

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**AKTİF TERMOGRAMLAR ÜZERİNDEN MEME LEZYONLARINDA DERİN
ÖĞRENME YARDIMIYLA MALİNİTE TESPİTİ**

Soner ÇİVİLİBAL

**FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS**

OCAK 2022

ANTALYA

**T.C.
AKDENİZ ÜNİVERSİTESİ**



**AKTİF TERMOGRAMLAR ÜZERİNDEN MEME LEZYONLARINDA DERİN
ÖĞRENME YARDIMIYLA MALİNİTE TESPİTİ**

Soner ÇİVİLİBAL

**FEN BİLİMLERİ ENSTİTÜSÜ
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS**

OCAK 2022

ANTALYA

T.C.
AKDENİZ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

AKTİF TERMOGRAMLAR ÜZERİNDEN MEME LEZYONLARINDA DERİN
ÖĞRENME YARDIMIYLA MALİNİTE TESPİTİ

Soner ÇİVİLİBAL
BİYOMEDİKAL MÜHENDİSLİĞİ
ANABİLİM DALI
YÜKSEK LİSANS

Bu tez 26/01/2022 tarihinde jüri tarafından Oybirliği / ~~Oyçokluğu~~ ile kabul edilmiştir.

Prof. Dr. Ahmet BOZKURT (Danışman)

Doç. Dr. Kerim Kürşat ÇEVİK

Doç. Dr. Emre DANDIL

ÖZET

AKTİF TERMOGRAMLAR ÜZERİNDEN MEME LEZYONLARINDA DERİN ÖĞRENME YARDIMIYLA MALİNİTE TESPİTİ

Soner ÇİVİLİBAL

Yüksek Lisans, Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Ahmet BOZKURT

Ocak 2022; 67 sayfa

Gelişen bilgisayar donanımları ile paralel artış gösteren yapay zekâ uygulamaları, hızlı ve yüksek doğrulukta sonuç vererek erken tanıya olanak sağlamaları ve olası metastazların önlenmesi gibi avantajlarından dolayı biyomedikal alanında kanserli dokuların tespitinde sıklıkla tercih edilmektedir. Bu tez çalışmasında termal meme görüntüleri üzerinden meme bölgelerinin bölütlenmesi ve sınıflandırılması işlemleri çalışılmıştır. Açık veri setinden alınan termal görüntüler derin öğrenme modellerine verilmeden önce bazı ön işlemlerden geçirilmiştir. Ön işlemlerin ardından meme bölgeleri bölütlenerek eğitim işlemleri için meme bölgesi dışında kalan alanlar otomatik olarak kırılmıştır. Daha sonra sınıflandırma için iki farklı yöntem denenmiştir. İlk yöntemde meme bölgelerinin el yordamıyla bölütlenmesi ve transfer öğrenme uygulanarak sınıflandırılması yapılmıştır. İkinci yöntemde ise meme bölgelerinin otomatik bölütlenmesinin ardından transfer öğrenme uygulanarak lezyon sınıflandırılması çalışılmıştır. İkinci yöntemde kullanılan otomatik bölütleme işlemi için U-Net ve Mask R-CNN teknikleri denenmiş ve Mask R-CNN metodunun daha yüksek başarımlar göstermesi nedeniyle çalışmaya bu metod ile devam edilmiştir. Çalışmada kullanılan iki farklı yöntemin de eğitim işlemlerinde önceden eğitilmiş InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG16, VGG19 ve Xception mimarileri ile transfer öğrenme uygulanmıştır. Çalışmanın bulguları incelendiğinde en yüksek eğitim doğruluğu, kesinliği ve duyarlılığını Xception (%100) mimarisi vermiştir. Eğitilen mimarilerin test başarımları incelendiğinde InceptionV3 ve MobileNet mimarilerinde %100 doğruluk, kesinlik ve duyarlılık elde edilmiştir. Kullanılan mimariler arasında en uzun sürede eğitilen ve en geç test sonucu veren mimariler Xception ve VGG mimarileri olurken en hızlı test sonucu veren mimari ise MobileNet mimarisi olmuştur.

ANAHTAR KELİMELEER: Meme Lezyonu, Derin Öğrenme, Termal Görüntüleme, Sınıflandırma, Bölütleme

JÜRİ: Prof. Dr. Ahmet BOZKURT

Doç. Dr. Kerim Kürşat ÇEVİK

Doç. Dr. Emre DANDIL

ABSTRACT

DETERMINATION OF MALINITY BY DEEP LEARNING IN SOME BREAST LESIONS THROUGH ACTIVE THERMOGRAMS

Soner ÇİVİLİBAL

MSc Thesis in Biomedical Engineering

Supervisor: Prof. Dr. Ahmet Bozkurt

January 2022; 67 pages

Artificial intelligence applications, which have increased in parallel with advances in computer hardware, are frequently preferred in cancer detection in biomedical field because they give rapid and high accuracy results, enable early diagnosis and prevent possible metastasis. In this thesis, segmentation and classification of breast regions were studied by thermal breast images. The images taken from an online data set were preprocessed before they were given to deep learning models. Then, the mammary regions were segmented and clipped from the outer areas for further training procedures. After this, two different methods were tried for classification. In the first method, the breast regions were manually segmented and classified by applying transfer learning. In the second method, lesion classification was studied by applying transfer learning after automatic segmentation of breast regions. For the automatic segmentation process used in the second method, U-Net and Mask R-CNN techniques were tried and the study continued with Mask R-CNN method because of higher performance. For the training of both methods used in the study, transfer learning was applied with the pre-trained InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG16, VGG19 and Xception architectures. When the findings of the study were examined, the Xception architecture (100%) gave the highest training accuracy, precision and sensitivity. When the test performances of the trained architectures were examined, 100% accuracy, highest precision and sensitivity were obtained by InceptionV3 and MobileNet architectures. Among the architectures used, Xception and VGG architectures were the architectures that needed the longest training time, while the architecture that gave the fastest test results was the MobileNet architecture.

KEYWORDS: Breast Lesion, Deep Learning, Thermal Imaging, Classification, Segmentation

COMMITTEE: Prof. Dr. Ahmet BOZKURT

Assoc.Prof. Dr. Kerim Kürşat ÇEVİK

Assoc. Prof. Dr. Emre DANDIL

ÖNSÖZ

Bana yüksek lisans programım boyunca motivasyon ve desteklerini esirgemeyen, her konuda beni ve arkadaşlarımı bilgilendiren, bizlere yol gösteren, bizler için yoğun emek harcayan, gün/saat fark etmeksizin bizlerle iletişime geçip sorunlarımıza ortak olan, çözüm arayan ve bizleri evlatlarından ayırmayan danışmanım Prof. Dr. Ahmet Bozkurt'a, tezim boyunca kodlama ve diğer çalışma alanlarımda yardımcı olan ve yol gösteren Doç. Dr. Kerim Kürşat Çevik ve Doç. Dr. Emre DANDIL hocalarıma, beni lisans dönemimde yapay zeka konusuna yönlendiren ve lisans eğitimi dönemim bitmesine rağmen yardıma ihtiyacım olan her zaman yardımları benden esirgemeyen Dr. Öğr. Üyesi Aykut Eken ve Dr. Pınar Deniz Tosun hocalarıma, en önemlisi benim her zaman arkamda duran annem ve babam başta olmak üzere tüm aileme en içten dileklerle teşekkür ederim.

İÇİNDEKİLER

ÖZET.....	i
ABSTRACT.....	ii
ÖNSÖZ	iii
AKADEMİK BEYAN	vi
SİMGELER VE KISALTMALAR.....	vii
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ	xiii
1. GİRİŞ	1
2. KAYNAK TARAMASI	4
3. MATERYAL VE METOT	10
3.1. Meme Kanseri Tespitinde Kullanılan Görüntüleme Yöntemleri	10
3.2. Termal Görüntüleme Tekniği	11
3.2.1. Termal (kızılötesi / infrared) radyasyon	11
3.2.2. Termal kameralar.....	12
3.2.3. Statik (pasif) termal görüntüleme tekniği	13
3.2.4. Dinamik (aktif) termal görüntüleme tekniği.....	14
3.3. Görüntü İşleme Teknikleri	15
3.3.1. Görüntü bölütleme	16
3.3.2. Özellik çıkartma.....	17
3.3.3. Görüntü sınıflandırılması.....	18
3.4. Makine Öğrenmesi	18
3.4.1. Makine öğrenmesi algoritmaları.....	19
3.4.2. Çapraz doğrulama	21
3.4.3. Karmaşıklık matrisi	22
3.4.4. Bölütleme başarımlı değerlendirme yöntemleri	23
3.4.5. Alıcı-işleyici karakteristik (ROC) eğrisi.....	24
3.5. Derin Öğrenme	24
3.6. Evrişimsel Sinir Ağları (ESA).....	25

3.6.1. Giriş katmanı	27
3.6.2. Evrişim katmanları.....	27
3.6.3. Havuzlama katmanları	29
3.6.4. Tam bağlantılı katmanlar	30
3.6.5. Çıkış katmanı	32
3.7. Mask R-CNN.....	33
3.8. Transfer Öğrenme.....	35
3.9. Ön Eğitimli Sinir Ağı Mimarileri.....	35
3.9.1. AlexNet.....	36
3.9.3. GoogleNet.....	37
3.9.4. ResNet.....	37
3.9.5. VGG-Net.....	38
3.10. U-Net	39
4. BULGULAR.....	41
4.1. Veri Seti Oluşturma.....	41
4.2. Önerilen Yöntem	43
4.3. Transfer Öğrenme Modellerinin Eğitim ve Test Sonuçları.....	49
5. TARTIŞMA	55
6. SONUÇLAR	59
7. KAYNAKLAR	61
ÖZGEÇMİŞ	

AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduđum “Aktif Termogramlar Üzerinden Meme Lezyonlarında Derin Öğrenme Yardımıyla Malinite Tespiti” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynađını gösterdiğimi beyan ederim.

26/01/2022

Soner ÇİVİLİBAL



AKADEMİK BEYAN

Yüksek Lisans Tezi olarak sunduğum “Aktif Termogramlar Üzerinden Meme Lezyonlarında Derin Öğrenme Yardımıyla Malinite Tespiti” adlı bu çalışmanın, akademik kurallar ve etik değerlere uygun olarak yazıldığını belirtir, bu tez çalışmasında bana ait olmayan tüm bilgilerin kaynağını gösterdiğimi beyan ederim.

26/01/2022

Soner ÇİVİLİBAL

SİMGELER VE KISALTMALAR

Simgeler

.	: ondalık ayırıcı
F1	: kesinlik ve duyarlılık değerlerinin harmonik ortalamasını gösteren skor
Mat	: MATLAB programı tarafından kullanılan dosya formatı
Hz	: hertz
KHz	: kilo hertz
MHz	: mega hertz
GHz	: giga hertz
json	: JavaScript bilgi saklama ve transferi formatı
λ	: dalga boyu
μm	: mikrometre
A/D	: analogdan dijitale dönüşüm
D/A	: dijitalden analoga dönüşüm
C1, ... , Cn	: evrişim katmanlarının sayısı
P1, ... , Pn	: havuzlama katmanlarının sayısı
z_i	: softmax giriş vektörünün öğeleri
e^{z_i}	: giriş vektörünün her öğesine uygulanan üstel fonksiyon
K	: sınıf sayısı
Σ	: toplam sembolü

Kısaltmalar

AUC	: Area Under the Curve (Eğri Altında Kalan Alan)
BAT	: Brown Adipose Tissue (Kahverengi Yağ Dokusu)
BN	: Bayes Network (Bayes Ağı)
CLAHE	: Contrast Limited Adaptive Histogram Equalization

	(Kontrast Sınırlı Uyarlamalı Histogram Eşitleme)
CNN	: Convolutional Neural Network (Evrışimsel Sinir Ağları, ESA)
CPU	: Central Processing Unit (Merkezi İşlem Birimi)
CUDA	: Compute Unified Device Architecture (Compute Birleşik Cihaz Mimarisi)
DMR	: Database For Mastology Research (Mastoloji Araştırmaları Veritabanı)
DSA	: Derin Sinir Ağı
DT	: Decision Tree (Karar Ağacı)
DWT	: Discrete Wavelet Transform (Ayrık Dalgacık Dönüşümü)
FIR	: Far-Infrared (Uzak Kızılötesi)
FPR	: False Positive Rate (Yanlış Pozitif Oranı)
GLCM	: Gray Level Co-Occurrence Matrix (Gri Düzey Birlikte Oluşum Matrisi)
GPU	: Graphics Processing Unit (Grafik İşleme Ünitesi)
GVFS	: Gradient Vector Flow Snakes (Gradyan Vektör Akış Yılanları)
KNN	: K-Nearest Neighbors (K-En Yakın Komşular)
LDA	: Linear Discriminant Analysis (Doğrusal Ayırıcı Analiz)
LWIR	: Long-Wavelength Infrared (Uzun Dalga Boylu Kızılötesi)
MATLAB	: Matrix Laboratory (Matris Laboratuvarı)
mAP	: Mean Average Precision (Ortalama Hassasiyet)
MLP	: Multilayer Perceptron Network (Çok Katmanlı Algılayıcı)
MRG	: Manyetik Rezonans Görüntüleme
MWIR	: Mid-Wavelength Infrared (Orta Dalga Boylu Kızılötesi)
NIR	: Near-Infrared (Yakın Kızılötesi)
PCA	: Principal Component Analysis (Temel Bileşen Analizi)
PET	: Positron Emission Tomography (Pozitron Emisyon Tomografisi)
PNN	: Probabilistic Neural Network (Olasılıksal Sinir Ağı)

R-CNN	: Region-based CNN (Bölge Tabanlı Evrişimsel Sinir Ağı)
ReLU	: Rectified Linear Unit (Doğrultulmuş Doğrusal Birim)
RGB	: Red Green Blue (Kırmızı Yeşil Mavi)
ROC	: Receiver Operating Characteristic (Alıcı İşletim Karakteristiği)
ROI	: Region of Interest (İlgi Bölgesi)
RPN	: Region Proposal Network (Bölge Teklif Ağı)
RNN	: Recurrent Neural Networks (Tekrarlayan Sinir Ağları)
SIFT	: Scale Invariant Feature Transform (Ölçekle Değişmeyen Özellik Dönüşümü)
SPECT	: Single Photon Emission Computerized Tomography (Tek Foton Emisyonlu Bilgisayarlı Tomografi)
SVM	: Support Vector Machine (Destek Vektör Makinesi, DVM)
SWIR	: Short-Wavelength Infrared (Kısa Dalga Boylu Kızılötesi)
TL	: Transfer Learning (Transfer Öğrenme)
TPR	: True Positive Rate (Doğru Pozitif Oranı)
TRF	: Tree Random Forest (Ağaç Rastgele Orman)
VGG	: Visual Geometry Group (Görsel Geometri Grubu)
VIA	: VGG Image Annotator (VGG Görüntü Açıklaması)
WEKA	: Waikato Environment for Knowledge Analysis (Bilgi Analizi için Waikato Ortamı)

ŞEKİLLER DİZİNİ

Şekil 3.1. Elektromanyetik spektrum.....	12
Şekil 3.2. Termal kamera bileşenleri	13
Şekil 3.3. Statik termal görüntüleme.....	14
Şekil 3.4. Soğuk stres uygulaması ile görüntülenecek bölgenin (a) dijital kamera ile alınan görüntüsü, (b) termal kamera ile alınan görüntüsü ve (c) termal görüntüden seçilen lezyon görüntüsü	15
Şekil 3.5. Görüntü ön işleme (a) renkli görüntü, (b) gri seviye görüntüsü ve (c) siyah-beyaz görüntü	15
Şekil 3.6. Renkli görüntü oluşumu (a) kırmızı bileşeni, (b) yeşil bileşeni, (c) mavi bileşeni ve (d) üç bileşenin toplamı ile oluşan renkli görüntü	16
Şekil 3.7. Bölütleme örnekleri (a) orjinal görüntü, (b) eşikleme ile bölütleme, (c) kenar tabanlı bölütleme ve (d) bölgesel tabanlı bölütleme	16
Şekil 3.8. Özellik çıkarımı (a) orjinal görüntü ve (b) özellik çıkarımı sonucu elde edilen özellikler	17
Şekil 3.9. Makine öğrenmesi (a) model oluşumu ve (b) yanıt tahmini	18
Şekil 3.10. Sinir hücresi genel görünümü	20
Şekil 3.11. Yapay sinir ağı matematiksel modeli	21
Şekil 3.12. Çapraz doğrulama	21
Şekil 3.13. Karmaşıklık matrisi	22
Şekil 3.14. Bölütleme performansının değerlendirilmesi	23
Şekil 3.15. ROC eğrisi	24
Şekil 3.16. Makine öğrenmesi ve derin öğrenme farkı	25
Şekil 3.17. Evrimsel sinir ağı	26
Şekil 3.18. 6 *6 boyutundaki girdiye 3 *3 boyutlu filtre uygulandığında elde edilen 4 *4 boyutlu özellik haritası	28
Şekil 3.19. ReLU katmanının çıktı verilerine etkisi	29
Şekil 3.20. Piksel ekleme (a) 5 *5 boyutlu giriş verisine piksel eklenerek (b) 7 *7 boyutlu yeni bir giriş verisinin oluşturulması	29

Şekil 3.21. Maksimum ve ortalama havuzlama (a) orjinal görüntü, (b) maksimum havuzlama ve (c) ortalama havuzlama	30
Şekil 3.22. Düzleştirme işlemi	31
Şekil 3.23. Softmax hata fonksiyonu grafiği	32
Şekil 3.24. Dropout ile bazı nöronların göz ardı edilmesi (a) yapay sinir ağı ve (b) bırakma kullanılan yapay sinir ağı	32
Şekil 3.25. Faster R-CNN ile iki basamaklı çalışma mekanizması	33
Şekil 3.26. Örnek bölütleme ile Mask R-CNN	34
Şekil 3.27. Bölütleme örnekleri a) semantik bölütleme ve b) nesne bölütleme	34
Şekil 3.28. Transfer Öğrenme	35
Şekil 3.29. AlexNet mimarisi.....	36
Şekil 3.30. GoogleNet mimarisi	37
Şekil 3.31. ResNet mimarisi	38
Şekil 3.32. Kalıntı modülü	38
Şekil 3.33. VGGNet mimarisi.....	39
Şekil 3.34. U-Net mimarisi	39
Şekil 4.1. Termal kamera (a) tripotun yerleştirileceği konum ve (b) hastaların kameradan 1 m uzakta duracağı konum	42
Şekil 4.2. Statik termografi hasta pozisyonları a) Ön b) 45 ⁰ sağ c) 90 ⁰ sağ d) 45 ⁰ sol e) 90 ⁰ sol	42
Şekil 4.3. Soğutucu fanın konumu	43
Şekil 4.4. Çalışmada kullanılan sınıflandırma yöntemlerinin akış şeması	44
Şekil 4.5. Bir termal görüntü için a) VIA ile tek sınıf “meme” olarak etiketlenen konturlanmış meme görüntüsü ve b) bu poligonun “.json” dosyasının gösterimi	44
Şekil 4.6. Bir termal görüntünün a) VIA ile bölütlenmiş hali, b) sağ ve sol memenin ikili (binary) maskeleri ve c) sağ ve sol memenin bölütlenmiş halleri	45
Şekil 4.7. Bir hastanın örnek kırılan (a) sol meme ve (b) sağ meme görüntüsü	46
Şekil 4.8. Bölütleme için kullanılan yöntemlerin bölütleme sonuçları a) orjinal görüntü b) VIA ile etiketlenmiş referans sağ ve sol meme görüntüsü c) VIA ile	

etiketlenmiş U-Net için kullanılan referans sağ ve sol meme görüntüsü d) Mask R-CNN bölütlemesinin sonucu ve e) U-Net bölütlemesinin sonucu	47
Şekil 4.9. Termal meme görüntüsünün Mask R-CNN ile otomatik bölütleme sonucu elde edilmiş a) maskeli hali, b) sol ve sağ meme bölütlenmiş hali ve c) bölütlenen bölgelerin kırılmış hali	48
Şekil 4.10. Transfer öğrenme modellerinin doğruluk grafiği	49
Şekil 4.11. Transfer öğrenme modellerinin kayıp grafiği.....	49
Şekil 4.12. InceptionV3 modeli a) eğitim veri seti karmaşıklık matrisi b) birinci yöntem karmaşıklık matrisi ve c) ikinci yöntem karmaşıklık matrisi.....	50
Şekil 4.13. MobileNet modeli a) eğitim veri seti karmaşıklık matrisi b) birinci yöntem karmaşıklık matrisi ve c) ikinci yöntem karmaşıklık matrisi.....	50
Şekil 4.14. MobileNetV2 modeli a) eğitim veri seti karmaşıklık matrisi b) birinci yöntem karmaşıklık matrisi ve c) ikinci yöntem karmaşıklık matrisi.....	51
Şekil 4.15. ResNet50 modeli a) eğitim veri seti karmaşıklık matrisi b) birinci yöntem karmaşıklık matrisi ve c) ikinci yöntem karmaşıklık matrisi.....	51
Şekil 4.16. VGG16 modeli a) eğitim veri seti karmaşıklık matrisi b) birinci yöntem karmaşıklık matrisi ve c) ikinci yöntem karmaşıklık matrisi.....	52
Şekil 4.17. VGG19 modeli a) eğitim veri seti karmaşıklık matrisi b) birinci yöntem karmaşıklık matrisi ve c) ikinci yöntem karmaşıklık matrisi.....	52
Şekil 4.18. Xception modeli a) eğitim veri seti karmaşıklık matrisi b) birinci yöntem karmaşıklık matrisi ve c) ikinci yöntem karmaşıklık matrisi.....	53

ÇİZELGELER DİZİNİ

Çizelge 4.1. İkinci yöntemde kullanılmak üzere denenmiş Mask R-CNN ve U-Net ile yapılan bölütleme başarımları	47
Çizelge 4.2. Transfer öğrenmede kullanılan eğitilmiş ağların eğitim ve test süreleri	48
Çizelge 4.3. Transfer öğrenme modellerinin hiperparametre ve değerleri	48
Çizelge 4.4. Transfer öğrenmede kullanılan modellerin başarımları.....	53

1. GİRİŞ

Meme kanseri son yıllarda oldukça sık görülen ve yaşamı tehdit eden kanser türlerinden biridir. Küresel Kanser Gözlemevi (GLOBOCON) tarafından 2020’de yapılan bir araştırmada meme kanserinin insidans oranı %11.7, ölüm oranı ise %13.6 olarak bildirilmiştir (Sung vd. 2021). Meme lezyonu görüntüleme yöntemlerinde mamografi altın standart olarak gösterilir. Bu yöntemin non-invaziv olması, erken teşhise olanak sağlaması ve hekimlerin ulaşmakta zorluk çekebilecekleri küçük boyutlu kitleleri saptayabilmeleri avantajları arasında yer alır. Ancak tüm bu avantajlara rağmen, yöntemin iyonize radyasyon içermesi, hasta konforunu bozması ve doku yoğunluğunun artmasıyla görüntüleme zorluğunun da paralel olarak artması gibi dezavantajları bulunur. Bu dezavantajların giderilmesi, daha hızlı ve doğru sonuçlar elde edilebilmesi ise alternatif görüntüleme ve tanı yöntemlerinin geliştirilmesi ile mümkündür. Yeni tanı yöntemlerinin değiştirmesi gereken en önemli uygulamalardan birisi de iyonlaştırıcı radyasyonun ve meme sıkıştırmasının getirdiği hasta konforunun bozulmasının önüne geçilmesidir.

Hastalardan tanısız amaçlı termal görüntüler elde edilmesinin tarihçesi oldukça eski zamanlara dayanmaktadır (Bagavathiappan vd. 2009). Eski zamanlarda hasta kişilerin şüpheli vücut bölgelerine ıslak çamur veya ıslak kil uygulanırdı. Daha sonra bölge kurumaya bırakılarak normal deriye göre daha çabuk kuruyan bir bölgede tümör şüphesine işaret ederdi. Zamanla bu tür gözlemlerden yola çıkılarak normal bölgelere göre tümörlü bölgelerin vücudun tamamına göre daha sıcak olduğu sonucuna varılmıştır (Ring 2004). Günümüzde ise teknolojik gelişmeler sıcaklık bilgisinin çeşitli cihazlar ile öğrenilmesi ve görüntülenebilmesini mümkün kılar. Bu tür cihazların başında termal kameralar gelir. Bu sistemler, askeri teknolojiler, enerji sektörü, inşaat işleri, elektrik tesisleri, tıpta yüksek ateşli hastaların tedavisinde, elektriksel kaçak ve sağlamlık testleri gibi birçok alanda kullanılmaktadır (Gade ve Moeslund 2014).

Meme lezyonlarının görüntülenmesinde de tercih edilen termal kameralar cisimlerin yaymış olduğu elektromanyetik radyasyonun elektrik enerjisine çevrilmesine dayanarak sıcaklık bilgisini tespit eder. Lezyonlu dokuların, yer aldıkları vücut bölgesinde metabolizma hızını ve kan akış hızını artırmasının bir sonucu olarak lokal sıcaklık artışına yol açması, lezyon içeren sığ vücut bölgelerinin yaydığı kızıl ötesi ışımanın termal kameralarla görüntülenebilmesine ve böylelikle tümör tespiti yapılabilmesine olanak sağlar (Zuluaga Gomez vd. 2021). Meme termografisinde görülebilecek lenf nodülleri gibi yoğun damarlı yapıların lezyonlu bölgelerin tespit edilmesinde hatalara sebep olabilmektedir. Bu hataların önüne geçilebilmesi, daha hızlı ve doğru sınıflandırma işlemlerinin gerçekleştirilebilmesi için görüntü işleme ve yapay sinir ağlarının kullanılması gerekmektedir.

Termografi, aktif ve pasif termografi olmak üzere günümüzde iki şekilde uygulanabilmektedir. Pasif termografide herhangi bir dış uyarana gerek olmadan görüntüleme yapılır ve uygulaması kolay olduğundan kullanımı daha sık tercih edilir. Aktif termografide ise görüntüleme işlemi bir dış uyarana etkisi sonrasında yapılır (Baffa ve Lattari 2018). Aktif termal görüntüleme tekniği kullanılarak farklı kanser türlerinin teşhisine yönelik çalışmalar literatürde mevcuttur (Mambou vd. 2018; Farooq ve Corcoran 2020; Hakim ve Awale 2020; Ghayoumi Zadeh vd. 2021). Meme lezyonlarının tespitine yönelik çalışmalar genellikle elektromanyetik spektrumun kızıl ötesi, görünür

veya mor ötesi bölgesindeki ışınlarla tümörlü bölgenin görüntülerinin alınması yoluyla yapılmaktadır (Tello-Mijares vd. 2019). Termografi tekniği ile tümör tespiti ise, lezyon içeren bölgenin sıcaklığının normal dokudan farklı olması ilkesine dayanmakta olup bölgeye soğuk stres uygulanarak sıcaklık gradyanı oluşturulmasıyla tekniğin etkinliğinin artırılması ilkesini kullanmaktadır (Silva vd. 2014). Soğuk stres sonrasında şüpheli doku ve çevresinin termal görüntüsü belirli aralıklarla kaydedilerek zamana göre sıcaklık değişim profili çıkarılmaktadır. Malin lezyonun bulunduğu yerleşim yerinde sıcaklık artışı daha yavaş gerçekleşeceğinden alınacak termogramlarla malin lezyon tespiti daha kolay olmaktadır (Abdel-Nasser vd. 2019). Ancak toplanan görüntüler üzerinde gürültü olarak adlandırılan kısımlar olabilir. Bu durumlarda ise lezyon ile sağlıklı dokuyu gözle ayırt etmek ve lezyonun sınırlarını belirlemek daha zor olmaktadır. Bu zorlukların bazıları görüntü işleme ve bölütleme işlemleri ile giderilebilirken bazıları için de yapay zekâ uygulamalarına ihtiyaç vardır.

Günümüzde bilgisayarlar insan hayatında oldukça önemli bir yere sahiptir ve eğitim, iletişim, bankacılık, havacılık, eğlence, araştırma, mühendislik, veri toplama ve veri analizi gibi birçok alanda kullanılmaktadır. Bilgisayarlar yardımı ile yapılan çalışmalardan bazıları yapay zekâ uygulamalarıdır. Bu uygulamalar makine öğrenmesi ve derin öğrenme algoritmaları olmak üzere iki temel alan üzerine yoğunlaşmıştır (Alafi 2019; Goyal vd. 2020). Özellikle görüntü sınıflandırılması çalışmalarında geleneksel makine öğrenmesi algoritmaları kullanıldığında görüntünün yapı ve bileşiminin ihmal edilebildiği bilinmektedir (Benbrahim vd. 2020). Derin öğrenme algoritmaları ise görüntü üzerinden otomatik olarak özellik çıkarımı yaptıkları için makine öğrenmesine göre başarı oranı daha yüksek sonuçlar verebilmektedir (Shoieb vd. 2016).

Makine öğrenmesi ve derin öğrenme algoritmaları insanların öğrenme durumlarını taklit ederek karar vermeye odaklanır ve insan beynindeki bilgi aktarımını gerçekleştiren sinaptik iletimlere benzer bir ağ kullanırlar (Izonin vd. 2015; Yin ve Gelenbe 2016). Sinaptik iletimde bilgi aktarımı, mesajı gönderen nöronun aksonu ile mesajı alacak nöronun soması arasında gerçekleşir. Bu iletimi taklit etmek üzere geliştirilmiş modern derin öğrenme algoritmalarında birçok alternatif mimari kullanılabilir (Shrestha ve Mahmood 2019). Günümüzde mevcut ağ mimarileri kullanıldığında elde edilen yüksek başarımlar yapay sinir ağlarının özellikle medikal görüntülerde rastlanan farklı özelliklerdeki nesnelere tanıma konusunda faydalı olabileceğini göstermektedir (Wang vd. 2016; Sultana ve Puhan 2018; Mohamed vd. 2019).

Son yıllarda biyomedikal görüntülerin toplanması, işlenmesi ve şüpheli lezyonların tespit edilmesi için görüntüler üzerinden şüpheli bölgelerin bölütlenmesi ve özellik çıkarımı işlemleri daha kolaylıkla gerçekleştirilebilmektedir (Iranmakani vd. 2020). Özellik çıkarılması işlemlerinin ardından sınıflandırma işlemleri için makine öğrenmesi ve derin öğrenme yöntemleri yaygın olarak kullanılmaktadır (Yassin vd. 2018; Dhahri vd. 2019). Makine öğrenimi ve derin öğrenme çalışmalarında başarımın yüksek olması büyük miktardaki veri setlerinin kullanılması ile sağlanmaktadır. Ancak biyomedikal alanda verilerin elde edilmesi diğer çalışmalara göre zorlu ve sınırlayıcı olmaktadır. Bu sebeple çalışmalarda daha önceden büyük veri kümeleri üzerinden eğitilmiş ağlar ile transfer öğrenme kullanılmasının başarımı artırdığı bilinmektedir (Roslidar vd. 2020; Zuluaga-Gomez vd. 2021).

Bu tezin amacı, ölümcül bir hastalık olan meme kanserinin erken teşhisinin termal görüntüler üzerinden ve derin öğrenme yardımıyla gerçekleştirilmesidir. Lezyonlu bölgelerin normal bölgelerden daha sıcak olması ve termal kameralar ile cisimlerin sıcaklıklarına göre görüntülenebiliyor olması termal görüntülerin bu çalışmada tercih edilme nedenidir. Termal kameralar ile soğuk stres uygulamalarında, sıcaklığın stres uygulanmasının ardından her bölgeden (hastalıklı/sağlıklı) aynı zamanlarda normale dönmediği bilinir. Buna göre lezyonlu bölgelerin daha geç normale döneceği literatürdeki çalışmalarda da görüldüğü gibi bilinen bir durumdur. Tüm bunlar göz önünde bulundurulduğunda meme lezyonlarının termografi ile görüntülenmesinin lezyon hakkında daha fazla bilgi vermesi beklenmektedir.

Bu tez çalışmasında, meme kanserinin teşhisi için non-invaziv bir yöntem olan termal görüntüleme yöntemi ile elde edilen görüntülerin derin öğrenme analizleri ile beraber bölütleme ve sınıflandırılması çalışılmıştır. Tezde kullanılan termal meme görüntüleri erişime açık bir kaynakta sunulan (Silva vd. 2014) veri setinden alınmıştır. Veri setindeki termal meme görüntüleri statik ve dinamik olmak üzere iki ayrı yöntem ile toplanarak farklı veri setleri olarak sunulur. Statik termogram görüntüleri hastanın belirli pozisyonda herhangi bir dış uyaran kullanılmadan alınan termal görüntülerden oluşur. Dinamik termogramlar ise görüntülenecek bölgeye soğuk stres uygulanmasının ardından bölge tekrar ısınmaya (normale dönmeye) geçerken belirli aralıklarla termal görüntülerin alınması ile toplanmıştır. Alınan termal görüntüler yapay zekâ uygulamalarına verilmeden önce belirli ön işlemlerden geçirilmiştir. Yapılan görüntü ön işlemlerinin ardından meme dışındaki bölgelerin ortadan kaldırılması için bölütleme işlemleri yapılmıştır. Bu işlemlerle beraber derin öğrenme aşamasında yapılacak özellik çıkarımı ve sınıflandırma işlemleri için bir zemin hazırlanmıştır. Son olarak uygun özelliklerin seçiminin ardından derin öğrenme algoritmaları kullanılarak şüpheli lezyonun malin/benin olarak sınıflandırılması ele alınmıştır.

Bu tez çalışmasının birinci bölümünde meme kanseri, yapay zekâ uygulamaları, termal kameralar, termografi ve soğuk stres uygulamaları hakkında genel bilgiler verilmiştir. İkinci bölümünde literatürde benzer konularda yapılan bazı çalışmalara değinilmiştir. Üçüncü bölümünde çalışmanın gerçekleştirilmesinde görüntülerin elde edilmesi, depolanması, ön işlem, bölütleme ve sınıflandırılmasının yapıları hakkında yöntem bilgileri verilmiştir. Dördüncü bölümünde, yapılan çalışma sonucunda elde edilen sonuçlar sunulmuştur. Beşinci bölümünde, bu çalışmadan elde edilen sonuçlar ile literatürdeki diğer çalışmalardan elde edilen sonuçlar karşılaştırılarak ele alınmıştır. Bu çalışmadan elde edilen sonuçların literatüre sağlayacağı katkılar ile ilerleyen çalışmalarda yapılabilecek başarıyı artırıcı önerilere altıncı bölümde yer verilmiştir.

2. KAYNAK TARAMASI

Günümüzde meme lezyonlarının teşhisi için çeşitli yöntemler kullanılmaktadır. Bu yöntemlerden başlıcaları mamografi, ultrason, manyetik rezonans görüntüleme ve termal görüntülemedir. Bu yöntem ile elde edilen görüntüleri kullanarak yapılan birçok yapay zekâ çalışmaları literatürde mevcuttur. Meme kanserinin doğru bir şekilde teşhisi için derin öğrenme yöntemleri diğer makine öğrenme algoritmalarına göre daha başarılı sonuçlar verir (Jiménez-Gaona vd. 2020; Abdelrahman vd. 2021). Evrişimsel sinir ağları transfer öğrenme yöntemi ile birlikte en sık olarak kullanılan derin öğrenme yöntemlerinden biridir. Literatürde kullanılan çalışmaların çoğunda evrişimsel sinir ağları ikili sınıflandırma problemlerinde kullanılmak üzere kamuya açık platformlarda sunulan veri setlerini kullanır.

Schaefer vd. (2009) yaptıkları çalışmada istatistiksel özellikler ve bulanık sınıflandırma kullanarak meme kanseri teşhisini çalışmışlardır. Çalışmada kullanılan veri setinde 29 malin ve 117 benin meme lezyonu bulunan hastalar yer almıştır. Termal meme görüntüleri üzerinde öncelikle sağ ve sol memenin karşılaştırılarak asimetri analizi yapılarak işlemlere başlanmıştır. Bunun için çeşitli istatistiksel özellikler (ortalama sıcaklık, iki meme arasındaki mutlak sıcaklık farkı, standart sıcaklık sapması, medyan sıcaklık) kullanılmıştır. Her meme için dört temel istatistiksel özellik, dört moment özelliği, sekiz histogram özelliği, sekiz çapraz birlikte oluşum özelliği, karşılıklı bilgi ve iki Fourier tanımlayıcısı kullanılarak memeler karakterize edilmiştir. Görüntülerde kontrast artırılması ve alt özelliklerin çıkarılması için Laplacian filtresi kullanılmıştır. Tüm bu işlemlerin ardından sınıflandırma işlemleri için bulanık kural tabanlı sınıflandırıcı kullanılmıştır. Sonuç olarak malin ve benin lezyonlu termal meme görüntüleri üzerinden sınıflandırma başarılarının %80 olduğu raporlanmıştır.

Acharya vd. (2012) yaptıkları çalışmada doku özelliklerini bir Destek Vektör Makinesi (DVM) ile kullanarak meme kanseri tespitini amaçlamışlardır. Çalışmada kullanılan termal meme görüntüleri Singapur Genel Hastanesi'nde Tanısal Radyoloji Anabilim Dalı'nda bulunan 25 normal ve 25 meme kanseri hastasından alınmıştır. Veri setinden alınan termal meme görüntüleri üzerinde bazı ön işlemler ve özellik çıkarımı işlemleri uygulanmıştır. Özellik çıkarımı işlemleri ile moment1, moment3, çalışma yüzdesi ve gri seviye düzensizliği olmak üzere dört doku özelliği çıkarılmıştır. Elde edilen dokusal öznitelikler daha sonra normal veya kötü huylu memenin sınıflandırılması için bir makine öğrenmesi algoritmasına (destek vektör makinesi) aktarılmıştır. Araştırmacılar sonuç olarak DVM sınıflandırıcısının meme kanseri olan ve olmayan hastaların birbirinden ayrımını %88.10 doğruluk, %85.71 duyarlılık ve %90.48 özgüllük değerleri ile gerçekleştirdiklerini raporlamışlardır.

Mookiah vd. (2012) çalışmalarında Ayrık Dalgacık Dönüşümü (Discrete Wavelet Transform, DWT) ve doku özelliklerini kullanarak meme kanseri teşhisi üzerinde çalışmışlardır. Çalışmada kullanılan termal görüntüler Acharya ve arkadaşlarının (2012) kullandıkları veri setinden alınmıştır. Alınan görüntüler üzerinden özellik çıkarımı işlemleri uygulanarak görüntünün karakteristik bilgileri çıkarılmıştır. Çıkarılan özelliklerin istatistiksel olarak anlamlı olup olmadıklarının kontrolü bağımsız t-testi ile yapılmıştır. Çalışmada Karar Ağacı (Decision Tree, DT), Bulanık Sugeno (Fuzzy Sugeno), Naive Bayes, K-En Yakın Komşular (K-Nearest Neighbors, KNN), Gauss Karışım Modeli (Gaussian Mixture Model) ve Olasılıksal Sinir Ağı (Probabilistic Neural

Network, PNN) olmak üzere 6 sınıflandırma algoritması kullanılmıştır. Araştırmacılar sonuç olarak kullanılan sınıflandırma algoritmalarından Karar Ağacı ve Bulanık Sugeno için %93.30 doğruluk, %86.70 duyarlılık ve %100 özgüllük değerleri ile en yüksek başarıyı elde ettiklerini raporlamışlardır.

Golestani vd. (2014) meme termogramları üzerinden meme lezyonu bölütlenmesini çalışmışlardır. Çalışmada kullanılan termal meme veri seti Ann Arbor Thermography (2008)'den alınan 30 görüntüden oluşmuştur. Veri setinden alınan görüntüler üzerinde en sıcak olan bölgeler ayıklanarak orjinal görüntü ile karşılaştırılmıştır. Görüntülerin ayıklanması işlemleri için k-ortalamar, bulanık c-ortalamar ve bölge tabanlı bir bölütleme yöntemi olan seviye belirleme algoritması kullanılmıştır. Üç bölütleme yönteminin karşılaştırılması sonucu orjinal görüntüye benzerliği yönünden en iyi bölütlemeyi seviye belirleme algoritmasının gösterdiği raporlanmıştır.

Milosevic vd. (2014) çalışmalarında termal meme görüntüleri üzerinden özellik çıkarımı ve bölütleme yöntemlerine dayalı anormal meme paternlerinin teşhisini çalışmışlardır. Çalışmada kullanılan termal meme veri seti 26 normal ve 14 anormal hastadan oluşmaktadır. Toplanan termal meme görüntüleri gri seviyeye dönüştürüldükten sonra sağ ve sol meme bölgeleri el yordamıyla kırılarak ön işlemler yapılmıştır. Ön işlemlerin ardından sınıflandırma algoritmalarının beslenmesi ve görüntülerin anlamlandırılması için özellik çıkarımı işlemleri gerçekleştirilmiştir. Özellik çıkarımı işlemi için Gri Düzey Birlikte Oluşum Matrisi (Gray Level Co-Occurrence Matrix, GLCM) kullanılmıştır. Özellik çıkarımı işlemleri sonucunda elde edilen bilgiler K-NN, SVM ve Naive Bayes makine öğrenmesi algoritmaları ile sınıflandırılmıştır. Sınıflandırma çalışmalarının ardından test edilen üç makine öğrenmesi arasında en yüksek başarıyı %92.5 doğruluk değeri ile KNN algoritması vermiştir.

Pramanik vd. (2015) yaptıkları çalışmada dalgacık tabanlı termogram analizi ile meme kanseri teşhisini çalışmışlardır. Çalışmada kullanılan termal meme görüntüleri halka erişime açık kaynakta bulunan veri setinden (Silva vd. 2014) temin edilmiştir. Veri seti 102 gönüllü denekten (123 kanserli ve 183 sağlıklı) üçer görüntü (90 derece sol, orta, 90 derece sağ) olmak üzere toplamda 306 termal görüntüden oluşmaktadır. Çalışmada meme bölgesi dışındaki bölgelerin ortadan kaldırılarak özellik çıkarımı ve sınıflandırma işlemlerinin gerçekleştirilmesi önerilmiştir. Özellik çıkarımı metodu için Dalgacık Dönüşümü (Wavelet Transform) tercih edilmiştir. Özellik çıkarımı işlemlerinin ardından sınıflandırma işlemleri için İleri Beslemeli Çok Katmanlı Algılayıcı (Feed-Forward Multilayer Perceptron Network, MLP) tercih edilmiştir. Sonuç olarak önerilen prosedürlerin ardından %90.48 doğruluk, %87.6 hassasiyet ve %89.73 özgüllük değerleri elde edilmiştir.

Lopez vd. (2017) yaptıkları çalışmada yapılan egzersize bağlı olarak yorgunluk algılanması için termal kameralar ile derin öğrenme yöntemini kullanmışlardır. Çalışmada kullanılan veri seti 19 kişiden (11 erkek ve 8 kadın) alınan 5700 termal görüntüden oluşmaktadır. Veri setinden alınan görüntüler üzerinde yorgunluğun algılanabilmesi için öncelikle göz ve burun bölgeleri belirlenerek hizalama yapılmıştır. Ardından seçilen bölgeden derin özellik vektörlerinin çıkartılabilmesi için bir evrişimli sinir ağı (AlexNet ve VGG) ve son adımda ise yorgunluk durumunun belirlenebilmesi için Destek Vektör Makinesi (DVM) kullanılmıştır. Kullanılan veri setinin az olması ve

birçok çalışmada olduğu gibi önceden eğitilmiş evrişimli sinir ağları (AlexNet, VGG-16 ve VGG-19) üzerinden transfer öğrenme uygulanmıştır. Sonuç olarak AlexNet ile elde edilen %81.51 oranında doğruluk değeri ile egzersize bağlı yorgunluğun termal yüz görüntülerinden tespit edilebildiğini rapor etmişlerdir.

Baffa ve Lattari (2018) yaptıkları çalışmada statik ve dinamik termografi yöntemleri ile alınmış termogramlar üzerinde meme kanseri teşhisini çalışmıştır. Çalışmada kullanılan termal meme görüntüleri diğer birçok çalışmada da kullanılan (Silva vd. 2014) açık erişime sahip veri setinden alınmıştır. Çalışma statik ve dinamik termografi için ayrı veri setleri ile farklı görüntüler ile gerçekleştirilmiştir. Statik çalışma 117 sağlıklı ve 42 kanserli hastadan oluşurken dinamik çalışmada 95 sağlıklı ve 42 kanserli hasta görüntüsü kullanılmıştır. Alınan verilerin sınıflandırılması için Evrişimli Sinir Ağı (Convolutional Neural Network, CNN) tercih edilmiştir. CNN ağı herhangi bir ön işlem, bölütleme veya özellik çıkarımı işlemlerine gerek duymadığından termal meme görüntüleri ham halleriyle verilmiştir. Araştırmacılar sonuç olarak statik görüntüler üzerindeki sınıflandırma başarısını %98 doğruluk ve dinamik veri setinin başarısının %95 olarak bulunduğunu raporlamışlardır.

Karim vd. (2018) yaptıkları çalışmada termal meme görüntüleri üzerinden meme anomalisi teşhisini gerçekleştiren yeni bir yaklaşım önermişlerdir. Çalışmada kullanılan termal meme görüntüleri halka erişime açık veri seti olan Mastoloji Araştırmaları Veritabanı (Database For Mastology Research, DMR) veri setinden (Silva vd. 2014) alınmıştır. Bu veri seti 50 normal ve 30 meme anomalisi bulunan denekten alınan termal görüntülerden oluşmaktadır. Çalışmada öncelikle ham halde alınan termogramların yeniden boyutlandırılması ve RGB görüntü formatının gri seviye formatına (beyaz en sıcak bölgeler, siyah en soğuk bölgeler) dönüştürülmesi işlemleri gerçekleştirilmiştir. Yapılan ön işlemlerin ardından tıbbi uzmanlar tarafından el yordamıyla bölütleme uygulanmıştır. Bölütlenen termogramlar üzerinden özellik çıkarımı işlemleri için GLCM kullanılmıştır. Özellik çıkarımı işlemlerinin ardından sınıflandırma işlemleri için DVM tercih edilmiştir. Sonuç olarak DVM ile sınıflandırma başarımının %91.25 doğruluk, %93.3 duyarlılık ve %90 özgüllük olduğu bildirilmiştir.

Fernández-Ovies vd. (2019) yaptıkları çalışmada termal meme görüntüleri üzerinden meme kanseri teşhisi için derin sinir ağları kullanımını çalışmışlardır. Çalışmada kullanılan veri seti diğer birçok çalışmada da kullanılan DMR-IR (Silva vd. 2014) veri setinden alınan 175 sağlıklı ve 41 kanserli hasta görüntüsünden oluşur. Veri setinden alınan görüntülerin sınıflandırılması için ResNet18, ResNet34, ResNet50, ResNet152, VGG16 ve VGG19 olmak üzere farklı CNN mimarileri kullanmışlardır. Sonuç olarak kullanılan CNN mimarileri arasında en iyi sonucu %100 doğrulukla ResNet34 ve ResNet50 mimarileri vermiştir. Araştırmacılar bu sınıflandırma başarılarının karşılaştırılması sonucunda ResNet mimarisinin VGG mimarisine göre termogramlar üzerindeki sınıflandırma başarısının daha yüksek olduğunu belirtmişlerdir.

Tello-Mijares vd. (2019) yaptıkları çalışmada gradyan vektör akışı ve evrişimsel sinir ağı kullanarak termal meme görüntüleri üzerinde bölütleme ve sınıflandırma konusunu çalışmışlardır. Çalışmada kullanılan veri setinde (Silva vd. 2014) 35 normal ve 28 kanserli hasta yer almaktadır. Veri setinden alınan görüntüler üzerinde Gauss filtresi kullanılarak ön işlemler yapılmıştır. Yapılan ön işlemlerin ardından Gradyan Vektör Akış Yılanları (Gradient Vector Flow Snakes, GVFS) kullanılarak bölütleme işlemleri

gerçekleştirilmiştir. Bölütleme işlemlerinin ardından bölütlenmiş meme görüntüleri evrişimsel sinir ağına (ESA) verilmiştir. Çalışmada ESA mimarisinin yanı sıra WEKA kullanılarak Ağaç Rastgele Orman (Tree Random Forest, TRF), MLP ve Bayes Ağı (Bayes Network, BN) algoritmaları da kullanılmıştır. Sonuç olarak TRF %85.71, MLP %88.88 ve NV %80.95 doğruluk gösterir iken ESA mimarisi %100 doğruluk başarısı göstermiştir.

Liang vd. (2019) yaptıkları çalışmada Mask R-CNN kullanımı ile ultrason görüntüleri üzerinden meme bölgelerinin bölütlenmesi ve sınıflandırılmasını çalışmışlardır. Çalışmada kullanılan veriler iki farklı veri setinden alınmıştır. İlk veri seti 150 görüntü (51 malin) ve ikinci veri seti 163 görüntüden (53 malin) oluşmaktadır. Veri setinden alınan görüntülerin meme bölgelerinin etiketlenmesi işlemleri uzman doktorlar tarafından yapılmıştır. Çalışmada model ve kullanılan yöntem performansının değerlendirilmesi için yalnızca katı (rigid-only), konvansiyonel elastik (conventional elastic) ve çok ölçekli süper piksel elastik (multi-scale super-pixel elastic) olmak üzere üç grupta çalışılmıştır. Üç gruba ayrılmış veri seti aynı ayarlar ile Mask R-CNN mimarisinde sınıflandırılması çalışılmıştır. Sonuç olarak ayrılan üç grup için zar katsayı değerleri sırasıyla 82.80, 82.20 ve 83.93 olarak elde edilmiştir. Sınıflandırma performansları yalnızca katı için %77.62, konvansiyonel elastik için %78.50 ve çok ölçekli süper piksel elastik için %80.42 olarak bulunmuştur.

Chiao vd. (2019) yaptıkları çalışmada sonogram görüntüleri üzerinden Mask R-CNN kullanarak meme bölgelerinin algılanması, bölütlenmesi ve sınıflandırılmasını çalışmışlardır. Çalışmada kullanılan veriler Çin Tıp Üniversitesi Hastanesi'nde bulunan hastalardan alınan 307 ultrason görüntüsünden (178 benin ve 129 malin) oluşmaktadır. Veri setinden alınan görüntüler üzerinde lezyonlu bölgelerin konturlanması işlemleri uzman radyologlar tarafından gerçekleştirilmiştir. Konturlanmış görüntüler ile eğitilen modelin performansının değerlendirilmesi için Ortalama Hassasiyet (Mean Average Precision, mAP) kullanılmıştır. Sonuç olarak validasyon verilerinde lezyon tanımlanması başarısının mAP değerinin 0.75 ve sınıflandırma doğruluğunun %85 olarak bulunduğu raporlanmıştır.

Farooq ve Corcoran (2020) yaptıkları çalışmada meme kanseri hastalarında tümör sınıflandırılması için termal kameralar kullanarak elde edilen termal görüntülerden oluşan veri setini ESA ile eğitmişlerdir. Çalışmalarında kullandıkları veri seti 18'i kanserli ve 22'si iyi huylu olmak üzere toplam 40 hastadan alınan termal meme görüntülerinden oluşmaktadır. Alınan görüntülerin ön işleme aşamasında görüntü kontrastının artırılması, keskinleştirilme ve normalizasyon işlemleri için Kontrast Sınırlı Uyum Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization, CLAHE) uygulanmıştır. Yapılan ön işlemlerinin ardından sınıflandırma işlemleri için Derin Sinir Ağı (DSA) kullanılmıştır. Daha önceden eğitilmiş bir InceptionV3 derin sinir ağı ile transfer öğrenme uygulanmıştır. Sonuç olarak eğitim doğruluğu %93.73, doğrulama doğruluğu %91.32, test doğruluğu ise %80, hassasiyet %83.33, özgüllük %77.77 ve F1 skoru %76.89 olarak hesaplandığı rapor edilmiştir.

Snehalatha ve Sangamithirai (2021) yaptıkları çalışmada termal görüntüler üzerinde çeşitli evrişimli sinir ağları ve makine öğrenmesi algoritmaları kullanarak obez-normal insanların vücutlarının farklı bölgelerindeki sıcaklık farklarını ve Kahverengi Yağ Dokusu (Brown Adipose Tissue, BAT) aktivasyonunun analizi ile birlikte obezite

sınıflandırma problemini çalışmışlardır. Çalışmada 337 sağlıklı ve 310 obez denek kullanılarak termal görüntüler toplanmıştır. Bu çalışmada transfer öğrenme işlemi için VGG16, VGG19, ResNet50 ve DenseNet121 modelleri kullanılmıştır. CNN modelinin yanı sıra çalışmada makine öğrenmesi algoritmaları da uygulanmış ve bu aşama için gerekli özellik çıkarımı işlemleri manuel olarak yapılmıştır. Çalışmada özellik seçimi için Ölçekle Değişmeyen Özellik Dönüşümü (Scale Invariant Feature Transform, SIFT) metodu kullanılarak elde edilen özellikler LDA (Linear Discriminant Analysis – Doğrusal Ayırıştırıcı Analiz), K-NN (K-Nearest Neighborhood - K En Yakın Komşuluk) ve DVM (Destek Vektör Makinesi) modellerine girdi olarak aktarılmıştır. Sonuç olarak en iyi başarıyı %92 doğruluk oranıyla SIFT-SVM modeli ile geliştirilmiş olan özel ağ göstermiştir.

Zuluaga-Gomez vd. (2021) yaptıkları çalışmada evrimsel sinir ağları kullanımı ile meme kanseri teşhisini çalışmışlardır. Çalışmada kullanılan veriler diğer birçok çalışmada da kullanılan termal meme görüntülerine açık erişim sağlayan DMR-IR (Silva vd. 2014) veri setinden temin edilmiştir. Veri setinden alınan görüntülerde 19 sağlıklı ve 38 kanserli hasta görüntüleri yer almaktadır. Alınan her meme görüntüsünün ROI'si (Region Of Interest – İlgi Bölgesi) orjinal gri ölçekli maske görüntüsünden bölümlere ayrılmıştır. Bu işlemlerin ardından her bir görüntü üzerinden meme bölgesinin kırılması, yeniden boyutlandırılması ve normalleştirme işlemleri uygulanmıştır. Yapılan ön işlem ve bölütleme işlemlerinin ardından son teknoloji (ResNet, SeResNet, InceptionV3, VGG16, InceptionResNetV2 ve Xception) CNN mimarileri ve kendi geliştirdikleri mimari ile sınıflandırma işlemleri yapılmıştır. Araştırmacılar sonuç olarak kendi geliştirdikleri CNN modelinin son teknoloji modellere göre daha yüksek başarı oranlarının (%92 doğruluk, %94 kesinlik, %91 duyarlılık ve %92 F1 puanı) bulunduğunu raporlamışlardır.

Ghayoumi Zadeh vd. (2021) yaptıkları çalışmada aktif termografi kullanarak özellik çıkarımı yoluyla meme kanseri olan hasta ile sağlıklıların birbirinden ayrılmasını çalışmışlardır. Çalışmada Mastoloji Araştırmaları Veri Tabanı kullanılmıştır (Silva vd. 2014). Çalışmada kullanılan veri seti 41 kanserli hasta ve 155 sağlıklı hastadan alınan termal meme görüntülerinden oluşur. Meme bölgesinin net bir şekilde görülebildiği durumda bölütleme el yordamıyla veya yarı otomatik şekilde, görünemediği durumda ise yapay sinir ağları yardımıyla gerçekleştirilmiştir. Özellik çıkarımı için ortalama, enerji, standart sapma, entropi, çarpıklık, homojenite, basıklık ve varyans önerilmiştir. Çıkarılan özelliklerin ardından sınıflandırma işlemi için otomatik kodlayıcı (autoencoder) kullanılmıştır. Sonuçta çalışmanın eğitim kısmı için %98.08 doğruluk, %96.87 hassasiyet ve %98.4 özgüllük değerleri, test kısmı için ise %94.87 doğruluk, %87.5 hassasiyet ve %96.77 özgüllük oranları raporlanmıştır.

Literatürdeki çalışmalardan da görüldüğü üzere mamogram ve ultrason yöntemlerinin dışında cisimlerin yaydığı elektromanyetik radyasyonunun elektrik enerjisine dönüştürülmesi ile görüntüleme sağlayan termal görüntüleme çalışmaları da meme lezyonlarının tespitinde sıklıkla yer almaktadır. Lezyonların normal deriden sıcaklık farklılıklarının bulunduğu yapılan çalışmalar sonucu bilinmektedir. Bu sebepten dolayı meme lezyonlarının görüntülenmesinde bu çalışmada termal görüntüleme yöntemlerinden aktif termografi tekniği kullanılmıştır. Bu şekilde mamografinin en büyük dezavantajlarından biri olan iyonize radyasyon içermesi ve hasta konforunu bozacak bir sıkıştırma gereği ortadan kaldırılmış olacaktır.

Bu çalışmada termogramlar üzerinden algılama, bölütleme ve sınıflandırma çalışmalarının tek bir çatı altında yapılması hedeflenmiştir. Literatürdeki çalışmalarda hasta bazında sınıflandırma veya termogramlardaki en sıcak bölgelerin bölütlenmesinin ardından yapılan sınıflandırma çalışmalarına sıklıkla rastlanmıştır. Hasta bazında yapılan çalışmalarda kişinin kanserli bir hasta olduğu tanısı yapılabilir ancak kişinin hangi memesinin kanserli olduğu bilgisine erişilemez. Termogram üzerinde en sıcak bölgenin işaretlenmesi çalışmasında lezyonlu bölge tüm sınırlarıyla teşhis edilebilir ancak meme bölgesinde yer almayan ve kilolu hastalarda sıcak bölge olarak yer alan boyun, koltuk altı, meme altı ve lenf nodülleri gibi bölgeler yanlış sınıflandırmaya sebep olacaktır. Bu çalışmada ise öncelikle meme bölgesi el yordamı ve otomatik olarak iki farklı şekilde bölütlenmiştir. Sınıflandırma mimarilerinin eğitimi işlemlerinde ise bölütlenen meme görüntüleri üzerinde lezyon sınıflandırması yapılmıştır. Bu şekilde hasta bazında değil, meme bazında sınıflandırma çalışarak kişinin hangi memesinin kanserli olduğu bilgisine erişim sağlanması hedeflenmiştir. Bunun yanında en sıcak bölgelerin bölütlenmesi yerine bölütlenmiş meme görüntüleri üzerinden yapılan sınıflandırma ile meme bölgesi dışında yer alan sıcak bölgelerin sebep olacağı yanlış sınıflandırmanın önüne geçilmesi amaçlanmıştır. Sınıflandırma işlemlerinde ise literatürdeki birçok çalışmada olduğu gibi az sayıda veri ile yüksek doğruluk değerlerine ulaşılmasını sağlayan önceden öğrenilen bilgilerin yeni problemlerde çözümüne olanak tanıyan transfer öğrenme yöntemi kullanılmıştır.

3. MATERYAL VE METOT

3.1. Meme Kanseri Tespitinde Kullanılan Görüntüleme Yöntemleri

Meme kanseri akciğer ve kolon kanseri ile beraber kadınlarda en sık olarak görülen kanser türlerinden biri iken diğer kanserler arasında kardiyovasküler kanserlerden sonra ölümü tetikleyen en önemli kanser türüdür (Harbeck ve Gnant 2016). Amerika ve Avrupa ülkelerinde yapılan istatistiksel çalışmalar sonucunda kadın nüfusunun yaklaşık %12'lik kısmının meme kanseri olduğu ispatlanmıştır (Grosenick vd. 2016). Sigara kullanımı, moleküler mekanizmalar, obezite, hareketsizlik, alkol kullanımı ve genetik mekanizmalar gibi bazı faktörler meme kanseri oluşumuna doğrudan sebebiyet vermese de kanser riskini artıran sebepler arasında yer almaktadır. Diğer tüm kanser tiplerinde olduğu gibi meme kanserinde de erken teşhis hayati önem taşımaktadır. Yapılan çalışmalar erken teşhis edilen meme kanserinin hastanın yaşamını 5 yıla kadar uzatabileceğini göstermiştir (Wang 2018).

Meme kanseri hastalarından gözlenen bazı belirtilerden yola çıkarak kanser şüphesinin farkına varıp hastayı erken evrede tedaviye yönlendirmek mümkündür. Bu belirtiler arasında meme boyutlarındaki düzensizlik, bazı bölgelerde çukurlaşma, memede şişlik veya kalınlaşma, renk değişikliği, meme ucunda akıntı veya ağrı hissedilmesi sayılabilir. Meme kanseri teşhisi için günümüzde mamografi, sonografi, MRI (Magnetic Rezonance Imaging - Manyetik Rezonans Görüntüleme), SPECT (Single Photon Emission Computerized Tomography - Tek Foton Emisyonlu Bilgisayarlı Tomografi), PET (Positron Emission Tomography - Pozitron Emisyon Tomografisi), optik ve mikrodalga görüntüleme gibi yöntemler mevcuttur (Iranmakani vd. 2020).

Mamografide altın standart olarak film taramalı mamografi kullanımı gerçekleştirilir. Ancak bu yöntem meme yoğunluğu fazla olan (bez doku oranı fazla memeler) hastalarda kanser tespitini sınırlamaktadır. Bu sınırlamaların ortadan kaldırılması ve yöntemin iyileştirilmesi için dijital mamografi yöntemi geliştirilmiştir. Bu yöntem ile birlikte görüntü depolama ve transfer işlemleri kolaylaşmıştır. Mamografinin uygulanması ile meme kanserinden ölümlerin oranının %20-40 düzeylerinde azaldığını gösteren (Greenwood vd. 2018) çalışmalar olsa da, İngiltere ve Kanada'da yapılan bazı çalışmalar mamografinin ölüm riskinin azaltılmasına herhangi katkıda bulunmadığını göstermiştir (Autier ve Boniol 2018).

Sonogramlar, mamografi gibi hasta konforunu bozacak memeyi sıkıştırma vb. bir dış müdahale gerektirmez. Hastanın meme bölgesine sürülen jel ve tümör şüphesi bulunan bölgede gezdirilen prob ile görüntüleme sağlanır. Bu yöntemin girişimsiz olması ve iyonize radyasyon içermemesi avantajları arasında yer alır. Ancak sonogramda ses sinyalleri deri yüzeyinden uygulandığı için büyük hacimli memelerde veya derinde bulunan tümörlerin görüntülenmesinde başarılı sonuçlar vermezler (Chiao vd. 2019; Liang vd. 2019).

Manyetik Rezonans Görüntüleme (MRG) yöntemi meme kanseri teşhisinde çok sık kullanılmayıp genellikle mamografi ve ultrason ile çalışılmış hastalara tamamlayıcı yöntem olarak tercih edilmektedir. MRG yönteminin erken teşhis ve hasta sağ kalımı üzerindeki etkisi düşük olduğundan genellikle kanser riski yüksek hastaların taranması

çalışılmaktadır (Iranmakani vd. 2020). MRG yöntemi, mamografi ve ultrason yöntemlerine göre duyarlılığı daha yüksek olsa da maliyetli ve uzun süreli bir yöntemdir.

SPECT duyarlılığı (%96.4) oldukça yüksektir ve lezyon konumunun tam tespitinin yapılmasında doğruluk değerinin yüksek olması avantajları arasında yer almaktadır. Ancak bu yöntemin uzaysal çözünürlüğünün düşük olmasından dolayı küçük lezyonların ayırt edilebilirliği yeterli düzeyde değildir. Bu sebeple düşük riskli hastalar için kullanımı tercih edilmez. PET yönteminin SPECT'e göre en önemli avantajlarından birisi uzaysal çözünürlüğünün yüksek olmasından dolayı küçük lezyon tespitinde daha başarılı olmasıdır (Champion vd. 2015).

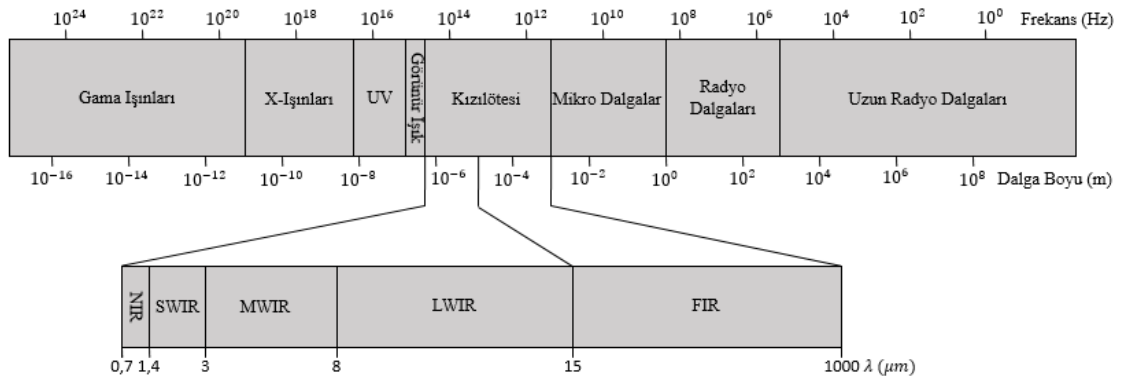
Optik görüntüleme tekniği ile klinikte kullanılan yöntemlerden (mamografi, ultrason veya MRI gibi) farklı olarak meme dokusunun anatomik, metabolik ve fizyolojik yapıları hakkında daha fazla bilgiye erişimi mümkün kılar. Bu yöntemin diğer görüntüleme yöntemlerine kıyasla iyonlaştırıcı olmayan ışınları kullanması ve düşük maliyetli olması avantajları arasında yer alır. Ancak ilgili bölgeye yönlendirilen ışınların dokuya nüfus etme derinliğinin sınırlı olması ve düşük uzaysal çözünürlüğe sahip olması dezavantajlarından (Grosenick vd. 2016).

Mikrodalga görüntüleme, mikrodalga tomografi ve radar tabanlı mikro dalga görüntüleme olmak üzere iki tipte kullanılmaktadır. Mikrodalga tomografi meme dokusunda dielektrik özellikler hakkında çok az bilgi erişimine olanak tanırken radar tabanlı mikro dalga görüntüleme ile dielektrik özellikler hakkında çok daha fazla bilgi edinilerek iç organ yapıları haritalanabilir. Mikrodalga görüntüleme yöntemlerinde çözünürlük radyasyonun frekans aralığına bağlıdır. Dalga boyu ne kadar kısa olur ise görüntüdeki çözünürlük o kadar yüksek olacaktır. Dalga boyunun kısa olması çözünürlüğü arttırdığı gibi penetrasyon derinliğinin azalmasına sebep olmaktadır. Bu yöntemler ile tümörlerin iyi veya kötü huylu olmasının tespiti dokular arasındaki dielektrik özelliklere bakılarak tespit edilmektedir (Iranmakani vd. 2020).

3.2. Termal Görüntüleme Tekniği

3.2.1. Termal (kızılötesi / infrared) radyasyon

Termal radyasyon, sıcaklığı mutlak sıfırın üzerinde olan nesnelere yayılan ışımadır. Yayımlanan radyasyonun şiddeti cisimlerin sıcaklıklarına göre değişirken enerji spektrumu ise elektromanyetik spektrumun *kızılötesi spektrum* adı verilen aralığına denk gelir. Kızılötesi spektrumun elektromanyetik spektrumdaki konumu Şekil 3.1'de gösterilmektedir.



Şekil 3.1. Elektromanyetik spektrum (Gade ve Moeslund 2014)

Şekil 3.1’de görüldüğü gibi, kızılötesi spektrum 0.7-1,000 μm dalga boyu aralığına (NIR: Near-Infrared - Yakın Kızılötesi; SWIR: Short-Wavelength Infrared - Kısa Dalga Boylu Kızılötesi; MWIR: Mid-Wavelength Infrared - Orta Dalga Boylu Kızılötesi; LWIR: Long-Wavelength Infrared - Uzun Dalga Boylu Kızılötesi; FIR: Far-Infrared - Uzak Kızılötesi) sahiptir ve elektromanyetik spektrumda görünür ışık ile mikro dalgalar arasında yer alır. Kızılötesi spektrum kendi içerisinde beş alt alana ayrılır. Bunlardan orta ve uzun dalga boyu kızılötesi aralığı nesnelere termal olarak yaydığı ışınları içeren termal kızılötesi olarak adlandırılan bölgedir. Bu aralıkta dalga boyuna sahip ışınlar termal görüntüleme tekniklerinde kullanılır (Gade ve Moeslund 2014).


3.2.2. Termal kameralar

Termal kameralar, cisimlerden yayılan termal radyasyonu yakalamaya yarayan sensörler ve sensörlerden alınan bilgileri işleyen detektörlerden oluşur (Chrzanowski vd. 2000). Normal kameralar ile cisimlerin görüntülerinin alınması için doğal veya yapay olarak bir aydınlatma sistemine ihtiyaç duyulurken, termal kameralar cisimlerin sıcaklıklarından dolayı yaydıkları termal ışımaya dayanarak görüntü oluşturduğundan normal kameralara üstünlük sağlar.

Termal kameralar ilk zamanlarda askeri uygulamalarda gece görüşü ve gözetleme işlemleri için kullanılır ve yüksek maliyetli olarak görülürdü. Sonradan termal kameraların ticarileştirilmesi ve birçok alanda kullanılması beraberinde daha kaliteli termal kameraların daha uygun fiyatlara satılmasını sağladı. Günümüzde geniş kullanım alanına sahip olan termal kameralar askeri, endüstriyel, veterinerlik, enerji sektörü, inşaat, elektrik tesisleri, tarım, tıp bilimi, gaz algılama ve sağlamlık testleri gibi birçok alanda kullanılır (Gade ve Moeslund 2014).

Termal kameralar Şekil 3.2’de görüldüğü gibi lens, sensör, işlemci ve monitör olmak üzere dört ana bölümden oluşur. Lensler kameranın en ucunda bulunur ve görüntülenen bölgedeki nesnelere doğru yönlendirilerek nesnelere yayılan termal ışınları odaklayarak sensöre iletir. Sensör ise algıladığı kızılötesi ışınların sıcaklığındaki değişimlere göre elektrik direnci değişen çok sayıda *bolometre* içerir. Tipik bir termal kamerada bolometreler, çevre sıcaklığından etkilenmemesi için termoelektrik bir soğutucu ile birlikte bir vakum kabının içerisinde yer alır. Bolometre kızılötesi radyasyonu emdiğinde direnci değişir ve devreden akan elektrik akımını değiştirir. Bu


akım değişimi akım/gerilim dönüştürücüleri yardımı ile voltaj değerlerine çevrilir. Bu gerilim değeri de A/D dönüştürücü ile analog gerilim değerinden dijital sinyallere dönüştürülür. Bu sinyaller daha sonra okunmak üzere işlemciye aktarılır. Burada odak düzlemi dizisinde olacak düzensizlikler, dedektörlerden gelen hatalı sinyaller, ofset ve kazanç düzeltme gibi düzeltme işlemleri yapılır ve en sonunda video oluşturma devresine iletilerek video sinyaller haline getirilir ve bir monitör devresi aracılığıyla ekrana yansıtılır (Gade ve Moeslund 2014).



Şekil 3.2. Termal kamera bileşenleri

3.2.3. Statik (pasif) termal görüntüleme tekniği

Statik termal görüntüleme tekniğinde nesnelere yayılan kızılötesi radyasyon termal kameralar tarafından algılanarak sıcaklık bilgisine dönüştürülür. Sıcaklık değeri ne kadar yüksek ise cisimlerin yayacağı kızılötesi radyasyon şiddeti de o kadar yüksektir. Sıcaklık bilgisi hesaplanırken cisme dışarıdan herhangi bir etken ile termal stres uygulanmaz. Şekil 3.3'te görüldüğü gibi görüntülenme işlemleri cismin kendi sahip olduğu sıcaklık bilgisine göre gerçekleştirilir (Magalhaes vd. 2019).

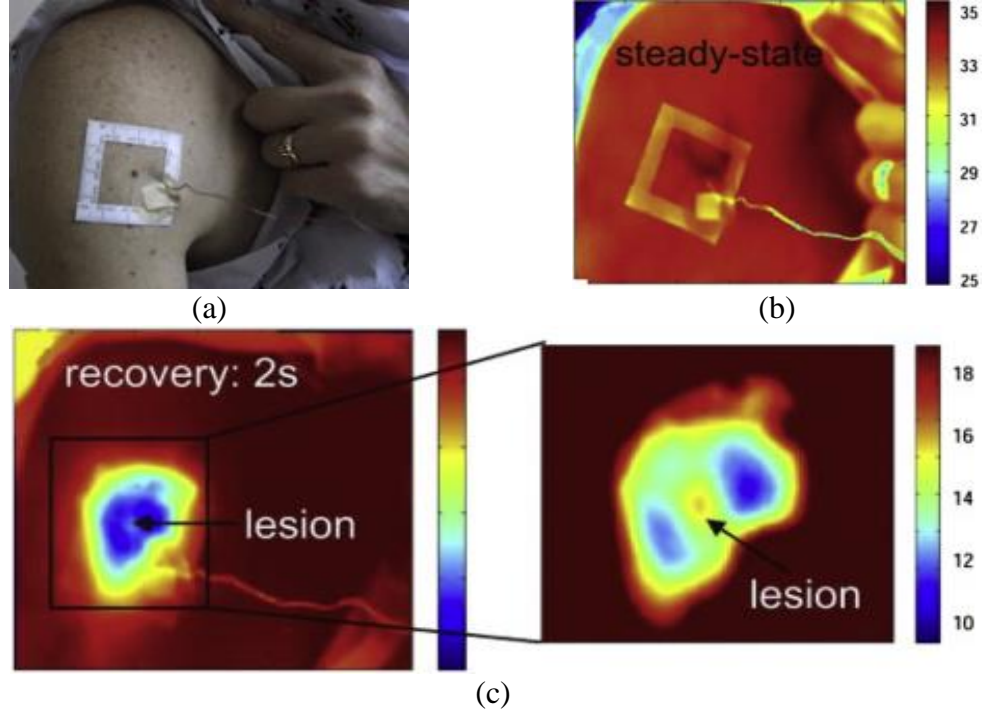


Şekil 3.3. Statik termal görüntüleme (Bagavathiappan vd. 2013)

3.2.4. Dinamik (aktif) termal görüntüleme tekniği

Dinamik termal görüntüleme tekniğinde statik termal görüntülemeden farklı olarak termal görüntüsü alınacak cisme dışarıdan soğutma veya ısıtma uygulanarak cismin sıcaklığı değiştirilir. Sıcaklık değerinin değiştirilmesi işlemine *termal stres* adı verilir. Bölge soğutulacak ise uygulanacak prosedüre *soğuk stres uygulaması*, ısıtılacak ise *sıcak stres uygulaması* adı verilir. Soğuk stres uygulamalarında öncelikle bölge çeşitli yöntemler ile soğutulur. Soğutma işlemleri için taşınabilir klimalar, soğutma tüpleri, fan veya soğutma paketi (cold gel pack) gibi yöntemler tercih edilir. İnsan vücuduna uygulanan dinamik termografi çalışmalarında genellikle jel pack kullanımı tercih edilir (Magalhaes vd. 2019).


Meme lezyonlarının termal kamera ile görüntülenmesi çalışmalarında aktif termal görüntüleme yöntemi sıklıkla kullanılır (Milosevic vd. 2014; Silva vd. 2014; Farooq ve Corcoran 2020; Ghayoumi Zadeh vd. 2021). Malin tipte meme lezyonlarının görece normal meme dokularından daha sıcak olması termal kamera ile ayırt edilebilirliklerini artırmaktadır. Ayrıca bu tip lezyonlar sıcaklık değişimine normal deriye göre daha geç tepki verir ve dokunun eski sıcaklığına dönmesi daha uzun zaman alır. Bu özellikten yararlanılarak lezyonun bulunduğu bölgenin sıcaklığı düşürülür ve soğuma sürecinde belli periyotlarla lezyonlu bölgenin termal görüntüsü alınır. Şekil 3.4'te termal kamera ile alınmış aktif termogram görüntüsü verilmiştir.



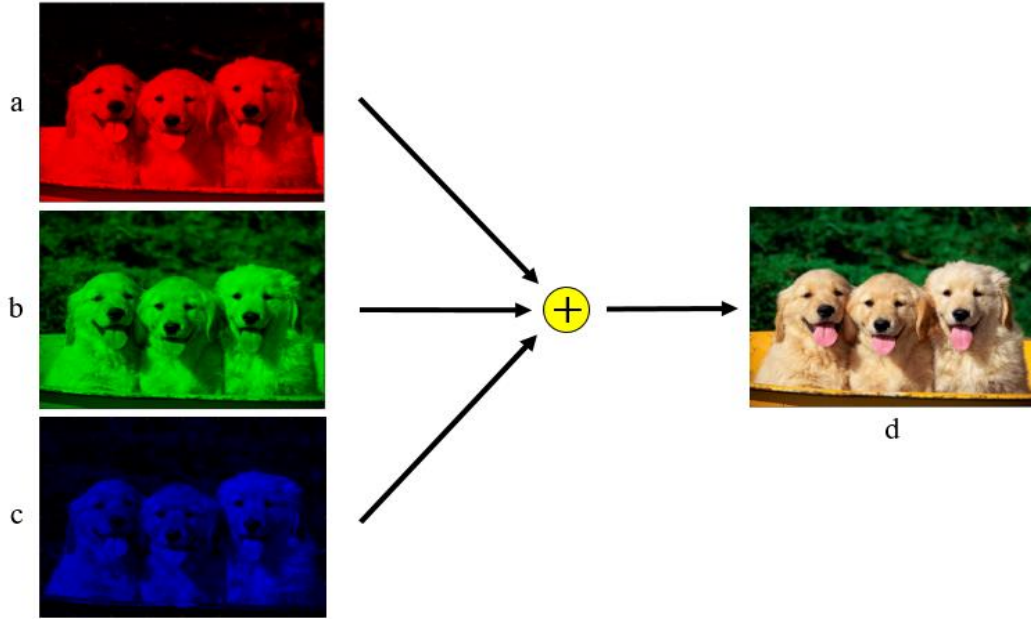
Şekil 3.4. Soğuk stres uygulaması ile görüntülenecek bölgenin (a) dijital kamera ile alınan görüntüsü, (b) termal kamera ile alınan görüntüsü ve (c) termal görüntüden seçilen lezyon görüntüsü (Çetingül ve Herman 2011)

3.3. Görüntü İşleme Teknikleri

Normal veya termal bir kamera ile alınmış dijital görüntüler, bilgisayar ortamına aktarılmış yatay ve düşey doğruları olan iki boyutlu bir piksel matrisinden oluşur. Bu görüntüler Şekil 3.5'te gösterildiği gibi siyah-beyaz, gri seviye ve renkli görüntüler olmak üzere üç ayrı şekilde bulunabilir. Siyah-beyaz görüntülerin piksel değerleri 0 veya 1 değerlerini alabilir. Gri seviyedeki görüntülerin piksel değerleri 0-255 arasında değişir. Renkli görüntüler ise Şekil 3.6'da gösterildiği gibi üç farklı renk kanalı içerir (R: red - kırmızı; G: green - yeşil; B: blue - mavi) ve her kanalın piksel değeri 0-255 arasında değişebilir. Bu üç kanalın karışımı ile pikselin renk değeri elde edilir (Choraş ve Choraş 2019).



Şekil 3.5. Görüntü ön işleme (a) renkli görüntü, (b) gri seviye görüntüsü ve (c) siyah-beyaz görüntü (Anonim 1)




Şekil 3.6. Renkli görüntü oluşumu (a) kırmızı bileşeni, (b) yeşil bileşeni, (c) mavi bileşeni ve (d) üç bileşenin toplamı ile oluşan renkli görüntü

Görüntüler dijital ortama taşındıklarında görüntü kalitesinde düşüşler ile nesnelerin ayırımı zorlaştıran gürültüler, dış etkenler ve gereksiz bölgeler oluşabilir. Bu problemlerin ortadan kaldırılması, görüntülerden çeşitli yararlı bilgilerin elde edilmesi ve görüntülerin iyileştirilmesi için çeşitli filtreleme işlemleri ile görüntü işleme teknikleri kullanılır. Bu işlemler ile iyileştirilmiş görüntüler ve yüksek çözünürlüklü görüntüler elde edilirken, görünmesi zor bölgeler de görünür hale getirilebilir (Choraş ve Choraş 2019).

3.3.1. Görüntü bölütleme

Görüntü bölütleme, görüntüdeki nesnelerin farklı özelliklerinin tutulduğu anlamlı bölgelere ayrılması işlemidir. Nesneler arka plandan veya görüntüde bulunan diğer nesnelere ayrıştırılırken problemin türüne göre farklı bölütleme yöntemleri kullanılır. Bu yöntemler Şekil 3.7'de görüldüğü gibi kenar tabanlı bölütleme, bölgesel bölütleme ve eşikleme ile bölütleme yöntemleridir (Kaur ve Kaur 2014).



Şekil 3.7. Bölütleme örnekleri (a) orjinal görüntü, (b) eşikleme ile bölütleme, (c) kenar tabanlı bölütleme ve (d) bölgesel tabanlı bölütleme (Anonim 2)

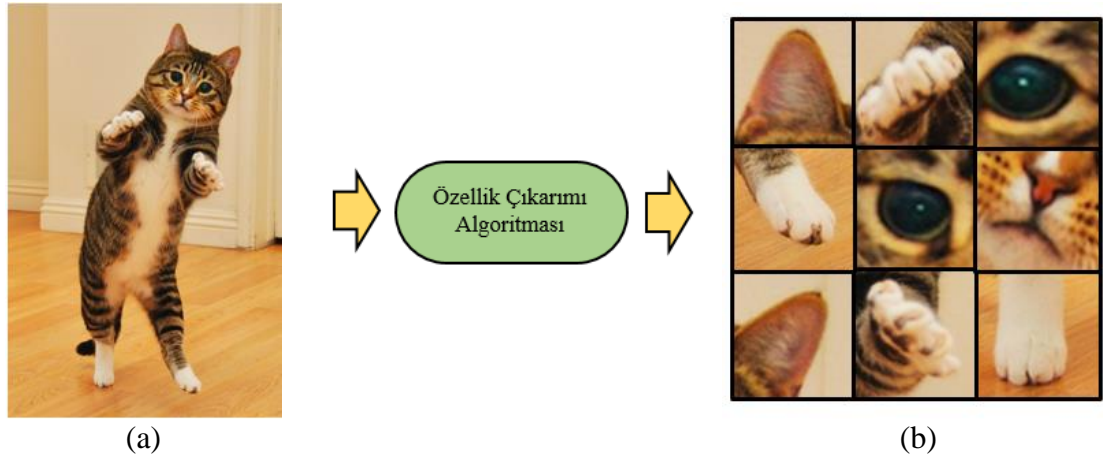
Görüntüdeki nesnenin arka plandan ayrılmasında sıklıkla tercih edilen yöntem eşikleme yöntemidir. Bölütleme yöntemleri içinde en hızlı çalışan bu uygulamada gri seviyeye dönüştürülmüş resmin histogramına bakılarak bir sınır değeri belirlenir ve bu değerin altı 0 (siyah), üstü ise 1'e (beyaz) eşitlenir. Görüntüde eşikleme işlemlerinde literatürde yaygın kullanılan yöntemler arasında Bernsen's metodu, Parker's metodu ve Niblack's metodu gösterilebilir (Choraś ve Choraś 2019).

Kenar tabanlı bölütlemde renkli görüntülerdeki renk, parlaklık ve doku özelliklerine bakılır. Kenar belirlenmesi için gri seviyeye dönüştürülmüş görüntüdeki ani değişiklik kenar olarak algılanarak bu bölgeler işaretlenir. Kenar tabanlı bölütleme için kullanılan yaygın yöntemler arasında Sobel Kenar Dedektörü, Canny Kenar Dedektörü, Prewitt Kenar Dedektörü ve Roberts Kenar Dedektörü gösterilebilir (Priyadharsini ve Sharmila 2019).

Bölgesel bölütleme ise kenar belirlemenin zor olduğu durumlarda kullanılır. Bu yöntemde seçilen bölgedeki renk, yoğunluk ve dokusal özelliklere benzer bölgeler seçilerek bölütleme yapılır. Görüntü bölütleme işlemlerinde en sık kullanılan yöntemler görüntü büyütme, görüntü bölme ve birleştirme işlemleridir (Choraś ve Choraś 2019).

3.3.2. Özellik çıkartma

Görüntü ön işleme ve bölütleme işlemlerinin bir devamı olarak uygulanan ve görüntülerden bilgi elde edilmeye çalışılan süreçtir. Gözle ayırt edilmesi zor olan görüntünün karakteristik bilgileri, çeşitli matematiksel formüller ve yöntemler ile öğrenilir ve böylece görüntü sınıflandırması işlemine yardımcı olur. Çıkarılacak bilgiler, görüntüdeki pikselleri, piksel gruplarını ve görüntünün tüm genel durumunu içerir. Şekil 3.8'de özellik çıkarımı çalışması şematize edilmiştir (Izonin vd. 2015).



Şekil 3.8. Özellik çıkarımı (a) orjinal görüntü ve (b) özellik çıkarımı sonucu elde edilen özellikler (Anonim 3)

Özellik çıkarımı işlemleri görüntü temelli veya şekil temelli olabilir. Görüntü temelli uygulamalarda histogram özellikleri kullanılarak görüntünün ortalama, varyans, enerji ve entropi gibi bilgilerine ulaşılır. Şekil temelli uygulamalarda ise etkili çap, dairesellik, izdüşümler ve yoğunluk gibi bilgiler elde edilir. Yapay zekâ uygulamalarında

bu işlemler sınıflandırma algoritmalarını beslemek için sisteme dâhil edilir. Makine öğrenmesinde kullanıcılar bu özellik çıkarımı işlemlerini elle tek tek yapar ve elde edilen bilgiler sınıflandırma algoritmalarına girdi olarak verilir. Derin öğrenme uygulamalarında ise özellik çıkarımı ve sınıflandırma işlemleri otomatik olarak yapılır (LeCun vd. 2015).

3.3.3. Görüntü sınıflandırılması

Görüntü işlemlerinin son basamağı olarak görüntü sınıflandırması işlemleri ile görüntülerden anlam çıkarılır. Bu işlemlerde bir piksel grubunun gri değerine bakılarak etiketleme işlemleri gerçekleştirilir. Sınıflandırılacak nesne veri tabanında aynı nesnenin bulunduğu farklı görüntülerden etiketleme yapılır. Bir nesnenin etiketlenmesinde o nesneden ne kadar fazla görüntü var ise sınıflandırma başarısı o kadar yüksek olacaktır (Padmavathi ve Krishna 2014).

Biyomedikal alanlarda yapılan sınıflandırma çalışmaları kanser teşhislerinde sıklıkla karşılaşılmaktadır (Acharya vd. 2012; Milosevic vd. 2014; Pramanik vd. 2015). Bu çalışmalarda modellerin eğitimleri için kullanılacak görüntülerin sınırlı olduğu bilinmektedir. Görüntü sayısının yetersiz olduğu çalışmalarda ise sınıflandırma başarımları düşük olmaktadır. Bu sorunun önüne geçilmesi için makine öğrenmesi çalışmalarında sınıflandırılacak görüntüler üzerinde yapılan en doğru bölütleme ve bölütlenmiş görüntüler üzerinden modeli en iyi temsil eden özelliklerin çıkarılması ile yapılır (Karim vd. 2018). Derin öğrenme çalışmalarında en uygun mimarinin seçilmesi, en uygun mimarinin tasarlanması veya önceden eğitilmiş mimarilerin transfer öğrenme uygulanarak sınıflandırma gerçekleştirilir (Fernández-Ovies vd. 2019). Sınıflandırma işlemlerinin ardından kullanılan modellerin sınıflandırma işlemlerini ne kadar yüksek doğrulukta yaptığını nicel bilgiler ile desteklemek için performans değerlendirme metrikleri kullanılır (Pramanik vd. 2015).

3.4. Makine Öğrenmesi

Makine öğrenmesi, deneyimlerden yola çıkarak öğrenmeyi ve geliştirmeyi sağlayan yapay zekâ uygulamalarının bir alt dalıdır (Izonin vd. 2015). Bu uygulamalar, Şekil 3.9'da görüldüğü gibi bilinen girdi değerleri ve yanıtları kullanarak bir model oluşturur ve yeni veriler üzerinden yanıtların bulunmasında bu modeli kullanır. Bu uygulamalar ile karar verme aşamasında bir uzman gözüyle problemin incelenebilmesi ve uzmanlara bazı durumlarda yardımcı olunması amaçlanır.



Şekil 3.9. Makine öğrenmesi a) model oluşumu ve b) yanıt tahmini

Makine öğrenmesinde temel olarak *gözetimli* ve *gözetimsiz* olmak üzere iki farklı öğrenme yöntemi vardır (Sizochenko vd. 2019). Gözetimli öğrenmede veri setinden çıkartılacak öznitelikler belirlenir ve bu özniteliklerin hangi sınıfa ait olduğu (lezyon / lezyon değil) bilgileri girilerek etiketleme işlemleri gerçekleştirilir. Bu öğrenme türü

sınıflandırma ve regresyon çalışmalarında kullanışlıdır. Gözetimsiz öğrenmede ise önceden herhangi bir etiketleme yapılmadan algoritmanın kendi kendine öğrenmesi sağlanır. Bu öğrenme türü ise kümeleme ve boyut azaltılması işlerinde kullanılır.

Makine öğrenmesi çalışmalarında veri setinden öznitelik çıkarımları manuel olarak gerçekleştirilir. Çıkarılan bu öznitelikler bazı durumlarda gereksiz olabilir ve bu durum sınıflandırma başarısını düşürebilir ve eğitim süresini artırır. Böyle durumlarda Temel Bileşen Analizi (Principal Component Analysis, PCA) gibi özellik seçici algoritmalar kullanılarak boyut azaltımına gidilir. Bu şekilde bilgisayarların gereksiz işlemlerden kaynaklanan uzun çalışma süresi kısaltılır ve böylece sınıflandırma başarısı artırılır (Padmavathi ve Krishna 2014).

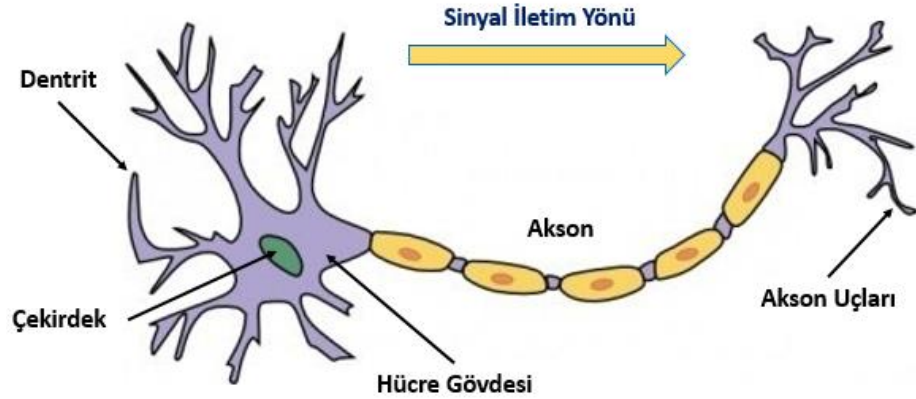
3.4.1. Makine öğrenmesi algoritmaları

Makine öğrenmesi çalışmalarında giriş verilerinden özniteliklerin çıkartılması (feature extraction) işlemlerinden sonra, öznitelik ve sınıf bilgileri (hasta/sağlıklı) ile birlikte model eğitilir. Eğitilen modele yeni veriler girilerek sınıflandırma işlemleri yapılır. Sınıflandırma işlemlerinin gerçekleştirilmesi için çeşitli makine öğrenmesi algoritmaları kullanılır. Her makine öğrenmesi algoritması ayrı ayrı matematiksel formüllere dayanır. Bu sebeple her algoritma her veri setinde yüksek başarımlar elde edemez. Sınıflandırma işleminin en doğru şekilde yapılması için öznitelik grubunu en iyi ayırt edebilecek makine öğrenmesi yönteminin kullanılması gerekir.

- **Karar Ağaçları (Decision Trees):** Hafıza kullanımları düşük olan kolay ve hızlı tahmin yapılabilen makine öğrenmesi algoritmalarıdır. Bir karar ağacı en üstte bulunan düğüm ile başlar ve her kararda bir dal seçimi yapılarak dallarını oluşturur. Yapılacak olan seçim etiketler takip edilerek yapılır. Ağacın sonunda iki ayrı sınıftan hangisine ait olduğu belirlenir. Karar ağaçlarının hızlı yanıt vermeleri için mümkün olduğu kadar kısa olması istenir (Brijain vd. 2014).
- **Doğrusal Regresyon (Linear Regression):** Ön işlemler sonucu elde edilen öznitelikler birbirlerine bağımlı veya bağımsız olabilir. Bu yöntemde bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişkinin olup olmadığına bakılarak sınıflandırma işlemleri gerçekleştirilir (Hacıoğlu 2017).
- **Diskriminant Analizi (Discriminant Analysis):** Farklı sınıfların farklı Gauss dağılımına dayanan veri ürettikleri varsayımını kullanır. Bu yöntem hızlı olması ve kolay yorumlanması yönüyle sınıflandırma işlemlerinde sıklıkla kullanılır (Rymarczyk vd. 2019).
- **Lojistik Regresyon (Logistic Regression):** Genellikle iki sınıflı sınıflandırma işlemlerinde tercih edilen kullanımı kolay algoritmalarıdır. Algoritmalarda sınıflandırıcı, kararın hangi sınıfta olduğunun tahminini etiketlerin doğrusal birleşimlerinin bir işlevi olarak modelleme yapar (Rymarczyk vd. 2019).
- **Destek Vektör Makineleri (Support Vector Machines):** Sınıf sayısının iki veya daha fazla olması durumunda tercih edilen gözetimli bir makine öğrenmesi algoritmasıdır. Bu algoritma ile bir sınıfa ait olan verilerin diğer sınıflardan ayrılması için en uygun düzlem bulunmaya çalışılır. Destek vektörleri ise seçilen düzleme en yakın olan veri noktalarından geçen vektörlerdir (Padmavathi ve Krishna 2014).
- **En Yakın Komşuluk (Nearest Neighbor):** Tahmin edilecek olan verinin en


yakınında bulunan komşu değerlerin hangi sınıflara ait olduğuna bakılarak tahmin yapan algoritmalarıdır (Bijalwan vd. 2014). Komşuluk değeri olarak eşitlik durumunun olmaması için 3, 5, 7 ve 9 gibi tek sayılar seçilir. Tahmin edilecek veri ile en yakın komşuları arasındaki uzaklık Kosinüs, Öklid veya Manhattan formülleri ile hesaplanır. Tahmine en yakın sınıflardan sayı üstünlüğü hangisinde ise o sınıf seçilir.

- **Naive Bayes:** Dengesiz ve az sayıda eğitim verisi bulunan çalışmalarda tercih edilen olasılıklı bir makine öğrenmesi algoritmasıdır (Bijalwan vd. 2014). Esas mantığı Bayes teoremine dayanan bu algoritma eğitim verilerini Bayes formülüne göre işleyip olasılık değerlerini hesaplar. Elde edilen olasılık değerlerini kullanarak yeni gelen verilerin sınıflandırılması işlemlerini gerçekleştirir.
- **Yapay Sinir Ağları:** Yapay zekâ veya makine öğrenmesi süreci canlılarda sinir hücreleri arasındaki bilgi aktarımı sürecine benzetilebilir. Bu işlem Şekil 3.10'daki gibi bilgiyi gönderen sinir hücresinin aksonu ile bilgiyi alan sinir hücresinin dentriti arasında gerçekleşir. Dentrit ve akson arasında sinaptik bir boşluk bulunur. Bilgiyi gönderen sinir hücresinin akson ucunda bilgiler nörotransmitterler içinde toplanır ve sinir ucuna aktivasyon potansiyelinin gelmesiyle sinaptik aralığa salınır. Bilgiyi alacak olan sinir hücresinde bir potansiyel fark ortaya çıkar. Bu farkın belirli bir düzeye ulaşmasıyla ve gerekli reseptörlerin iyon kapılarını açmasıyla, bilgiler karşı sinir hücresine geçiş yaparak bilgi aktarımı gerçekleştirilir.



Şekil 3.10. Sinir hücresi genel görünümü (Anonim 4)

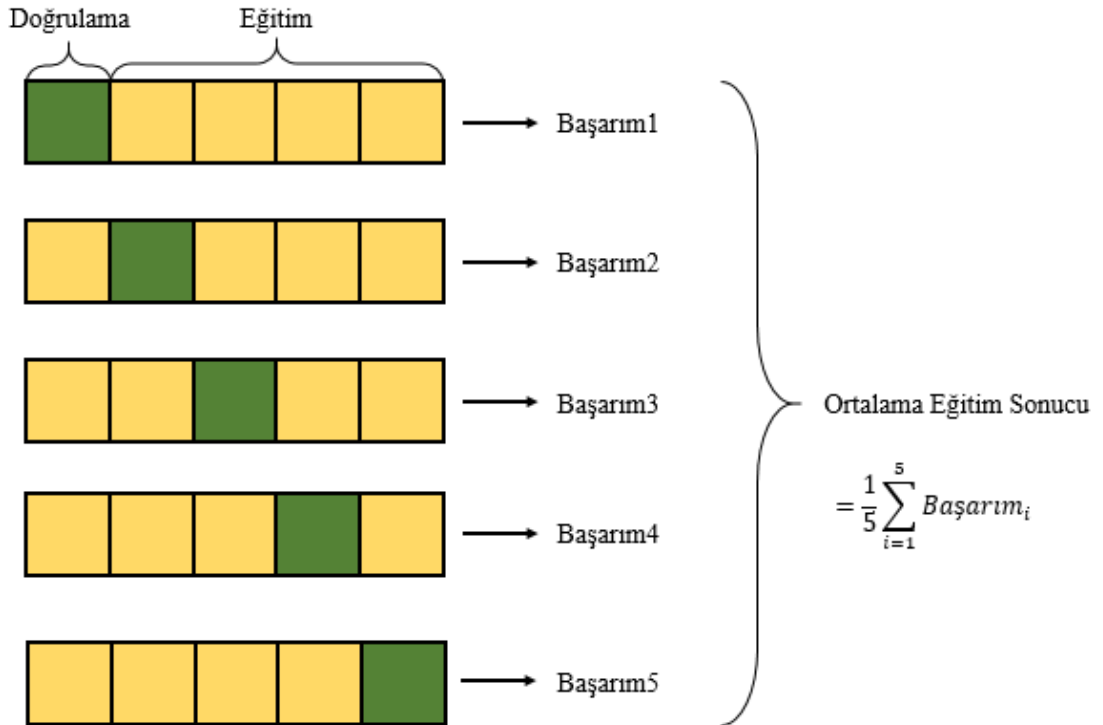
Yapay sinir ağları canlı sistemlerdeki yukarıda da anlatılan bilgi aktarımından ilham alınarak modellenmiş hesaplama sistemleridir. Bu ağlar giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç kısımdan oluşur. Şekil 3.11'de görüldüğü gibi giriş katmanında sisteme verilen girdiler belirli ağırlık değerleriyle çarpılarak gizli katmanlara aktarılır. Yapay sinir ağının asıl temelini oluşturan gizli katman, giriş katmanından alınan bilgilerin ağırlıklandırılarak çarpılmasının ardından tüm bilgileri toplar ve bunlara bias (önyargı) değerini (b) ekler. Tüm bu işlemlerin ardından uygun çıkış katmanına iletilir (O'Shea ve Nash 2015).



Şekil 3.11. Yapay sinir ağı matematiksel modeli

3.4.2. Çapraz doğrulama

Çapraz doğrulama işlemleri makine öğrenmesi algoritmalarında aşırı öğrenme (overfitting) veya diğer bir deyimle ezberleme yapılmasının önüne geçmek için kullanılan bir yöntemdir. Çapraz Doğrulama (Cross Validation) aşamasında çalışmada kullanılacak olan veriler ve etiketleri makine öğrenmesi algoritmasına giriş olarak verildikten sonra veri setinin bölümlenmesi için gerekli katlama sayısı seçilir. Seçilen bu sayıya göre çıkarılan öznitelikler n (girilen katlama sayısı) ayrık kümeye ayrılır. Şekil 3.12’de gösterildiği gibi n adet ayrık kümeden biri referans seçilerek geriye kalan $n - 1$ adet küme ile model eğitilir. Bu işlem her küme için ayrı ayrı referans seçilerek tekrarlanır. Son aşamada tüm eğitimlerin ortalaması alınarak test hatası hesaplanır (Bijalwan vd. 2014).



Şekil 3.12. Çapraz doğrulama

3.4.3. Karmaşıklık matrisi

Çalışmanın performansının değerlendirilmesi için sıklıkla kullanılan yöntemlerden biri Karmaşıklık Matrisi (Confusion Matrix) oluşturulmasıdır. Bu matriste, önceden bilinen gerçek değerler (Ground Truth) ile modelin tahmin ettiği yanıtlar yer alır (LeCun vd. 2015). Şekil 3.13'te gösterilen karmaşıklık matrisini daha iyi anlamak için, hastalara tümör teşhisi koyma sürecini ele alalım:

- **Doğru Pozitif (True Positive, TP):** Tümörlü hastanın “tümör var” olarak tahmin edilmesi.
- **Yanlış Negatif (False Negative, FN):** Tümörlü hastanın “tümör yok” olarak tahmin edilmesi.
- **Yanlış Pozitif (False Positive, FP):** Tümörü olmayan hastanın “tümör var” olarak tahmin edilmesi.
- **Doğru Negatif (True Negative, TN):** Tümörü olmayan hastanın “tümör yok” olarak tahmin edilmesi.

Şekil 3.13'te hasta grubu üzerinden elde edilen TP, TN, FP ve FN sayıları elde edilerek karmaşıklık matrisi oluşturulmuştur.

		Tahmin (Prediction)	
		Var	Yok
Bilinen Gerçek (Actual)	Var	Doğru Pozitif (True Positive, TP)	Yanlış Negatif (False Negative, FN)
	Yok	Yanlış Pozitif (False Positive, FP)	Doğru Negatif (True Negative, TN)

Şekil 3.13. Karmaşıklık matrisi

Karmaşıklık matrisi kullanılarak tümör tanımak üzere eğitilen modelinin doğruluğu, hassasiyeti ve özgüllük değerleri gibi performans değerlendirme metrikleri aşağıdaki bağıntılar yardımıyla hesaplanır (Tello-Mijares vd. 2019).

$$\text{Doğruluk (Accuracy)} = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

$$\text{Kesinlik (Precision)} = \frac{TP}{TP + FP} \quad (3.2)$$

$$\text{Duyarlılık (Recall)} = \frac{TP}{TP + FN} \quad (3.3)$$

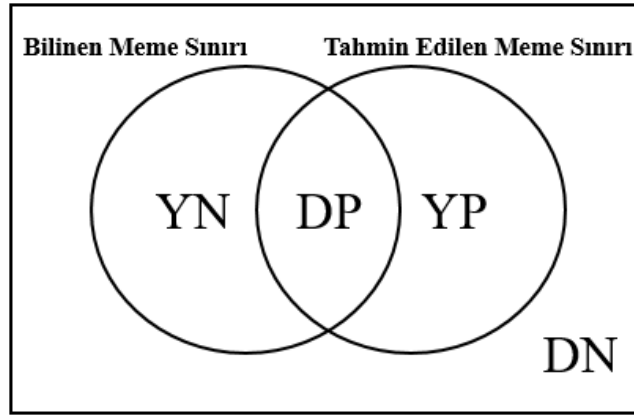
$$\text{F1 Skor (F1 Score)} = 2 * \frac{\text{Kesinlik} * \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (3.4)$$

3.4.4. Bölütleme başarımı değerlendirme yöntemleri

Çalışmada kullanılan bölütleme performansının değerlendirilmesi için sıklıkla kullanılan yöntemler Doğruluk, Duyarlılık, Özgüllük, F1 skoru, Kesinlik, MCC, Dice ve Jaccard indeksleridir. Bu şekilde aynı boyutlarda olan iki görüntü arasında piksel bazlı olarak benzerlikler saptanır.

Bölütleme başarımı değerlendirilmesi işlemleri Şekil 3.14'te görüldüğü gibi görüntüde her bir pikselin referans görüntüdeki konumu ile bölütlenmiş sonuç görüntüsündeki konumları etiketlenir.

- **Doğru Pozitif (DP):** Referans görüntüsünde maskelenmiş bir bölge içerisinde bulunan bir pikselin bölütlenmiş sonuç görüntüsünde de maskelenmiş bölge içerisinde yer aldığı durum
- **Doğru Negatif (DN):** Referans görüntüsünde maskelenmiş bir bölge içerisinde bulunmayan bir pikselin bölütlenmiş sonuç görüntüsünde de maskelenmiş bölge içerisinde yer almadığı durum
- **Yanlış Pozitif (YP):** Referans görüntüsünde maskelenmiş bölge içerisinde bulunmayan bir pikselin bölütlenmiş sonuç görüntüsünde maskelenmiş bölge içerisinde yer aldığı durum
- **Yanlış Negatif (YN):** Referans görüntüsünde maskelenmiş bir bölge içerisinde bulunan bir pikselin bölütlenmiş sonuç görüntüsünde maskelenmiş bölge içerisinde yer almadığı durum



Şekil 3.14. Bölütleme performansının değerlendirilmesi

Görüntü içerisinde yer alan tüm pikseller bu şekilde tek tek tespit edilerek görüntü boyunca DP, DN, YP ve YN durumlarından kaçar tane bulunduğu saptanır. Bulunan sayı değerlerine göre bölütleme başarımlarının hesaplanması aşağıdaki formüller ile yapılır (Aslanyürek ve Mesut 2021).

$$\text{Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN} \quad (3.5)$$

$$\text{Duyarlılık} = \frac{DP}{DP + YN} \quad (3.6)$$

$$\text{Özgüllük} = \frac{DN}{DN + YP} \quad (3.7)$$

$$\text{Kesinlik (Precision)} = \frac{DP}{DP + YP} \quad (3.8)$$

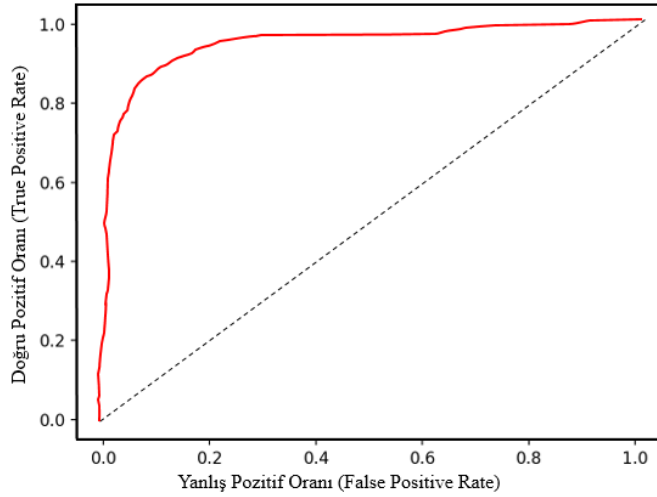
$$MCC = \frac{DP * DN - YP * YN}{\sqrt{(DP + YP) * (DP + YN) * (DN + YP) * (DN + YN)}} \quad (3.9)$$

$$\text{Dice} = \frac{2 * DP}{2 * DP + YP + YN} \quad (3.10)$$

$$\text{Jaccard İndeksi} = \frac{DP}{DP + YP + YN} \quad (3.11)$$

3.4.5. Alıcı-işleyici karakteristik (ROC) eğrisi

Eğitilen bir modelin yeni veriler üzerindeki tahmin etme başarısını özetlemek için kullanılan bir grafikdir. Şekil 3.15'te görüldüğü gibi ROC eğrisinin düşey eksenı sınıflandırıcının gerçek pozitif değeri doğru tahmin etme oranı olan doğru pozitif oranı (True Positive Rate, TPR) yatay eksenı ise yanlış pozitif değeri doğru tahmin etme oranıdır (False Positive Rate, FPR). Model performansının %100 başarıyı gösterdiği ideal durum tam karenin olduğu (0 eğim) durumdur. Bu durumda Eğri Altında Kalan Alan (Area Under the Curve, AUC) 1.0'a eşit olur. İdeal duruma ne kadar yaklaşırsa modelin performansının o kadar yüksek olduğu anlaşılır (Hoo vd. 2017).

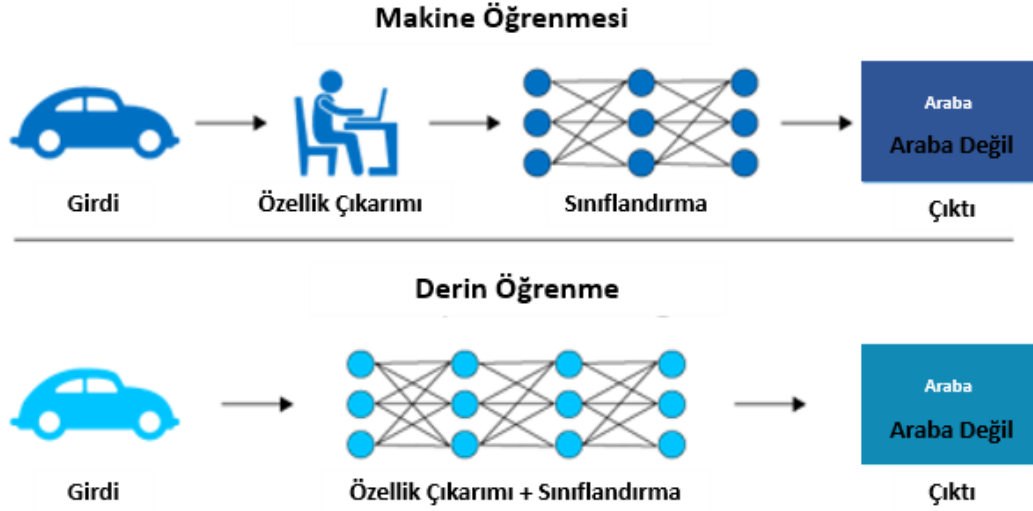


Şekil 3.15. ROC eğrisi

3.5. Derin Öğrenme

Derin öğrenme, canlılardaki biyolojik öğrenme sisteminden esinlenerek modellenen ve yapay sinir ağlarından oluşan makine öğrenmesinin bir alt dalıdır (LeCun vd. 2015). Genel makine öğrenmesi çalışmalarında sınıflandırma işlemi yapılmadan önce veriler işlenerek özellik çıkarımları yapılır ve çıkarılan bu özellikler yardımcı ile model

eğitimi gerçekleştirilir. Şekil 3.16’da görüldüğü gibi derin öğrenmede ise veriler modele ham bir şekilde verilir ve özellik çıkarımları model içerisinde otomatik olarak gerçekleştirilir. Otomatik özellik çıkarımı işlemleri derin öğrenme için bir avantaj olmasına karşın büyük veri setleri gerektirmesi ve bu verileri işleyebilecek güçlü iş istasyonlarına ihtiyaç duyması yönleriyle dezavantajları da vardır (Xin vd. 2018).

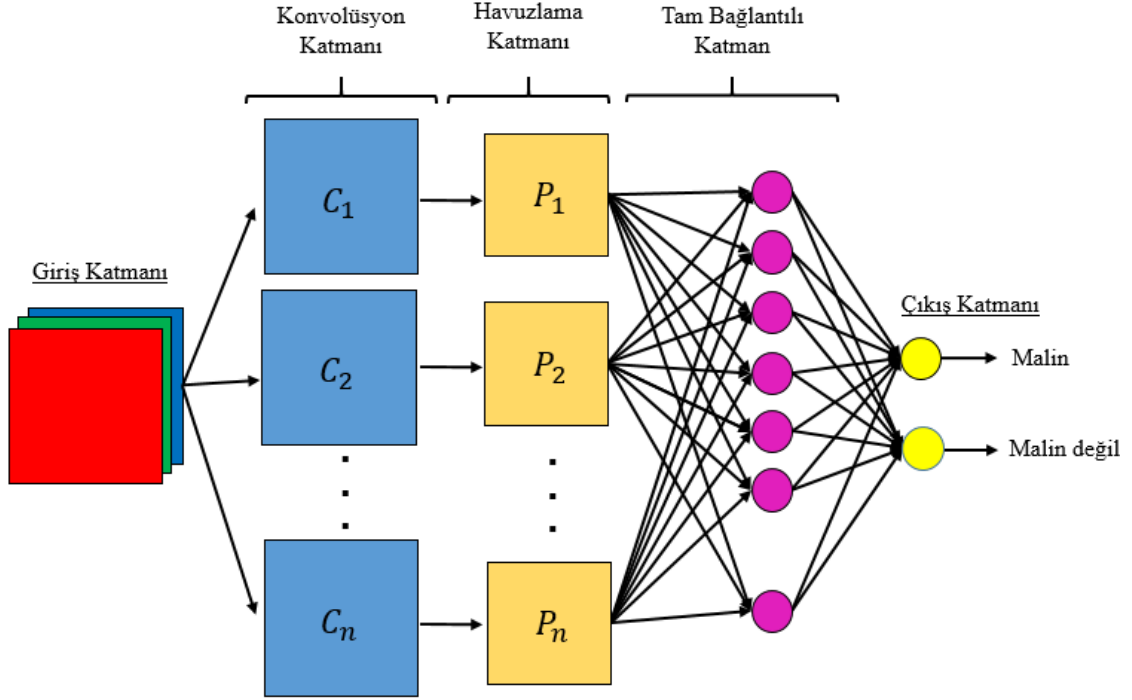


Şekil 3.16. Makine öğrenmesi ve derin öğrenme farkı (Anonim 5)

Derin öğrenme sistemleri derin yapay sinir ağlarından oluşur ve birçok gizli katmanları olan yöntemlerdir. En sık kullanılan derin öğrenme algoritmaları evrişimsel sinir ağları ve tekrarlayan sinir ağlarıdır. Tekrarlayan sinir ağları geleneksel sinir ağlarının yapamadığı önceki bilgileri kullanarak yeni gelen bilgilerin anlamlandırılmasını sağlar ve genellikle kelime tahmini amacıyla kullanılır. Bu sinir ağları kullanılarak metin, şiir veya şarkı yazılması çalışmaları bilinen çalışmalardandır. Evrişimsel sinir ağları ise genellikle görüntüler üzerinde fazla bir ön işlem gerektirmeyen ve nesne tanıma veya özellik çıkarılması çalışmalarında tercih edilen çok etkili mekanizmalardır (LeCun vd. 2015).

3.6. Evrişimsel Sinir Ağları (ESA)

ESA, görüntülerden nesne tespiti ve sınıflandırılması işlemlerinde sıklıkla kullanılan bir derin öğrenme modelidir. Bu model çeşitli görüntü işleme, özellik çıkarımı ve sınıflandırma işlemleri gerçekleştiren sıralı katmanlardan oluşur. Bu katmanlar Şekil 3.17’de gösterildiği gibi giriş katmanı, evrişim katmanları, havuzlama katmanları, tam bağlantılı katmanlar ve çıkış katmanıdır. Katmanların her biri bir önceki katmanın küçük bir bölümünde çalışıp, bir sonraki katmana iletilerek model akışı sağlanır (O’Shea ve Nash 2015).



Şekil 3.17. Evrişimsel sinir ağı

ESA’da, giriş görüntüleri üzerinde filtreler uygulanarak gerçekleştirilen evrişim işlemlerinin özellik haritaları oluşturulur. ESA’yı diğer yöntemlerden ayıran en önemli özelliği ise eğitim işlemleri gerçekleştirilirken evrişim işlemlerinde kullanılan filtrelerinin ayarlamasını yapabiliyor olmasıdır. Bu da büyük veri setlerinde kullanıldıklarında bile gerçek zamanlı ince ayarlamaların yapılabilmesine olanak tanır.

Görüntüler üzerinde nesne tanıma gibi sınıflandırma işlemlerinin yapılmasında veya özellik çıkarımı için ESA mimarileri kullanılır. Bir görüntü üzerinde ESA’larda evrişim katmanları ile özellikler çıkarılır. Mimari girişine verilen bir görüntüde gerçekleştirilen evrişim işlemlerinin ardından öncelikle görüntüdeki kenarlar bulunur. Bu işlem ile görüntünün küçük bir tanımı yapılır ve diğer katmanlara geçilir. Kenar bilgilerinin elde edilmesinin ardından, köşeler ve renk grupları bulunur. Görüntü tanımının ardından yine bir sonraki katmana geçilerek sınıflandırma katmanlarına varılana kadar özellik öğrenimleri gerçekleştirilir (Albawi vd. 2017).

Evrişimsel sinir ağlarının ilk katmanı giriş katmanıdır ve bu katmana veriler ham bir şekilde aktarılır. Giriş katmanlarına gelen veriler kendisinden sonraki katman olan evrişim katmanına verilir. Bu katmanda ise girişe verilen özellik çıkarımı işlemlerinin yapılması için evrişim (iç çarpım) işlemleri gerçekleştirilir. Evrişim işlemlerinin uygulanması ile matris boyutu bazı durumlarda düşmektedir. Nedeni ise görüntü matrisi üzerinde gezdirilecek olan çekirdek matrisinin (yapısal bileşen) evrişim işlemleri yaparken sağa ve aşağı doğru ne kadar ilerleyebileceği ile ilgilidir. Giriş matrisi ile evrişim katmanının çıkış matrisi (özellik haritası) aynı boyutta olması isteniyor ise padding (piksel ekleme) işlemleri uygulanır. Evrişim katmanlarının çıkışında negatif değerler ile karşılaşılabilir. Bu negatif değerlerin 0’a çekilmesi istenir ve bunun için “ReLU” aktivasyon fonksiyonu tercih edilir. Elde edilen özellik haritalarında çözünürlük

azaltılması ve boyut azaltılması işlemlerinin gerçekleştirilmesi için havuzlama katmanları kullanılır. Bu katmanlar maksimum ve ortalama olmak üzere iki çeşitte uygulanır. Havuzlama katmanlarının ardından elde edilen çıktı değerleri üzerinde düzleştirme işlemlerinin uygulanması ile sınıflandırma işlemlerinin yapıldığı tam bağlantılı katman kullanılır. Bu katman sonucunda elde edilen çıktı değeri çıkış katmanına iletilerek mimari sonlandırılır (Coşkun vd. 2017).

Evrişimsel sinir ağlarında benzer bölgelerden benzer özellikler oluşturulur. Bu özellikler sezgisel olarak açıklanabilmektedir. Evrişimsel sinir ağının en önemli özelliği evrişim (iç çarpım) işlemleri yaparak görüntünün her yerinden özelliklerin çıkartıldığı işlemidir. Yapılan bu evrişim işlemi yüksek düzeydeki uzamsal veriler için kullanışlı bir yöntemdir. Bir diğer sık kullanılan derin öğrenme yöntemlerinden biri olan Tekrarlayan Sinir Ağları (Recurrent Neural Networks; RNN) zamansal ilişkilerin sezgisel anlayışına dayanırken, evrişimsel sinir ağları ise mekânsal ilişkilerin sezgisel anlayışına dayanır. Evrişimsel sinir ağlarında diğer birçok yapay zekâ uygulamalarında kullanıldığı gibi aşırı uyumun (overfitting) engellenmesi için veri arttırma (data augmentation) yöntemi uygulanır. Veri arttırma işlemleri görüntünün çevrilmesi, döndürülmesi, kırılması veya yansıtılması gibi çeşitli işlemler uygulanarak yeni görüntüler olarak kaydedilerek veri sayısı arttırılır. Yapılan bu işlemler görüntünün temel özelliklerini değiştirmedeği için bir görüntü çok sayıda farklı görüntü ile kullanılabilir. Elde edilen bu farklı görüntüler ile zenginleşen veri seti kullanılarak yapılan çalışmanın genelleme gücü daha yüksek olacaktır (Albawi vd. 2017).

3.6.1. Giriş katmanı

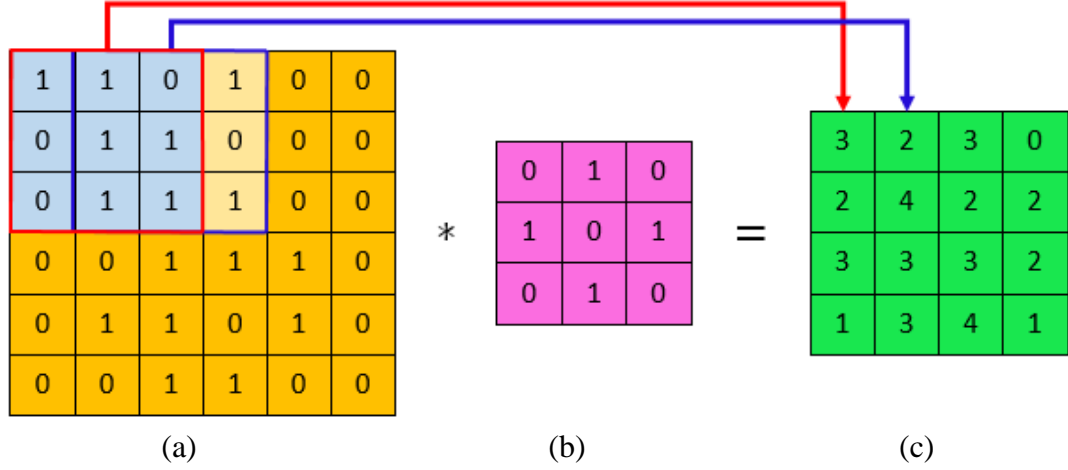
Çalışmada kullanılacak verilerin sinir ağına ham bir şekilde aktarıldığı katmandır. Giriş katmanında veri boyutları, sınıflandırma başarısı ve eğitim süresini önemli ölçüde etkileyen parametredir. Veri boyutu artıkça bellek kullanımı ve test süresi de artar. Bunun yanında sınıflandırma başarısı da artabilir. Veri boyutu azaltılırsa bellek kullanımı ve test süresi azalır, ancak sınıflandırma başarısı da azalabilir (Chen vd. 2020). Giriş katmanında dikkat edilmesi gereken nokta bellek kullanımı ve test süresini minimuma düşürürken, sınıflandırma başarısını maksimuma çıkartabilecek veri boyutlarıyla katmanın beslenmesidir.

3.6.2. Evrişim katmanları

Evrişim katmanı, ağı verilen giriş görüntülerinden özgün özelliklerin çıkarılması işlemlerinin gerçekleştirildiği katmandır. Çıkarılan bu özellikler görüntü içerisindeki nesnelere kenarları veya eğrisel bölgeleri gibi nesneye özel bilgilerdir. Daha özgün özelliklere ulaşılabilmesi için daha derin katmanlarla işlem yapılması gerekir (Albawi vd. 2017).

Evrişim işlemleri görüntü üzerine uygulanmadan önce bir çekirdek (filtre) matris oluşturulur ve konvolüsyon işlemi yapılır. Bu işlemde, filtre matrisi giriş verisinin üzerinde gezdirilerek her adımda bu matrisin her elemanına karşılık gelen piksellerle çarpma işlemi yapılır ve tüm sonuçlar toplanarak özellik haritası matrisinin ilgili elemanı elde edilir. Daha sonra bu elemanlar birleştirilerek özellik haritası tamamlanır. Şekil 3.18'de gösterildiği gibi, filtre matrisi görüntünün sol üst noktasından başlayarak her konvolüsyonun ardından birer piksel sağa kayarak tüm satır gezilir. İlk satırın tüm

sütunları gezildikten sonra alt satıra geçilerek işlemler tekrar edilir. Bu adım görüntü matrisinin sağ alt noktasına ulaşıldığında son bulur ve sonuçta her filtreye özgü özelliklerin bulunduğu bir özellik haritası elde edilir. Bu özellik haritası evrişimsel sınır ağının sonraki katmanına gönderilir (O'Shea ve Nash 2015).




Şekil 3.18. 6 * 6 boyutundaki girdiye 3 * 3 boyutlu filtre uygulandığında elde edilen 4 * 4 boyutlu özellik haritası

Şekil 3.18’de 6 * 6 boyutlu girdi verisine evrişim katmanında 3 * 3 boyutunda bir filtre uygulanmıştır. 3 * 3 boyutundaki kare matrisi 6 * 6 boyutundaki giriş matrisi içerisinde her konvolüsyon işleminden sonra bir piksel sağa kayarak ilerler. Tüm ilerleme işlemleri giriş matrisi üzerinde 4 piksel sağa ve 4 piksel aşağı gezdirilir. Bu sebepten dolayı konvolüsyon sonuçlarının depolandığı özellik haritası adı verilen yeni matris 4 * 4 boyutunda olur. Eğer giriş verisi 5 * 5 boyutunda olsaydı 3 * 3 filtre gezdirilmesi işlemlerinin ardından oluşacak özellik haritası 3 * 3 boyutunda olurdu (Coşkun vd. 2017).

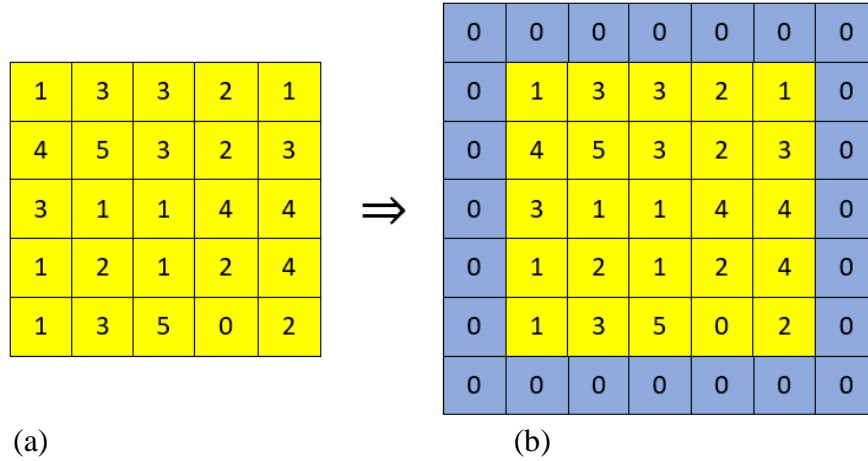
Evrişim katmanında yapılan konvolüsyon işlemlerinin ardından çıktı değerlerinin içerisinde negatif değer bulunabilir. Denklem 3.12’deki fonksiyon ile negatif değerlerin sifıra çekilmesi ve pozitif değerlerin belli bir eğim ile artışını sağlamak üzere Şekil 3.19’da da gösterilen *ReLU aktivasyon fonksiyonu* kullanılır. Bu fonksiyon matematiksel olarak aşağıdaki biçimde tanımlanır (İnik ve Ülker 2017).

$$f(x) = \begin{cases} 0 & \text{eğer } x < 0 \\ x & \text{eğer } x \geq 0 \end{cases} \quad (3.12)$$



Şekil 3.19. ReLU katmanının çıktı verilerine etkisi

Çekirdek matris görüntü üzerinde gezdirilirken her pikseli eşit sayıda kullanmaz. Çekirdek matrisin boyutuna göre kenardaki pikseller orta piksellere göre daha az kullanılır. Piksel gezme işlemleri sınırlı olduğu için giriş verisindeki tüm piksellerin eşit sayıda kullanılması ve çıkış matrisinin boyutunun girişe eşit olması istenir. Bu durumda giriş matrisine yeni pikseller eklenir. Bu eklenen piksellerin etkisiz olması için değerleri “0” olarak seçilir ve yapılan bu işleme *piksel ekleme* ya da literatürdeki adıyla *padding* denir. Şekil 3.20’de görüldüğü gibi 5×5 boyutundaki orjinal giriş verisi piksel ekleme işlemi ile 7×7 boyutuna dönüştürülür. Bu yeni giriş verisi üzerinde 3×3 ’lük filtre gezdirilip konvolüsyon işlemleri yapıldıktan sonra çıkış matrisinin (özellik haritası) boyutu 5×5 olur. Bu işlem sonucu giriş verisinin boyutu ile çıkış verisinin boyutu eşitlenmiş olur (Coşkun vd. 2017).

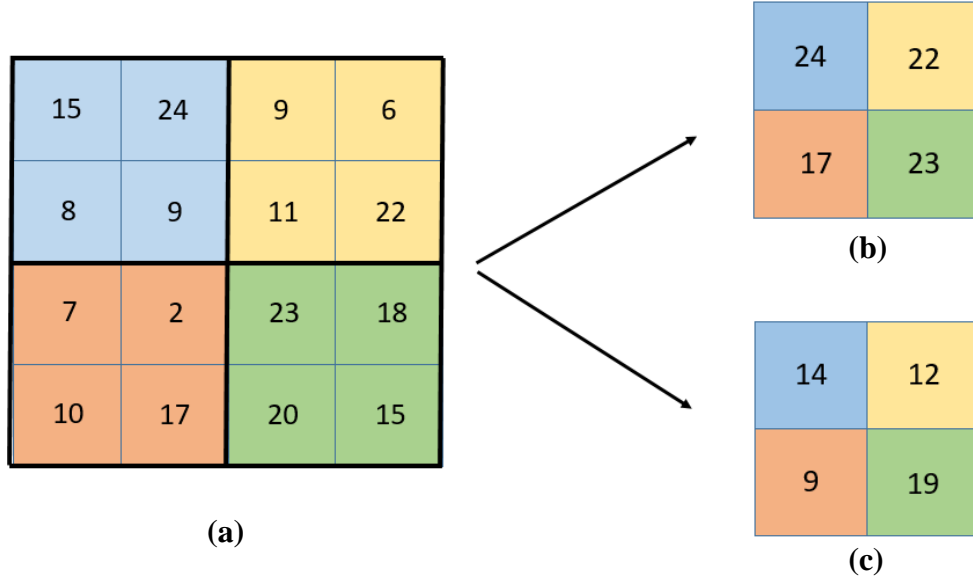


Şekil 3.20. Piksel ekleme (a) 5×5 boyutlu giriş verisine piksel eklenerek (b) 7×7 boyutlu yeni bir giriş verisinin oluşturulması

3.6.3. Havuzlama katmanları

Evrişim katmanından sonra elde edilen özellik haritalarına havuzlama işlemleri ile çözünürlük azaltma ve boyut azaltma işlemlerinin yapıldığı katmandır. Böylece hesaplama işlemleri hızlandırılmış olur. Genel olarak ortalama ve maksimum olmak üzere iki çeşit havuzlama yöntemi vardır. Bu iki yöntem arasında maksimum havuzlama yöntemi daha iyi çalıştığından literatürde kullanımı sıklıkla tercih edilir. Şekil 3.21’de

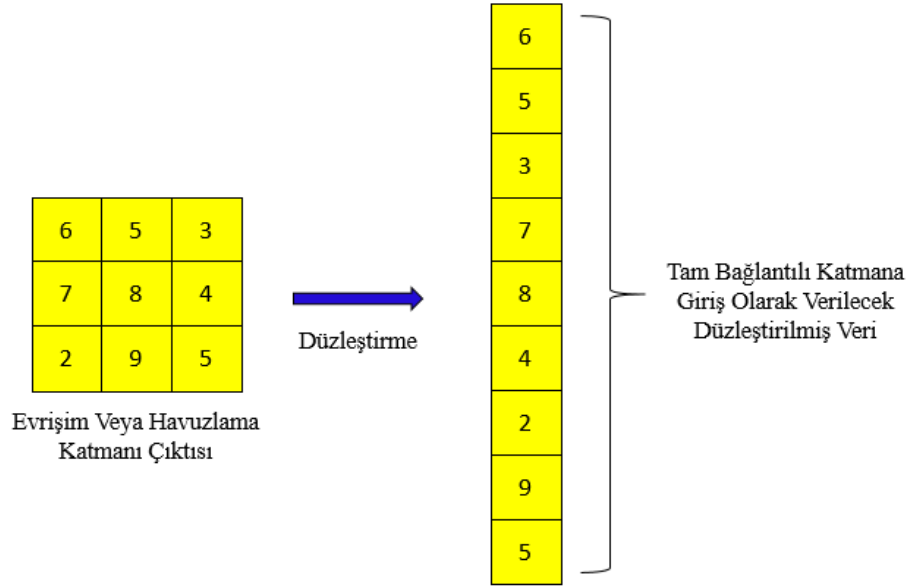
gösterildiği gibi maksimum havuzlama yönteminde kare boyutunda alınmış orjinal görüntü eşit kare parçalara bölünür. Bölünen ve kare matrislerden oluşan her bölümdeki maksimum piksel değeri alınarak yeni ve indirgenmiş matrise yerleştirilir. Ortalama havuzlama yönteminde ise her bölümdeki piksellerin ortalaması alınarak yeni ve indirgenmiş matris doldurulur (O'Shea ve Nash 2015).



Şekil 3.21. Maksimum ve ortalama havuzlama (a) orjinal görüntü, (b) maksimum havuzlama ve (c) ortalama havuzlama

3.6.4. Tam bağlantılı katmanlar

Evrişimsel sinir ağının sınıflandırma işlemini yapan katmanıdır. Bu katmana evrişim ve havuzlama katmanlarından gelen çıktı verileri verilmeden önce veriler üzerinde *düzleştirme* işlemleri yapılır. Literatürde bu düzleştirme işlemine *flattening* adı verilir. Düzleştirme işlemi ile Şekil 3.22’de gösterildiği gibi matris formundaki çıktı verileri vektör formuna (tek sütun) dönüştürülmüş olur. Bu işlemin ardından veriler sınıflandırma işlemlerinin yapılması için tam bağlantılı katman girişine verilir (Chen vd. 2020).

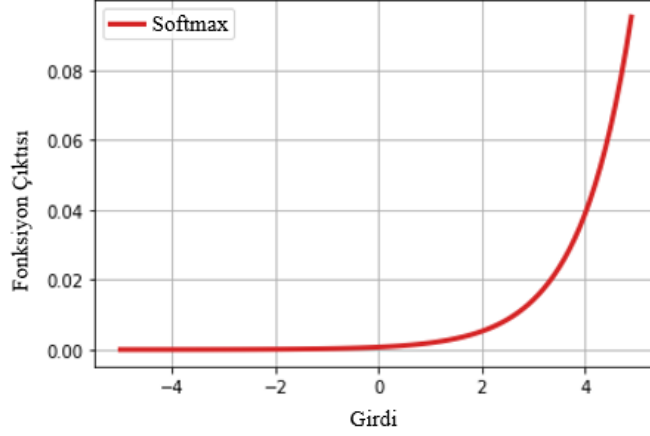


Şekil 3.22. Düzleştirme işlemi

Tam bağlantılı katmanlar ve katmanlardaki nöron sayıları ihtiyaca göre bir veya daha fazla sayıda bulunabilirler. Bu katmanların girişine düzleştirme işlemi yapıldıktan sonra elde edilen çıktı verileri aktarılır. Alınan tüm veriler üzerinde ağırlıklandırma işlemleri uygulanarak veriler birleştirilir. En uygun nöron ağırlığının bulunabilmesi ve sınıflandırma işleminin gerçekleştirilmesi için hata fonksiyonları kullanılır (Nakahara vd. 2017). Bu katmanlarda genel olarak Şekil 3.23'te gösterilen ve Denklem 3.13'te formülü verilen Softmax hata fonksiyonu kullanılır. Softmax, girilen girdi bilgilerinin hangi sınıfa ait olduğunun belirlenmesi için 0-1 arasında olasılık değerlerinden oluşan çıkış bilgileri üretir. Bu olasık değerleri yapay sinir ağının çıktı değerlerinin normalizasyonu ile elde edilir.

$$\sigma(\vec{z})_i = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (3.13)$$

Burada \vec{z} , Softmax fonksiyonunun giriş vektörü,
 z_i , Softmax giriş vektörünün öğeleri,
 e^{z_i} , Giriş vektörünün her öğesine uygulanan üstel fonksiyon,
 K , Sınıf sayısı,
 $\sum_{j=1}^K e^{z_j}$, 0-1 arasında normalizasyon işlemidir.




Şekil 3.23. Softmax hata fonksiyonu grafiği

3.6.5. Çıkış katmanı

Bu katman evrişimsel sinir ağlarının son katmanı olup, ağdaki genel hatayı azaltmak ve aşırı öğrenmenin önüne geçmek üzere bırakma (dropout) işlemini kullanır. Literatürde bu çıkış katmanı tam bağlantılı katmanlarla birlikte de gösterilebilir ve sahip olduğu nöron sayısı sınıflandırılacak sınıf sayısına eşittir. Tam bağlantılı katmanda Softmax ile oluşturulan olasılık değerlerine göre çıkış katmanına veri aktarılır (O'Shea ve Nash 2015).


Çok fazla sayıda veri içeren ağlarda tüm nöronların kullanılmasının aşırı uyuma sebep olabileceği bilinmektedir. Bu durum ağın sınıflandırma başarısını düşüren ve istenmeyen bir durumdur. Aşırı uyumun ve modelin ezberleme yapmasının önüne geçebilmek için Şekil 3.24'te gösterildiği gibi rastgele seçilmiş bazı nöronlar eğitim sırasında göz ardı edilerek bırakma işlemleri uygulanır. Bu işlemin temeli, modelin ezberleme yapmasının önüne geçilebilmesi için bazı nöronların rastgele olarak kapatılıp göz ardı edilmesidir (Chen vd. 2020).



Şekil 3.24. Dropout ile bazı nöronların göz ardı edilmesi (a) yapay sinir ağı ve (b) bırakma kullanılan yapay sinir ağı


3.7. Mask R-CNN

Bölge Tabanlı Evrişimsel Sinir Ağı (Region-based CNN, R-CNN) mimarisi, görüntüde nesne algılama için kullanılan bir derin öğrenme mimarisi olup görüntüde yer alan nesnelere sınırlayıcı kutu içerisine alarak sınıflandırma yapmayı hedefler (He vd. 2017). Sonraları Faster R-CNN olarak geliştirilen bu mimari Mask R-CNN mimarisinin temelini oluşturur. R-CNN ve Faster R-CNN mimarileri görüntüler üzerinde Şekil 3.25'te gösterildiği gibi sınıflandırma ve sınırlayıcı kutular içerisinde algılama işlemleri yaparak iki basamakta çalışır. İki basamaklı çalışma mekanizmasında ilk basamakta bölge önerisi verilmesi için görüntü üzerinde bir kez çalışacak olan ResNet, VGG, Inception gibi mimarileri omurga olarak ele alıp bir Bölge Teklif Ağı (Region Proposal Network, RPN) oluşturulur. İkinci basamakta ise ilk basamakta önerilen bölgeler sınırlayıcı kutular içerisine alınarak nesne sınıflandırması yapılır. Sınırlayıcı kutular her nesne için farklı boyutlarda olmaktadır. Sınıflandırma işlemlerini gerçekleştirecek olan Tam Bağlantılı Katmanlar için görüntü boyutlarının aynı olması gerekir. Mimaride boyut eşitleme yöntemi olarak RoIAlign kullanılır (Ren vd. 2016). RoIAlign yöntemi her RoI için özellik haritalarının çıkarılmasına yarayan bir yöntemdir. R-CNN ve Faster R-CNN'de ayrıca RoI havuzlama (RoIPool) katmanı kullanılır. Bu katmanda nicelleştirme işlemleri zor olduğu için Mask R-CNN mimarisinde bu katman yerine RoIAlign katmanını kullanılmaktadır. RoIAlign katmanı ise çıkarım yapılan özellik haritalarını girdi boyutlarına uygun olacak şekilde hizalar.




Şekil 3.25. Faster R-CNN ile iki basamaklı çalışma mekanizması (Ren vd. 2016)

Mask R-CNN bu mimarilere bir basamak daha ekleyerek sınırlayıcı kutu içerisine aldığı nesneyi maskeleyerek sınıflandırma yapabilen bir mimaridir. Şekil 3.26'da görüldüğü gibi Mask R-CNN mimarisinin ilk iki basamağı Faster R-CNN gibi çalışırken üçüncü basamak olarak örnek bölütleme yöntemi ile ilgili bölgedeki nesne maskelenmiştir.



Şekil 3.26. Örnek bölütleme ile Mask R-CNN (He vd. 2017)

Mask R-CNN ile görüntü bölütlenmesi diğer bölütleme yöntemlerinde olduğu gibi görüntüyü piksellerine ayırıp birden çok bölgelere ayrılması işlemleri ile gerçekleştirilir. Genel olarak semantik bölütleme (semantic segmentation) ve nesne bölütlenmesi (instance segmentation) olmak üzere iki tipte çalışır (He vd. 2017). Arka plan bölütleme yöntemi olarak da bilinen semantik bölütleme Şekil 3.27’de gösterildiği gibi her pikseli sabit bir sınıfa atamaktadır. Nesne bölütlenmesi ise semantik bölütlemeden farklı olarak her pikseli aynı sınıfa atmak yerine aynı sınıfı kendi içerisinde bölümlere ayırır.




Şekil 3.27. Bölütleme örnekleri **a)** semantik bölütleme ve **b)** nesne bölütlenmesi (Anonim 6)

Mask R-CNN bölütleme işlemlerinin zor olduğu ve sınırlı sayıda veri setinin içerildiği biyomedikal alanında maskeleme işlemleri ile lezyonlu bölgelerin sınırlarını ve sınıfını belirlemede başarılı sonuçlar elde etmektedir (Chiao vd. 2019; Liang vd. 2019). Literatürde kullanılan Mask R-CNN çalışmalarında eğitim işlemleri yapılmadan önce eğitim ve test olmak üzere veri setleri ayrıştırılır ve bu veri setleri el yordamıyla bölütleme ile uzmanlar tarafından sınır bölgeleri belirtilmiş bir şekilde eğitilir. Sınır bölgeleri belirlenirken bölgenin sınıfı da belirtilmelidir. Literatürdeki çalışmalarda uzman doktorlar tarafından sınırlarının belirlenmesi için VGG (VGG Image Annotator; VIA)

(Dutta ve Zisserman 2019) gibi yazılımlar aracılığıyla sınır noktaları belirlenir. Eğitim ve test işlemleri ise VGG gibi yazılımlarda etiketlenen veriler üzerinden gerçekleştirilir. Eğitimin ardından model ağırlıklarının indirilerek etiketi yapılmamış test verileri üzerinde modelin daha önceden görmediği görüntüler için nesne bölütlemesi, algılaması ve sınıflandırılmasını gerçekleştirir (Chiao vd. 2019; Liang vd. 2019).

3.8. Transfer Öğrenme

Transfer öğrenme, Şekil 3.28’de görüldüğü gibi önceden eğitilmiş modeller üzerinden öğrenilen bilgilerin yeni problemleri tanımadaki kullanılması işlemidir (Torrey ve Shavlik 2010). Bu işlemler bir makine öğrenmesi modeli veya tekniği değil, bir tasarım yöntemi olarak bilinir. Transfer öğrenimi için kullanılan modeller, milyonlarca görüntüler ve binlerce sınıf ile eğitilen, aylar süren eğitim süresi ve yüksek maliyetli donanımlarla eğitilmiştir. Genel olarak kullanılan transfer öğrenimi modelleri VGG, ResNet ve Inception gibi önceden eğitilmiş modellerdir. Bu eğitilmiş modellerin öğrendiği bilgilerin yeni problemlerin çözümünde kullanılması eğitim süresini kısaltır. Çünkü yeni modeli eğitmek için sıfırdan başlanmaz, öğrenmeye önceden eğitilmiş modelin öğrendiği bilgilerle başlanır. Bu çalışmaların en önemli avantajı az sayıda veri kullanılarak yapılacak çalışmalarda yüksek başarı göstermeleridir (Lopez vd. 2017; Snehalatha ve Sangamithirai 2021).



Şekil 3.28. Transfer Öğrenme

Transfer öğrenme çalışmalarında önceden eğitilmiş olan modellerin öğrendiği bilgilere benzer problemlerin çözümünde kullanılması başarıyı artırmaktadır. Örneğin önceden eğitilmiş olan bir modelde kedi ve köpek ayrımı yapan bir model kullanılmış ve bu model çeşitli ayırıcı özellikleri öğrenmiş olsun. Bu modelin iki farklı problemin çözümünde kullanılacağını düşünelim. İlk problem araba ve otobüs ayrımı yapacak olan çalışma, ikinci problem ise aslan ve kaplan gibi hayvanların ayrımını yapacak olan çalışma olsun. Bu transfer öğrenimi ile ilk çalışmada şekilsel bilgiler, kenarlar ve köşe bilgileri kullanılarak ayırım işlemleri yapılabilir. İkinci çalışmada ise kedi ve köpeklerden göz, kulak, bacak, kafa ve kuyruk gibi daha spesifik özellikler öğrenildiği için ilk çalışmaya göre daha yüksek başarı elde edilecektir. Bu sebeple biyomedikal görüntüler gibi veri setinin toplanmasında zorluk çekilen alanlarda az sayıda veri ile nesne öğrenimi sağlayan bu metodolojinin kullanımının başarıyı artırması hedeflenir (Lopez vd. 2017; Snehalatha ve Sangamithirai 2021).

3.9. Ön Eğitilmiş Sinir Ağı Mimarileri


Nesne tanıma ve sınıflandırma alanında son on beş yılda hızlı ilerlemeler ve başarılı çalışmalar gerçekleştirilmiştir. Geliştirilen mimariler daha önceki mimarilerin eksikliklerinin giderilmesi ve iyileştirilmesi işlemleriyle veya farklı metodların

geliştirilmesi sonucu ilerlemiştir. Nesne tanınması için dünyaca bilinen ImageNet yarışmaları ESA mimarilerinin hızla ilerlemesine ön ayak olmuştur (Krizhevsky vd. 2012). Bu mimarilerin son olarak geldiği noktada insan nesne ayırt etme başarısından daha iyi başarımlara ulaşıldığı araştırmacılar tarafından raporlanmıştır. Alt başlıklarda kısaca açıklanan bu mimariler, milyonlarca görüntüden ve binlerce sınıftan oluşan işlem yükü ağır, donanım ve depolama maliyeti yüksek ve transfer öğrenimine zemin hazırlayan mimarilerdir.

3.9.1. AlexNet

Dünyaca bilinen nesne tanıma yarışmalarını organize eden ImageNet'in 2012 yılındaki yarışmasını Krizhevsky ve arkadaşlarının geliştirdiği, 10 milyon görüntü ve 1,000 ayrı sınıftan oluşan AlexNet mimarisi kazanmıştır (Krizhevsky vd. 2012). Bu mimari, kendisinden önceki mimarilere kıyasla oldukça başarılı sonuçlar elde etmiş ve ilerleyen yıllarda geliştirilen başarılı çalışmalara öncü olmuştur. Aynı zamanda bu mimariyi inşa eden araştırmacılar derin öğrenme çalışmalarında ReLU aktivasyon fonksiyonunu ve bırakma işlemlerini literatüre ilk kazandıran kişiler olmuşlardır. AlexNet mimarisi 60 milyon parametreye sahip çok büyük bir mimaridir. Bir giriş katmanı, 5 evrişim katmanı, 7 ReLU katmanı, 2 normalizasyon katmanı, 3 havuzlama katmanı, 3 tam bağlantılı katman, 1 softmax katmanı, 2 bırakma ve 1 çıkış katmanı olmak üzere 25 katmandan oluşur. Bazı kaynaklarda açık hali verilmeden kısaca 8 katmanlı olduğu söylenen AlexNet'in giriş katmanına verilen görüntülerin 256×256 boyutunda RGB görüntüler olması gerekir. Bu boyutta olmayan görüntüler yeniden boyutlandırılarak 256×256 'a dönüştürülür. Eğer giriş görüntüsü gri tonlamalı ise (tek kanallı) 3 kanallı RGB görüntüsüne dönüştürülmesi gerekir. AlexNet'in ilk katmanı beslenirken 256×256 boyutundaki görüntülerden 227×227 boyutlarında rastgele kırma işlemleri ile yeni boyutta görüntüler ile beslenir (Krizhevsky vd. 2012).

AlexNet mimarisinde Şekil 3.29'da görüldüğü gibi üçüncü tam bağlantılı katmana kadar olan bölümlerde görüntünün alınması, ön işlemlerden geçirilmesi ve özellik çıkarımlarının yapılması işlemleri ile özellikler öğrenilir. Üçüncü tam bağlantılı katman ve softmax katmanı ile sınıflandırma işlemleri yapılarak çıkış katmanında görüntü 1,000 ayrı sınıftan hangisine ait ise o sınıf çıktı olarak verilir. AlexNet mimarisinin nesne tanıma başarısı %84.6 olarak bulunmuştur. Aynı zamanda nesne tanımda önceki mimarilerdeki %26.2'lik hata yüzdesi %15.3'e kadar düşürülmüştür (Krizhevsky vd. 2012).




Şekil 3.29. AlexNet mimarisi (Krizhevsky vd. 2012)

Her yıl düzenlenen ImageNet yarışmalarında 2013 yılındaki yarışmayı AlexNet'ten esinlenerek geliştirilen ZfNet mimarisi kazanmıştır (Zeiler ve Fergus 2013). ZfNet geliştiricileri AlexNet'ten farklı olarak öncelikle ilk evrişimli katmandaki 11×11 boyutlu filtreyi 7×7 boyutuna indirmişlerdir. Bu işlem görüntü üzerinde daha detaylı incelemeyi sağlayarak daha fazla özellik öğrenimini sağlamıştır. AlexNet'e göre değiştirilen bir başka özellik ise evrişimli katmanlardaki filtre sayısını ve tam bağlantılı katmanlardaki nöron sayılarını iki katına çıkarmalarıdır. Tüm bu işlemlerle birlikte 2012 yılında sunulan AlexNet mimarisindeki nesne tanımasındaki hata yüzdesini %15.3'ten %14.8'e indirebilmişlerdir (Zeiler ve Fergus 2013).

3.9.3. GoogleNet

ImageNet yarışmalarında 2014 yılındaki yarışmanın kazananı görüntü sınıflandırma ve nesne algılama problemlerini çözen GoogleNet olmuştur (Szegedy vd. 2015). Bu mimari AlexNet'in 60 milyonluk parametre sayısını 5 milyona düşürürken nesne tanımadaki hata yüzdesi %5.7'e düşmüştür. Şekil 3.30'da da gösterildiği gibi önceki mimarilere göre derinlik ve genişlik artırılırken katman sayısı 22'e düşürülmüştür (Szegedy vd. 2015).



Şekil 3.30. GoogleNet mimarisi (Szegedy vd. 2015)


GoogleNet mimarisinde giriş katmanına verilecek görüntüler 224×224 boyutunda olmalıdır. Eğer boyutlar bu düzeyde değilse boyut azaltılmasıyla girişe uygun hale getirilmelidir. Giriş katmanlarından sonra evrişim katmanlarında 1×1 , 3×3 ve 5×5 boyutlarında filtreler kullanılır. Bu kare filtreler görüntü üzerinde gezdirilerek görüntülerin boyutları azaltılırken, büyük filtreler kullanılarak uzamsal bilgiler elde edilir. İkinci evrişim katmanında 1×1 'lik evrişim filtresi kullanılır. Bu şekilde katman işlem sayısı azaldığı için hesaplama yükü de azaltılmış olur. Evrişim katmanından sonra havuzlama katmanlarıyla verilerin yükseklik ve genişlikleri azaltılarak alt örnekleme hazırlanır. Son katmanlarda kullanılan ortalama havuzlama katmanlarıyla tüm özellik haritalarının ortalaması alınır. Mimaride aşırı uyumun önüne geçilebilmesi için %40 bırakma yöntemi, girdi vektörü içindeki bir sayı kümesinin olasılık dağılımını türetmek için de Softmax aktivasyon fonksiyonu kullanılır (Anand vd. 2020).

3.9.4. ResNet

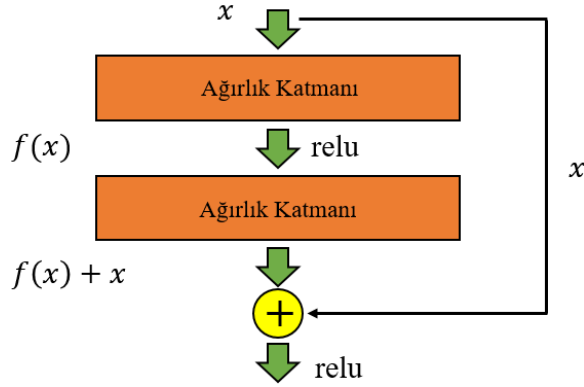
ResNet geliştiricileri önceki mimarilere göre mimarinin eğitiminde daha derin ağlar kullanmışlardır. ResNet mimarisi 152 katmandan oluşmuş ve 2015 yılında gerçekleştirilen ImageNet yarışmasını %3.6 hata yüzdesiyle kazanmıştır (He vd. 2016). Bu yönüyle ResNet nesne tanımadaki %5-10 arasında hata yapan insanı geride bırakmıştır.

Geliştirilen mimarilerde katman sayısının artmasının mimarinin başarımını artırdığı bilinir ancak bu artış bir noktadan sonra mimarinin başarımını düşürür. ResNet geliştiricileri kendilerinden önceki mimarilerden daha fazla sayıda katman kullanır. Başarım oranındaki beklenen düşüşün olmaması için geliştirdikleri çok basit bir yöntem vardır. Bu yöntemde Şekil 3.31’de atlamalı bağlantılar kullanılarak ilerleme sağlanır. Atlamalı bağlantılar ile katman çıkışı iki katman önceki katmanın çıkışından gelen değerlerin ağırlığı ile toplanarak ilerlenir. Bu şekilde son katmandan sıfır (etkisiz) ağırlık çıkması durumunda iki katman önceki ağırlığın eklenmesi ile sıfır olma problemi çözülür (Budhiman vd. 2019).

Mimaride ilk evrişim katmanında 7×7 filtre kullanılarak evrişim yapılır. Diğer evrişim katmanlarında ise 3×3 boyutlarında filtreler kullanılır. Mimarinin devamında gelen katmanlar ikili şekilde ilerleyen ve Şekil 3.32’de gösterilen kalıntı modüllerinden oluşur. En son katmanında tam bağlantılı katman ve Softmax ile sınıflandırma işlemi yapılır (He vd. 2016).



Şekil 3.31. ResNet mimarisi (He vd. 2016)




Şekil 3.32. Kalıntı modülü

3.9.5. VGG-Net

VGG-Net mimarisinin 16 katmanlı VGG16 ve 19 katmanlı VGG19 olmak üzere iki farklı mimarisi vardır. VGG-Net mimarisi 2014 yılında yapılan ImageNet yarışmasında mimarisini tanıtmıştır (Muhammad vd. 2018). Bu mimari ile AlexNet’ten daha iyi başarım değerleri elde etmişlerdir. AlexNet’te kullanılan 60 milyon parametre sayısı bu mimaride 140 milyona yükseltilmiştir. Bu durum başarımı artırırken bellek kullanımını da artırmaktadır. AlexNet’ten bir diğer farkı ise daha küçük boyutlardaki filtreler kullanmasıdır. Kullanılan filtre boyutları 3×3 boyutundadır. Şekil 3.33’te gösterilen bu model giriş katmanı, evrişim katmanları, havuzlama katmanları, tam bağlı


katmanlar, ReLU katmanı, çıktı katmanı ve Softmax katmanı olmak üzere 41 katmandan oluşmaktadır. AlexNet'ten bir diğer farkı da giriş katmanına görüntülerin $224 \times 224 \times 3$ boyutlarında verilmesi gerekliliğidir (Simonyan ve Zisserman 2014).



Şekil 3.33. VGG-Net mimarisi (Simonyan ve Zisserman 2014)

3.10. U-Net

U-Net mimarisi diğer mimarilere göre daha küçük veri setlerinde daha yüksek başarımlar gösteren ve biyomedikal bölütleme işlemlerinde sıklıkla kullanılan mimarilerdendir (Weng vd. 2019). Mimari Şekil 3.34'te görüldüğü gibi "U" harfine benzemektedir. U-Net mimarisi iki bölüme ayrılır. İlk bölümde giriş görüntüsünün yükseklik ve genişliğinin boyut azalması işlemleri uygulanarak görüntünün ne olduğu ile ilgilenilir. Bu bölüme Encoder (kodlayıcı) adı verilir. İkinci bölüme ise Decoder (Kod Çözücü) adı verilir ve boyut artırması işlemleri yapılırken görüntünün nerede olduğu öğrenilmeye çalışılır. Ardarda kullanılan evrişim katmanları sayesinde çıkış görüntüsünün çözünürlüğünün artırılması hedeflenmektedir. Piksel bazlı görüntü bölütlenmesi işlemlerinde U-Net diğer modellere kıyasla daha başarılı bir performans sergilemektedir (Ronneberger vd. 2015).



Şekil 3.34. U-Net mimarisi (Weng vd. 2019)

Mimarinin girişine uygulanan görüntüler, çıkış katmanının sonucunda bölütlenmiş görüntü haritası elde edilir. Mimari yalnızca evrişim katmanlarından oluşur ve diğer evrişimsel sinir ağlarında olduğu gibi tam bağlı katman bulunmaz. Kullanılan evrişim katmanlarında aktivasyon fonksiyonu olarak ReLU kullanılır (Weng vd. 2019).

Encoder katmanına görüntü boyutu $572*572*1$ boyutunda verilmektedir. Bu bölümde sürekli sıkıştırma işlemleri ile her katmanda görüntü boyutu yarıya düşmektedir. Mimarinin evrişim katmanlarında kullanılan piksel ekleme (padding) işlemlerinde 'Same' kullanılmaktadır. Same işlemi kenar pikselleri üst ve yan tarafa doğru simetriği alınarak genişletilir. İlk evrişim katmanında kullanılan 3. piksel ekleme işleminin ardından $572*572$ boyutunda girilen görüntü $568*568$ boyutuna kadar düşmektedir. Bu düşüşün sebebi ise her Same işleminin ardından iki pikselin kaybolmasıdır. Encoder katmanında ilk katmandan sonra görüntü boyutu $284*284$ boyutuna MaxPooling (Maksimum Havuzlama) işlemi ile yarılanmaktadır. Mimarinin Encoder katmanında beş katman boyunca bu işlemler devam etmektedir ve bu katman sonucunda $32*32$ boyutuna inmektedir. Mimarinin Encoder katmanında sürekli boyut azaltılması işlemlerinin ardından Decoder katmanında genişletilme işlemleri sonucunda görüntü çıkış görüntüsü $388*388$ boyutlarında sonlanmaktadır. Görüntü genişletme işlemlerinde ise UpConv adı verilen işlemler ile görüntü boyutu iki katına çıkarılır. Decoder katmanındaki tüm katmanlar encoder katmanında karşılık geldiği katmanlar ile birleştirilir. 5. katman ile biten encoder katmanının ardından 6. katmandaki görüntünün yarısı 5. katmandan gelen görüntünün UpConv sonucu iken diğer yarısı 4. katmandan gelen görüntüdür. Bu şekilde diğer katmanlarda Encoder katmanında eşleştikleri katman ile birleşerek çıkış görüntüsüne kadar genişleyerek ilerler. Bu katman sonucunda görüntünün nerede olduğu bilgisi ile beraber bölütlenen görüntü haritası çıkış katmanında elde edilir (Anonim 7).

Bu bölümde meme kanseri görüntüleme yöntemleri, termal görüntüleme yöntemi, görüntü işleme yöntemleri, makine öğrenmesi ve algoritmaları, derin öğrenme, evrişimsel sinir ağları, Mask R-CNN, U-Net ve transfer öğrenme mimarileri anlatılmıştır. Dördüncü bölümde bu bölümde alt yapısı anlatılan materyaller kullanılarak çalışmada yürütülen sınıflandırma işlemlerinin ve çalışmadan elde edilen sonuçlar sunulmuştur.

4. BULGULAR


Bu tez çalışmasında termal meme görüntüleri üzerinden meme hacminin bölütlenmesi, meme tümörlerinin tespiti ve sınıflandırılması amaçlanmış ve iki farklı yöntem denenmiştir:

1. Meme bölgelerinin el yordamıyla bölütlenmesinin ardından CNN mimarisi ve transfer öğrenme yardımıyla sınıflandırılması
2. Meme bölgelerinin Mask R-CNN ve U-Net teknikleri ile otomatik bölütlenmesinin ardından CNN mimarisi ve transfer öğrenme yardımıyla lezyon sınıflandırılması

Her iki yöntem için de yapay sinir ağı eğitimleri öncesinde görüntülerdeki meme bölgelerinin sınırları el yordamıyla belirlenmiştir. Bu belirleme işlemleri VIA (Dutta ve Zisserman 2019) web tarayıcısı kullanılarak yapılmıştır. Kullanılan web tarayıcısı ile her bir görüntünün sınıf ve nesne lokalizasyon bilgileri “.json” uzantılı bir dosyaya kaydedilmiştir. Birinci yöntem için, “.json” dosyasında yer alan bilgiler bir python kodu ile okunarak sınırları belirlenmiş her meme bölgesi için bir maske oluşturulmuştur. Daha sonra bu maske orjinal görüntü ile üst üste getirilerek meme bölgesinin arka plandan bölütlenmesi sağlanmıştır. İkinci yöntemde ise el yordamıyla bölütleme işlemi yerine otomatik bölütleme yapılmıştır. Meme bölgelerinin otomatik olarak bölütlenmesi için Mask R-CNN ve U-Net denenmiştir. Birinci ve ikinci yöntemler ile sonucu elde edilen görüntülerin sınıflandırma işlemleri için önceden eğitilmiş ESA’lar (InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG16, VGG19 ve Xception) ile transfer öğrenme uygulanmıştır.

4.1. Veri Seti Oluşturma


Çalışmada kullanılan veriler meme kanserinin erken teşhisi için mastolojik görüntüleri toplayan ve yöneten çevrimiçi bir platformdan alınmıştır (Silva vd. 2014). Bu veri tabanında meme kanseri olan ve hastalığı bulunmayan kişilerden toplanan termogramlar ve mamogramlar yer almaktadır. Veri tabanında yer alan termal meme görüntüleri FLIR SC-620 termal kamera ile 640*480 çözünürlük ve 45 μm piksel değerleri ile toplanmıştır. Alınan veri setinde 19 sağlıklı kişi ile 37 meme kanserli hasta yer almaktadır. Hastalardan termal meme görüntülerinin toplanmasından önce Şekil 4.1’de görüldüğü gibi kameranın sabitleneceği tripotun ve hastanın duracağı noktanın konumları mesafe ölçümleri yapılarak belirlenmiştir. Kamera ile hasta arasındaki mesafenin artması veya azalması aynı sıcaklık değerleri için farklı bilgiler verebileceğinden hastaların vücut bölgelerinden yansıyan sıcaklık değerlerinin her hasta için aynı şartlarda toplanmasını sağlamak amacıyla bu işlemler yapılmıştır.



Şekil 4.1. Termal kamera (a) tripotun yerleştirileceği konum ve (b) hastaların kameradan 1 m uzakta duracağı konum (Silva vd. 2014)

Çalışmada verileri alınan gönüllü kişiler prokol öncesinde prosedürler hakkında bilgilendirip onamları alındıktan sonra klinik termometre ile vücut sıcaklıkları ölçülmüştür. Hastalardan görüntü alınmadan önce hastaların 2 saat öncesinden itibaren sigara kullanmaması, kafein veya alkol almaması, yoğun egzersiz yapmaması ve krem veya merhem sürmemesi istenmiştir. Bu tarz işlemler memeden yayılacak sıcaklık bilgilerinde yanlış sonuçlar doğurabilmektedir. Tüm kontrollerin ardından hastaların üzerindeki elektromanyetik dalgaların saçılmasında gürültü oluşturacak ve ilgili bölgeyi olumsuz etkileyecek materyaller çıkarılmıştır. Hastaların 10 dakika boyunca oda sıcaklığında bekletilmesinin ardından kendileri için belirlenen noktaya geçmesi, kafasının sabitlenmesi, ellerin baş üstüne kaldırılması ve üstlerinin çıkarılması sonrasında görüntü alımına başlanmıştır.

Veri setinde bulunan termal meme görüntüleri hem statik termografi hem de dinamik termografi yöntemleri uygulanarak toplanmıştır. Her iki yöntem için farklı protokoller takip edilmiştir. Statik termografi için hastalar 10 dakika oda sıcaklığında bekletildikten sonra kameradan 1 metre mesafede bulunan konuma geçerek Şekil 4.2’de gösterildiği gibi önden, 45 derece sağ, 90 derece sağ, 45 derece sol ve 90 derece sol olmak üzere farklı pozisyonlarda görüntüler toplanmıştır.



Şekil 4.2. Statik termografi hasta pozisyonları a) Ön, b) 45⁰ sağ, c) 90⁰ sağ, d) 45⁰ sol ve e) 90⁰ sol (Silva vd. 2014)

Dinamik termografi yönteminde ise statik termogramların alınmasının ardından hastanın önünün kameraya yöneldiği pozisyonda Şekil 4.3’te gösterilen fan yardımı ile yalnızca göğsün orta bölgesindeki sıcaklık değerinin 30.5°C'nin altına düşene kadar soğutulma işlemi yapılmıştır. İstenilen sıcaklık değeri sağlandığında soğutma fanı

kapatılmış ve statik yöntemden farklı olarak üç farklı pozisyonda görüntü toplanmıştır. Hastanın önü kameraya yönelmiş iken fanın kapatılmasının ardından 5 dakika boyunca her 15 saniyede bir görüntüleri toplanmıştır. Hasta bir de 90 derece sağ ve 90 derece sol döndürülerek birer görüntü daha alınmıştır. Dinamik termografide toplamda hasta başına 20 termal meme görüntüsü toplanmıştır.

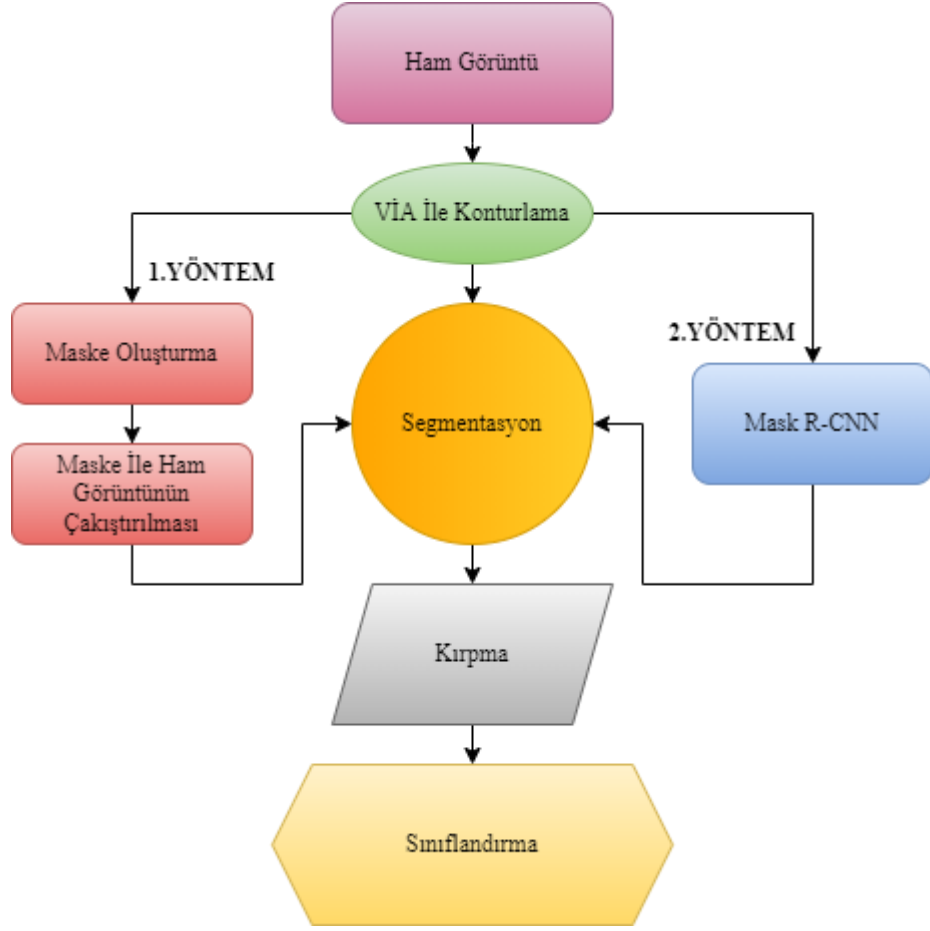


Şekil 4.3. Soğutucu fanın konumu (Silva vd. 2014)

4.2. Önerilen Yöntem


Çalışma kapsamında meme kanserinin sınıflandırılması için Şekil 4.4'te görüldüğü gibi iki farklı çalışma yöntemi incelenmiştir. Birinci yöntem VIA yazılımı ile el yordamıyla sınır bölgeleri belirlenmiş memelerin görüntüden kırılması ve önceden eğitilmiş CNN ağlarına verilerek sınıflandırma işleminin yapılmasını içermektedir. İkinci yöntem ise meme bölgelerinin otomatik bölütlenmesinin ardından ilk yöntemde olduğu gibi kırılarak önceden eğitilmiş CNN ağları ile transfer öğrenme uygulanarak sınıflandırılmasını amaçlamaktadır.

Her iki yöntemde de veri setinden alınan 56 gönüllüden (kişi başına 20 termal görüntü) toplanan 1120 termal meme görüntüsü üzerinde çalışılmıştır. Veri dağılımı evrimsel sinir ağlarını beslemek üzere rastgele seçilerek %80 eğitim (896 görüntü) ve %20 test (244 görüntü) olarak yapılmıştır. Dağılımı yapılan termal meme görüntüleri evrimsel sinir ağlarını beslemek için ham halleriyle kullanılmamıştır. Ham halde beslenildiği takdirde sadece hasta bazında yani sağlıklı-hasta şeklinde bir sınıflandırma yapılabilecektir. Ancak bu çalışmada sınıflandırmanın hasta bazında değil, meme bazında yapılması ve termal görüntüde yer alan hangi memenin kanserli hangi memenin sağlıklı olduğunun tespitinin yapılabilmesi amaçlanmıştır.



Şekil 4.4. Çalışmada kullanılan sınıflandırma yöntemlerinin akış şeması

Meme bölgelerinin konturlanması işlemleri için kullanılan VIA web tarayıcısında meme bölgeleri poligon olarak işaretlenmiş ve tek sınıf “meme” olarak etiketlenmiştir. Etiketleme işlemleri eğitim ve test veri setleri için ayrı ayrı yapılmıştır. Yapılan tüm etiketleme ve sınıf etiketinin girilmesi işlemlerinin ardından Şekil 4.5.b’de gösterildiği gibi tanımlanan tüm bilgiler bir dosyaya toplu olarak “.json” formatında kaydedilmiştir.



a)

```

"p_PAC_58_DN5.jpg18586":{
  "filename": "p_PAC_58_DN5.jpg",
  "size":18586,
  "regions":[
    {
      "shape_attributes":{
        "name":"polygon",
        "all_points_x":[340,351,368,383,...
        "all_points_y":[359,372,387,397,...
      },
      "region_attributes":{"objects":"meme"}},
    {
      "shape_attributes":{
        "name":"polygon",
        "all_points_x":[214,223,234,244,...
        "all_points_y":[404,399,391,380,...
      },
      "region_attributes":{"objects":"meme"}},
    "file_attributes":{}
  }...

```

b)

Şekil 4.5. Bir termal görüntü için a) VIA ile tek sınıf “meme” olarak etiketlenen konturlanmış meme görüntüsü ve b) bu poligonun “.json” dosyasında gösterimi

Kaydedilen “.json” dosyasından alınan her poligona ait noktaların x ve y piksel koordinatları kullanılarak her meme için ikili (binary) görüntülerden oluşan maskeler oluşturulmuştur. Daha sonra her maske ile orjinal görüntü üst üste çakıştırılarak Şekil 4.6’da gösterildiği gibi her hasta için sağ ve sol meme görüntüsü arka plandan ayrıştırılmış bir şekilde farklı iki görüntü olarak kaydedilmiştir. Sağ ve sol meme görüntülerinin kaydedilirken karıştırılmaması için sol meme için hasta numarasının sonuna “_1” (h_PAC_11_DN00_1 gibi) ve sağ meme için “_2” eklenerek görüntü dosyaları isimlendirilmiştir. Bu şekilde veri setinde bulunan termal görüntü sayısı (1120 adet) iki katına (2240 adet) çoğaltılmıştır.



Şekil 4.6. Bir termal görüntünün **a)** VIA ile bölütlenmiş hali, **b)** sağ ve sol memenin ikili (binary) maskeleri ve **c)** sağ ve sol memenin bölütlenmiş halleri

Sağ ve sol meme bölgeleri Şekil 4.6.c’de gösterildiği gibi ayrı ayrı kaydedildikten sonra elde edilen görüntüler incelendiğinde, her meme görüntüsünde siyah arka planın meme bölgesine oranla resmin daha büyük kısmını kapladığı görülmüştür. Evrimsel sinir ağlarında alınan veriler belirli boyutlara küçültülmektedir ve eşit oranda küçültülen görüntülerde bazı veri kayıpları olabilmektedir. Bu şekilde hem meme bilgisinde hem arka plan bilgisinde kayıplar olması mümkündür. Ayrıca arka plan bilgisinin özellik çıkarımı aşamasında hiçbir etkisi yoktur ve gereksiz bilgi olarak görüntü üzerinde yer kaplar. Bu nedenle sadece memenin içerisinde bulunduğu bölge için bir kırpma işlemi uygulanmıştır. Bu işlem öncesinde arka planda yer alan siyah bölgenin piksel değerinin “0” olduğu ve bu piksel değeri dışındaki her değer meme bölgesine ait olduğu bilinmektedir. Bu bilgiden yola çıkılarak meme bölgesini içeren sınırlandırıcı kutu oluşturulmaya çalışılmıştır. Sınırlandırıcı kutu oluşturmak için görüntü üzerinde ilk piksel değerinden başlanarak ve tüm pikseller üzerinde teker teker kaydırılarak kontrol edilmiştir. Kontroller esnasında 0’dan farklı olan ilk piksel değeri işaretlenmiş ve bu işaretlemeler yukarıdan, soldan, sağdan ve aşağıdan yapılmıştır. Bu şekilde noktaların birleştirilmesi ile oluşan sınırlandırıcı kutu içerisinde sadece meme bölgesi yer alacak şekilde kırpılma işlemleri yapılmıştır. Sonuçta kırpılan meme görüntüleri Şekil 4.7’de gösterildiği hale getirilmiştir.



Şekil 4.7. Bir hastanın örnek kırpılan (a) sol meme ve (b) sağ meme görüntüsü


Kırpma işlemlerinin ardından kırpılan her meme görüntüsü bir önceki adımda yapıldığı gibi hasta isminin önüne “crop_” kelimesinin eklenmesi ile “crop_h_PAC_11_DN00_1” şeklini alacak şekilde yeniden kaydedilmiştir. Yapılan değişikliklerin ardından veri dağılımları eğitim verisinde hasta ve sağlıklı olmak üzere iki ayrı dosya oluşturulmuştur. Eğitimde kullanılan görüntüler 1182 sağlıklı meme ve 610 kanserli memeden oluşmuş, test veri setinde ise 298 sağlıklı meme ve 150 kanserli meme yer almıştır.

İkinci yöntemde ise meme bölgelerinin bölütlenmesi el yordamıyla değil, otomatik şekilde yapılmıştır. Bunun için U-Net ve Mask R-CNN metodları denenmiştir. U-Net ile bölütleme işlemleri öncelikle her görüntünün json dosyasından alınan x ve y piksel koordinatları kullanılarak ikili görüntü formatında maskeler oluşturulmuştur. Oluşturulan maskeler ve orjinal görüntü ile U-Net eğitildikten sonra bölütleme yapılmış ve bölütlenen meme bölgeleri “.png” formatında dosyalanmıştır. Mask R-CNN ile bölütleme işlemleri ise kaydedilen “.json” dosyasıyla önceden eğitilmiş ResNet101 mimarisine 60 devir sayısında eğitimi yapılmıştır. Mask R-CNN eğitimi bölütleme başarımının daha yüksek olması için sadece “meme” etiketiyle tek sınıf olarak yapılmıştır. Eğitim veri seti ile eğitilen mimari test veri setinde bulunan görüntüler üzerinde sınırlandırıcı kutu içerisinde aldığı meme bölgelerini maskeleyerek her bir meme için ayrı ayrı bölütlenmiş meme görüntüleri “.png” formatında kaydedilmiştir.

İki farklı bölütleme metodu ile elde edilen görüntüler bir Python kodu ile kendileri içerisinde modellerin eğitiminde kullanılan referans meme bölgesi ile eğitim sonucu tahmin edilen meme bölgeleri karşılaştırılarak bölütleme başarımları ölçülmüştür. Kod içerisinde yer alan değerlendirme işlemleri referans ve tahmin bölgeleri içerisinde yer alan her pikselin bulunduğu konum baz alınarak yapılmıştır. Görüntü üzerinde yer alan tüm pikseller buldukları konuma göre Bölüm 3.4.3’te anlatıldığı gibi DP, DN, YP ve YN olarak tespit edilerek kendi içerisinde toplanmıştır. Sonrasında toplanan değerler Denklem 3.5 ile Doğruluk, Denklem 3.6 ile Duyarlılık, Denklem 3.7 ile Özgüllük, Denklem 3.8 ile Kesinlik, Denklem 3.9 ile MCC, Denklem 3.10 ile Dice ve Denklem 3.11 ile Jaccard indeksi hesaplanarak Çizelge 4.1’e kaydedilmiştir. Şekil 4.8’de U-Net ve Mask R-CNN ile elde edilen bölütlenmiş meme görüntüleri verilmiştir.


Çizelge 4.1. İkinci yöntemde otomatik bölütleme kullanılmak üzere denenmiş Mask R-CNN ve U-Net ile yapılan bölütleme başarımları

Teknikler	Doğruluk	Duyarlılık	Özgüllük	Kesinlik	MCC	Dice	Jaccard
Mask R-CNN	0.9896	0.9253	0.9962	0.9605	0.9366	0.9413	0.8900
U-Net	0.9718	0.8701	0.9917	0.9555	0.8946	0.9086	0.8365



Şekil 4.8. Bölütleme için kullanılan tekniklerin bölütleme sonuçları, a) orjinal görüntü, b) VIA ile etiketlenmiş referans sağ ve sol meme görüntüsü, c) VIA ile etiketlenmiş U-Net için kullanılan referans sağ ve sol meme görüntüsü, d) Mask R-CNN bölütlemesinin sonucu ve e) U-Net bölütlemesinin sonucu

Şekil 4.8 incelendiğinde Mask R-CNN ile yapılan bölütleme işleminin U-Net'e göre meme hacmini ve sınır bölgelerini tahmin etmede gözle görülebilir derecede daha başarılı olduğu görülmüştür. Çizelge 4.1 incelendiğinde ise referans meme bölgesi ile tahmin edilen maske bölgesi arasındaki korelasyonu gösteren MCC değeri, tahmin edilen meme bölgesinin referans meme bölgesinin ne kadarını kapsadığını gösteren duyarlılık değeri ile beraber literatürde sıklıkla kullanılan Dice ve Jaccard değerlerinin U-Net'e göre daha başarılı olduğu görülmektedir. Mask R-CNN ile bölütlenen meme görüntülerinde Şekil 4.9.b'de görüldüğü gibi meme bölgesi dışında siyah gereksiz alanlar mevcuttur. Birinci yöntemde de olduğu gibi bölütlenen meme bölgesinin arkasında bulunan siyah gereksiz kısımlar Şekil 4.9.c'de görüldüğü gibi kırılmıştır. Kırılan sağ ve sol meme bölgeleri bölütlendikten sonra birinci yöntem ile aynı notasyonda dosyalama işlemleri yapılmıştır. Tüm işlemlerin ardından Mask R-CNN bölütlemesi ile elde edilen görüntüler ile çalışmada eğitilen sınıflandırma mimarilerinin testi yapılmıştır.



Şekil 4.9. Termal meme görüntüsünün Mask R-CNN ile otomatik bölütleme sonucu elde edilmiş **a)** maskeli hali, **b)** sol ve sağ meme bölütlenmiş hali ve **c)** bölütlenmiş bölgelerin kırpılmış hali

Her iki yöntemde de bölütleme ve kırpma işlemlerinin sonucunda dosyalanan veriler ile önceden belirlenen ESA'ların (InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG-16, VGG-19 ve Xception) eğitimi yapılmıştır. ESA eğitimleri her iki yöntem için de aynı eğitim görüntüleri kullanılarak yapılmıştır. İki yöntemin farkı ise test veri setinde bulunan görüntülerin farklı metotlar ile bölütlenmesidir. ESA'ların eğitimi için 3.9 GHz Xeon işlemcili ve 32 GB RAM bellekli tek bir grafik işlem birimi (GPU) (NVIDIA'nın CUDA platformunu kullanan GeForce GTX 1050 TI) makinesi kullanılmıştır. Çalışmada gerçekleştirilen eğitim süreleri Çizelge 4.2'de ve kullanılan hiperparametreler Çizelge 4.3'te verilmiştir. Test işlemleri ise 8 GB RAM bellekli 2.40 GHz Intel(R) Core(TM) i5-6200U CPU işlemcili bir bilgisayar ile gerçekleştirilmiştir ve test süreleri Çizelge 4.2'de verilmiştir.


Çizelge 4.2. Transfer öğrenmede kullanılan eğitilmiş ağların eğitim ve test süreleri

Eğitilmiş Ağlar	Çalışma Süreleri (sn)		
	Eğitim	Test	
		1. Yöntem	2. Yöntem
InceptionV3	3200	41	40
MobileNet	3300	25	20
MobileNetV2	3700	21	20
ResNet50	3500	64	62
VGG16	3400	138	141
VGG19	3600	167	171
Xception	4065	72	74

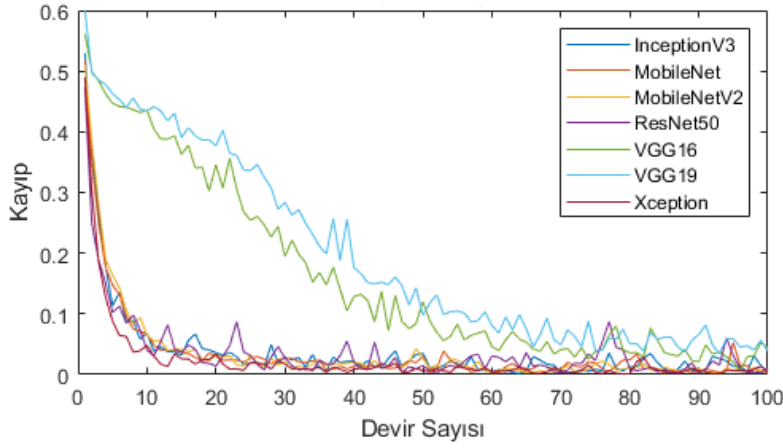
Çizelge 4.3. Transfer öğrenme modellerinin hiperparametre ve değerleri

Hiperparametreler	Değerler
Optimizasyon Algoritması	Adam
Aktivasyon Fonksiyonu	Softmax
Öğrenme Hızı	0.001
Devir Sayısı	100
Yığın Boyutu	32

Eğitim işlemleri yapılırken modellerin devir sayısına karşılık doğruluk değerlerinin ilerleyişini gösteren doğruluk grafiği Şekil 4.10'da verilmiştir. Şekil 4.11'de ise her devir sayısında modellerin kayıp oranını gösteren kayıp grafiği verilmiştir.



Şekil 4.10. Transfer öğrenme modellerinin doğruluk grafiği




Şekil 4.11. Transfer öğrenme modellerinin kayıp grafiği


4.3. Transfer Öğrenme Modellerinin Eğitim ve Test Sonuçları

Çalışmada önerilen her iki yöntemde de aynı eğitim ve test verileri transfer öğrenme modelleri üzerinden 100 devir sayısı (epoch) ve 32 yığın boyutu (batch size) ile eğitilmiştir. Eğitim süreleri Çizelge 4.2'de verilmiştir. Önerilen her iki yöntem de aynı veri seti üzerinden 1792 kırılmış termal meme görüntüsü ile eğitilmiştir. İlk yöntemde kullanılan test veri seti el yordamıyla bölütlenerek kırılan 448 termal meme görüntüsü içerirken ikinci yöntemin test veri setinde Mask R-CNN ile otomatik bölütlenerek kırılan 448 termal meme görüntüsü yer almıştır. Her iki yöntemde de eğitim veri setinde bulunan termal meme görüntüleri tek sınıf (meme) üzerinden eğitilerek bölütleme işlemleri gerçekleştirilmiştir.


Model eğitimlerinin ve test sonuçlarının değerlendirilmesi için Şekil 3.13'te tanımlanan iki sınıflı (hasta ve sağlıklı) ve 2*2 boyutlu karmaşıklık matrisleri oluşturulmuştur. Bu matrisler her bir model ve yöntem için ayrı ayrı hazırlanmıştır. Şekil 4.12'de InceptionV3; Şekil 4.13'te MobileNet; Şekil 4.14'te MobileNetV2; Şekil 4.15'te ResNet50; Şekil 4.16'da VGG16; Şekil 4.17'de VGG19; Şekil 4.18'de Xception modelinin 100 devir sayısındaki eğitim ve test verileri için elde edilen karmaşıklık matrisleri verilmiştir.




Şekil 4.12. InceptionV3 modeli, a) eğitim veri seti karmaşıklık matrisi, b) birinci yöntem karmaşıklık matrisi ve c) ikinci yöntem karmaşıklık matrisi




Şekil 4.13. MobileNet modeli, a) eğitim veri seti karmaşıklık matrisi, b) birinci yöntem karmaşıklık matrisi ve c) ikinci yöntem karmaşıklık matrisi




Şekil 4.14. MobileNetV2 modeli, **a)** eğitim veri seti karmaşıklık matrisi, **b)** birinci yöntem karmaşıklık matrisi ve **c)** ikinci yöntem karmaşıklık matrisi




Şekil 4.15. ResNet50 modeli, **a)** eğitim veri seti karmaşıklık matrisi, **b)** birinci yöntem karmaşıklık matrisi ve **c)** ikinci yöntem karmaşıklık matrisi



Şekil 4.16. VGG16 modeli, **a)** eğitim veri seti karmaşıklık matrisi, **b)** birinci yöntem karmaşıklık matrisi ve **c)** ikinci yöntem karmaşıklık matrisi



Şekil 4.17. VGG19 modeli, **a)** eğitim veri seti karmaşıklık matrisi, **b)** birinci yöntem karmaşıklık matrisi ve **c)** ikinci yöntem karmaşıklık matrisi



Şekil 4.18. Xception modeli, **a)** eğitim veri seti karmaşıklık matrisi, **b)** birinci yöntem karmaşıklık matrisi ve **c)** ikinci yöntem karmaşıklık matrisi

Şekil 4.12-18’de verilen karmaşıklık matrisleri incelendiğinde InceptionV3, MobileNet, MobileNetV2 ve ResNet50 mimarilerinin kanserli memeleri tespit etme oranlarının sağlıklı memeleri tespit etme oranlarına göre daha başarılı olduğu görülmüştür. Xception, VGG16 ve VGG19 mimarilerinde ise diğer mimarilerin tersine sağlıklı meme görüntülerinin kanserli meme görüntülerinden daha iyi tespit edildiği görülmüştür. Eğitilen mimariler içerisinde kanserli memeleri en düşük başarımla tespit eden mimarilerin VGG16 ve VGG19 olduğu görülmektedir. Eğitim sonuçları incelendiğinde Xception, InceptionV3, MobileNet ve ResNet50 mimarilerinin kanserli memeleri %100 hassasiyetle tespit ettiği görülmektedir. InceptionV3 ve MobileNet aynı başarıyı test verileri üzerinde de gösterirken Xception ve ResNet50 aynı hassasiyeti gösterememektedir. Xception mimarisi sağlıklı memeleri %100 özgüllük değeri ile tespit edebilirken en yakın takipçisi %99.9 ile InceptionV3 mimarisi olmuştur.

Karmaşıklık matrisleri kullanılarak Denklem 3.1 ile doğruluk, Denklem 3.2 ile kesinlik, Denklem 3.3 ile duyarlılık ve Denklem 3.4 ile F1 skorları hesaplanmış ve sonuçlar Çizelge 4.4’e yerleştirilmiştir.

Çizelge 4.4. Transfer öğrenmede kullanılan modellerin başarımları (E: eğitim; T: birinci yöntem için test; M: ikinci yöntem için test başarısı)

Modeller	Sonuçlar											
	Doğruluk			Kesinlik			Duyarlılık			F1 Skoru		
	E	T	M	E	T	M	E	T	M	E	T	M
InceptionV3	0.999	1.0	1.0	0.998	1.0	1.0	1.0	1.0	1.0	0.999	1.0	1.0
MobileNet	0.998	1.0	1.0	0.995	1.0	1.0	1.0	1.0	1.0	0.998	1.0	1.0
MobileNetV2	0.996	0.993	0.991	0.990	0.993	0.980	0.997	0.987	0.993	0.993	0.989	0.987
ResNet50	0.999	0.991	0.998	0.997	0.993	0.993	1.0	0.981	1.0	0.998	0.986	0.996
VGG16	0.987	0.984	0.984	0.995	0.986	0.974	0.966	0.967	0.983	0.980	0.976	0.976
VGG19	0.987	0.987	0.982	0.987	0.974	0.973	0.974	0.987	0.973	0.980	0.980	0.973
Xception	1.0	0.998	0.998	1.0	1.0	1.0	1.0	0.993	0.993	1.0	0.996	0.996

Çizelge 4.4 incelendiğinde hasta ve sağlıklı meme görüntülerinin sınıflandırılmasında en yüksek başarıyı sırasıyla Xception, InceptionV3 ve MobileNet mimarilerinin gösterdiği görülmektedir. Eğitilen modellerin testleri göz önünde bulundurulduğunda ise en yüksek sınıflandırma başarılarını InceptionV3 ve MobileNet mimarisi göstermiştir. ResNet50 mimarisinin eğitim doğruluğu MobileNet'ten daha yüksek olmasına rağmen test başarıyı daha düşüktür. Buradan yola çıkarak MobileNet mimarisinin termal görüntülerde önceden sınıfı bilinmeyen test görüntülerinin sınıflandırılmasında ResNet50'ye göre daha uygun olduğu sonucuna varılabilir. İncelenen modeller arasında kanser olarak tahminde bulunulan memelerin kaçının kanser olduğu bilgisini en yüksek başarımda yine InceptionV3 ve MobileNet mimarileri sağlamıştır. Kanserli memelerden kaçını doğru bir şekilde kanserli olarak tahmin eden mimariler InceptionV3, MobileNet ve ResNet50 olmuştur. Kesinlik ve duyarlılık değerlerinin harmonik ortalamasının hesaplanması ile elde edilen F1 skoru incelendiğinde ise en yüksek başarımları yine InceptionV3 ve MobileNet göstermiştir.

Doğruluk ve kayıp grafikleri mimarilerin görüntüleri ne kadar iyi öğrendiği hakkında bilgiler verir (Zuluaga-Gomez vd. 2021). Doğruluk eğrilerinin her devir sayısında artarak ilerlemesi ve artmayı bıraktığı noktada eğitimin kesilmesi beklenir. Kayıp grafiğinin de her devir sayısında kayıp sayısının azalması ve azalmanın bittiği yerde eğitimin kesilmesi gerekmektedir. Şekil 4.10 ve 4.11 incelendiğinde Xception, InceptionV3, MobileNet, MobileNetV2 ve ResNet50 mimarilerinin birbirlerine yakın eğrilerde ilerledikleri ve 30. devir sayısında artışı neredeyse durdukları ve düz bir eğriye yakın bir şekilde ilerledikleri görülmektedir. Ancak VGG mimarileri eğitimlerini diğer mimarilere göre çok daha geç tamamladıkları görülmüştür.

Tüm bu sonuçlar göz önüne alındığında bu çalışmadaki verilerin eğitiminde ve test işlemlerinde kullanılan mimariler içerisinde en yüksek başarıyı sırasıyla Xception, InceptionV3, MobileNet, ResNet50 ve MobileNetV2 göstermektedir. Xception mimarisi InceptionV3 ve MobileNet'ten yüksek başarımları gösterse de eğitim ve test süreleri göz önünde bulundurulduğunda bu mimarilerden çok daha yavaş çalıştığı gözlenmiştir. MobileNet mimarisi ile gerçekleştirilen test süresi kullanılan tüm mimarilerden çok daha kısadır. MobileNet'in yüksek başarımları göstermesi, çok daha hızlı çalışması ve mobil cihazlara entegre edilebilir olması diğer mimarilere göre ilave avantajlar içermektedir. VGG16 ve VGG19 modelleri eğitim ve test sürelerinin diğer mimarilere göre uzun olması, başarımları diğerlerine göre düşük olması ve doğruluk-kayıp grafiklerinden de görüldüğü üzere diğer mimarilere göre çok daha yüksek devir sayısında eğitimlerini tamamlamaktadır.

5. TARTIŞMA

Bu tez çalışmasında termal meme görüntüleri üzerinden tümörlü memelerin tespiti, bölütlenmesi ve sınıflandırılması çalışılmıştır. Çalışmada kullanılan veriler erişime açık kaynaklı olan DMR-IR (Silva vd. 2014) veri setinden alınmıştır. Tümörlü meme tespiti ve bölütlenmesi işlemleri için iki farklı yöntem denenmiştir. İlk yöntemde tümörlü meme bölgeleri el yordamıyla bölütlenmiş, ikinci yöntemde ise tespit ve bölütleme işlemleri otomatik olarak yapılmıştır.

Literatürdeki çalışmalarda termal meme görüntüleri üzerinden meme kanseri teşhisi için makine öğrenmesi ve derin öğrenme yöntemlerinin sıklıkla kullanıldığı görülmüştür (Karim vd. 2018; Ghayoumi Zadeh vd. 2021). İncelenen çalışmalar sonucunda özellikle görüntü sınıflandırılması çalışmalarında standart makine öğrenmesi algoritmaları kullanıldığında görüntünün yapısı ve bileşimi ihmal edilebilmektedir (Benbrahim vd. 2020). Derin öğrenme algoritmaları ise görüntü üzerinden otomatik olarak özellik çıkarımı yaptıkları için makine öğrenmesine göre daha yüksek başarımlar elde edildiği gözlenmiştir (Shoieb vd. 2016). Meme kanseri teşhisi için yapılan makine öğrenmesi ve derin öğrenme çalışmalarında sıklıkla meme kanseri olan hasta sınıflandırmasının yapıldığı görülmüştür. Bu şekilde yapılan sınıflandırmalar sonucunda hastanın meme kanseri olup olmadığı anlaşılabilir ancak hangi memenin kanserli olduğu bilgisi eksik kalmaktadır. Bu çalışmada geliştirilen yöntemler ile bu sorunun önüne geçilmesi için hasta bazında değil, meme bazında sınıflandırma yapılması önerilmiştir.

Literatür çalışmalarında yer almayıp bu çalışmada var olan bir diğer farklılık ise kanserli memelerin bölütleme yöntemidir. Literatürdeki termal meme bölütleme çalışmalarında birçok algoritma çalışılmıştır ancak çalışmalar arasında Mask R-CNN ve U-Net ile yapılmış herhangi bir çalışmaya rastlanmamıştır. Meme kanseri bölütleme çalışmalarında Mask R-CNN yönteminin ultrason veya mamogram görüntülerinde kullanıldığı görülmüştür. Bu çalışmada önerilen ikinci yöntemde U-Net ve Mask R-CNN ile bölütleme çalışılmıştır. Bölütleme işlemlerinin ardından sınıflandırma işlemlerinde yine literatürde sıklıkla tercih edilen önceden eğitilmiş ağlar üzerinden transfer öğrenme yöntemi önerilmiştir.

Farooq ve Corcoran (2020) yaptıkları çalışmada termal meme görüntüleri ile tümör sınıflandırılmasını çalışmışlardır. Toplanan görüntüleri öncelikle CLAHE yöntemi ile ön işlemlerden geçirdikten sonra DVM ve Naive Bayes yöntemi ile özellik çıkarımını çalışmışlardır. Sınıflandırma işlemleri için DSA kullanan araştırmacılar sonuç olarak eğitim doğruluğunu %93.73, validasyon doğruluğunu %91.32 değerlerinde, test doğruluğunu %80, hassasiyeti %83.33, özgüllüğü %77.77 ve F1 skorunu %76.89 olarak bulduğunu raporlamışlardır. Bu tez çalışmasında sınıflandırma işlemleri için yedi farklı önceden eğitilmiş ağ üzerinden transfer öğrenme uygulanmıştır. Çalışma sonucunda en yüksek başarıyı veren Xception ile eğitimde doğruluk, kesinlik, duyarlılık ve F1 skorunda %100 başarımlar sağlanırken test verilerinde %99.8 doğruluk, %100 kesinlik, %99.3 duyarlılık ve %99.6 F1 skoru başarımları elde edilmiştir. Bu çalışmanın performansının daha yüksek çıkmasının sebebi olarak kullanılan verilerin sınıflandırılmaya daha uygun olması ile beraber makine öğrenmesi yerine derin öğrenme ve transfer öğrenmesinin uygulanmasının da etkili olduğu düşünülmektedir.

Schaefer vd. (2009) yaptıkları çalışmada istatistiksel özelliklerin bulunması ile beslenen bulanık kural tabanlı sınıflandırma yöntemi ile kanser teşhisini çalışmışlardır. Sonuç olarak malin ve benin lezyonlu meme sınıflandırmasının %80 doğrulukta yapılabildiğini raporlamışlardır. Bu tez çalışmasında test verisetlerinde InceptionV3 ve MobileNet ile %100 doğruluk, kesinlik ve duyarlılık elde edilmiştir. Schaefer ve arkadaşlarının çalışmalarında kullandıkları bulanık kural tabanlı sınıflandırma yönteminin uygun özellikler ile beslenemediğinden sınıflandırma başarımının düşük olabileceği düşünülmektedir. Bu çalışmada ise özellik seçiminin derin öğrenme modelinin kendi içerisinde en doğru özellikleri seçip sınıflandırmayı yapmış olmasının başarımı artırdığı söylenebilir.

Acharya vd. (2012) yaptıkları çalışmada makine öğrenmesi yöntemlerini kullanarak kanser teşhisini çalışmışlardır. Alınan görüntüler üzerinde özellik çıkarımı için doku özelliklerini, sınıflandırma için ise DVM sınıflandırıcısını kullanmışlardır. Çalışmalarının sonucunda %88.10 doğruluk, %85.71 duyarlılık ve %90.48 özgüllük değerlerini bulmuşlardır. Bu çalışma ile aynı veri setini kullanan Mookiah vd. (2012) DWT ve doku özellikleri ile beslenen makine öğrenmesi algoritmalarını kullanarak kanser teşhisini çalışmışlardır. Çıkarılan özellikler ile beslenen altı farklı algoritma içerisinde en yüksek başarıyı DT ve Bulanık Sugeno ile %93.30 doğruluk, %86.70 duyarlılık ve %100 özgüllük elde ettiklerini raporlamışlardır. Bu tez çalışmasında kullanılan yedi farklı mimariden en yüksek eğitim doğruluğunu %100 başarımla Xception, en yüksek kesinlik ve duyarlılığı %100 başarımla InceptionV3 ve MobileNet vermiştir. Acharya ve arkadaşları ile Mookiah ve arkadaşlarının çalışmalarında sınıflandırma için tercih edilen makine öğrenmesi başarımlarının düşük olması uygun özellik seçimi yapılamamış olması veya uygun sınıflandırıcı kullanılmaması gibi sebeplerden kaynaklanmış olabileceği düşünülmektedir.

Milosevic vd. (2014) yaptıkları çalışmada termal görüntüler ile meme kanseri teşhisi için özellik çıkarımı ve makine öğrenmesi algoritmaları ile sınıflandırılmasını çalışmışlardır. Özellik çıkarımı için GLCM ve sınıflandırma için KNN, DVM ve Naive Bayes algoritmalarını kullanmışlardır. Çalışma sonucunda en yüksek başarıyı %92.5 doğruluk değeri ile KNN algoritması vermiştir. Bu tez çalışmasında derin öğrenme kullanılarak özellik çıkarımı ve sınıflandırma işlemleri birleştirilmiştir. Çalışma sonucunda kullanılan yedi farklı mimarinin eğitim doğruluğu %98-100 ve test veri setinin doğruluğu %98-100 aralığında yer almaktadır. Milosevic ve arkadaşlarının çalışmalarında yine diğer tüm makine öğrenmesi çalışmalarında olduğu gibi algoritmaların görüntünün yapısı ve bileşimini ihmal edebileceği göz önünde bulundurulmadan derin öğrenme yerine makine öğrenmesi ile çalışmalarının pay sahibi olabileceği düşünülmektedir.

Golestani vd. (2014) çalışmalarında termal meme görüntüleri üzerinden lezyonlu bölgelerin bölütlenmesini çalışmışlardır. Bölütleme için k-ortalamlar, bulanık c-ortalamlar ve seviye belirleme algoritmasını kullanmışlardır. Kullanılan her üç yöntem ise en sıcak bölgelerin bulunması esasına dayanır. Çalışmalarında kullandıkları üç bölütleme yöntemi arasında en yüksek başarıyı seviye belirleme algoritmasının verdiğini nitel olarak raporlamışlardır. Ancak çalışmalarında bölütleme başarımı nicel olarak belirtilmemiştir. Bu tez çalışmasında kullanılan Mask R-CNN ile bölütleme başarımı %98.96 doğruluk, %92.53 duyarlılık, %99.62 Özgüllük, %94.13 F1 skoru, %96.05

kesinlik, %93.66 MCC, %94.13 Dice ve %89 Jaccard değerleri elde edilmiş ve nicel olarak belirtilmiştir.

Bu tez çalışmasında yararlanılan DMR-IR veri setini (Silva vd. 2014) kullanan literatürde birçok çalışma mevcuttur. Bu çalışmalar makine öğrenmesi ve derin öğrenme yöntemleri ile termal görüntüler üzerinden meme kanserinin teşhisini içermektedir. Pramanik vd. (2015) termal meme görüntüleri üzerinden DWT ile özellik çıkarımı ve MLP ile sınıflandırılmasını çalışmışlardır. Çalışmalarının sonucunda %90.48 doğruluk, %87.6 hassasiyet ve %89.73 özgüllük değerlerini elde etmişlerdir. Baffa ve Lattari (2018) veri setinden alınan görüntüleri evrişimsel sinir ağına vererek sınıflandırılmasını çalışmışlardır. Statik ve dinamik olmak üzere iki ayrı çalışma yapılmıştır. Sonuç olarak statik görüntüler ile beslenen ESA ile %98 ve dinamik görüntülerde %95 doğruluk elde etmişlerdir. Karim vd. (2018) veri setinden alınan görüntülerde el yordamıyla yapılan bölütleme işlemlerinin ardından özellik çıkarımı için GLCM kullanmışlardır. Çıkarılan özellikler kullanılarak beslenen DVM sınıflandırıcısının sonucunda %91.25 doğruluk, %93.3 duyarlılık ve %90 özgüllük değerlerini elde etmişlerdir. Ghayoumi Zadeh vd. (2021) makine öğrenmesi kullanarak termal meme görüntülerinden kanser sınıflandırmasını çalışmışlardır. Sınıflandırma işlemleri için Matris Laboratuvarı (Matrix Laboratory, MATLAB) programı ile otokodlayıcı yöntemini kullanmışlardır. Çalışma sonucunda önerdikleri yöntem ile eğitim verilerinde %98.08 doğruluk, %96.87 hassasiyet ve %98.4 özgüllük değerleriyle, test verilerinde ise %94.87 doğruluk, %87.5 hassasiyet ve %96.77 özgüllük elde ettiklerini raporlamışlardır. Fernández-Ovies vd. (2019) veri setinden alınan termal meme görüntülerinde yapılan ön filtreleme ve veri artırma işlemlerinin ardından önceden eğitilmiş evrişimsel sinir ağları üzerinden transfer öğrenimi ile meme kanseri sınıflandırılmasını çalışmışlardır. Çalışmalarında veri setindeki tüm meme görüntüleri üzerinde çalışılmamıştır. Veri setinden alınan görüntüler ön filtreleme işlemlerinin ardından normal ve anormal meme görüntülerinin eşit olması için (2411 sağlıklı ve 534 kanserli hasta görüntüleri 500 olarak rasgele sabitlenmiştir) rastgele görüntü seçilmesi ile eşitleme yapılmıştır. Çalışmalarının sonucunda ResNet34 ve ResNet50 mimarilerinde %100 doğruluk değerinin elde edildiği raporlanmıştır. Tello-Mijares vd. (2019) hem makine öğrenmesi hem de derin öğrenme kullanarak meme kanseri teşhisini çalışmışlardır. Makine öğrenmesi için özellik çıkarımı işlemlerinin ardından WEKA kullanılarak TRF, BN ve MLP sınıflandırıcıları denenmiştir. Derin öğrenme için görüntüdeki gürültülerin giderilmesi amacıyla Gauss Filtresi, bölütleme için GVFS ve bölütlenen görüntülerin sınıflandırılması için ESA kullanılmıştır. Çalışmalarının sonucunda TRF %85.71, MLP %88.88 ve NV %80.95 doğruluk gösterir iken ESA mimarisi ile %100 doğruluk değerlerine ulaşılmıştır. Zuluaga-Gomez vd. (2021) termal meme görüntüleri üzerinden meme kanseri teşhisi için kendi ESA modelini geliştirmişlerdir. Veri setinden alınan görüntüler üzerinde meme bölgesinin kırılması, yeniden boyutlandırması ve normalleştirme işlemleri yapıldıktan sonra ESA ile sınıflandırma yapılmıştır. Kendi ESA modellerini son teknoloji modeller ile kıyaslamışlardır. Çalışmalarının sonucunda kendi modellerinin %92 doğruluk, %94 kesinlik, %91 duyarlılık ve %92 F1 skoru ile diğer modellere göre daha başarılı olduğunu raporlamışlardır. Bu tez çalışmasında aynı veri setinden alınan termal meme görüntüleri yedi farklı önceden eğitilmiş ESA'lar üzerinden transfer öğrenme ile sınıflandırılmıştır. Çalışma sonucunda eğitim doğruluğu, kesinlik ve duyarlılık değerlerinde %100 başarımlı değeri ile en yüksek başarımlı Xception mimarisi göstermiştir. Ancak bu mimari diğer mimarilere göre çok daha yavaş (4065 sn eğitim süresi ve 74 sn test süresi) işlem

görmektedir. Kullanılan yedi mimari arasında en kısa süreli eğitim ve test işlemini (3300 sn eğitim süresi ve 20 sn test süresi) gerçekleştiren mimari MobileNet olmuştur. Bu çalışmada yukarıda belirtilen diğer literatür çalışmalarına göre daha yüksek sınıflandırma performansı sağlanmasının sebebi olarak meme bölgelerinin bölütlenmesinin yüksek başarımda yapılması, hasta bazında değil, meme bazında sınıflandırma yapılması, rasgele seçilen eğitim ve test verilerinin veri setini daha uygun temsil etmiş olması, uygun mimariler ile transfer öğrenme uygulanması ve son olarak Şekil 4.10-11’de de görüleceği şekilde eğitimlerinin uygun devir sayısında yapılmış olmasının büyük pay sahibi olduğu düşünülmektedir.

6. SONUÇLAR

Bu çalışmada termal meme görüntüleri üzerinde eğitilen evrişimsel sinir ağları kullanılarak meme kanserinin tespiti, meme hacminin bölütlenmesi ve sonrasında sınıflandırılması konusu ele alınmıştır. Çalışmada kullanılan termal meme görüntüleri erişime açık kaynaklı sunulan DMR-IR (Silva vd. 2014) veri setinden alınmıştır. Eğitim öncesinde her görüntüdeki meme hacmi VIA web arayıcısı (Dutta ve Zisserman 2019) kullanılarak el yordamıyla poligonlar ile sınırları belirlenmiş ve “meme” şeklinde etiketlenmiştir. Konturlama işlemlerinin ardından bir Python kodu ile her meme görüntüsü için bir maske oluşturulmuştur. Daha sonra bu maske ile orjinal görüntü çakıştırılarak hastanın meme görüntüsü resmin geri kalanından bölütlenmiştir. ESA mimarilerinin girişine verilmeden önce otomatik olarak yapılacak boyut azaltımı işleminde oluşabilecek veri kaybını en aza indirebilmek amacıyla meme görüntüleri kırılmış ve ESA mimarilerinin eğitiminde bu görüntüler kullanılmıştır. Çalışmada iki farklı yöntem denenmiştir. Birinci yöntemde yapay sinir ağı el yordamıyla bölütlenip kırılan görüntüleri eğitim verileri ile eğitildikten sonra yine aynı yöntem ile bölütlenip kırılmış meme görüntüleri ile test edilmiştir. Bu yöntemde el yordamıyla yapılan bölütlemenin işlem yükünün fazla olması ve zaman gerektirmesi nedeniyle ikinci yöntemde insan faktörü olmadan otomatik ve hızlı bir bölütleme çalışmasının yapılması hedeflenmiştir. Bu şekilde eğitilmiş bir meme kanseri bölütlenmesini çalışan ağ önceden hiç görmediği yeni bir veri gelmesi durumunda bölütleme işlemlerini otomatik olarak yapabilecektir. Otomatik bölütleme işlemleri için U-Net ve Mask R-CNN metodları denenmiştir. U-Net ile bölütlenen meme görüntülerinin 0.9718 doğruluk, 0.9086 dice ve 0.8365 jaccard değerlerinin Mask R-CNN tekniğinin 0.9896 doğruluk, 0.9413 dice ve 0.8900 jaccard değerlerinden daha düşük olduğu görülmüştür.

Bu tez çalışmasında literatürdeki diğer çalışmalardan farklı olarak hasta bazında değil, meme bazında sınıflandırma çalışılmıştır. Bu şekilde meme kanseri olan hastanın hangi memesinin kanserli olduğu tespit edilmeye çalışılmıştır. Çalışmada kullanılan yedi farklı (InceptionV3, MobileNet, MobileNetV2, ResNet50, VGG16, VGG19 ve Xception) önceden eğitilmiş ESA mimarileri ile transfer öğrenme tekniği uygulanmıştır. Çalışmanın sonucunda eğitilen mimariler arasında en yüksek başarıyı Xception, InceptionV3 ve MobileNet mimarileri göstermiştir. Bu üç mimariden en yüksek eğitim doğruluğu, kesinliği ve duyarlılığını %100 başarımla Xception vermiştir. Bu mimari InceptionV3 ve MobileNet mimarilerine göre daha yüksek başarımla gösterse de eğitim süresinin bu mimarilere göre daha uzundur. Buradan yola çıkarak bu mimarinin InceptionV3 ve MobileNet mimarilerine göre daha geç öğrendiği sonucuna varılabilir. Eğitilen mimariler içerisinde test verilerinde en yüksek doğruluk, kesinlik ve duyarlılığı %100 başarımla InceptionV3 ve MobileNet vermiştir. Bu da kullanılan mimariler arasında termal meme kanserini en iyi tespit eden mimariler olduğunu göstermektedir. Her iki mimarinin eğitim süreleri birbirine yakın olsa da MobileNet mimarisinin test süresi neredeyse yarı yarıya daha kısadır. Bu da mimarinin eğitilen diğer mimarilere göre daha hızlı sonuç verebildiğini göstermektedir ve bu durum hızlı teşhis için oldukça önemli bir faktördür. MobileNet mimarisinin başarımlarının yüksek olması ve hızlı sonuç vermesinin yanında bu mimarinin mobil uygulamalara entegre edilebilir olması mimariyi ön plana çıkarmaktadır. Eğitilen mimarilerin eğitim ve test süreleri ile başarımları göz önünde bulundurulduğunda VGG mimarilerinin diğer mimarilere göre çok daha yavaş çalıştığı ve başarımlarının diğer mimarilere göre düşük olduğu görülmüştür.

İleriki çalışmalarda daha fazla sayıda termal meme görüntüsü içeren veriler ile eğitilen mimarinin otomatik bölütleme işlemlerinin ardından tekrar dosyalama işlemlerine gerek duyulmadan bölütleme ve sınıflandırmanın birleştirildiği bir yöntem geliştirilebilir. Bu işlemlerin ardından özellikle MobileNet gibi mobil cihazlara entegre edilebilir mimarilerin eğitimi ile geliştirilebilecek bir derin öğrenme ara yüzü tasarlanabilir ve bu ara yüz kullanılarak mobil cihazlar ile teşhis işlemi yapılabilir. Böylece yeni hasta görüntüleri hızlı bir şekilde ağa aktarılabilecek ve uzmanların meme kanseri teşhisinde daha hızlı ve doğru sonuç vermelerine katkı sağlayacaktır.

7. KAYNAKLAR

- Abdel-Nasser, M., Moreno, A. and Puig, D. 2019. Breast cancer detection in thermal infrared images using representation learning and texture analysis methods. *Electronics*, 8(1): 1-18.
- Abdelrahman, L., Al Ghamdi, M., Collado-Mesa, F. and Abdel-Mottaleb, M. 2021. Convolutional neural networks for breast cancer detection in mammography: A Survey. *Computers in Biology and Medicine*, 131: 1-16.
- Acharya, U. R., Ng, E. Y. K., Tan, J. H. and Sree, S. V. 2012. Thermography based breast cancer detection using texture features and support vector machine. *Journal Of Medical Systems*, 36(3): 1503-1510.
- Alafi, B. 2019. Artificial intelligence and deep learning. *The Journal Of Cognitive Systems*, 4(2): 57-61.
- Albawi, S., Mohammed, T. A. and Al-Zawi, S. 2017. Understanding of a convolutional neural network. Paper presented at the 2017 International Conference on Engineering and Technology (ICET).
- Anand, R., Shanthi, T., Nithish, M. and Lakshman, S. 2020. Face recognition and classification using googlenet architecture. *Springer*, 261-269.
- Aslanyürek, M. ve Mesut, A. 2021. Kümeleme performansını ölçmek için yeni bir yöntem ve metin kümeleme için değerlendirmesi. *Avrupa Bilim ve Teknoloji Dergisi*, (27): 53-65.
- Autier, P. and Boniol, M. 2018. Mammography screening: A major issue in medicine. *European Journal of Cancer*, 90: 34-62.
- Baffa, M. d. F. O. and Lattari, L. G. 2018. Convolutional neural networks for static and dynamic breast infrared imaging classification. Paper presented at the 2018 31st SIBGRAPI Conference on Graphics, Patterns and Images (SIBGRAPI).
- Bagavathiappan, S., Saravanan, T., Philip, J., Jayakumar, T., Raj, B., Karunanithi, R., Panicker, T., M., R., Korath, M., P. and Jagadeesan, K. 2009. Infrared thermal imaging for detection of peripheral vascular disorders. *J Med Phys*, 34(1): 43-47.
- Bagavathiappan, S., Lahiri, B. B., Saravanan, T., Philip, J. and Jayakumar, T. 2013. Infrared thermography for condition monitoring – A Review. *Infrared Physics & Technology*, 60: 35-55.
- Benbrahim, H., Hachimi, H. and Amine, A. 2020. Deep convolutional neural network with tensorflow and keras to classify skin cancer images. *Scalable Computing*, 21(3): 379-389.
- Bijalwan, V., Kumar, V., Kumari, P. and Pascual, J. 2014. KNN based machine learning approach for text and document mining. *International Journal of Database Theory and Application*, 7(1): 61-70.
- Brijain, M., Patel, R., Kushik, M. and Rana, K. 2014. A survey on decision tree algorithm for classification. *IJEDR*, 2(1): 1-5.

- Budhiman, A., Suyanto, S. and Arifianto, A. 2019. Melanoma cancer classification using ResNet with data augmentation. Paper presented at the 2019 International Seminar on Research of Information Technology and Intelligent Systems (ISRITI).
- Champion, L., Lerebours, F., Alberini, J. L., Fourme, E., Gontier, E., Bertrand, F. and Wartski, M. 2015. 18F-FDG PET/CT to predict response to neoadjuvant chemotherapy and prognosis in inflammatory breast cancer. *Journal of Nuclear Medicine*, 56(9): 1315-1321.
- Chen, H., Chen, A., Xu, L., Xie, H., Qiao, H., Lin, Q. and Cai, K. 2020. A deep learning CNN architecture applied in smart near-infrared analysis of water pollution for agricultural irrigation resources. *Agricultural Water Management*, 240: 1-8.
- Chiao, J.Y., Chen, K.Y., Liao, K. Y.K., Hsieh, P.H., Zhang, G. and Huang, T.C. 2019. Detection and classification the breast tumors using Mask R-CNN on sonograms. *Medicine*, 98(19): 1-5.
- Choraś, M. and Choraś, R. S. 2019. Image processing and communications: Techniques, algorithms and applications. Springer, Poland. 340 s.
- Chrzanowski, K., Fischer, J. and Matyszekiel, R. 2000. Testing and evaluation of thermal cameras for absolute temperature measurement. *Optical Engineering*, 39(9): 2535-2544.
- Coşkun, M., Uçar, A., Yildirim, Ö. and Demir, Y. 2017. Face recognition based on convolutional neural network. Paper presented at the 2017 International Conference on Modern Electrical and Energy Systems (MEES).
- Çetingül, M. P. and Herman, C. 2011. Quantification of the thermal signature of a melanoma lesion. *International Journal of Thermal Sciences*, 50(4): 421-431.
- Dhahri, H., Al Maghayreh, E., Mahmood, A., Elkilani, W. and Faisal Nagi, M. 2019. Automated breast cancer diagnosis based on machine learning algorithms. *Journal Of Healthcare Engineering*, 2019: 1-11.
- Dutta, A. and Zisserman, A. 2019. The VIA annotation software for images, audio and video. Paper presented at the Proceedings of the 27th ACM International Conference on Multimedia.
- Farooq, M. A. and Corcoran, P. 2020. Infrared imaging for human thermography and breast tumor classification using thermal images, Letterkenny, Ireland.
- Fernández-Ovies, F. J., Alférez-Baquero, E. S., de Andrés-Galiana, E. J., Cernea, A., Fernández-Muñiz, Z. and Fernández-Martínez, J. L. 2019. Detection of breast cancer using infrared thermography and deep neural networks. IWBBIO 2019. Lecture Notes in Computer Science, vol 11466. Springer, Cham.
- Gade, R. and Moeslund, T. B. 2013. Thermal cameras and applications: A survey. *Machine Vision and Applications*, 25(1): 245-262.
- Ghayoumi Zadeh, H., Fayazi, A., Binazir, B. and Yargholi, M. 2021. Breast cancer diagnosis based on feature extraction using dynamic models of thermal imaging and deep autoencoder neural networks. *Journal of Testing and Evaluation*, 49(3): 1-18.

- Golestani, N., EtehadTavakol, M. and Ng, E. 2014. Level set method for segmentation of infrared breast thermograms. *EXCLI Journal*, 13: 241.
- Goyal, M., Knackstedt, T., Yan, S. and Hassanpour, S. 2020. Artificial intelligence-based image classification methods for diagnosis of skin cancer: Challenges and opportunities. *Comput Biol Med*, 127: 104065.
- Greenwood, H. I., Dodelzon, K. and Katzen, J. T. 2018. Impact of advancing technology on diagnosis and treatment of breast cancer. *Surgical Clinics*, 98(4): 703-724.
- Grosenick, D., Rinneberg, H., Cubeddu, R. and Taroni, P. 2016. Review of optical breast imaging and spectroscopy. *Journal Of Biomedical Optics*, 21(9): 1-28.
- Hacıoğlu, R. 2017. Prediction of solar radiation based on machine learning methods. *Journal of Cognitive Systems*, 2(1): 16-20.
- Hakim, A. and Awale, R. N. 2020. Thermal imaging - an emerging modality for breast cancer detection: A Comprehensive Review. *J Med Syst*, 44(8): 1-18.
- Harbeck, N. and Gnant, M. 2016. Breast cancer. *Lancet*, 389(10074): 1134-1150.
- He, K., Gkioxari, G., Dollár, P. and Girshick, R. 2017. Mask R-CNN. Paper presented at the Proceedings of the IEEE International Conference on Computer Vision.
- He, K., Zhang, X., Ren, S. and Sun, J. 2016. Deep residual learning for image recognition. Paper presented at the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition.
- Hoo, Z. H., Candlish, J. and Teare, D. 2017. What is an ROC curve?. *Emergency Medicine Journal*, 34(6): 357-359
- Iranmakani, S., Mortezaadeh, T., Sajadian, F., Ghaziani, M. F., Ghafari, A., Khezerloo, D. and Musa, A. E. 2020. A review of various modalities in breast imaging: Technical aspects and clinical outcomes. *Egyptian Journal of Radiology and Nuclear Medicine*, 51(1): 1-22.
- Izonin, I., Tkachenko, R., Peleshko, D., Rak, T. and Batyuk, D. 2015. Learning-based image super-resolution using weight coefficients of synaptic connections. Paper presented at the 2015 Xth International Scientific and Technical Conference "Computer Sciences and Information Technologies" (CSIT), Lviv, Ukraine.
- İnik, Ö. ve Ülker, E. 2017. Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. *Gaziosmanpaşa Bilimsel Araştırma Dergisi*, 6(3): 85-104.
- Jiménez-Gaona, Y., Rodríguez-Álvarez, M. J. and Lakshminarayanan, V. 2020. Deep-learning-based computer-aided systems for breast cancer imaging: A critical review. *Applied Sciences*, 10(22): 8298.
- Karim, C. N., Mohamed, O. and Ryad, T. 2018. A new approach for breast abnormality detection based on thermography. *Medical Technologies Journal*, 2(3): 245-254.
- Kaur, D. and Kaur, Y. 2014. Various image segmentation techniques: A review. *International Journal of Computer Science and Mobile Computing*, 3(5): 809-814.
- Krizhevsky, A., Sutskever, I. and Hinton, G. E. 2012. Imagenet classification with deep convolutional neural networks. *Advances In Neural Information Processing Systems*, 25: 1097-1105.

- LeCun, Y., Bengio, Y. and Hinton, G. 2015. Deep learning. *Nature*, 521: 436-444.
- Liang, Y., He, R., Li, Y. and Wang, Z. 2019. Simultaneous segmentation and classification of breast lesions from ultrasound images using Mask R-CNN. Paper presented at the 2019 IEEE International Ultrasonics Symposium (IUS).
- Lopez, M. B., del-Blanco, C. R. and Garcia, N. 2017. Detecting exercise-induced fatigue using thermal imaging and deep learning. Paper presented at the 2017 Seventh International Conference on Image Processing Theory, Tools and Applications (IPTA).
- Magalhaes, C., Vardasca, R., Rebelo, M., Valenca-Filipe, R., Ribeiro, M. and Mendes, J. 2019. Distinguishing melanocytic nevi from melanomas using static and dynamic infrared thermal imaging. *J Eur Acad Dermatol Venereol*, 33(9): 1700-1705.
- Mambou, S. J., Maresova, P., Krejcar, O., Selamat, A. and Kuca, K. 2018. Breast cancer detection using infrared thermal imaging and a deep learning model. *Sensors*, 18(9): 1-19.
- Milosevic, M., Jankovic, D. and Peulic, A. 2014. Thermography based breast cancer detection using texture features and minimum variance quantization. *EXCLI Journal*, 13: 1204.
- Mohamed, A., Mohamed, W. A. and Zekry, A. H. 2019. Deep learning can improve early skin cancer detection. *INTL Journal Of Electronics And Telecommunications*, 65(3): 507-512.
- Mookiah, M. R. K., Acharya, U. R. and Ng, E. 2012. Data mining technique for breast cancer detection in thermograms using hybrid feature extraction strategy. *Quantitative InfraRed Thermography Journal*, 9(2): 151-165.
- Muhammad, U., Wang, W., Chattha, S. P. and Ali, S. 2018. Pre-trained VGG-Net architecture for remote-sensing image scene classification. Paper presented at the 2018 24th International Conference on Pattern Recognition (ICPR).
- Nakahara, H., Fujii, T. and Sato, S. 2017. A fully connected layer elimination for a binarized convolutional neural network on an fpga. Paper presented at the 2017 27th International Conference on Field Programmable Logic and Applications (FPL).
- O'Shea, K. and Nash, R. 2015. An introduction to convolutional neural networks. arXiv preprint arXiv:1511.08458.
- Padmavathi, K. and Krishna, K. S. R. 2014. Myocardial infarction detection using magnitude squared coherence and support vector machine. Paper presented at the 2014 International Conference on Medical Imaging, m-Health and Emerging Communication Systems (MedCom). India.
- Pramanik, S., Bhattacharjee, D. and Nasipuri, M. 2015. Wavelet based thermogram analysis for breast cancer detection. Paper presented at the 2015 International Symposium on Advanced Computing and Communication (ISACC).
- Priyadharsini, R. and Sharmila, T. S. 2019. Object detection in underwater acoustic images using edge based segmentation method. *Procedia Computer Science*, 165: 759-765.

- Ren, S., He, K., Girshick, R. and Sun, J. 2016. Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Transactions On Pattern Analysis And Machine Intelligence*, 39(6): 1137-1149.
- Ring, E. F. 2004. The historical development of thermal imaging in medicine. *Rheumatology*, 43(6): 800-802.
- Ronneberger, O., Fischer, P. and Brox, T. 2015. U-Net: Convolutional networks for biomedical image segmentation. MICCAI 2015. Lecture Notes in Computer Science, vol 9351. Springer, Cham.
- Roslidar, R., Rahman, A., Muharar, R., Syahputra, M. R., Arnia, F., Syukri, M., Pradhan, B. and Munadi, K. 2020. A review on recent progress in thermal imaging and deep learning approaches for breast cancer detection. *IEEE Access*, 8: 116176-116194.
- Rymarczyk, T., Kozłowski, E., Kłosowski, G. and Niderla, K. 2019. Logistic regression for machine learning in process tomography. *Sensors*, 19(15): 1-19.
- Schaefer, G., Závisek, M. and Nakashima, T. 2009. Thermography based breast cancer analysis using statistical features and fuzzy classification. *Pattern Recognition*, 42(6): 1133-1137.
- Shoieb, D. A., Youssef, S. M. and Aly, W. M. 2016. Computer-aided model for skin diagnosis using deep learning. *Journal of Image and Graphics*, 122-129.
- Shrestha, A. and Mahmood, A. 2019. Review of deep learning algorithms and architectures. *IEEE Access*, 7: 53040-53065.
- Silva, L., Saade, D., Sequeiros, G., Silva, A., Paiva, A., Bravo, R. and Conci, A. 2014. A new database for breast research with infrared image. *Journal of Medical Imaging and Health Informatics*, 4(1): 92-100.
- Simonyan, K. and Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. arXiv preprint arXiv:1409.1556.
- Sizochenko, N., Syzochenko, M., Fjodorova, N., Rasulev, B. and Leszczynski, J. 2019. Evaluating genotoxicity of metal oxide nanoparticles: Application of advanced supervised and unsupervised machine learning techniques. *Ecotoxicology and Environmental Safety*, 185: 1-22.
- Snehalatha, U. and Sangamithirai, K. 2021. Computer aided diagnosis of obesity based on thermal imaging using various convolutional neural networks. *Biomedical Signal Processing and Control*, 63: 1-10.
- Sultana, N. N. and Puhan, N. B. 2018. Recent deep learning methods for melanoma detection: A review. In: Ghosh, D., Giri, D., Mohapatra, R., N., Savas, E., Sakurai, K. and Singh, L., P. (Eds.) Mathematics and computing. Springer, Singapore, pp. 118-132.
- Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A. and Bray, F. 2021. Global cancer statistics 2020: Globocan estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal For Clinicians*, 71(3): 209-249.

- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V. and Rabinovich, A. 2015. Going deeper with convolutions. *IEEE*. Boston.
- Tello-Mijares, S., Woo, F. and Flores, F. 2019. Breast cancer identification via thermography image segmentation with a gradient vector flow and a convolutional neural network. *Journal Of Healthcare Engineering*, 2019: 1-13.
- Torrey, L. and Shavlik, J. 2010. Transfer learning. In: Olivas, E., S., Guerrero, J., D., Sober, M., M., Benedito, J., R., M. and Lopez, A., J., S. (Eds) Handbook of research on machine learning applications and trends: Algorithms, methods, and techniques. IGI global, United States, pp. 242-264.
- Wang, D., Khosla, A., Gargeya, R., Irshad, H. and Beck, A. H. 2016. Deep learning for identifying metastatic breast cancer. *ArXiv*, 1-7.
- Wang, L. 2018. Microwave sensors for breast cancer detection. *Sensors*, 18(2): 1-17.
- Weng, Y., Zhou, T., Li, Y. and Qiu, X. 2019. NAS-Unet: Neural Architecture Search for Medical Image Segmentation. *IEEE Access*, 7: 44247-44257.
- Xin, Y., Kong, L., Liu, Z., Chen, Y., Li, Y., Zhu, H., Gao, M., Hou, H. and Wang, C. 2018. Machine learning and deep learning methods for cybersecurity. *IEEE Access*, 6: 35365-35381.
- Yassin, N. I., Omran, S., El Houbay, E. M. and Allam, H. 2018. Machine learning techniques for breast cancer computer aided diagnosis using different image modalities: A Systematic Review. *Computer Methods And Programs In Biomedicine*, 156: 25-45.
- Yin, Y. and Gelenbe, E. 2016. Deep learning in multi-layer architectures of dense nuclei. *ArXiv*, 1-10.
- Zeiler, M. D. and Fergus, R. 2014. Visualizing and understanding convolutional networks. Paper presented at the European Conference on Computer Vision.
- Zuluaga-Gomez, J., Al Masry, Z., Benagoune, K., Meraghni, S. and Zerhouni, N. 2021. A CNN-based methodology for breast cancer diagnosis using thermal images. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*, 9(2): 131-145.
- Anonim 1: <https://www.animais.info/imagens-fundos-de-ecra-de-caes-jpg-1680x1050> [Son Erişim Tarihi: 12.12.2021]
- Anonim 2: What Is Image Segmentation? <https://www.mathworks.com/discovery/image-segmentation.html> [Son Erişim Tarihi: 01.11.2021]
- Anonim 3: <https://www.flickr.com/photos/30892277@N06/6432223359/sizes/o/> [Son Erişim Tarihi: 15.11.2021]
- Anonim 4: https://www.turkcebilgi.com/sinir_hücresi [Son Erişim Tarihi: 11.09.2021]
- Anonim 5: Opperman, A. Artificial Intelligence vs. Machine Learning vs. Deep Learning: What's the Difference? <https://builtin.com/artificial-intelligence/ai-vs-machine-learning> [Son Erişim Tarihi: 10.11.2021]

Anonim 6: Sharma P. 2019. Computer vision tutorial: A step-by-step introduction to image segmentation techniques (part 1) <https://www.analyticsvidhya.com/blog/2019/04/introduction-image-segmentation-techniques-python/> [Son Erişim Tarihi: 15.11.2021]

Anonim 7: Harshall L. 2019. Understanding Semantic Segmentation with UNET. <https://towardsdatascience.com/understanding-semantic-segmentation-with-unet-6be4f42d4b47> [Son Erişim Tarihi: 15.12.2021]

ÖZGEÇMİŞ

SONER ÇİVİLİBAL

sonercivilibal07@gmail.com



ÖĞRENİM BİLGİLERİ

Yüksek Lisans	
2019-2022	Akdeniz Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Anabilim Dalı, Antalya
Lisans	
2015-2019	Düzce Üniversitesi, Mühendislik Fakültesi, Biyomedikal Mühendisliği Bölümü, Düzce

MESLEKİ VE İDARİ GÖREVLER

Stajyer	
08/2018 – 09/2018	Sağlık Bilimleri Üniversitesi, Antalya Eğitim ve Araştırma Hastanesi, Antalya
Stajyer	
08/2017 – 09/2017	Akdeniz Üniversitesi, Tıp Fakültesi Hastanesi, Antalya

ESERLER

Ulusal hakemli dergilerde yayımlanan makaleler

1- Eken, A., Çalışkan, Ş., Çivilibal, S. ve Tosun, P. 2021. Sigara Kullanma Durumunun Çoklu Fizyolojik Ölçümler ve Makine Öğrenmesi Teknikleri Kullanılarak Tahmini. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 23(67): 55-69. <https://dergipark.org.tr/tr/pub/deumffmd/issue/59584/684861>