araştırma makalesinin amacı, yüksek nesne algılama ve görüntü sınıflandırma doğruluğu elde etmek için ağ derinliğinin ne kadar önemli olduğunu göstermektir. Bu model boyunca konvolüsyon katmanları bloklarında, ağın derinliğini artırmak için üst üste yığılmış bir şekilde birçok filtre kullanılmaktadır. Bu ağ, yüksek boyutlu filtreler yerine yalnızca 3x3 (conv3) filtreler kullanılarak basit hale getirilmiştir. Özellik matrisinin boyutunu azaltmak için maksimum örnekleme katmanları konvolüsyon katmanları bloklarından sonra yerleştirilmiştir. Böylece ağ, her bir konvolüsyon ve maksimum örnekleme katmanından sonra 4096 düğüme sahip iki tam bağlı katman içermektedir. Son olarak Softmax sınıflandırıcı 1000 (ImageNet sınıf sayısı) çıktı sınıfı ile gelir. VGG16 modelinin mimarisi 16 katman derinliğindedir ve 224x224 giriş görüntü boyutuna sahiptir [184]. VGG16'nın mimarisi Şekil 8.13'te gösterilmektedir [185].

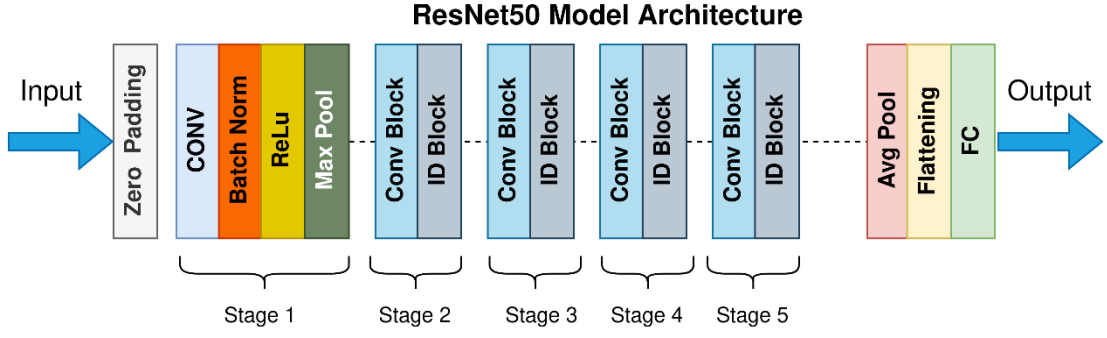


Şekil 8.13. VGG16 mimarisi [185].

8.3.1.2. ResNet50

ResNet, 2015 yılında He ve arkadaşları tarafından geliştirilmiştir. "Ağ içinde ağ mimarileri", "Artık bloklar" (Residual Blocks) veya "Kimlik bloğu" (Identity Block) olarak bilinen benzersiz mimarisi, mikro mimari modüllere dayanmaktadır. "ResNet50" adındaki modelin "50" sayısı, toplam katman sayısını temsil etmektedir. Bu ağ, bir seferde birkaç konvolüsyon katmanını atlamak için derin bir konvolüsyon sinir ağına bir kısayol bağlantısı ekleme prensibi ile çalışmaktadır. Bu kısayol bağlantıları artık bloklarla sonuçlanmaktadır. Artık blok, kendisine eklenen konvolüsyon katmanının çıktısını almaktadır. Daha derin ağın bozulma sorununun derin artık öğrenme mimarisi aracılığıyla ele alınması amaçlanmaktadır. Artık bloklar eklendiğinde, mimari bir artık ağ oluşturan 34 katmanlı bir ağdan oluşmaktadır [186].

3x3 konvolüsyondan önceki 1x1 konvolüsyon darboğazı ile ResNet50'nin katman derinliği VGG16'dan önemli ölçüde daha azdır. Sonuç olarak, ResNet50 VGG'den daha fazla katmana sahip olsa da, toplam parametre sayısı önemli ölçüde daha düşüktür. Ayrıca, ResNet50 tek bir maksimum örnekleme katmanı kullanmaktadır. Bunun yerine, çözünürlük azaltma işlemi, Şekil 8.14'teki adım 2 ile konvolüsyon kullanılarak gerçekleştirilmektedir [174]. Şekil 8.14, ResNet50'nin mimarisini göstermektedir[187].



Şekil 8.14. ResNet50 mimarisi [187].

8.3.2. CNN Uygulaması

Bu tez çalışmasında önerilen metodoloji, YOLO'dan elde edilen kesilmiş kitle görüntülerini sınıflandırmak için CNN ön eğitilmiş modellerin kullanılmasını içermektedir. Özellikle VGG16 ve ResNet50, ImageNet veri seti üzerinde halihazırda eğitilmiş olan ağırlıklarla birlikte bu çalışma için tercih edilmiştir. Transfer öğrenme yaklaşımları için sınıflandırıcıların performansı doğruluk (Accuracy), kesinlik (Precision), duyarlılık (Recall), F1 skoru ve karışıklık matrisi (Confusion Matrix) üzerinden incelenmiştir. VGG16 ve ResNet50 her bir ön eğitilmiş model için, hem Yöntem A hem de Yöntem B ile elde edilen kitle görüntüleri kullanılarak ayrı ayrı deneyler gerçekleştirilmiştir. Bu şekilde, dengesiz ve dengeli veriyle eğitilmiş YOLO'nun çıktılarının CNN modelinin girdisi olarak performansı test edilmiştir.

Çalışmaları yürütmek için Google Colaboratory kullanılmıştır. Yaygın olarak kullanılan DL framework'leri olan Keras ve Tensorflow da dahil olmak üzere gerekli dosyaların içe aktarılması, CNN ortamının kurulmasındaki ilk adımdır. Bir sonraki adım, veri seti dosyalarını Google Colaboratory ortamına yüklemektir. Veri seti her deneyde eğitim ve test için sırasıyla %80 ve %20 oranında bölünmüştür. Sınıf etiketlemesi ise 0'dan 2'ye kadar olan sınıflara "iyi huylu", "kötü huylu" ve "şüpheli" olarak atanmıştır. Ardından, giriş görüntüleri 224x224 olarak yeniden boyutlandırılmıştır. Daha sonra, ön eğitilmiş modellerin katmanları yüklendikten sonra dondurulmuştur. Sonrasında, aşırı uyumu azaltmak için 0.2'lik bir dropout oranına sahip bir dropout katmanı eklenmiştir. Ayrıca, ön eğitilmiş modelden elde

edilen çok boyutlu çıktı, özelliklerin çıkarıldığı katmanın üstüne bir düzleştirme katmanı eklenerek Sci-Kit Learn kütüphanesindeki geleneksel sınıflandırıcıların gereksinimine göre tek boyutlu bir diziye dönüştürülmüştür. Son olarak, iki yoğun katman (Dense Layer) eklenmiştir. İlk yoğun katman 512 nöron ve ReLU aktivasyon fonksiyonu içermektedir. Son yoğun katmanı ise, üç nöron (sınıf sayısına karşılık gelir) ve çok sınıflı sınıflandırma için Softmax aktivasyon fonksiyonundan oluşmaktadır. Softmax fonksiyonu, tüm bireysel sınıfların her veri noktası için 0 ile 1 arasında bir olasılık vermektedir. K sınıflardan oluşan bir kümedeki belirli bir j sınıfı için hesaplanan olasılık, Eşitlik 8.8 ile ifade edilmektedir [180].

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \text{ for } j = 1, \dots, K \quad (8.8)$$

Bunu takiben, eğitim aşamasına başlamak için 32'lik bir batch size seçilmiştir. Bu tezde CNN modeli eğitimi için 30, 50, 90, 120 ve 150 olmak üzere çeşitli epoch değerleri kullanılmıştır. Ayrıca CNN modeli, loss fonksiyonu olarak Kategorik Çapraz Entropi (Categorical Cross Entropy) ile Adam ve SGD optimizier kullanılarak eğitilmiştir. Bunun ardından, modelin performansını doğrulamak için test seti kullanılmıştır. Şekil 8.15, CNN uygulamasının akış diyagramını göstermektedir.



Şekil 8.15. CNN uygulamasının akış diyagramı.

8.4. PERFORMANS DEĞERLENDİRME METRİKLERİ

Bir modelin performansı, çoğunluğu modelin yaklaşımından etkilenen çeşitli metrikler kullanılarak değerlendirilmektedir. Performans değerlendirme metrikleri çoğunlukla modelin ne kadar iyi çalıştığını göstermek için kullanılmaktadır. Bu tez

çalışmasında, nesne tanıma ve sınıflandırma modelleri için kullanılan performans değerlendirme metrikleri bu kısımda ele alınmıştır.

Doğruluk veya hata oranı (Accuracy veya Error Rate), sınıflandırıcıların genelleme yeteneğini değerlendirmek için en yaygın kullanılan ölçütlerden biridir. Doğruluk, eğitilmiş bir sınıflandırıcının, eğitim sırasında görmediği verilerle karşılaştırıldığında doğru tahmin ettiği örneklerin toplamını ifade eden bir metriktir. Bu ölçüm, model tarafından üretilen çıktı ile beklenen çıktı arasındaki tutarsızlıkları ölçen temel bir performans ölçütüdür. Eşitlik 8.9 ile gösterilen doğruluk, eğitilmiş modelin genel performansını değerlendirmek için temel bir ölçüt sağlamaktadır [167].

$$\text{Doğruluk} = \frac{TP+TN}{TP+FN+FP+TN} \quad (8.9)$$

Burada, doğru pozitif (True Positive (TP)), meme kanseri hastası olarak doğru bir şekilde teşhis edilen vakaları temsil etmektedir. Doğru negatif (True Negative (TN)), sağlıklı olarak doğru bir şekilde teşhis edilen vakaları ifade etmektedir. Yanlış pozitif (False Positive (FP)), meme kanseri hastası olmayan ancak yanlışlıkla hasta olarak teşhis edilen vakaları temsil etmektedir. Yanlış negatif (False Negative (FN)), meme kanseri hastası olmasına rağmen yanlışlıkla sağlıklı olarak teşhis edilen vakaları göstermektedir.

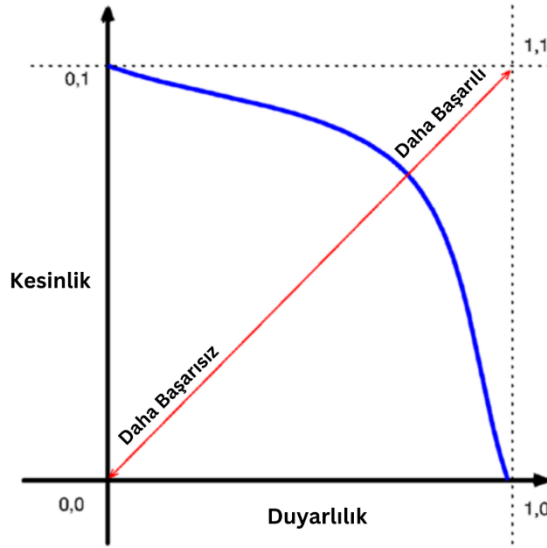
Kesinlik, pozitif olarak tahmin edilen verilerin ne kadarının doğru tahmin edildiğini göstermektedir. Başka bir deyişle, yüksek kesinlik, daha az FP anlamına gelmektedir. Kesinlik hesaplamak için Eşitlik 8.10 kullanılır [167]

$$\text{Kesinlik} = \frac{TP}{TP+FP} \quad (8.10)$$

Duyarlılık, Eşitlik 8.11'de gösterildiği gibi doğru tespit edilen meme kanser hasta sayısı (TP) ile toplam meme kanser hasta sayısı (TP+FN) arasındaki orantı olarak tanımlanabilir [167].

$$\text{Duyarlılık} = \frac{TP}{TP+FN} \quad (8.11)$$

Kesinlik ve duyarlılık (Precision-Recall (PR)) genellikle Şekil 8.16’da gösterildiği gibi bir PR eğrisi kullanılarak görselleştirilmektedir. PR eğrisi, kesinliği Y ekseninde ve duyarlılığı X ekseninde gösterir. Eğri üzerindeki her nokta, modelin çıktı puanlarına veya olasılıklarına uygulanan farklı bir karar eşiğini temsil etmektedir. Karar eşiği, modelin tahminleri puanlarına veya olasılıklarına göre nasıl sınıflandıracığını belirlemektedir. Örneğin, eşik daha düşük ayarlanırsa, daha fazla tahmin pozitif olarak sınıflandırılabilir (daha yüksek duyarlılık), ancak bu, potansiyel FP’ler nedeniyle daha düşük hassasiyete yol açabilmektedir. Tersine, daha yüksek bir eşik belirlemek hassasiyeti artırabilir ancak duyarlılık azaltabilmektedir [188].



Şekil 8.16. PR eğrisi [188].

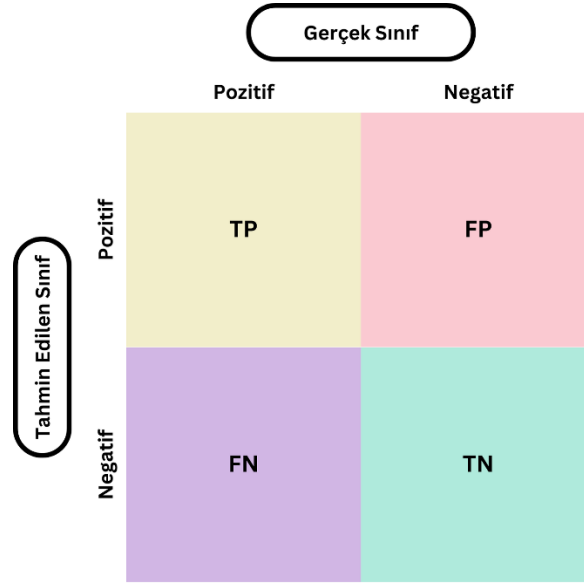
Özgüllük (Specificity), modelin mevcut her bir sınıfın TN tahmin etme yeteneği olarak tanımlanabilir. Özgüllüğü hesaplamak için Eşitlik 8.12 kullanılmaktadır [167].

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (8.12)$$

F1 skoru (F1 score), modelin kesinlik ve duyarlılık değerlerinin harmonik ortalaması olarak tanımlanmaktadır. F1 skoru yükseldikçe modelin daha iyi performans gösterdiği anlamına gelmektedir. F1 skoru Eşitlik 8.13 ile elde edilmektedir [167].

$$F1 \text{ skoru} = \frac{2 * Kesinlik * Duyarlilik}{Kesinlik + Duyarlilik} \quad (8.13)$$


ML’de en yaygın kullanılan performans değerlendirme yöntemlerden biri, bir sınıflandırma sisteminin belirlediği gerçek ve tahmin edilen sınıflar hakkında ayrıntılar içeren karışıklık matrisidir [189]. Şekil 8.17’de gösterildiği gibi her sütun tahmin edilen bir sınıfı temsil ederken, her satır gerçek bir sınıf örneğini göstermektedir.



Şekil 8.17. Karışıklık matrisi.

Eğitim kaybı (Training Loss), bir DL modelinin eğitim verilerine uyumunu değerlendirmek için kullanılan ve eğitim setindeki her örnek için hataların toplamını hesaplayarak hesaplanan bir metriktir. Öte yandan doğrulama kaybı (Validation Loss), modelin performansını doğrulamak için kullanılan veri setinin bir kısmı olan doğrulama seti üzerindeki performansını değerlendirmektedir. Doğrulama kaybı eğitim kaybından yüksekse, modelin yetersiz uyum (Underfitting) gösterdiği, yani verilerden etkili bir şekilde öğrenemediği ve hata yaptığı anlamına gelmektedir. Aşırı uyum (Overfitting), doğrulama kaybı yine eğitim kaybından yüksek ancak sıklıkla dalgalanıyorsa ortaya çıkmaktadır. Bu, model eğitim verilerinden gürültü de dahil olmak üzere aşırı öğrendiğinde ve eğitim verilerinde iyi performans gösterirken test veri setinde kötü performans gösterdiğinde meydana gelmektedir. Aşırı uyum

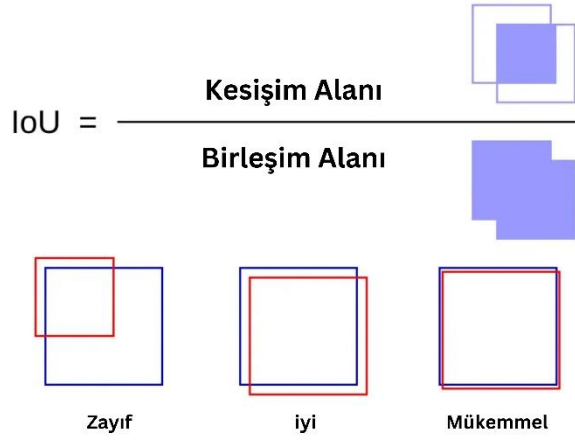
durumunda, doğrulama kaybı başlangıçta düşebilir ancak daha sonra tekrar yükselmeye başlamaktadır. Hem eğitim hem de doğrulama loss değerleri azaldığında ve sabitlendiğinde, bu optimal uyumu (Optimal fit) göstermektedir, bu da modelin iyi eğitilmiş olduğu ve aşırı veya yetersiz uyum olmadan test verilerine etkili bir şekilde genelleme yapabileceği anlamına gelmektedir [167]. Şekil 8.18, bahsedilen üç durumunun görünümünü sunmaktadır [190].



Şekil 8.18. Model doğrulama halleri. a) yetersiz uyum, b) optimal uyum, c) aşırı uyum [190].

Nesne tanıma bağlamında, TP, TN, FP ve FN kavramları sınıflandırmadakilere biraz farklıdır. Bir gerçek referans sınırlayıcı kutu (ground-truth bounding box) doğru bir şekilde tespit edildiğinde, bu TP olarak adlandırılmaktadır. Tersine, var olan bir nesne yanlışlıkla tespit edildiğinde veya var olmayan bir nesne yanlış tespit edildiğinde FP oluşmaktadır. Tespit edilmeyen bir gerçek referans sınırlayıcı kutuya FN denmektedir. TN sonucunun nesne algılama bağlamında geçersiz olduğunu belirtmekte fayda vardır çünkü her görüntüde algılanmaması gereken sonsuz sayıda sınırlayıcı kutu vardır [191].

Yukarıda bahsedilen kavramları uygulayabilmek için "doğru tespit" ve "yanlış tespit" kavramlarını tanımlamak gerekmektedir. IoU'yu hesaplamak bunu yapmak için yaygın olarak kullanılan bir yöntemdir. Tahmin edilen nesne sınırlayıcı kutuları ile gerçek referans veri sınırlayıcı kutusu arasındaki örtüşme derecesi, IoU'nun hesapladığı değerdir (Şekil 8.19). IoU, 0 ile 1 arasında değer alan bir metriktir ve ne kadar yüksek olursa, tahminin o kadar iyi olduğunu göstermektedir [191].



Şekil 8.19. Birlik Üzerinden Kesişim [192].

Bununla birlikte, nesne tespit modelinin doğruluğunu belirlemek için, tespit edilen nesnelerin gerçek referans verileriyle karşılaştırılması gerekmektedir. Ortalama Hassasiyet (Mean Average Precision (mAP)), nesne tanıma algoritmalarını değerlendirmek için yaygın olarak benimsenen bir metriktir. Birden fazla algılama sınıfındaki, her sınıf için PR eğrilerini dikkate alır ve hem hassasiyeti hem de duyarlılığını göz önünde bulundurarak nesne tanıma performansının kapsamlı bir değerlendirmesini sağlamaktadır. Eşitlik 8.14, mAP hesaplamak için kullanılmaktadır [191].

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (8.14)$$

Yukarıdaki eşitlikte, her bir i nesnesi için ortalama doğruluk ($\{AP\}_i$) değerlerinin toplanıp, toplam nesne sayısı N 'ye bölünmesiyle mAP hesaplanmaktadır.

BÖLÜM 9

BULGULAR

Bu tezdeki tüm deneyler Python programlama dili kullanılarak Google Colaboratory üzerinde gerçekleştirilmiştir. Bu bölümde, tezin YOLO ve CNN aşamalarında gerçekleştirilen eğitim ve test sonuçları incelenmiştir. Tüm eğitim deneylerinin test sonuçları çizelgeler şeklinde özetlenirken, en iyi performans gösteren modellerin elde ettiği grafiksel performans değerlendirme matrisleri de paylaşılmıştır.

9.1. YOLO

Daha önce belirtildiği gibi, mamografi görüntülerinde bulunan kitle tanıma işlemi gerçekleştirmek için YOLO kullanılmıştır. Bu çerçevede, YOLO'nun iki farklı versiyonu olan YOLOv5 ve YOLOv7 modelleri kullanılmıştır. İki versiyonun da alt modelleri test edilip en iyi sonuç veren modelin çıktısı, CNN aşamasının girdisi olarak kullanılmıştır.

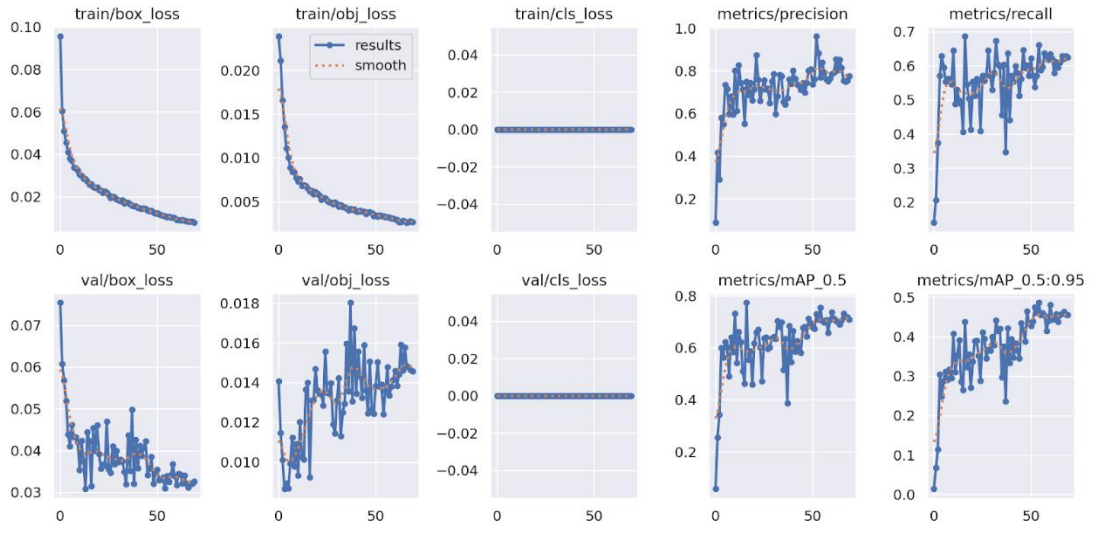
9.1.1. YOLOv5

Giriş görüntüsü 640x640 boyutunda alınarak YOLOv5n, YOLOv5s, YOLOv5m, YOLOv5l ve YOLOv5x modelleri eğitilmiştir. Bu eğitim deneyleri sonucunda test aşamaların sonuçları Çizelge 9.1'de sunulmuştur. YOLOv5 ile toplam 11 eğitim yapılmış olup, en iyi sonuçları elde etmek için hiper parametreler üzerinde çalışılmıştır.


Çizelge 9.1. YOLOv5 test sonuçları.

Model	Görüntü Boyutu	Optimizier	Batch size	Epoch	mAP@0.5 (%)	Kesinlik (%)	Duyarlılık (%)
Yolov5x	640x640	Adam	16	50	82.3	97.6	65.9
Yolov5x	640x640	SGD	16	50	90.1	99.7	80.5
Yolov5x	640x640	AdamW	16	50	79.0	90.6	62.6
Yolov5n	640x640	SGD	16	50	89.9	92.7	82.1
Yolov5s	640x640	SGD	16	50	89.4	98.0	79.1
Yolov5m	640x640	SGD	16	50	87.6	95.9	76.4
Yolov5l	640x640	SGD	16	50	89.6	96.9	79.7
Yolov5x	640x640	SGD	8	50	85.7	96.8	74.8
Yolov5x	640x640	SGD	32	50	89.4	98.0	79.5
Yolov5x	640x640	SGD	16	70	90.7	100.0	80.5
Yolov5x	640x640	SGD	16	90	89.8	96.1	80.5


Eğitimler YOLOv5x modeli, 16 batch size ve 50 epoch ile başlanmış olup, SGD, Adam ve AdamW optimizier'ları performansını değerlendirmek üzere ilk üç eğitim deneyleri gerçekleştirilmiştir. Bu optimizier'lar arasında en yüksek mAP veren SGD olmuştur. Ardından, seçilen SGD ile YOLOv5n, YOLOv5s, YOLOv5m ve YOLOv5l modelleri de eğitilmiş ve test edilmiştir. Bu testler sonucunda versiyonlar kıyaslandığında, YOLOv5x'in mAP, kesinlik ve duyarlılık açısından en yüksek değerler elde etmiştir. Daha sonra, en iyi batch size bulmak üzere, 8 ve 32 seçenekleri kullanarak ek eğitim deneyleri yapılmıştır. En yüksek mAP değerini veren YOLOv5x modeli için, SGD optimizier ile 16 batch size kullanılarak 70, 80 ve 90 epoch süreli eğitim deneyleri gerçekleştirilmiştir. En iyi performansı 70 epoch ile elde edilen modelin eğitim sonuçları Şekil 9.1-9.4'te sunulmuştur.



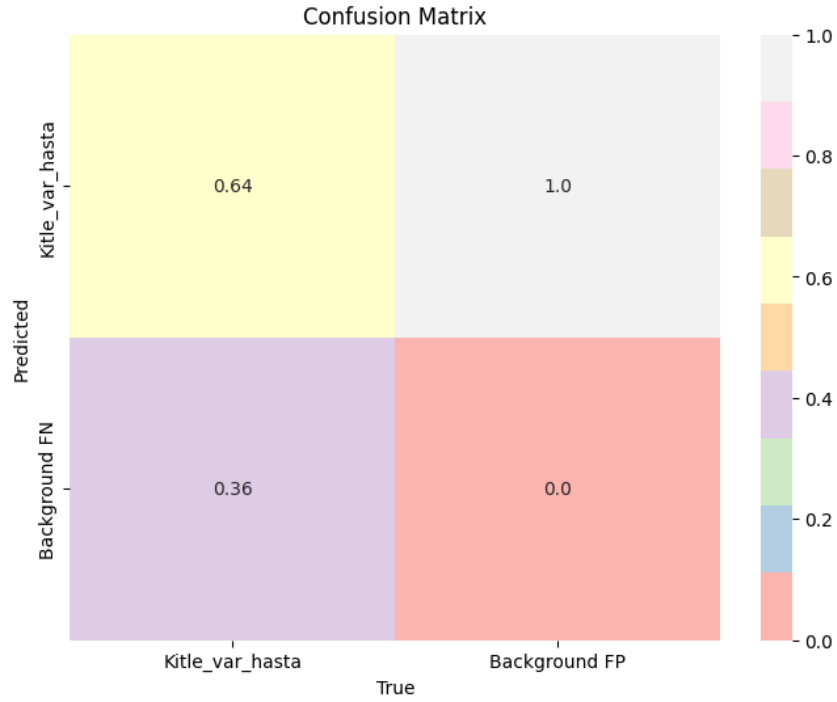
Şekil 9.1. Eğitim aşamanın loss ve doğruluk grafikleri.



Şekil 9.2. Eğitim aşamasından elde edilen F1-skoru grafiği.




Şekil 9.3. Eğitim aşamasından elde edilen PR eğrisi.




Şekil 9.4. Eğitim aşamasından elde edilen karışıklık matrisi.


Aynı modelin test aşamasından elde edilen performans değerlendirme grafikleri Şekil 9.5-9.7’de gösterilmiştir.



Şekil 9.5. Test aşamasından elde edilen F1-skoru grafiği.



Şekil 9.6. Test aşamasından elde edilen PR eğrisi.



Şekil 9.7. Test aşamasından elde edilen karışıklık matrisi.

9.1.2. YOLOv7

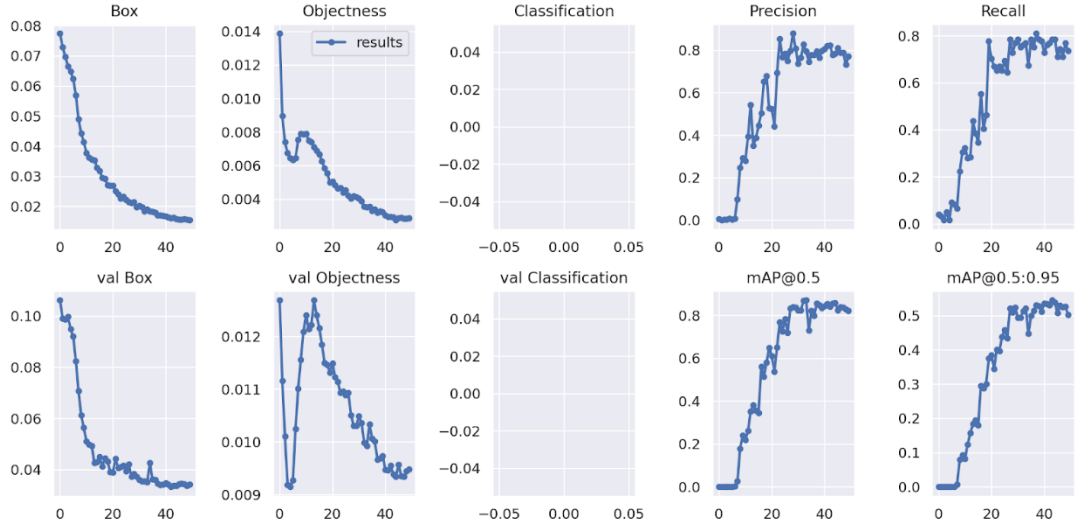
YOLOv7 eğitimlerinde, giriş görüntüleri YOLOv5'teki gibi 640x640 boyutunda kullanılmıştır. YOLOv7-tiny modeli için başlangıçta 16 batch size, SGD optimizier ve 50 epoch ile yapılan eğitimler, en yüksek doğruluğu sağlayan hiper parametreleri belirlemek için toplamda 7 farklı eğitim denemesi gerçekleştirilmiştir. Bu deneylerde, optimizier, YOLOv7 modeli, batch size ve epoch sayısı değiştirilerek farklı parametreler denenmiştir. Gerçekleştirilen YOLOv7'nin eğitim denemelerin sonuçları Çizelge 9.2'de özetlenmiştir.

Çizelge 9.2. YOLOv7 test sonuçları.


Model	Görüntü Boyutu	Optimizier	Batch size	Epoch	mAP @0.5 (%)	Kesinlik (%)	Duyarlılık (%)
YOLOv7-tiny	640x640	SGD	16	50	78.6	77.9	72.4
YOLOv7-tiny	640x640	Adam	16	50	80.9	87.2	732
YOLOv7	640x640	Adam	16	50	90.0	95.0	78.0

YOLOv7x	640x640	Adam	16	50	95.9	97.4	91.0
YOLOv7x	640x640	Adam	32	50	93.6	96.6	91.1
YOLOv7x	640x640	Adam	8	50	93.0	94.2	91.9
YOLOv7x	640x640	Adam	16	60	88.9	93.4	80.5


Bu testler arasında, YOLOv7x modeli, Adam optimizier ve 16 batch size ile 50 epoch süren eğitimde %95.9 ortalama hassasiyetle en yüksek doğruluğu gösteren model olarak seçilmiştir. Bu model, YOLOv5 ve YOLOv7 modelleri arasında en iyi performansı sergilediği için, çıktıları, CNN modelinin eğitilmesinde kullanılmıştır. Modelin eğitim sonuçları Şekil 9.8-9.11’de gösterilmiştir.




Şekil 9.8. Eğitim aşamanın loss ve doğruluk grafikleri.



Şekil 9.9. Eğitim aşamasından elde edilen F1-skoru grafiği.




Şekil 9.10. Eğitim aşamanın PR eğrisi.




Şekil 9.11. Eğitim aşamasından elde edilen karışıklık matrisi.


Aynı modelin test aşamasından elde edilen performans değerlendirme grafikleri Şekil 9.12-9.14'te gösterilmiştir.



Şekil 9.12. Test aşamasından elde edilen F1-skoru grafiği.



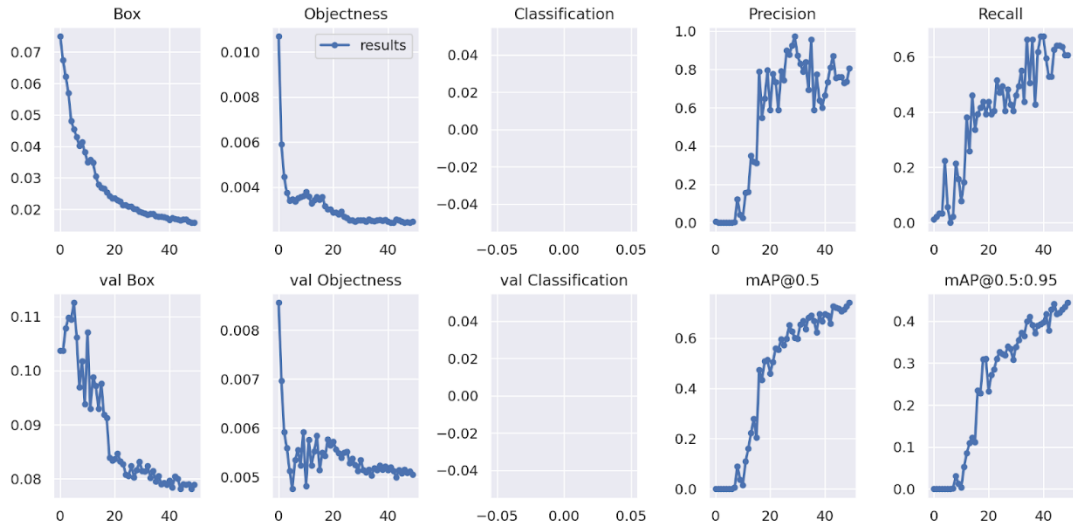
Şekil 9.13. Test aşamasından elde edilen PR eğrisi.




Şekil 9.14. Test aşamasından elde edilen karışıklık matrisi.

Önceki bölümlerde bahsedilen "Yöntem B" olarak adlandırılan yaklaşımın değerlendirilmesi için YOLO eğitiminde kitle içeren ve içermeyen (background)


görüntü sayıları arasında dengeyi sağlayan veri seti kullanılarak ek bir eğitim deneyi gerçekleştirilmiştir. Yöntem B’de kullanılan veri setin içerisinde 2232 görüntü mevcut. Bunlar içerisinde eşit sayıda kitle içeren ve kitle içermeyen görüntü mevcuttur. Bu yöntemde de Yöntem A’da olduğu gibi, görüntüler 80%, 10% ve 10% sırayla, eğitim, test ve doğrulama olarak ayrılmıştır. Yöntem B ile yapılan eğitim deneyinde kullanılan parametreler, YOLOv7 eğitimleri arasında en iyi sonuç veren modelin parametreleridir. Bu parametreler, YOLOv7x modeli, Adam optimizör, 16 batch size ve 50 epoch olarak belirlenmiştir. Bu yöntemin sonuçları, sırasıyla mAP %81.9, kesinlik %95.5 ve duyarlılık %72.6 olarak elde edilmiştir. Bu yöntemin eğitim ve test aşamasından elde edilen performans değerlendirme grafikleri Şekil 9.15-9.21’de sunulmuştur.




Şekil 9.15. Eğitim aşamanın loss ve doğruluk grafikleri.




Şekil 9.16. Eğitim aşamasından elde edilen F1-skoru grafiği.




Şekil 9.17. Eğitim aşamanın PR eğrisi.




Şekil 9.18. Eğitim aşamasından elde edilen karışıklık matrisi.



Şekil 9.19. Test aşamasından elde edilen F1-skoru grafiği.




Şekil 9.20. Test aşamasından elde edilen PR eğrisi.




Şekil 9.21. Test aşamasından elde edilen karışıklık matrisi.


Aşağıdaki Şekiller 9.22-9.24'te, kötü huylu, şüpheli ve iyi huylu sınıflarına ait kitle içeren görüntülerin, Yöntem A ve Yöntem B modelleri kullanılarak yapılan kitle tespit sonuçları gerçek referans sınırlayıcı kutularıyla birlikte sunulmuştur.



Şekil 9.22. Kötü hulu kitle tespiti. a) Yöntem A çıktısı, b) Yöntem B çıktısı, c) gerçek referans sınırlayıcı kutu.




Şekil 9.23. Şüpheli kitle tespiti. a) Yöntem A çıktısı, b) Yöntem B çıktısı, c) gerçek referans sınırlayıcı kutu.



Şekil 9.24. İyi huylu kitle tespiti. a) Yöntem A çıktısı, b) Yöntem B çıktısı, c) gerçek referans sınırlayıcı kutu.

Yöntem A ve Yöntem B’den elde edilen ağırlık dosyalarıyla sınırlayıcı kutulara göre kesilmiş görüntülerle yeni veri setleri oluşturulmuştur. Bu veri setleri, iyi huylu, şüpheli ve kötü huylu sınıflardan oluşan iki ayrı veri setidir. Her bir veri seti, ilgili yöntemden (A ve B) elde edilen görüntülerden oluşturulmuştur. Şekil 9.25’te bu veri sette bulunan her bir sınıfa ait bir örnek bulunmaktadır.



Şekil 9.25. Kitle veri seti. a) iyi huylu kitle, b) şüpheli kitle, c) kötü huylu kitle.

YOLOv5 ve YOLOv7’nin tüm modelleri başlangıçta 50 epoch ile eğitilmiştir. Çizelge 9.3, bu deneylerin eğitim süreleri ve test aşamasından elde edilen mAP ve doğruluk sonuçları özetlenmiştir.

Çizelge 9.3. YOLOv5 ve YOLOv7 modellerin performansı.

Model	Eğitim Süresi (Saat)	mAP@0.5 (%)	Doğruluk (%)
YOLOv5n	0.099	89.9	66.0
YOLOv5s	0.096	89.4	80.0
YOLOv5m	0.166	87.6	69.0
YOLOv5l	0.235	89.6	80.0
YOLOv5x	0.258	90.7	80.0
YOLOv7-tiny	1.810	80.9	74.0
YOLOv7	1.856	90.0	76.0
YOLOv7x	1.869	95.9	93.0

Şekil 9.26, Çizelge 9.3'te karşılaştırılan modellerin eğitim sürelerini boyunca mAP@0.5 değerlerin değişimini göstermektedir.



a



b

Şekil 9.26. YOLOv5 ve YOLOv7 modellerin mAP@0.5 eğrileri. a)YOLOv5 modelleri, b) YOLOv7 modelleri.

9.2. CNN

Bu tez çalışmasının ikinci aşamasında, CNN, önceki aşamada elde edilen kitle görüntülerini iyi huylu, şüpheli ve kötü huylu olarak sınıflandırmak için kullanılmıştır. Bu işlem, CNN'in ön eğitilmiş modellerini olan VGG16 ve ResNet50 modelleri kullanılarak gerçekleştirilmiştir. Kullanılan görüntüler %80 ve %20 oranında eğitim ve test olarak ayrılmıştır. Çeşitli hiper parametreler ve onların farklı değerleri ile en başarılı modeli tespit etmek amaçlanmıştır.


9.2.1. VGG16 Sonuçları

Yöntem A ve Yöntem B çıktularından oluşan veri setleri, eğitimlerde ayrı ayrı kullanılmıştır. Aşağıdaki Çizelge 9.4'te, Yöntem A veri setinin VGG16 modeliyle elde edilen test sonuçları gösterilmektedir.


Çizelge 9.4. Yöntem A veri setinin VGG16 test sonuçları.

Model	Epoch	Optimizer	Doğruluk (%)	F1-skoru (%)	Kesinlik (%)	Duyarlılık (%)
VGG16	30	Adam	83.5	83.0	85.0	83.0
VGG16	30	SGD	79.9	79.0	81.0	80.0
VGG16	50	Adam	83.8	84.0	86.0	84.0
VGG16	90	Adam	85.6	86.0	87.0	86.0
VGG16	120	Adam	89.6	90.0	90.0	90.0
VGG16	120	SGD	84.4	85.0	85.0	85.0
VGG16	150	Adam	83.1	83.0	85.0	83.0

Çizelge 9.4'te gösterildiği gibi, Yöntem A ve VGG16 eğitimleri arasında en yüksek doğruluk Adam optimizör ve 120 epoch ile elde edilmiştir. Bu modelin performans grafikleri ve karışıklık matrisi şekil 9.27 ve 9.28'de sunulmuştur.



Şekil 9.27. Performans grafikleri. a) loss grafiği, b) doğruluk grafiği.




Şekil 9.28. Karışıklık matrisi.

Yöntem B veri setinin VGG16 modeli ile elde edilen test sonuçları Çizelge 9.5'te gösterilmiştir.


Çizelge 9.5. Yöntem B veri setinin VGG16 test sonuçları.

Model	Epoch	Optimizer	Doğruluk (%)	F1-skoru (%)	Kesinlik (%)	Duyarlılık (%)
VGG16	30	Adam	87.1	87.0	87.0	87.0
VGG16	30	SGD	83.3	83.0	83.0	83.0
VGG16	50	Adam	88.0	88.0	88.0	88.0
VGG16	90	Adam	88.0	88.0	88.0	88.0
VGG16	120	Adam	86.6	87.0	87.0	87.0
VGG16	150	Adam	88.5	89.0	89.0	89.0
VGG16	150	SGD	86.6	87.0	87.0	87.0

Çizelge 9.5'te görüldüğü gibi, Yöntem B ve VGG16 eğitimleri için en yüksek doğruluk, Adam optimizer ve 150 epoch ile elde edilmiştir. Bu modelin performans grafiği ve karışıklık matrisi Şekil 9.29 ve 9.30'da gösterilmiştir.



Şekil 9.29. Performans grafikleri. a) loss grafiği, b) doğruluk grafiği.



Şekil 9.30. Karışıklık matrisi.


9.2.2. ResNet50 Sonuçları

Çizelge 9.6'da, Yöntem A veri setinin ResNet50 modeliyle elde edilen test sonuçları gösterilmektedir.


Çizelge 9.6. Yöntem A veri setinin ResNet50 test sonuçları.

Model	Epoch	Optimizer	Doğruluk (%)	F1-skoru (%)	Kesinlik (%)	Duyarlılık (%)
ResNet50	30	Adam	87.7	88.0	88.0	88.0
ResNet50	30	SGD	86.3	86.0	87.0	86.0
ResNet50	50	Adam	88.8	89.0	89.0	89.0
ResNet50	90	Adam	86.3	86.0	87.0	86.0
ResNet50	120	Adam	91.7	92.0	92.0	92.0
ResNet50	120	SGD	88.1	88.0	88.0	88.0
ResNet50	150	Adam	84.9	85.0	86.0	85.0

ResNet50 modeli kullanılarak 120 epoch boyunca gerçekleştirilen eğitim, %91.7 doğruluk ile CNN eğitimleri arasında en yüksek başarıya ulaşmıştır. Bu eğitimin performans grafikleri ve karışıklık matrisi Şekil 9.31 ve Şekil 9.32’de gösterilmiştir.



Şekil 9.31. Performans grafikleri. a) loss grafiği, b) doğruluk grafiği.




Şekil 9.32. Karışıklık matrisi.

Yöntem B veri setinin ResNet50 modeli ile elde edilen test sonuçları ise, Çizelge 9.7’de sunulmuştur.

Çizelge 9.7. Yöntem B veri setinin ResNet50 test sonuçları.

Model	Epoch	Optimizer	Doğruluk (%)	F1-skoru (%)	Kesinlik (%)	Duyarlılık (%)
ResNet50	30	Adam	87.1	87.0	87.0	87.0
ResNet50	30	SGD	67.9	62.0	80.0	68.0
ResNet50	50	Adam	86.6	87.0	87.0	87.0
ResNet50	90	Adam	87.0	87.0	88.0	87.0
ResNet50	120	Adam	88.9	89.0	89.0	89.0
ResNet50	120	SGD	89.9	90.0	90.0	90.0
ResNet50	150	Adam	88.5	89.0	89.0	89.0

Yöntem B veri setinin ResNet50 eğitimlerinde ulaştığı en yüksek doğruluk %89.9’dur. Bu doğruluk SGD optimizasyonu ve 120 epoch değeri ile elde edilmiştir. Şekil 9.33 ve 9.34, bu eğitimin performans grafikleri ve karışıklık matrisi göstermiştir.



Şekil 9.33. Performans grafikleri. a) loss grafiği, b) doğruluk grafiği.

iyi huylu	34	1	2
kötü huylu	1	93	9
şüpheli	3	5	61
	iyi huylu	kötü huylu	şüpheli

Şekil 9.34. Karışıklık matrisi.

BÖLÜM 10

TARTIŞMA

Bu tez çalışmasında, otomatik meme kanseri teşhisine yönelik hibrit bir DL yaklaşımı sunulmuştur. Bu tez çalışmasında INbreast veri seti kullanılmıştır. Bu veri setindeki 410 görüntünü 107'si kitle içerirken, geri kalan görüntüler, kalsifikasyon, yapısal distorsiyon ve sağlıklı görüntüler içermektedir. Önerilen yöntem, iki farklı DL modelini kullanmıştır. Kitle tespiti ve lokalizasyonu için YOLO'dan yararlanırken, tespit edilen kitlelerin iyi huylu, kötü huylu ve şüpheli olarak sınıflandırması için CNN modelleri kullanılmıştır.

Kitle tespitini içeren ilk aşamada YOLOv5 ve YOLOv7 versiyonları kullanılmıştır. Ayrıca, bu modeller üç farklı optimizör olan Adam, SGD ve AdamW kullanılarak kıyaslanmıştır. Mümkün olan en iyi performans, batch size ve epoch sayısı gibi hiper parametrelerin ayarlanmasıyla elde edilmeye çalışılmıştır. YOLOv5 için, maksimum mAP, duyarlılık ve kesinlik, YOLOv5x versiyonu, SGD optimizör, 16 batch size ve 70 epoch ile elde edilmiştir. YOLOv7x, Adam optimizör, 16 batch size ve 50 epoch süren eğitim, YOLOv7 için en yüksek mAP, duyarlılık ve kesinlik elde etmiştir.

YOLOv5 için SDG optimizör ve YOLOv7 için Adam optimizör kullanılmasına rağmen, tüm modeller aynı epoch sayısı, batch size ve her çalıştırma için aynı eğitim ve test ver setlerini kullanılarak uygulandığından, sonuçlar karşılaştırmalı olarak analiz edilebilir. Çizelge 9.3'te gösterildiği gibi, YOLOv7 ile karşılaştırıldığında, YOLOv5 modelleri nispeten daha kısa bir eğitim süresine sahiptir. Kullanılan tüm modeller arasında YOLOv5s en kısa eğitim süresine sahiptir. mAP değeri açısından, YOLOv7x %95.9 ile en yüksek skora sahiptir. YOLOv7x modeli ayrıca %93.0 ile en yüksek doğruluğu kaydetmiştir. YOLOv5 modelleri arasında ise YOLOv5x %90.7 mAP skoru ve %80.0 doğruluk oranı ile en yüksek

performansı sergilemiştir. Şekil 9.26, eğitim deneylerindeki eğitim süreci boyunca mAP@0.5 değerlerin değişimini göstermektedir.

YOLOv5x, YOLOv5 modelleri arasında, test aşamasında en yüksek doğruluk ve mAP değer veren model olmasına rağmen, eğitim aşamasında, diğer modellerle nispeten benzer eğri göstermiştir (Şekil 9.26a). YOLOv7 ve YOLOv7x eğitim süreci boyunca benzer bir performansla artarken, Şekil 9.26b’de gösterildiği gibi YOLOv7x son birkaç epochta YOLOv7’den daha üstün performans göstermektedir. Şekil 10.1, ilgili YOLO algoritmalarının en iyi iki modelini karşılaştırmaktadır. YOLOv5x eğitim süresinin, YOLOv7x’e kıyasla başlangıç aşamasında epoch sayısı ile birlikte mAP’nin hızlı bir şekilde arttığı, ancak YOLOv7’nin eğitimin son aşamasına doğru YOLOv5x eğitim süresinden daha iyi performans gösterdiği gözlemlenebilir.

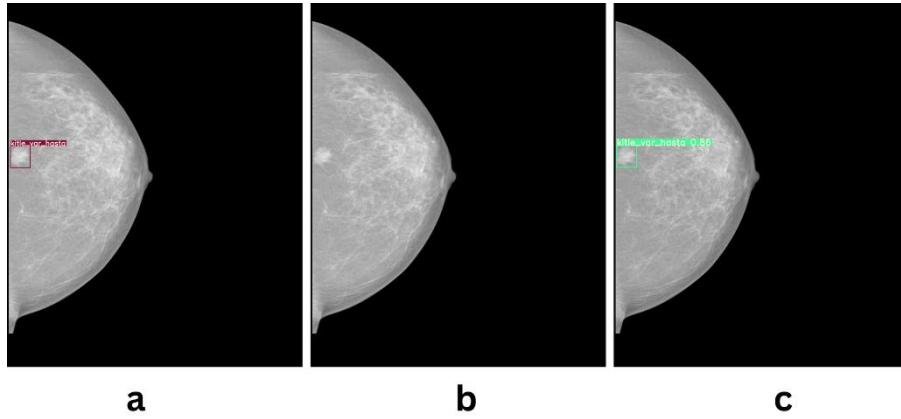


Şekil 10.1. YOLOv5x ve YOLOv7x modellerin karşılaştırması.


Daha düşük mAP puanlarına sahip olmasının yanı sıra, YOLOv5’in aşırı uyum (overfitting) sorunları da vardır. YOLOv5 modellerinin sonuç loss ve mAP eğrileri incelendiğinde, bunların önemli ölçüde dalgalandığı görülmektedir. Ayrıca, loss eğrilerinin birkaçı artıyor gibi görünmektedir ki bu da aşırı uyuma işaret etmektedir. Şekil 9.1’e bakıldığında, YOLOv5x’in eğitim ve doğrulama eğrileri karşılaştırıldığında, eğitim ve doğrulama loss eğrileri arasında kayda değer bir boşluk olduğu da fark edilmektedir. Bu da modelin eğitim setini çok iyi ezberlediği için yeni verilere genelleme yapamadığını gösterebilir. Bu da aşırı uyumun bir işareti olabilir.

Bununla birlikte, Yöntem A ile Yöntem B karşılaştırıldığında, Yöntem A’nın doğruluğu %93.0 iken, Yöntem B’nin doğruluğu %73.0’dır. Bu durum daha fazla


arka plan görüntüsü eklenerek performansı artırılmaya çalışılan Yöntem B'nin daha başarısız olduğunu göstermektedir. Şekil 10.2 ve 10.3 Yöntem B'nin FP ve FN tahmin olarak örnek sunmaktadır. Özellikle, Şekil 10.4'te gösterildiği gibi, bu model küçük kitleleri tanımlamakta başarısız olmuştur. Bu hatalar, bu yöntem kullanılarak elde edilen verilerin kalitesi üzerinde bir etkisi vardır ve bu da daha sonra sınıflandırma aşaması üzerinde bir etkiye yol açmıştır. Bu yaklaşım daha önce Pacal ve arkadaşları tarafından kolorektal kanser teşhisinde polip tespiti için YOLO kullanımına ilişkin bir çalışmada incelenmiştir. Bu çalışmada, pozitif ve negatif örneklerin oranları 1:1, 1:0.5 ve 1:10 olarak değerlendirilmiştir. Buna göre çalışma, negatif örneklerin oranı %10'dan fazla olmadığında, negatif örneklerle eğitimin daha iyi performans gösterdiği sonucuna varmıştır [193].



Şekil 10.2. Modellerin tahmini. a) gerçek referans, b) Yöntem B tahmini (FN), c) Yöntem A tahmini.




Şekil 10.3. Modellerin tahmini. a) gerçek referans, b) Yöntem B tahmini (FP), c) Yöntem A tahmini.




Şekil 10.4. Modellerin tahmini. a) gerçek referans, b) Yöntem B tahmini (küçük kitleleri tahmin edememesi), c) Yöntem A tahmini.

A ve B yöntemleri kullanılarak elde edilen kırpılmış kitle görüntüleri, bu tezin ikinci aşamasında iyi huylu, şüpheli ve kötü huylu olarak sınıflandırılmıştır. Bu adımda özellik çıkarıcı ve sınıflandırıcı olarak ön eğitilmiş CNN modelleri ResNet50 ve VGG16 kullanılmıştır. Her iki modeli eğitmek için SGD ve Adam optimizer'ları kullanılmıştır. Eğitim deneyleri 30, 50, 90, 120 ve 150 olmak üzere çeşitli epoch sayıları üzerinde ve 32'lik bir batch size'le gerçekleştirilmiştir.

ResNet50 modeli, Yöntem A veri setini kullanırken daha iyi sonuçlar vermiştir. Model, Yöntem B verisi ile eğitildiğinde ve özellikle SGD optimizör kullanıldığında, şüpheli ve kötü huylu kitleleri tanımlamakta zorlanmıştır. Bunun yanı sıra, SGD optimizör ile eğitilen ResNet50 modelleri, loss ve doğruluk grafikleri incelendiğinde, grafiklerinde daha fazla dalgalanma sergileme eğiliminde olduğu görülmektedir. Bu dalgalanma genellikle SGD kullanımlarında görülür, çünkü SGD parametrelerini sık sık günceller ve yüksek varyansa sahip parametrelerin sık sık güncellenmesi dalgalanmaya yol açmaktadır [194]. Adam optimizör kullanılarak 120 epoch süresince eğitilen model, Yöntem A için %91.7 ile en iyi sonucu üretmiştir. Yöntem B'de, 120 epoch ve SGD kullanılarak gerçekleştirilen eğitim ResNet50 modeli için %89.9 ile en iyi sonuç elde edilmiştir. Şekil 10.5'te, ResNet50 modeli için SGD ve Adam optimizörleri kullanılarak eğitilen en yüksek doğruluk sağlayan modellerin, Yöntem A ve Yöntem B için eğitim ve test performansı karşılaştırılmaktadır.




a




b

Şekil 10.5. ResNet50'nin Yöntem A ve Yöntem B veri setleri üzerinde SGD ve Adam optimizier'larla eğitim ve test doğruluk grafikleri. a) Yöntem A, b) Yöntem B.

Diğer yandan, Yöntem B verileriyle karşılaştırıldığında, VGG16 Yöntem A verilerini kullanırken daha iyi performans göstermiştir. Yöntem B verilerini kullanırken VGG16 sıklıkla kötü huylu sınıf için yanlış pozitif tahminlerde bulunmuş ve iyi huylu sınıfı tahmin etmede hataya düşmüştür. Adam optimizier her iki yöntem için de en iyi sonuçları vermiştir. B yönteminin 150 epoch kullanarak yapılan eğitimi, %88.5 ile bu yöntem için maksimum doğruluğu sağlamıştır. Yöntem A'da ise, 120 epoch kullanarak yapılan eğitimi VGG16 için %89.6 ile en iyi doğruluğu üretmiştir. Şekil 10.6'da, VGG16 modeli için SGD ve Adam optimizier'ları kullanılarak eğitilen en yüksek doğruluk sağlayan modellerin, Yöntem A ve Yöntem B için eğitim ve test performansı karşılaştırılmaktadır.



a



b

Şekil 10.6. VGG16'nın Yöntem A ve Yöntem B veri setleri üzerinde SGD ve Adam optimizer'larla eğitim ve test doğruluk grafikleri. a) Yöntem A, b) Yöntem B.

Genel olarak, Yöntem A'nın verilerini kullanan ResNet50 modeli, CNN aşamasında en yüksek doğruluk puanına sahip olmuştur. Gelecekteki araştırmalarda daha büyük bir veri seti kullanılması YOLO ve CNN modellerinin performansını artırabilir. Ayrıca segmentasyon, nesne tespitinden sonra ve sınıflandırma aşamasından önce uygulanarak sınıflandırma performansını geliştirebilir. Sınıflandırma aşamasına bir segmentasyon adımının dahil edilmesi, daha fazla araştırma gerektiren potansiyel bir alandır. Segmentasyon, tespit edilen kitlelerin kesin sınırlarını belirleyerek özellikleri hakkında değerli bilgiler sağlayabilir. Bu bilgiler, modelin iyi huylu, kötü huylu ve şüpheli kitleler arasında daha da yüksek doğrulukla ayırım yapma becerisini potansiyel olarak geliştirebileceği düşünülmektedir. Bunun için U-Net ve Mask R-CNN modelleri kullanılabilir seçeneklerdir.

Çizelge 10.1, önerilen yöntem ile mamografi görüntülerinde kitle tespiti ve sınıflandırması yapan diğer çalışmaların karşılaştırmasını sunmaktadır. Bu tezde

önerilen metodoloji, farklı bir yaklaşımla uygulanmış olup, mevcut çalışmaların elde ettiği doğruluk değerlerine ulaşmayı başarmıştır. Ayrıca, bu tezde diğer çalışmalardan farklı olarak, sınıflandırma aşamasında şüpheli kitlelerin belirlenmesi ve sınıflandırılması süreci, önerilen yöntemin ayırt edici bir özelliği olarak öne çıkmaktadır. Şüpheli kitleler, uzman tarafından iyi huylu veya kötü huylu olduğuna dair kesin karar verilmediği kitlelerdir. Genellikle ekstra takip veya biyopsi gerektirmektedir. Bu nedenle, sınıflandırma aşamasına şüpheli kitle sınıflandırmasını dahil etmek, DL modelin başarı oranını düşüreceği ön görülmektedir. Ancak, şüpheli sınıfının eklenmesi, daha fazla bilgi sağlayarak tanı sürecini iyileştirebileceğini düşünülmektedir.

Çizelge 10.1. Önceki araştırma çalışmalarına genel bakış.

Yayın	Yöntem	Veri seti	Sınıflar	Kitle tespit doğruluğu (%)	Sınıflandırma doğruluğu (%)
Al-Antari vd. 2020 [195]	DL, YOLO9000	DDSM, INbreast	İyi huylu / Kötü huylu	99.1	97.5
	detector/ InceptionResNet-V2			97.2	95.3
Hamed vd. 2021 [196]	YOLOv4 ve Inception Net v3	INbreast	İyi huylu / Kötü huylu	97.8	91.0
Al-Antari vd. 2018 [197]	Morfolojik işlemlere dayalı görüntü işleme/ Derin inanç ağı ("Deep belief network" - DBN)	DDSM	Normal / İyi huylu / Kötü huylu	86.0	90.4
Al-Masni vd. 2018 [198]	FCNN, YOLO	DDSM	İyi huylu / Kötü huylu	99.7	97.0
Al-Antari vd. 2018 [199]	YOLO, FrCN, DCNN	INbreast	İyi huylu / Kötü huylu	98.9, Segmentasyon doğruluğu (%92.9)	95.6
Önerilen Yöntem	YOLOv7x ve ResNet50	INbreast	İyi huylu / Şüpheli / Kötü huylu	95.9	91.7

BÖLÜM 11

SONUÇ

Meme kanserinin erken teşhisi ölüm oranlarını azaltmak için büyük önem taşımaktadır. Ancak radyologların her gün analiz etmesi gereken mamogram sayısının giderek artması bir zorluk yaratmaktadır. AI destekli teşhis sistemleri, radyologları karar verme süreçlerinde desteklemek için değerli ikinci okuyucular olarak işlev görerek bu noktada devreye girmektedir. Bu tez, mamogramlardaki kitlelerin tespiti ve sınıflandırılması için DL modellerinden yararlanan özgün bir hibrit yöntemi sunmaktadır.

Tez çalışmasında kullanılan ve 410 görüntüden oluşan INbreast veri setinin içerisinde, toplamda 107 kitle içeren görüntü ve 62 sağlıklı görüntü kullanılmıştır. Bu veri seti, veri artırma teknikleri kullanılarak kitle içeren ve sağlıklı görüntü sayısı sırayla, 1183 ve 1116 görüntüye genişletilmiştir. Bu adımın gerçekleştirilmesi ile model genel olarak daha sağlam hale gelmekte ve daha geniş bir varyans aralığından öğrenebilmektedir. Önerilen yaklaşımın kendisi iki aşamaya ayrılmıştır. İlk aşama, tüm mamografi görüntüleri üzerindeki olası kitlelerin YOLO nesne algılama algoritması kullanılarak tanımlanmasıdır. YOLOv5 ve YOLOv7 değerlendirildikten sonra, YOLOv7 modelin, %95.9 mAP değerle, %90.7 mAP elde eden YOLOv5'ten daha yüksek performans sağlamıştır. Bu değer, Yöntem A olarak adlandırılan yöntem (%90 kitle görüntüsü ve %10 sağlıklı görüntü) kullanılarak elde edilmiştir. Aynı model Yöntem B olarak adlandırılan yöntem (%50 kitle ve %50 sağlıklı görüntü) kullanılarak eğitilmiştir ve %81.9 mAP değeri elde edilmiştir.

Tespitin ardından, her iki yöntem için, tanımlanan sınırlayıcı kutular kırılmış ve sınıflandırma aşamasına geçilmiştir. Burada, kitleleri iyi huylu, kötü huylu ve şüpheli olmak üzere üç sınıfa ayırmak için ön eğitilmiş CNN modellerinden yararlanılmıştır. VGG16 ve ResNet50 modelleri bu aşamada değerlendirilmiştir. Tez'de, Yöntem

A'dan elde edilen veri ile eğitilen ResNet50 mimarisi, sınıflandırma doğruluğu açısından, %91.7 doğruluk değeri sağlayarak, %89.6 doğruluk sağlayan VGG16 mimarisinden daha iyi performans göstermiştir. Bu durum, veri kullanılabilirliğinin kısıtlı olabileceği durumlarda önceden eğitilmiş modellerin faydasını vurgulamaktadır.

Bu tezde, mamogram analizi için DL tabanlı bir yaklaşımın potansiyelini ortaya koymaktadır. Kitle tespiti için YOLOv7x'i ve sınıflandırma için ResNet50 modelini kullanan önerilen model, en iyi performans gösteren çalışmalara yaklaşan bir doğruluk elde etmiştir. Bu, radyologlara erken ve doğru meme kanseri tespitinde yardımcı olma konusunda umut verici bir adım anlamına gelmektedir. Daha büyük ve daha çeşitli veri setleriyle testler de dahil olmak üzere daha fazla araştırma, modelin iyileştirilmesi ve gerçek dünyadaki etkinliğinin sağlanması için kritik öneme sahip olacaktır. Sonuç olarak, bu tür ilerlemeler erken teşhis oranlarını önemli ölçüde iyileştirme ve meme kanserinin daha etkili bir şekilde tespit ve tedavi edildiği bir geleceğe katkıda bulunma potansiyeline sahiptir.

KAYNAKLAR

1. Houssein, E. H., Emam, M. M., Ali, A. A., and Suganthan, P. N., "Deep and machine learning techniques for medical imaging-based breast cancer: A comprehensive review", *Expert Systems With Applications*, 167: 1-20 (2021).
2. Jairam, M. P. and Ha, R., "A review of artificial intelligence in mammography", *Clinical Imaging*, 88: 36-44 (2022).
3. Şehirli, E. and Aldashash, A., "A Review Of Deep Learning-Based Detection Methods Of Breast Cancer", *Middle East International Conference on Contemporary Scientific Studies-VIII*, Adana, 135-148 (2023).
4. Ellis, H. and Mahadevan, V., "Anatomy and physiology of the breast", *Surgery (Oxford)*, 31 (1): 11–14 (2013).
5. Sabel, M. S., "Essentials of breast surgery", *Mosby*, Philadelphia, 1-15 (2009).
6. Sun, S. X., Bostanci, Z., Kass, R. B., Mancino, A. T., Rosenbloom, A. L., Klimberg, V. S., and Bland, K. I., "Breast physiology: Normal and abnormal development and function", *The Breast: Comprehensive Management Of Benign And Malignant Diseases 5th ed*, *Elsevier*, Amsterdam, 37-56 (2018).
7. Anderson, E., "The role of oestrogen and progesterone receptors in human mammary development and tumorigenesis.", *Breast Cancer Research: BCR*, 4 (5): 197-201 (2002).
8. Harris, J. R., Pine, J. W., Goolsby, J., Moyer, E., Dougherty, B., and Mallon, T., "Diseases of the Breast 2nd ed", *Lippincott Williams & Wilkins*, Philadelphia, 1-15 (2001).
9. İnternet: Çalışkan, M., "Hastalarımıza Özel - Prof. Dr Müjgan Çalışkan", <https://drmujiangaliskan.com/category/hastalarimiza-ozel/> (2024).
10. Lawrence W. and Bassett MD., "Imaging of breast masses", *Radiologic Clinics Of North America*, 38 (4): 669-691 (2000).
11. Henkel, A., Cooper, R. A., Ward, K. A., Bova, D., and Yao, K., "Malignant-appearing microcalcifications at the lumpectomy site with the use of FloSeal hemostatic sealant", *American Journal Of Roentgenology*, 191 (5): 1371-1373 (2008).

12. Venta, L. A., Kim, J. P., Pelloski, C. E., and Morrow, M., "Management of complex breast cysts.", *American Journal Of Roentgenology*, 173 (5): 1331-1336 (2013).
13. Vorherr, H., "Fibrocystic breast disease: pathophysiology, pathomorphology, clinical picture, and management", *American Journal Of Obstetrics And Gynecology*, 154 (1): 161-179 (1968).
14. Budimlija, Z., Lu, C., Axler-DiPerte, G., Seifarth, J., Popiolek, D., Fogt, F., and Prinz, M., "Malignant tumors and forensics--dilemmas and proposals.", *Croatian Medical Journal*, 50 (3): 218-227 (2009).
15. Pui, M. H. and Movson, I. J., "Fatty tissue breast lesions", *Clinical Imaging*, 27 (3): 150-155 (2003).
16. Hernández, P.A., Estrada, T.T., Pizarro, A.L., Cisternas, M.D., and Tapia, C.S. "Breast calcifications: description and classification according to BI-RADS 5th Edition", *Rev. Chil. Radiol*, 22 (2): 80-91 (2016).
17. Internet: El-Feky, M. and Kruger, G., "Benign Breast Calcifications", <http://radiopaedia.org/cases/benign-breast-calcifications> (2024).
18. Tot, T., Gere, M., Hofmeyer, S., Bauer, A., and Pellas, U., "The clinical value of detecting microcalcifications on a mammogram", *Seminars In Cancer Biology*, 72: 165-174 (2021).
19. Liberman, L. and Menell, J. H., "Breast imaging reporting and data system (BI-RADS)", *Radiologic Clinics Of North America*, 40 (3): 409-430 (2002).
20. Gaur, S., Dialani, V., Slanetz, P. J., and Eisenberg, R. L., "Architectural distortion of the breast", *American Journal Of Roentgenology*, 201 (5): 662-670 (2013).
21. Reilley, A. F., "Breast asymmetry: classification and management", *Aesthetic Surgery Journal*, 26 (5): 596-600 (2006).
22. Stone, K. and Wheeler, A., "A Review of Anatomy, Physiology, and Benign Pathology of the Nipple", *Annals Of Surgical Oncology*, 22: 3236-3240 (2015).
23. Waldman, R. A., Finch, J., Grant-Kels, J. M., and Whitaker-Worth, D., "Skin diseases of the breast and nipple: Inflammatory and infectious diseases", *Journal Of The American Academy Of Dermatology*, 80 (6): 1483-1494 (2019).
24. Akram, M., Iqbal, M., Daniyal, M., and Khan, A., "Awareness and current knowledge of breast cancer", *Biological Research*, 50: 1-23 (2017).
25. Apantaku, L. M., "Breast Cancer Diagnosis and Screening", *American Family Physician*, 62 (3): 596-602 (2000).

26. İnternet: Amerikan Kanser Derneği tıbbi ve editoryal içerik ekibi , "Breast Cancer: Introduction | Cancer.Net", <https://www.cancer.org/cancer/types/breast-cancer/if-you-have-breast-cancer.html> (2022).
27. West, A.K.V., Wullkopf, L., Christensen, A., Leijnse, N., Tarp, J.M., Mathiesen, J., Erler, J.T., and Oddershede, L.B., "Division induced dynamics in non-Invasive and invasive breast cancer", *Biophysical Journal*, 112 (3): 123a (2017).
28. Nakhlis, F. and Morrow, M., "Ductal carcinoma in situ", *Surgical Clinics*, 83 (4): 821-839 (2003).
29. Frykberg, E. R., "Lobular Carcinoma In Situ of the Breast", *The Breast Journal*, 5 (5): 296-303 (1999).
30. Harris, L.N., Ismaila, N., McShane, L.M., and Hayes, D.F., "Use of Biomarkers to Guide Decisions on Adjuvant Systemic Therapy for Women With Early-Stage Invasive Breast Cancer: American Society of Clinical Oncology Clinical Practice Guideline Summary", *Journal Of Clinical Oncology Practice*, 12 (4): 384-389 (2016).
31. Ziperstein, M.J., Guzman, A., and Kaufman, L.J., "Evaluating breast cancer cell morphology as a predictor of invasive capacity", *Biophysical Journal*, 110 (3): 621a (2016).
32. İnternet: Lee, V., "Metastatic Breast Cancer", <https://www.breastcancer.org/types/metastatic> (2024).
33. Arpino, G., Bardou, V.J., Clark, G.M., and Elledge, R.M., "Infiltrating lobular carcinoma of the breast: tumor characteristics and clinical outcome", *Breast Cancer Research*, 6 (3): 1-8 (2004).
34. Molland, J.G., Donnellan, M., Janu, N.C., Carmalt, H.L., Kennedy, C.W., and Gillett, D.J., "Infiltrating lobular carcinoma—a comparison of diagnosis, management and outcome with infiltrating duct carcinoma", *The Breast Journal*, 13 (5): 389-396 (2004).
35. Somiari, R. I., Sullivan, A., Russell, S., Somiari, S., Hu, H., Jordan, R., George, A., Katenhusen, R., Buchowiecka, A., Arciero, C., Brzeski, H., Hooke, J., and Shriver, C., "High-throughput proteomic analysis of human infiltrating ductal carcinoma of the breast", *Proteomics*, 3 (10): 1863-1873 (2003).
36. Gallager, H.-, "Pathologic types of breast cancer: their prognoses", *Cancer*, 53 (3): 623-629 (1984).
37. Cooper, H.S., Patchefsky, A.S., and Krall, R.A., "Tubular carcinoma of the breast", *Cancer*, 42 (5): 2334-2342 (1978).

38. Hance, K. W., Anderson, W. F., Devesa, S. S., Young, H. A., and Levine, P. H., "Trends in Inflammatory Breast Carcinoma Incidence and Survival: The Surveillance, Epidemiology, and End Results Program at the National Cancer Institute", *JNCI: Journal Of The National Cancer Institute*, 97 (13): 966-975 (2005).
39. Robertson, F.M., Bondy, M., Yang, W., Yamauchi, H., Wiggins, S., Kamrudin, S., Krishnamurthy, S., Le-Petross, H., Bidaut, L., Player, A.N., and Barsky, S.H., "Inflammatory breast cancer: the disease, the biology, the treatment", *CA: a cancer journal for clinicians*, 60 (6): 351-375 (2010).
40. Arnold, M., Morgan, E., Rungay, H., Mafra, A., Singh, D., Laversanne, M., Vignat, J., Galow, J.R., Cardoso, F., Siesling, S., and Soerjomataram, I., "Current and future burden of breast cancer: Global statistics for 2020 and 2040", *The Breast*, 66: 15-23 (2022).
41. İnternet: "Breast Cancer Statistics And Resources | Breast Cancer Research Foundation", <https://www.bcrf.org/breast-cancer-statistics-and-resources> (2024).
42. İnternet: "Breast Cancer", <https://www.who.int/news-room/fact-sheets/detail/breast-cancer> (2024).
43. İnternet: "Cancer Today", <https://gco.iarc.fr/today/en/fact-sheets-populations#countries> (2024).
44. Ozmen, V., "Breast cancer in the world and Turkey", *The Journal Of Breast Health*, 4 (2): 6–12 (2008).
45. İnternet: Türkyılmaz, M., Oruç, E. İ., Dündar, S., Ergün, A. K., Sevinç, A., and Tütüncü, S. "Kanser İstatistikleri", <https://hsgm.saglik.gov.tr/tr/kanser-istatistikleri> (2024).
46. Özmen, V., "Breast cancer in Turkey: clinical and histopathological characteristics (analysis of 13.240 patients)", *The Journal Of Breast Health*, 10 (2): 98-105 (2014).
47. Karellas, A. and Vedantham, S., "Breast cancer imaging: A perspective for the next decade", *Medical Physics*, 35 (11): 4878-4897 (2008).
48. Kerlikowske, K., Grady, D., Rubin, S. M., Sandrock, C., and Ernster, V. L., "Efficacy of Screening Mammography: A Meta-analysis", *JAMA*, 273 (2): 149-154 (1995).
49. Kopans, D. B., "Sonography Should Not Be Used for Breast Cancer Screening Until Its Efficacy Has Been Proven Scientifically", *American Journal of Roentgenology*, 182 (2): 489-91 (2012).

50. Diakides, M., Bronzino, J., and Peterson, D., "Medical Infrared Imaging: Principles and Practices", *CRC Press*, Florida, 1-6 (2012).
51. Ibrahim, A. M. and Baharudin, B., "Classification of mammogram images using shearlet transform and kernel principal component analysis", *3rd International Conference on Computer and Information Sciences (ICCOINS)*, Kuala Lumpur, 340-344 (2016).
52. Kanadam, K. P. and Chereddy, S. R., "Mammogram classification using sparse-ROI: A novel representation to arbitrary shaped masses", *Expert Systems With Applications*, 57: 204-213 (2016).
53. Bronzino, J. and Peterson, D., "Biomedical Signals, Imaging, and Informatics 4th ed", *CRC Press*, Boca Raton (2015).
54. Shareef, M., Ashraf, M. A., and Sarfraz, M., "Natural cures for breast cancer treatment", *Saudi Pharmaceutical Journal*, 24 (3): 233-240 (2016).
55. Dromain, C. and Balleyguier, C., "Contrast-enhanced digital mammography", *Digital Mammography*, 187-198 (2010).
56. James, J. J. and Tennant, S. L., "Contrast-enhanced spectral mammography (CESM)", *Clinical Radiology*, 73 (8): 715-723 (2018).
57. Kuhl, C. K., "Abbreviated breast MRI for screening women with dense breast: the EA1141 trial", *The British Journal Of Radiology*, 91 (1090): 1-6 (2018).
58. Mohamed, A. A., Luo, Y., Peng, H., Jankowitz, R. C., and Wu, S., "Understanding Clinical Mammographic Breast Density Assessment: a Deep Learning Perspective", *Journal Of Digital Imaging*, 31 (4): 387-392 (2018).
59. Truhn, D., Schradang, S., Haarbuerger, C., Schneider, H., Merhof, D., and Kuhl, C., "Radiomic versus Convolutional Neural Networks Analysis for Classification of Contrast-enhancing Lesions at Multiparametric Breast MRI", *Radiology*, 290 (2): 290-297 (2019).
60. Kelly, K. M., Dean, J., Comulada, W. S., and Lee, S. J., "Breast cancer detection using automated whole breast ultrasound and mammography in radiographically dense breasts", *European Radiology*, 20 (3): 734-742 (2010).
61. Corsetti, V., Houssami, N., Ghirardi, M., Ferrari, A., Speziani, M., Bellarosa, S., Remida, G., Gasparotti, C., Galligioni, E., and Ciatto, S., "Evidence of the effect of adjunct ultrasound screening in women with mammography-negative dense breasts: interval breast cancers at 1 year follow-up", *European Journal Of Cancer*, 47 (7): 1021-1026 (2011).
62. Heywang-Köbrunner, S. H., Viehweg, P., Heinig, A., and Küchler, C. H., "Contrast-enhanced MRI of the breast: accuracy, value, controversies, solutions", *European Journal Of Radiology*, 24 (2): 94-108 (1997).

63. Honda, E., Nakayama, R., Koyama, H., and Yamashita, A., "Computer-Aided Diagnosis Scheme for Distinguishing Between Benign and Malignant Masses in Breast DCE-MRI", *Journal Of Digital Imaging*, 29 (3): 388–393 (2016).
64. Internet: Davis, L. E., "Mammogram and Breast MRI: What's the Difference?", <https://www.verywellhealth.com/difference-between-a-mammogram-and-a-breast-mri-430274> (2022).
65. Salhab, M., Al Sarakbi, W., and Mokbel, K., "The evolving role of the dynamic thermal analysis in the early detection of breast cancer", *International Seminars In Surgical Oncology*, 2: 1-5 (2005).
66. Gautherie, M. and Gros, C. M., "Breast thermography and cancer risk prediction", *Cancer*, 45 (1): 51–56 (1980).
67. Hossam, A., Harb, H. M., and Abd El Kader, H. M., "Automatic image segmentation method for breast cancer analysis using thermography", *JES. Journal Of Engineering Sciences*, 46 (1): 12-32 (2018).
68. Frize, M., Herry, C., and Roberge, R., "Processing of thermal images to detect breast cancer: Comparison with previous work", *Proceedings of the Second Joint 24th Annual Conference and the Annual Fall Meeting of the Biomedical Engineering Society][Engineering in Medicine and Biology*, Texas, 1159-1160 (2002).
69. Kandlikar, S. G., Perez-Raya, I., Raghupathi, P. A., Gonzalez-Hernandez, J. L., Dabydeen, D., Medeiros, L., and Phatak, P., "Infrared imaging technology for breast cancer detection—Current status, protocols and new directions", *International Journal Of Heat And Mass Transfer*, 108: 2303–2320 (2017).
70. Moskowitz, M., "Efficacy of computerized infrared imaging", *American Journal Of Roentgenology*, 181 (2): 596-596 (2003).
71. Schillaci, O., Danieli, R., Romano, P., Santoni, R., and Simonetti, G., "Scintimammography for the detection of breast cancer", *Expert Review Of Medical Devices*, 2 (2): 191-196 (2005).
72. Alnafea, M., "Detection and diagnosis of breast diseases", *Breast Imaging, IntechOpen*, Rijeka, 3-20 (2017).
73. Mohan, H., "Textbook of Pathology 6th ed.", *Jaypee Brothers Medical Pub*, New Delhi, 7-11 (2010).
74. Rubin, R., Strayer, D., and Rubin, E., "Rubin's Pathology: Clinicopathologic Foundations of Medicine 5th ed.", *LWW*, Baltimore (2008).
75. Spanhol, F. A., Oliveira, L. S., Petitjean, C., and Heutte, L., "A dataset for breast cancer histopathological image classification", *IEEE Transactions On Biomedical Engineering*, 36 (7): 1455-1462 (2015).

76. Alsolami, A. S., Shalash, W., Alsaggaf, W., Ashoor, S., Refaat, H., and Elmogy, M., "King Abdulaziz University Breast Cancer Mammogram Dataset (KAU-BCMD)", *Data*, 6 (11): 1-15 (2021).
77. Al-Dhabyani, W., Gomaa, M., Khaled, H., and Fahmy, A., "Dataset of breast ultrasound images", *Data In Brief*, 28: 1-5 (2020).
78. Internet: Hacking, C., "Normal Breast MRI - Dense Breasts", <http://radiopaedia.org/cases/normal-breast-mri-dense-breasts-1> (2024).
79. Internet: Eagle Institute of Clinical Thermology, "About Breast Thermography - Breast Thermography | Breast Thermography", <https://breastthermography.com/breast-thermography/> (2024).
80. Brem, R. F., Schoonjans, J. M., Kieper, D. A., Majewski, S., Goodman, S., and Civelek, C., "High-Resolution Scintimammography: A Pilot Study", *The Journal Of Nuclear Medicine*, 43 (7): 909-915 (2002).
81. Internet: Johns Hopkins Pathology, "Types of Breast Cancer - Breast Pathology", <https://pathology.jhu.edu/breast/types-of-breast-cancer> (2024).
82. Welch, H. and Passow, H., "Quantifying the benefits and harms of screening mammography", *JAMA Internal Medicine*, 174 (3): 448-454 (2014).
83. Nelson, H. D., Tyne, K., Naik, A., Bougatsos, C., Chan, B. K., and Humphrey, L., "Screening for breast cancer: An update for the U.S. Preventive Services Task Force", *Annals Of Internal Medicine*, 151 (10): 727-737 (2009).
84. Gøtzsche, P. C. and Jørgensen, K. J., "Screening for breast cancer with mammography", *Cochrane Database Of Systematic Reviews*, (6): 1-70 (2013).
85. Holland, R., Rijken, H., and Hendriks, J., "The Dutch population-based mammography screening: 30-year experience", *Breast Care*, 2 (1): 12-18 (2007).
86. Suckling, J., Parker, J., Dance, D., Astley, S., Hutt, I., Boggis, C., Ricketts, I., Stamatakis, E., Cerneaz, N., Kok, S., Taylor, P., Betal, D., and Savage, J., "Mammographic image analysis society (mias) database v1. 21", *Apollo - University Of Cambridge Repository*, (2015).
87. Heath, M., Bowyer, K., Kopans, D., Kegelmeyer, P., Moore, R., Chang, K., and Munishkumar, S., "Current Status of the Digital Database for Screening Mammography", *In Proceedings of the 5th International Workshop on Digital Mammography*, Toronto, 212-218 (2000).
88. Lee, R., Gimenez, F., Hoogi, A., Miyake, K., and Gorovoy, M., "A curated mammography data set for use in computer-aided detection and diagnosis research", *Scientific Data*, 4 (1): 1-9 (2017).

89. Lopez, M.G., Posada, N., Moura, D.C., Pollán, R.R., Valiente, J.M.F., Ortega, C.S., Solar, M., Diaz-Herrero, G., Ramos, I.M.A.P., Loureiro, J., and Fernandes, T.C., "BCDR: a breast cancer digital repository", *15th International conference on experimental mechanics*, Porto, 113-120 (2012).
90. Halling-Brown, M. D., Warren, L. M., Ward, D., Lewis, E., Mackenzie, A., Wallis, M. G., Wilkinson, L. S., Given-Wilson, R. M., McAvinchey, R., and Young, K. C., "Optimam mammography image database: a large-scale resource of mammography images and clinical data", *Radiology: Artificial Intelligence*, 3 (1): 1-6 (2020).
91. Matheus, B. R. N. and Schiabel, H., "Online mammographic images database for development and comparison of CAD schemes", *Journal Of Digital Imaging*, 24 (3): 500–506 (2011).
92. Badano, A., Graff, C. G., Badal, A., Sharma, D., Zeng, R., Samuelson, F. W., Glick, S. J., and Myers, K. J., "Evaluation of digital breast tomosynthesis as replacement of full-field digital mammography using an in silico imaging trial", *Jama Network Open*, 1 (7): 1-12 (2018).
93. Nilsson, N. J., "The quest for artificial intelligence", *Cambridge University Press*, New York, (2010).
94. Kaul, V., Enslin, S. and Gross, S. A., "History of artificial intelligence in medicine", *Gastrointestinal endoscopy*, 92 (4): 807-812 (2020).
95. Russell, S. J. and Norvig, P., "Artificial Intelligence: A Modern Approach 3rd Edition", *Pearson*, New Jersey, 366-390, 437-460, 550-551, 693-755, 971-975 (2009).
96. Bishop, C. M., "Pattern Recognition and Machine Learning", *Springer*, New York, 225-277 (2006).
97. Lee, D. and Yoon, S. N., "Application of artificial intelligence-based technologies in the healthcare industry: Opportunities and challenges", *International Journal Of Environmental Research And Public Health*, 18 (1): 1-18 (2021).
98. Kirk, M. D., Pires, S.M., Black, R. E., Caipo, M., Crump, J.A., Devleeschauwer, B., Döpfer, D., Fazil, A., Fischer-Walker, C. L., Hald, T., and Hall, A. J., "World Health Organization Estimates of the Global and Regional Disease Burden of 22 Foodborne Bacterial, Protozoal, and Viral Diseases, 2010: A Data Synthesis", *PLoS Medicine*, 12 (12): 1-21 (2015).
99. Davenport, T. H. and Glaser, J., "Just-in-time delivery comes to knowledge management.", *Harvard Business Review*, 80 (7): 107-111 (2002).
100. Davenport, T. and Kalakota, R., "The potential for artificial intelligence in healthcare", *Future Healthcare Journal*, 6 (2): 94-98 (2019).

101. Zhao, M. and Jiang, Y., "Great expectations and challenges of artificial intelligence in the screening of diabetic retinopathy", *Eye*, 34 (3): 418-419 (2020).
102. Forghani, R., Savadjiev, P., Chatterjee, A., Muthukrishnan, N., Reinhold, C., and Forghani, B., "Radiomics and artificial intelligence for biomarker and prediction model development in oncology", *Computational And Structural Biotechnology Journal*, 17: 995–1008 (2019).
103. Peete, R., Majowski, K., Lauer, L., and Jay, A., "Artificial Intelligence in Healthcare", *Artificial Intelligence and Machine Learning for Business for Non-Engineers*, CRC Press, Boca Raton, 89-101 (2019).
104. Jafarian, F., Taghipour, M., and Amirabadi, H., "Application of artificial neural network and optimization algorithms for optimizing surface roughness, tool life and cutting forces in turning operation", *Journal Of Mechanical Science And Technology*, 27 (5): 1469–1477 (2013).
105. Badr, M., Al-Otaibi, S., Alturki, N., and Abir, T., "Detection of Heart Arrhythmia on Electrocardiogram using Artificial Neural Networks", *Computational Intelligence And Neuroscience*, 2022: 1-10 (2022).
106. Anaya-Isaza, A., Mera-Jiménez, L., and Zequera-Diaz, M., "An overview of deep learning in medical imaging", *Informatics In Medicine Unlocked*, 26: 1-29 (2021).
107. Engelbrecht, A., "Computational Intelligence: An Introduction 2nd ed", *John Wiley & Sons*, New Jersey, 17-24 (2007).
108. Ayodele, T. O., "Machine learning overview", *New Advances In Machine Learning, Rijeka*, 9-18 (2010).
109. Provost, F. and Kohavi, R., "On applied research in machine learning", *Machine Learning*, 30: 127-132 (1998).
110. Mahesh, B., "Machine learning algorithms-a review", *International Journal Of Science And Research (IJSR)*, 9 (1): 381–386 (2018).
111. Cios, K. J., Swiniarski, R. W., Pedrycz, W., and Kurgan, L. A., "Unsupervised learning: association rules", *Data Mining: A Knowledge Discovery Approach*, 289-306 (2007).
112. Sinaga, K. P. and Yang, M. S., "Unsupervised K-means clustering algorithm", *IEEE*, 8: 80716-80727 (2020).
113. Ghahramani, Z., "Unsupervised learning", *Advanced Lectures on Machine Learning*, Springer, Berlin, 72–112 (2003).

114. LeCun, Y., Bengio, Y., and Hinton, G., "Deep learning", *Nature*, 521: 436–444 (2015).
115. Kumar, R., "Machine Learning and Cognition in Enterprises: Business Intelligence Transformed", *Apress*, California, 58-59 (2017).
116. Ker, J., Wang, L., Rao, J., and Lim, T., "Deep learning applications in medical image analysis", *IEEE*, 6: 9375-9389 (2017).
117. Ganesan, K., Acharya, R. U., Chua, C. K., Min, L. C., Mathew, B., and Thomas, A. K., "Decision support system for breast cancer detection using mammograms", *Journal Of Engineering In Medicine*, 227 (7): 721-732 (2013).
118. Dhungel, N., Carneiro, G., and Bradley, A.P., "Automated mass detection in mammograms using cascaded deep learning and random forests", *2015 international conference on digital image computing: techniques and applications (DICTA)*, Adelaide, 1-8 (2015).
119. Jiao, Z., Gao, X., Wang, Y., and Li, J., "A deep feature based framework for breast masses classification", *Neurocomputing*, 197: 221-231 (2016).
120. Suzuki, S., Zhang, X., Homma, N., Ichiji, K., Sugita, N., Kawasumi, Y., Ishibashi, T., and Yoshizawa, M., "Mass detection using deep convolutional neural network for mammographic computer-aided diagnosis", *2016 55th Annual conference of the society of instrument and control engineers of Japan (SICE)*, Tsukuba, 1382-1386 (2016).
121. Jiang, F., Liu, H., Yu, S., and Xie, Y., "Breast mass lesion classification in mammograms by transfer learning", *Proceedings of the 5th international conference on bioinformatics and computational biology*, Hong Kong, 59–62 (2017).
122. Dhungel, N., Carneiro, G., and Bradley, A. P., "A deep learning approach for the analysis of masses in mammograms with minimal user intervention", *Medical image analysis*, 37: 114-128 (2017).
123. Ribli, D., Horváth, A., Unger, Z., Pollner, P., and Csabai, I., "Detecting and classifying lesions in mammograms with deep learning", *Scientific reports*, 8: 1-7 (2018).
124. Wu, N., Phang, J., Park, J., Shen, Y., Huang, Z., Zorin, M., Jastrzębski, S., Févry, T., Katsnelson, J., Kim, E., and Wolfson, S., "Deep neural networks improve radiologists' performance in breast cancer screening", *IEEE transactions on medical imaging*, 39(4): 1184-1194 (2019).
125. Li, H., Zhuang, S., Li, D. A., Zhao, J., and Ma, Y., "Benign and malignant classification of mammogram images based on deep learning", *Biomedical Signal Processing and Control*, 51: 347-354 (2019).

126. Rahman, A. S. A., Belhaouari, S. B., Bouzerdoum, A., Baali, H., Alam, T., and Eldaraa, A. M., "Breast mass tumor classification using deep learning", *2020 IEEE international conference on informatics, IoT, and enabling technologies (ICIoT)*, Doha, 271-276 (2020).
127. Saber, A., Sakr, M., Abo-Seida, O. M., Keshk, A., and Chen, H., "A novel deep-learning model for automatic detection and classification of breast cancer using the transfer-learning technique", *IEEE*, 9: 71194-71209 (2021).
128. Baccouche, A., Garcia-Zapirain, B., Olea, C. C., and Elmaghraby, A. S., "Breast Lesions Detection and Classification via YOLO-Based Fusion Models.", *Computers, Materials & Continua*, 69 (1): 1407-1425 (2021).
129. Mahmood, T., Li, J., Pei, Y., Akhtar, F., Rehman, M. U., and Wasti, S. H., "Breast lesions classifications of mammographic images using a deep convolutional neural network-based approach", *Plos one*, 17 (1): 1-25 (2022).
130. Öziç, M. Ü., Yılmaz, A. S., Sandıraz, H. İ., and Estanto, B. H., "A Comparative Study of Breast Mass Detection Using YOLOv8 Deep Learning Model in Various Data Scenarios on Multi-View Digital Mammograms", *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 12 (4): 1212-1225 (2023).
131. Prinzi, F., Insalaco, M., Orlando, A., Gaglio, S., and Vitabile, S., "A YOLO-based model for breast cancer detection in mammograms", *Cognitive Computation*, 16: 107-120 (2024).
132. Moreira, I. C., Amaral, I., Domingues, I., Cardoso, A., Cardoso, M. J., and Cardoso, J. S., "Inbreast: toward a full-field digital mammographic database", *Academic radiology*, 19 (2): 236-248 (2012).
133. Balleyguier, C., Ayadi, S., Van Nguyen, K., Vanel, D., Dromain, C., and Sigal, R., "BIRADS™ classification in mammography", *European journal of radiology*, 61 (2): 192-194 (2007).
134. Yarlagadda, R.T., "Python engineering automation to advance artificial intelligence and machine learning systems", *International Journal of Innovations in Engineering Research and Technology [Ijiert]*, 5 (6): 87-97 (2018).
135. Wu, Y., "Object-oriented programming course reform using python language in the background of artificial intelligence", *2019 3rd International Conference on Education, Management Science and Economics (ICEMSE 2019)*, Singapore, 93-96 (2019).
136. Riedel, R., Florides, C., Stein, S., Spütz, K., Guerrero, D. A., and Konrad, C., "Improving Parameter Traceability in Model-Based Product Development Processes through Integration of Python-Based Domain Models", *Procedia CIRP*, 119: 539-544 (2023).

137. Internet: Sell, L., "GitHub – HumanSignal/labelImg", <https://github.com/HumanSignal/labelImg> (2018).
138. Alasadi, S. A. and Bhaya, W. S., "Review of data preprocessing techniques in data mining", *Academia.Edu*, Journal of Engineering and Applied Sciences, 12 (6): 4102-4107 (2017).
139. Saponara, S. and Elhanashi, A., "Impact of image resizing on deep learning detectors for training time and model performance", *ApplePies 2021 International Conference on Applications in Electronics Pervading Industry, Environment and Society*, Pisa, 10-17 (2021).
140. Su, H., Deng, J., and Fei-Fei, L., "Crowdsourcing annotations for visual object detection", *Workshops at the twenty-sixth AAAI conference on artificial intelligence*, Toronto, 40-46 (2012).
141. Kaur, P., Khehra, B. S., and Mavi, E. B. S., "Data augmentation for object detection: A review", *2021 IEEE International Midwest Symposium on Circuits and Systems (MWSCAS)*, Lansing, 537-543 (2021).
142. Buslaev, A., Iglovikov, V. I., Khvedchenya, E., Parinov, A., Druzhinin, M., & Kalinin, A. A., "Albumentations: fast and flexible image augmentations", *Information*, 11(2): 1-20 (2020).
143. Perre, A. C., Alexandre, L. A., and Freire, L. C., "Lesion classification in mammograms using convolutional neural networks and transfer learning", *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 7 (5-6): 550–556 (2018).
144. Chougrad, H., Zouaki, H., and Alheyane, O., "Deep convolutional neural networks for breast cancer screening", *Computer methods and programs in biomedicine*, 157: 19-30 (2018).
145. Falconi, L. G., Perez, M., Aguilar, W. G., and Conci, A., "Transfer learning and fine tuning in breast mammogram abnormalities classification on CBIS-DDSM database", *Advances in Science, Technology and Engineering Systems Journal*, 5 (2): 154-165 (2020).
146. Lévy, D. and Jain, A., "Breast Mass Classification from Mammograms using Deep Convolutional Neural Networks", *Arxiv*, (2016).
147. Abdelhafiz, D., Yang, C., Ammar, R., and Nabavi, S., "Deep convolutional neural networks for mammography: advances, challenges and applications", *BMC bioinformatics*, 20 (11): 75-94 (2019).
148. Zhao, Z. Q., Zheng, P., Xu, S. T., and Wu, X., "Object detection with deep learning: A review", *IEEE transactions on neural networks and learning systems*, 30(11): 3212-3232 (2019).

149. Patel, S., and Patel, A., "Object detection with convolutional neural networks", *Machine Learning for Predictive Analysis: Proceedings of ICTIS 2020*, Ahmedabad, 141: 529-539 (2021).
150. Li, K., Ma, W., Sajid, U., Wu, Y., and Wang, G., "Object detection with convolutional neural networks", *Deep Learning in Computer Vision 1st ed*, **CRC Press**, Boca Raton, 41-62 (2020).
151. Qureshi, R., Ragab, M. G., Abdulkader, S. J., Alqushaib, A., Sumiea, E. H., and Alhussian, H., "A Comprehensive Systematic Review of YOLO for Medical Object Detection (2018 to 2023)", *Authorea Preprints*, 11: 1-31 (2023).
152. Redmon, J., Divvala, S., Girshick, R., and Farhadi, A., "You only look once: Unified, real-time object detection", *Proceedings of the IEEE conference on computer vision and pattern recognition*, Las Vegas, 779-788 (2016).
153. Ye, J., Yuan, Z., Qian, C., and Li, X., "Caa-yolo: Combined-attention-augmented yolo for infrared ocean ships detection", *Sensors*, 22(10): 1-23 (2022).
154. Hussain, M., "YOLOv1 to v8: Unveiling Each Variant—A Comprehensive Review of YOLO", *IEEE*, 12: 42816-42833 (2024).
155. Wang, C. Y., Yeh, I. H., and Liao, H. Y. M., "YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information", *ArXiv*, (2024).
156. Internet: Glenn, Jocher, " Ultralytics/Yolov5 · GitHub", <https://github.com/ultralytics/yolov5/blob/master/README.md> (2023).
157. Antonakakis, M., Tzavaras, A., Tsakos, K., Spanakis, E. G., Sakkalis, V., Zervakis, M., and Petrakis, E. G., "Real-Time Object Detection using an Ultra-High-Resolution Camera on Embedded Systems", *2022 IEEE International Conference on Imaging Systems and Techniques (IST)*, Kaohsiung, 1-6 (2022).
158. Liu, H., Sun, F., Gu, J., and Deng, L., "SF-YOLOv5: A Lightweight Small Object Detection Algorithm Based on Improved Feature Fusion Mode", *Sensors*, 22 (15): 1-14 (2022).
159. Wu, B., Pang, C., Zeng, X., and Hu, X., "Me-yolo: Improved yolov5 for detecting medical personal protective equipment", *Applied Sciences*, 12 (23): 1-17 (2022).
160. Terven, J., Córdova-Esparza, D. M., and Romero-González, J. A., "A Comprehensive Review of YOLO Architectures in Computer Vision: From YOLOv1 to YOLOv8 and YOLO-NAS", *Machine Learning And Knowledge Extraction*, 5 (4): 1680-1716 (2023).

161. Wang, C. Y., Bochkovskiy, A., and Liao, H. Y. M., "YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors", *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, Vancouver, 7464-7475 (2023).
162. Olorunshola, O. E., Irhebhide, M. E., and Ewwiekpaefe, A. E., "A comparative study of YOLOv5 and YOLOv7 object detection algorithms", *Journal of Computing and Social Informatics*, 2 (1): 1-12 (2023).
163. Yang, H., Liu, Y., Wang, S., Qu, H., Li, N., Wu, J., Yan, Y., Zhang, H., Wang, J., and Qiu, J., "Improved Apple Fruit Target Recognition Method Based on YOLOv7 Model", *Agriculture*, 13 (7): 1-21 (2023).
164. Li, Q., Yang, X., Lu, R., Fan, J., Wang, S., and Qin, Z., "VisionICE: Air-Ground Integrated Intelligent Cognition Visual Enhancement System Based on a UAV", *Drones*, 7 (4): 1-17 (2023).
165. Internet: "Tips for Best Training Results - Ultralytics YOLOv8 Docs", https://docs.ultralytics.com/yolov5/tutorials/tips_for_best_training_results/ (2024).
166. Habib, G. and Qureshi, S., "Optimization and acceleration of convolutional neural networks: A survey", *Journal of King Saud University-Computer and Information Sciences*, 34 (7): 4244-4268 (2022).
167. Mehmood, F., Ahmad, S., and Whangbo, T. K. "An efficient optimization technique for training deep neural networks", *Mathematics*, 11 (6): 1-22 (2023).
168. Kingma, D. P. and Ba, J., "Adam: A method for stochastic optimization", *ArXiv*, (2014).
169. Loshchilov, I. and Hutter, F., "Decoupled weight decay regularization", *ArXiv*, (2019).
170. Brownlee, J., "What is the Difference Between a Batch and an Epoch in a Neural Network", *Machine learning mastery*, 20: 1-5 (2018).
171. LeCun, Y., Jackel, L.D., Bottou, L., Cortes, C., Denker, J. S., Drucker, H., Guyon, I., Muller, U. A., Sackinger, E., Simard, P., and Vapnik, V., "Learning algorithms for classification: A comparison on handwritten digit recognition", *Neural networks: the statistical mechanics perspective*, 261 (276): 1-16 (1995).
172. Benyahia, S., Meftah, B., and L zoray, O., "Multi-features extraction based on deep learning for skin lesion classification", *Tissue and Cell*, 74: 1-15 (2022).
173. Wadhawan, A. and Kumar, P., " Deep learning-based sign language recognition system for static signs", *Neural computing and applications*, 32 (12): 7957-7968 (2020).

174. Kattenborn, T., Leitloff, J., Schiefer, F., and Hinz, S., "Review on Convolutional Neural Networks (CNN) in vegetation remote sensing", *ISPRS journal of photogrammetry and remote sensing*, 173: 24-49 (2021).
175. Seven, G., Silaharoglu, G., Kochan, K., Ince, A. T., Arici, D. S., and Senturk, H., "Use of Artificial Intelligence in the Prediction of Malignant Potential of Gastric Gastrointestinal Stromal Tumors", *Digestive Diseases And Sciences*, 67: 273–281 (2022).
176. Géron, A., "Hands-on machine learning with scikit-learn, keras, and tensorflow: concepts", *O'Reilly Media, Inc*, California, (2022).
177. Dar, R. A., Rasool, M., and Assad, A., "Breast cancer detection using deep learning: Datasets, methods, and challenges ahead", *Computers in biology and medicine*, 149: 1-23 (2022).
178. İnternet: Şebin, B., "Evrışimsel Sinir Ağı (Convolutional Neural Network)", <https://medium.com/@sebinbusra/evri%C5%9Fimsel-sinir-a%C4%9F%C4%B1-convolutional-neural-network-f49f7b65c72> (2022).
179. Kora, P., Ooi, C. P., Faust, O., Raghavendra, U., Gudigar, A., Chan, W. Y., Meenakshi, K., Swaraja, K., Plawiak, P., and Acharya, U. R., "Transfer learning techniques for medical image analysis: A review", *Biocybernetics and Biomedical Engineering*, 42 (1): 79-107 (2022).
180. Salehi, A. W., Khan, S., Gupta, G., Alabdullah, B. I., Almjally, A., Alsolai, H., Siddiqui, T., and Mellit, A., "A study of CNN and transfer learning in medical imaging: Advantages, challenges, future scope", *Sustainability*, 15 (7): 1-28 (2023).
181. Sharma, S. and Mehra, R., "Conventional Machine Learning and Deep Learning Approach for Multi-Classification of Breast Cancer Histopathology Images—a Comparative Insight", *Journal of digital imaging*, 33 (3): 632-654 (2020).
182. Morid, M. A., Borjali, A., and Del Fiol, G., "A scoping review of transfer learning research on medical image analysis using ImageNet", *Computers in biology and medicine*, 128: 1-14 (2021).
183. Kim, H. E., Cosa-Linan, A., Santhanam, N., Jannesari, M., Maros, M. E., and Ganslandt, T., "Transfer learning for medical image classification: a literature review", *BMC medical imaging*, 22 (1): 1-13 (2020).
184. Jena, B., Nayak, G. K., and Saxena, S., "Convolutional neural network and its pretrained models for image classification and object detection: A survey", *Concurrency and Computation: Practice and Experience*, 34 (6): 1-42 (2021).
185. İnternet: Leung, K., "How to Easily Draw Neural Network Architecture Diagrams | by Kenneth Leung | Towards Data Science", <https://towardsdatascience.com/how-to-easily-draw-neural-network-architecture-diagrams-a6b6138ed875> (2021).

186. Mohapatra, S., Muduly, S., Mohanty, S., Ravindra, J. V. R., and Mohanty, S. N., "Evaluation of deep learning models for detecting breast cancer using histopathological mammograms Images", *Sustainable Operations and Computers*, 3: 296-302 (2022).
187. İnternet: Mukherjee, S., " The Annotated ResNet-50 Explaining how ResNet-50 works and why it is so popular | by Suvaditya Mukherjee | Towards Data Science", <https://towardsdatascience.com/the-annotated-resnet-50-a6c536034758> (2022).
188. Ketkar, N. and Moolayil, J., "Deep Learning with Python 2nd ed", *Apress*, California, 150-151 (2021).
189. Taner, A., Öztekin, Y. B., and Duran, H., "Performance analysis of deep learning CNN models for variety classification in hazelnut", *Sustainability*, 13 (12): 1-13 (2021).
190. İnternet: d’Avezac, L., "How to Efficiently Design Machine Learning System | by Leopold d’Avezac | Towards Data Science", <https://towardsdatascience.com/how-to-efficiently-design-machine-learning-system-caef9e05d5fb> (2020).
191. Padilla, R., Netto, S. L., and Da Silva, E. A., "A survey on performance metrics for object-detection algorithms", *2020 international conference on systems, signals and image processing (IWSSIP)*, Niteroi, 237-242 (2020).
192. İnternet: Tomar, N., "What Is Intersection over Union (IoU) in Object Detection? — Idiot Developer | by Nikhil Tomar | Medium", <https://nikhilroxtomar.medium.com/what-is-intersection-over-union-iou-in-object-detection-idiot-developer-39448ac56431> (2023).
193. Pacal, I., Karaman, A., Karaboga, D., Akay, B., Basturk, A., Nalbantoglu, U., and Coskun, S., "An efficient real-time colonic polyp detection with YOLO algorithms trained by using negative samples and large datasets", *Computers in biology and medicine*, 141: 1-11 (2022).
194. Ruder, S., "An overview of gradient descent optimization algorithms", *Arxiv*, (2016).
195. Al-Antari, M. A., Han, S. M., and Kim, T. S., "Evaluation of deep learning detection and classification towards computer-aided diagnosis of breast lesions in digital X-ray mammograms", *Computer methods and programs in biomedicine*, 196: 1-15 (2020).
196. Hamed, G., Marey, M., Amin, S. E., and Tolba, M. F., "Automated breast cancer detection and classification in full field digital mammograms using two full and cropped detection paths approach", *IEEE*, 9: 116898-116913 (2021).

197. Al-Antari, M. A., Al-Masni, M. A., Park, S. U., Park, J., Metwally, M. K., Kadah, Y. M., Han, S. M., and Kim, T. S. "An automatic computer-aided diagnosis system for breast cancer in digital mammograms via deep belief network", *Journal of Medical and Biological Engineering*, 38: 443–456 (2018).
198. Al-Masni, M. A., Al-Antari, M. A., Park, J. M., Gi, G., Kim, T. Y., Rivera, P., Valarezo, E., Choi, M. T., Han, S. M., and Kim, T. S., "Simultaneous detection and classification of breast masses in digital mammograms via a deep learning YOLO-based CAD system", *Computer methods and programs in biomedicine*, 157: 85–94 (2018).
199. Al-Antari, M. A., Al-Masni, M. A., Choi, M. T., Han, S. M., and Kim, T. S., "A fully integrated computer-aided diagnosis system for digital X-ray mammograms via deep learning detection, segmentation, and classification", *International journal of medical informatics*, 117: 44-54 (2018).

ÖZGEÇMİŞ

Aya ALDASHASH 2012 yılında lise öğrenimini bitirmiştir. 2017 yılında Karabük Üniversitesi Tıp Mühendisliği bölümünde başladığı lisans eğitimini, 2021 yılında tamamlamıştır. 2021 yılında başladığı yüksek lisans eğitimini Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Biyomedikal Mühendisliği Anabilim Dalında “Derin Öğrenme Modellerine Dayalı Mamografi Görüntülerinin Sınıflandırılması” adlı tezini savunarak tamamlamıştır.