



**MAMOGRAFİ GÖRÜNTÜLERİ KULLANARAK
EVİRİŞİMSEL SİNİR AĞI TABANLI
MEME KANSERİNİN ERKEN TESPİTİ**

YÜKSEK LİSANS TEZİ

Tuğçe ÇOBAN

Danışman

Doç. Dr. Uçman ERGÜN

BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI

Haziran 2025

AFYON KOCATEPE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**MAMOGRAFİ GÖRÜNTÜLERİ KULLANARAK EVRİŞİMSEL
SİNİR AĞI TABANLI MEME KANSERİNİN ERKEN TESPİTİ**

Tuğçe ÇOBAN

Danışman

Doç. Dr. Uçman ERGÜN

BİYOMEDİKAL MÜHENDİSLİĞİ ANABİLİM DALI

Haziran 2025

TEZ ONAY SAYFASI

Tuğçe ÇOBAN tarafından hazırlanan “Tez Onay Sayfası” adlı tez çalışması lisansüstü eğitim ve öğretim yönetmeliğinin ilgili maddeleri uyarınca 16 / 06 / 2025 tarihinde aşağıdaki jüri tarafından **oy birliği** ile Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü **Biyomedikal Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Doç. Dr. Uçman ERGÜN

Başkan : Prof. Dr. Sabri KOÇER
Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi

Üye : Doç. Dr. Uçman ERGÜN
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Üye : Doç. Dr. Celal Onur GÖKÇE
Afyon Kocatepe Üniversitesi, Mühendislik Fakültesi

Afyon Kocatepe Üniversitesi
Fen Bilimleri Enstitüsü Yönetim Kurulu’nun
..... /..... /..... tarih ve
..... sayılı kararıyla onaylanmıştır.

.....
Prof. Dr. Bekir YALÇIN
Enstitü Müdürü

BİLİMSEL ETİK BİLDİRİM SAYFASI
Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- Atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

16 / 06 / 2025

İmza

Tuğçe ÇOBAN

ÖZET

Yüksek Lisans Tezi

MAMOGRAFİ GÖRÜNTÜLERİ KULLANARAK EVRİŞİMSEL SİNİR AĞI TABANLI MEME KANSERİNİN ERKEN TESPİTİ

Tuğçe ÇOBAN

Afyon Kocatepe Üniversitesi

Fen Bilimleri Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Uçman ERGÜN

Dünya Sağlık Örgütü (WHO) verilerine göre, meme kanseri kadınlarda en yaygın kanser türüdür ve bu türden kaynaklanan ölüm oranları da oldukça yüksektir. Meme kanserinin doğru ve zamanında tespiti, tedavi sürecinin başarısını doğrudan etkileyen kritik bir faktördür. Geleneksel mamografi ve görüntüleme yöntemleri, radyologların deneyimlerine bağlı olarak farklılık gösterebilir; bu da yanlış pozitif veya negatif sonuçların ortaya çıkmasına yol açabilir. Bu bağlamda, yapay zeka ve derin öğrenme teknolojilerinin entegrasyonu, kanser teşhisinde önemli bir gelişme sağlamaktadır. Derin öğrenme algoritmaları, büyük veri setlerini işleyebilme ve öğrenme yetenekleri sayesinde, mamografi görüntülerindeki anormallikleri tanımada yüksek doğruluk oranları sunmaktadır.

Bu çalışmanın amacı, meme kanseri teşhisinde derin öğrenme tabanlı sınıflandırma sistemlerinin doğruluğunu ve güvenilirliğini artıran yeni bir model geliştirmektir. Breast Cancer Ensemble Convolutional Neural Network (BCECNN) modeli, AISSLab veri kümesi kullanılarak geliştirilmiştir. Model, beş farklı derin öğrenme mimarisinin (AlexNet, VGG16, ResNet-18, EfficientNetB0, XceptionNet) çıktılarının çoğunluk oylaması (majority voting) yöntemiyle birleştirildiği üçlü (TECNN) ve beşli (FECNN) ensemble yapıları kullanmaktadır. Bu metodoloji, her bir ağın güçlü yönlerini bir araya getirerek daha doğru ve güvenilir tahminler elde etmeyi amaçlamaktadır. Model, aşırı öğrenme problemini engellemek ve genelleme kapasitesini artırmak için transfer öğrenme teknikleri ile optimize edilmiştir. Transfer öğrenme, modelin sınırlı veri ile daha iyi

sonular elde etmesini saėlayarak, eėitimin daha verimli hale gelmesine katkı sağlamaktadır. BCECNN modelinin performansı, AISSLab veri kümesinden beş farklı sınıflandırma alt kümesi oluşturularak (AISSLab-v1, AISSLab-v2, AISSLab-v3, AISSLab-v4, AISSLab-v5) kapsamlı bir şekilde deėerlendirilmiřtir. Bu testler, modelin doėruluėunu, güvenilirliėini ve genellenebilirliėini farklı klinik senaryolar altında analiz etmeyi saėlamıřtır. Sonular, BCECNN modelinin %98,75 doėruluk oranına ulařtıėını ve mevcut literatürdeki en başarılı modellerden biri olduėunu göstermektedir. Bu, modelin meme kanseri teřhisinde olduka etkili bir ara olabileceėini ve klinik uygulamalarda güvenle kullanılabileceėini ortaya koymaktadır. Modelin önemli katkılarından biri de Açıklanabilir Yapay Zeka (XAI) tekniklerinin entegrasyonudur. Gradyan Aėırlıklı Sınıf Aktivasyon Haritalama (Grad-CAM) ve Yerel Yorumlanabilir Modelden Baėımsız Açıklamalar (LIME) gibi açıklanabilirlik yöntemleri kullanılarak, modelin karar süreçleri řeffařtırılmıřtır. Bu sayede klinik uzmanlar, modelin hangi görüntü bölgelerini kritik olarak deėerlendirdiėini görselleřtirebilmiř ve modelin kararlarının güvenilirliėini daha iyi analiz edebilmiřtir. Açıklanabilir yapay zeka desteėi, klinik uzmanların modelin sonularına duyduėu güveni artırmakta ve modelin klinik karar destek sistemlerinde kullanılabilirliėini kolaylařtırmaktadır. Sonu olarak, BCECNN modeli, yüksek doėruluk oranı, açıklanabilir yapay zekâ desteėi ve klinik uygulanabilirlik aısından önemli avantajlar sunmaktadır. Modelin, yapay zekâ tabanlı klinik karar destek sistemlerinin gelecekteki kullanımına katkı saėlayacak büyük bir potansiyeli vardır. Bu alıřma, derin öėrenme tekniklerinin meme kanseri teřhisi gibi kritik saėlık sorunlarında etkili bir řekilde kullanılabileceėini ve yapay zekâ uygulamalarının saėlık sektöründe nasıl daha verimli hale getirilebileceėini ortaya koymaktadır. Bu bağlamda, geliřtirilen BCECNN modeli, saėlık alanında yapay zekâ tabanlı sistemlerin klinik uygulamalara entegrasyonunu destekleyecek önemli bir adım teřkil etmektedir.

2025, xi + 95 sayfa

Anahtar Kelimeler: Meme Kanseri, Derin Öėrenme, AISSLab Veri Seti, Açıklanabilir Yapay Zeka, Topluluk Öėrenmesi, Evriřimsel Sinir Aėı

ABSTRACT

M.Sc. Thesis

CONVOLUTIONAL NEURAL NETWORK BASED EARLY DETECTION OF BREAST CANCER USING MAMMOGRAPHY IMAGES

Tuğçe ÇOBAN

Afyon Kocatepe University

Graduate School of Natural and Applied Sciences

Department of Biomedical Engineering

Supervisor: Assoc. Prof. Uçman ERGÜN

According to World Health Organisation (WHO) data, breast cancer is the most common type of cancer in women and the mortality rate from this type is very high. Accurate and timely detection of breast cancer is a critical factor that directly affects the success of the treatment process. Traditional mammography and imaging methods can vary depending on the experience of radiologists, which can lead to false positive or negative results. In this context, the integration of artificial intelligence and deep learning technologies provides a significant improvement in cancer diagnosis. Deep learning algorithms offer high accuracy rates in recognising abnormalities in mammography images thanks to their ability to process and learn from large data sets.

The aim of this study is to develop a new model that improves the accuracy and reliability of deep learning based classification systems in breast cancer diagnosis. The Breast Cancer Ensemble Convolutional Neural Network (BCECNN) model was developed using the AISSLab dataset. The model uses triple (TECNN) and quintuple (FECNN) ensemble structures in which the outputs of five different deep learning architectures (AlexNet, VGG16, ResNet-18, EfficientNetB0, XceptionNet) are combined by majority voting. This methodology aims to obtain more accurate and reliable predictions by combining the strengths of each network. The model is optimised with transfer learning techniques to avoid the overfitting problem and to increase its generalisation capacity. Transfer learning enables the model to obtain better results with limited data, thus contributing to more efficient training. The performance of the BCECNN model was

extensively evaluated by creating five different classification subsets from the AISSLab dataset (AISSLab-v1, AISSLab-v2, AISSLab-v3, AISSLab-v4, AISSLab-v5). These tests allowed to analyse the accuracy, reliability and generalisability of the model under different clinical scenarios. The results show that the BCECNN model achieves an accuracy of 98.75% and is one of the most successful models in the current literature. This shows that the model can be a highly effective tool in breast cancer diagnosis and can be used safely in clinical applications. One of the important contributions of the model is the integration of Explainable Artificial Intelligence (XAI) techniques. By using explainability methods such as Gradient Weighted Class Activation Mapping (Grad-CAM) and Locally Interpretable Model Independent Explanations (LIME), the decision processes of the model are made transparent. In this way, clinical experts were able to visualise which image regions were considered critical by the model and better analyse the reliability of the model's decisions. The support of explainable artificial intelligence increases the confidence of clinical experts in the results of the model and facilitates the use of the model in clinical decision support systems. In conclusion, the BCECNN model offers significant advantages in terms of high accuracy, explainable artificial intelligence support and clinical applicability. The model has great potential to contribute to the future use of artificial intelligence-based clinical decision support systems. This study demonstrates how deep learning techniques can be effectively used in critical health problems such as breast cancer diagnosis and how artificial intelligence applications can be made more efficient in the health sector. In this context, the developed BCECNN model constitutes an important step to support the integration of artificial intelligence-based systems into clinical applications in healthcare.

2025, xi + 95 pages

Keywords: Breast cancer, Deep Learning, AISSLab Dataset, Explainable Artificial Intelligence, Ensemble Learning, Convolutional Neural Network

TEŞEKKÜR

Bu araştırmanın konusu, deneysel çalışmaların yönlendirilmesi, sonuçların değerlendirilmesi ve yazım aşamasında gösterdiği büyük katkılardan dolayı tez danışmanım Sayın Doç. Dr. Uçman ERGÜN'e derin teşekkürlerimi sunarım.

Ayrıca, araştırma ve yazım sürecinde bana sürekli destek olan Sayın Arş. Gör. İsmail KAYADİBİ'ne de en içten teşekkürlerimi iletmek isterim. Bu süreçte yanı başımda olan, beni her zaman cesaretlendiren ve çalışmalarına yön veren değerli hocalarıma ve dostlarıma, öneri ve eleştirileriyle katkı sağladıkları için minnettarım.

Son olarak, araştırma boyunca maddi ve manevi desteklerinden dolayı her zaman yanımda olan aileme teşekkürlerimi sunarım. Onların sevgi, anlayış ve sabır dolu desteği, bu çalışmayı tamamlamama olanak sağlamıştır. Ailem, benim için her zaman bir güç kaynağı olmuş ve zorluklarla başa çıkmamda en büyük destekçim olmuştur. Bu tezdeki başarımda onların katkısı yadsınamaz.

Tuğçe ÇOBAN
Afyonkarahisar 2025

İÇİNDEKİLER DİZİNİ

	Sayfa
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
İÇİNDEKİLER DİZİNİ.....	vi
SİMGELER ve KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ.....	ix
ÇİZELGELER DİZİNİ.....	x
RESİMLER DİZİNİ	xi
1. GİRİŞ.....	1
2. LİTERATÜR BİLGİLERİ	5
2.1 Meme Anatomisi ve Meme Kanseri Tanısının Önemi	5
2.2 Meme Kanseri Tanı Yöntemleri	7
2.2.1 Mamografi.....	7
2.2.2 Ultrasonografi	8
2.2.3 Manyetik Rezonans Görüntüleme.....	10
2.2.4 Görüntüleme Eşliğinde Biyopsi Yöntemleri.....	11
2.2.5 Nükleer Tıp Yöntemleri	12
2.3 Meme Kanseri Tanısında Yapay Zeka Yöntemleri	12
2.3.1 Yapay Zeka	13
2.3.2 Makine Öğrenmesi	14
2.3.3 Derin Öğrenme.....	15
2.3.3.1 Evrişimsel Sinir Ağları.....	16
2.3.3.2 CNN Yapısı ve Katmanları	16
2.3.3.3 Evrişimsel Katman	18
2.3.3.4 Havuzlama Katmanı	19
2.3.3.5 Doğrultulmuş Lineer Birim (ReLU) Aktivasyon Fonksiyonu	21
2.3.3.6 Tam Bağlı Katman	22
2.3.4 Transfer Öğrenme	24
2.3.5 CNN Mimarileri.....	24
2.3.5.1 AlexNet	25
2.3.5.2 ResNet18	26
2.3.5.3 VGG16	26

2.3.5.4 EfficientNetB0.....	27
2.3.5.5 XceptionNet.....	28
2.3.6 Topluluk Öğrenmesi	29
2.3.6.1 Çoğunluk Oylaması Yöntemi.....	31
2.3.7 Açıklanabilir Yapay Zeka Yöntemleri.....	32
2.3.7.1 Grad-CAM (Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması).....	33
2.3.7.2 LIME (Yerel Yorumlanabilir Model-agnostik Açıklamalar).....	33
2.3.7.3 LIME-Mask.....	34
2.4 AISSLab Meme Kanseri Veri Seti.....	34
2.5 Meme Kanseri Anomali Tespiti ile İlgili Önceki Çalışmalar	37
3. MATERYAL ve METOT	47
3.1 AISSLab Ham ve Artırılmış Veri Seti.....	48
3.2 CNN Mimarisi	49
3.3 Görüntü Ön İşleme Yöntemleri	50
3.4 Transfer Öğrenme Yöntemi Uygulaması.....	51
3.5 Topluluk Öğrenme Yöntemi Uygulaması.....	52
3.6 Performans Metrikleri.....	54
3.7 Açıklanabilir Yapay Zeka Uygulaması.....	57
4. BULGULAR	58
4.1 Tek CNN Modeli Performansı.....	58
4.2 Topluluk Model Performansı.....	68
4.3 Açıklanabilir Yapay Zeka Sonuçlarının Değerlendirilmesi.....	75
4.4 Önerilen Yöntemin Literatürdeki Diğer Yöntemlerle Karşılaştırmalı Analizi	78
5. TARTIŞMA ve SONUÇ	80
6. KAYNAKLAR.....	84
ÖZGEÇMİŞ.....	95

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler

$\hat{y}$	Finalde Tahmin Edilen Sınıf
C	Tüm Sınıflar Kümesi
n	Topluluktaki Toplam Model Sayısı
K	Evrişim Filtresi
X	Giriş Görüntüsü
Y	Çıktı Görüntüsü
w_i	Belirlenen Ağırlık

Kısaltmalar

ACR	Amerikan Radyoloji Koleji
AUC	Eğri Altındaki Alan
BI-RADS	Meme Görüntüleme Raporlama ve Veri Sistemi
CNN	Evrişimsel Sinir Ağı
DL	Derin Öğrenme
FPR	Yanlış Pozitif Oranı
Grad-CAM	Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması
LIME	Yerel Yorumlanabilir Model-Agnostik Açıklamalar
MRI	Manyetik Rezonans Görüntüleme
ReLU	Doğrultulmuş Lineer Birim
t-SNE	t-Dağıtılmış Stokastik Komşu Gömme
TPR	Gerçek Pozitif Oranı
US	Ultrasonografi
WHO	Dünya Sağlık Örgütü
XAI	Açıklanabilir Yapay Zekâ
YZ	Yapay Zeka
SMOTE	Sentetik Azınlık Aşırı Örnekleme Tekniği
CAD	Bilgisayar Destekli Tanı
CLAHE	Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme
ViT	Görsel Dönüştürücü

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1 Meme Anatomisi: Meme yapısının temel bileşenleri	5
Şekil 2.2 a) Manyetik Rezonans Görüntüleme Cihazı: Meme kanseri tanısı için kullanılan yüksek çözünürlüklü görüntüleme cihazı, b) MRI görüntüsü: Meme kanserinin derin bölgelerdeki yayılımını gösteren yüksek çözünürlüklü görüntü.....	10
Şekil 2.3 Ultrasonografi ile biyopsi.....	11
Şekil 2.4 Sentiell lenf nodu biyopsisi	12
Şekil 2.5 Yapay zekanın alt dalları.....	14
Şekil 2.6 Makine öğrenmesi yöntemleri.....	15
Şekil 2.7 CNN mimari yapısı	17
Şekil 2.8 Evrişim işlemi	18
Şekil 2.9 Maksimum ve ortalama havuzlama	20
Şekil 2.10 ReLU aktivasyon fonksiyonu.....	22
Şekil 2.11 Transfer Öğrenme	24
Şekil 2.12 AlexNet Mimarisi	25
Şekil 2.13 ResNet18 Mimarisi.	26
Şekil 2.14 VGG16 Mimarisi	27
Şekil 2.15 EfficientNetB0 Mimarisi	28
Şekil 2.16 XceptionNet Mimarisi.....	29
Şekil 2.17 Topluluk Öğrenmesi.....	30
Şekil 2.18 t-SNE yöntemi ile BI-RADS seviyelerine göre veri seti dağılımı	35
Şekil 2.19 AISSLab veri setinden farklı sınıflardan örnek mamografi görüntüleri	36
Şekil 2.20 Anomalite maske görüntüleri.....	36
Şekil 3.1 Akış Şeması.....	48
Şekil 3.2 Veri artırma teknikleri.....	51
Şekil 3.3 TECNN yöntemi ile oluşturulan en iyi model kombinasyonu.....	53
Şekil 3.4 QECNN yöntemi ile oluşturulan model kombinasyonu.	54
Şekil 3.5 Karışıklık Matrisi	55
Şekil 4.1 Artırılmış AISSLab Veri Seti Roc Eğrileri: a) AISSLab-v1, b) AISSLab-v2, c) AISSLab-v3, d) AISSLab-v4, e) AISSLab-v5	67
Şekil 4.2 TECNN 50-100 epok karışıklık matrislerinin karşılaştırılması: a) AISSLab-v1, b) AISSLab-v2, c) AISSLab-v3, d) AISSLab-v4, e) AISSLab-v5	71
Şekil 4.3 QECNN 50-100 epok karışıklık matrislerinin karşılaştırılması: a) AISSLab-v1, b) AISSLab-v2, c) AISSLab-v3, d) AISSLab-v4, e) AISSLab-v5	74

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1 Veri seti sınıf dağılımı.....	35
Çizelge 2.2 Açıklanabilir yapay zeka yöntemlerini kullanan meme kanseri teşhis çalışmaları	43
Çizelge 3.1 Ham ve artırılmış veri seti dağılımı	48
Çizelge 3.2 Derin Öğrenme Model Parametleri	50
Çizelge 3.3 Üçlü ve beşli kombinasyonların listesi	53
Çizelge 4.1 Ham veri seti kullanılarak eğitilen CNN modellerinin karşılaştırmalı sınıflandırma performansları.	60
Çizelge 4.2 Veri artırma yöntemi kullanılarak eğitilen CNN modellerinin karşılaştırmalı sınıflandırma performansları.	644
Çizelge 4.3 Farklı ensemble modellerinin doğruluk metrikleri açısından karşılaştırılması.	Hata! Yer işareti tanımlanmamış. 9
Çizelge 4.4 Farklı CNN modelleri için Grad-CAM, LIME ve LIME-Mask tabanlı açıklanabilir yapay zeka görselleştirmeleri.	777
Çizelge 4.5 Literatürdeki meme kanseri sınıflandırma çalışmalarının karşılaştırılması	788

RESİMLER DİZİNİ

Sayfa

Resim 2.1 Mamografi Cihazı: Meme kanseri tespiti için kullanılan X-ışını temelli görüntüleme cihazı	8
Resim 2.2 Ultrasonografi Cihazı: Meme dokusundaki kist ve lezyonların tespiti için kullanılan ses dalgalarıyla görüntüleme yöntemi	9



1. GİRİŞ

Meme kanseri, dünya genelinde kadınlar arasında en yaygın görülen kanser türlerinden biri olup, halk sağlığı açısından büyük bir tehdit oluşturmaktadır. Dünya Sağlık Örgütü (WHO) verilerine göre, her yıl yaklaşık 2 milyondan fazla kadına meme kanseri tanısı konulmakta ve hastalık, kansere bağlı ölüm nedenleri arasında üst sıralarda yer almaktadır (Sun vd. 2017). Özellikle düşük ve orta gelirli ülkelerde erken teşhis ve tedaviye erişimde yaşanan kısıtlılıklar nedeniyle sağkalım oranları, yüksek gelirli ülkelere kıyasla önemli ölçüde düşüktür. Bu durum, meme kanseri ile mücadelede erken teşhisin ve etkili tedavi yöntemlerinin önemini ortaya koymaktadır. Meme kanseri, sadece bireysel bir sağlık problemi olmayıp, aynı zamanda iş gücü kaybına veya sağlık harcamalarına etkileri nedeniyle sağlık sistemine olumsuz etkileri olan bir hastalıktır (Alshawwa vd. 2024). Kanser tedavisinin maliyeti, hastalığa bağlı işgücü kaybı ve hastaların psikososyal etkilenimi, bu hastalığın sağlık sistemleri üzerindeki baskısını arttırmaktadır. Erken teşhis ile tedavi süreci daha az maliyetli olabilir. Gelişmiş ülkelerde erken tarama programları ve etkin tedavi yöntemleri sayesinde hastalığın sağkalım oranları artarken, gelişmekte olan ülkelerde bu oranlar düşüktür (Obeagu ve Obeagu 2024).

Meme kanseri, meme dokusundaki hücrelerin kontrolsüz bir şekilde çoğalmasıyla ortaya çıkan kötü huylu bir hastalıktır. Meme kanseri genellikle süt kanalları (duktal karsinom) veya süt bezleri (lobüler karsinom) içinde başlar ve zamanla çevre dokulara yayılabilir (Pandya ve Moore 2011). Hastalığın ilerleyen evrelerinde, lenf nodları ve diğer organlara metastaz yaparak tedavi sürecini daha karmaşık hale getirebilir. Meme kanserinin kesin nedeni bilinmemekle birlikte, genetik yatkınlık, hormon seviyelerindeki değişimler, yaşam tarzı faktörleri ve çevresel etkenler risk faktörleri arasında yer almaktadır (Łukasiewicz vd. 2021).

Meme kanseri teşhisinde yaygın olarak kullanılan kavramlar arasında normal ve anormal meme dokusu ayrımı önemli bir yer tutar. Normal meme dokusu kanser içermeyen, düzenli ve homojen bir yapıya sahipken, anormal meme dokusu kanser olarak değerlendirilen, düzensiz şekil, yoğunluk değişiklikleri ve şüpheli kitleler içerebilir (Bazira vd. 2022). Bu ayrım, meme kanseri teşhisinde temel bir değerlendirme kriteri olup, klinik karar süreçlerini doğrudan etkilemektedir. Bununla birlikte, anormal meme

dokusu içinde benign (iyi huylu) ve malign (kötü huylu) lezyonlar arasındaki ayrım, kanserin teşhis edilmesi açısından kritik bir öneme sahiptir. Benign lezyonlar, genellikle zararsız olup, hızlı büyümeyen ve çevre dokulara yayılmazken, malign tümörler agresif bir şekilde büyüyerek çevre dokulara ve uzak organlara metastaz yapabilir (Xiao vd. 2024). Bu nedenle, meme kanseri teşhisinde kullanılan sınıflandırma sistemleri, hem anormal dokunun varlığını hem de bu dokunun benign ya da malign olup olmadığını belirlemeye yöneliktir.

Meme kanserinin değerlendirilmesinde kullanılan en yaygın sınıflandırma sistemlerinden biri, Amerikan Radyoloji Koleji (ACR) tarafından geliştirilen Meme Görüntüleme Raporlama ve Veri Sistemi (BI-RADS) kategorileridir (Spak vd. 2017). BI-RADS sistemi, mamografi ve diğer görüntüleme yöntemleri kullanılarak tespit edilen lezyonların klinik olarak değerlendirilmesine yardımcı olmaktadır. BI-RADS 1 görüntüleme sırasında hiçbir anormal bulguya rastlanmaması durumudur. Meme dokusu tamamen normal olarak değerlendirilir. Kanser riski içermez. BI-RADS 2, Kesinlikle benign (iyi huylu) lezyonları ifade eder ve herhangi bir takip gerektirmez. BI-RADS 3, Büyük olasılıkla benign olan lezyonları içerir (%98 ihtimalle benign), ancak olası değişiklikleri izlemek için kısa süreli takip önerilir. BI-RADS 4, Şüpheli lezyonları kapsar ve daha ileri değerlendirme için biyopsi önerilir. Kendi içinde düşük, orta ve yüksek riskli olmak üzere alt gruplara ayrılabilir. BI-RADS 5, Yüksek ihtimalle malign (%95 ve üzeri) lezyonları tanımlar ve acil biyopsi gerektirir. BI-RADS 6 Biyopsi ile malign (kötü huylu) olduğu doğrulanmış meme kanseri vakalarını ifade eder. Kanser kesin olarak tespit edilmiştir ve tedavi sürecine başlanmalıdır.

Meme kanserinin erken teşhisi, hastalığın seyri üzerinde kritik bir etkiye sahiptir. Erken evrede tespit edilen vakalarda tedavi başarı oranları yükselmekte ve hastaların yaşam süreleri uzamaktadır. Geleneksel teşhis yöntemleri arasında klinik muayene, mamografi, Ultrasonografi (US) ve Manyetik Rezonans Görüntüleme (MRI) yer almaktadır (Kerlikowske vd. 2024). Mamografi, meme kanseri taramalarında en yaygın kullanılan yöntemlerden biri olmasına rağmen, yanlış negatif ve yanlış pozitif sonuçlar gibi sınırlamaları bulunmaktadır. Mamografi görüntülerinde meme kanseri, genellikle düzensiz şekilli kitleler, mikrokalsifikasyonlar ve asimetrik yoğunluklar şeklinde kendini

gösterir. Ancak bazı durumlarda, tümörlerin yoğun meme dokusu içinde gizlenmesi nedeniyle mamografide tespit edilmesi zor olabilir. Bu nedenle, erken teşhiste daha yüksek doğruluk oranları sunan yenilikçi teknolojilere duyulan ihtiyaç giderek artmaktadır.

Geleneksel tanı yöntemlerinin yanı sıra, yeni nesil biyomarkerlar ve moleküler genetik analizler de meme kanseri teşhisinde giderek daha fazla önem kazanmaktadır. Radiomics ve radiogenomics gibi ileri düzey görüntüleme teknikleri, tıbbi görüntülerden elde edilen niceliksel verileri genetik bilgilerle entegre ederek daha kişiselleştirilmiş teşhis ve tedavi stratejileri geliştirilmesine olanak tanımaktadır (Adam vd. 2023). Radiomics, tıbbi görüntülerden çıkarılan veri özelliklerini analiz ederek kanserin biyolojik özellikleri hakkında bilgi sağlarken, radiogenomics, bu görüntü özelliklerini genetik profillerle ilişkilendirerek hastalığın moleküler mekanizmalarını daha iyi anlamayı hedeflemektedir (Ghimire vd. 2024, Singh vd. 2024).

Son yıllarda, Yapay Zeka (YZ) ve özellikle Derin Öğrenme (DL) teknikleri, tıbbi görüntüleme alanında devrim niteliğinde ilerlemeler sağlamıştır. Yapay zeka tabanlı sistemler, meme kanseri teşhisinde doktorlara yardımcı olarak teşhis sürecini hızlandırmakta ve hata oranlarını azaltmaktadır(Shah vd. 2022). Derin öğrenme modelleri, büyük veri setlerinden öğrenerek meme kanseri ile ilişkili desenleri tanımlayabilmekte ve otomatik analizler gerçekleştirebilmektedir. Özellikle Evrimsel Sinir Ağı (CNN) gibi derin öğrenme yöntemleri, mamografi ve diğer görüntüleme teknikleri aracılığıyla elde edilen verileri işleyerek kanser teşhisine yönelik yüksek doğruluk oranları sunmaktadır (Ongsulee 2017). Ayrıca, transfer öğrenme ve topluluk öğrenme gibi yöntemler de meme kanseri teşhisinde önemli bir rol oynamaktadır. Transfer öğrenme, daha büyük veri setleri ile eğitilmiş derin öğrenme modellerinin, daha küçük veri setleri üzerinde yeniden eğitilmesine olanak tanımakta ve bu sayede sınırlı tıbbi veriye sahip ortamlarda dahi yüksek doğruluk oranları elde edilmesini sağlamaktadır(Solak ve Ceylan 2020). Topluluk öğrenme ise, birden fazla modelin çıktılarının birleştirilerek hata oranlarını azaltmayı ve genel doğruluğu artırmayı hedeflemektedir. Bu teknik, farklı algoritmaların güçlü yönlerini bir araya getirerek daha güvenilir teşhis sonuçları elde edilmesine olanak tanımaktadır (Hekal, Moustafa, ve

Elnakib 2023).

Yapay zekâ tabanlı sistemlerin klinik ortamda yaygın olarak benimsenebilmesi için zorluklar mevcuttur. Öncelikle, model kararlarının anlaşılabilir olması büyük önem taşımaktadır. Yapay zekanın karar verme mekanizmalarının şeffaf olmaması, klinisyenlerin bu sistemlere güven duymasını zorlaştırabilmektedir. Bu noktada, Açıklanabilir Yapay Zeka (XAI) teknikleri devreye girerek, modellerin nasıl karar verdiğini daha anlaşılır hale getirmeyi amaçlamaktadır(Gunning vd. 2019). Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM) ve Yerel Yorumlanabilir Model-Agnostik Açıklamalar (LIME) gibi yöntemler, yapay zeka modellerinin hangi bölgeleri dikkate alarak bir teşhis koyduğunu görselleştirerek klinisyenlere daha fazla bilgi sunmaktadır (Ribeiro, Singh, ve Guestrin 2016, Selvaraju vd. 2020).

Meme kanseri teşhisinde kullanılan teknolojilerin etkinliği, yalnızca yüksek doğruluk oranları ile değil, aynı zamanda klinik pratikte uygulanabilirlikleri ile de değerlendirilmektedir. Yapay zeka tabanlı sistemlerin başarılı bir şekilde entegre edilebilmesi için, hasta verilerinin güvenliği, etik sorunlar ve algoritmaların tarafsızlığı gibi konular da göz önünde bulundurulmalıdır. Sağlık verilerinin hassasiyeti nedeniyle, bu tür sistemlerin geliştirilmesi ve kullanımı sırasında hasta gizliliğini korumaya yönelik politikalar uygulanmalı ve algoritmaların herhangi bir popülasyon üzerinde önyargılı sonuçlar üretmemesi için dikkatle tasarlanmalıdır.


Meme kanseri teşhisinde yapay zeka ve derin öğrenme tekniklerinin kullanımı, erken teşhis olanaklarını artırmakta ve klinik süreçleri iyileştirmektedir. Ancak bu sistemlerin etkinliğini artırmak için, model kararlarının açıklanabilirliği, transfer öğrenme tekniklerinin kullanımı, biyomarker analizlerinin entegrasyonu ve etik kaygıların dikkate alınması gibi faktörlerin göz önünde bulundurulması gerekmektedir. Yapay zeka tabanlı çözümlerin klinik ortamlarda başarılı bir şekilde uygulanabilmesi, hem teknik gelişmelere hem de multidisipliner yaklaşımlara bağlıdır. Bu bağlamda, meme kanseri teşhisinde yenilikçi yaklaşımlar, hastaların sağkalım oranlarını artırmaya yönelik önemli katkılar sunmaktadır.

2. LİTERATÜR BİLGİLERİ

Bu bölümde, öncelikle meme anatomisi, meme kanseri tanısı ve erken teşhisin gerekliliği ele alınacaktır. Ardından, meme kanseri görüntüleme yöntemleri ve geleneksel yöntemlerin yanı sıra yeni teknolojilerin nasıl katkı sağladığı anlatılacaktır. Meme kanseri tanısında yapay zekâ ve derin öğrenme yöntemleri üzerine durulacak, derin öğrenme tekniklerinin meme kanseri tanısındaki rolü açıklanacaktır. Tıbbi görüntülemede transfer öğrenme ve topluluk öğrenme teknikleri ele alınacaktır. Son olarak, bölüm Açıklanabilir yapay zeka yöntemleri ile devam edecek ve halka açık AISSLab meme kanseri veri seti anlatılacaktır. Bölüm, meme kanseri tespiti için yapılan önceki çalışmalar ile sonlandırılacaktır.

2.1 Meme Anatomisi ve Meme Kanseri Tanısının Önemi

Meme, kadın vücudunun önemli bir organıdır ve başlıca süt üretimi ve emzirme işlevlerini yerine getirir. Memenin yapısı, süt bezleri, süt kanalları, yağ dokusu, lenf nodları, kaslar ve bağ dokusu gibi birçok bileşenden oluşur (Bazira vd. 2022). Her bir yapı, memenin fiziksel sağlığını korurken, aynı zamanda kanserin başlangıç ve yayılma süreçlerinde de kritik bir rol oynar. Şekil 2.1’de meme anatomisinin ana bileşenleri verilmiştir.



Şekil 2.1 Meme Anatomisi: Meme yapısının temel bileşenleri (İnt. Kay. 1).

Meme başı, areola adı verilen koyu renkli bir alanla çevrilidir ve süt kanallarının açıldığı noktadır. Meme başı, emzirme sırasında sütü taşıyan merkezi alan olarak işlev görür. Areola, meme başı etrafındaki bölgeyi kapsar ve bu alanın rengi genellikle hormonal

değişikliklere göre değişiklik gösterir. Süt bezleri, meme dokusunun içinde yer alan ve süt üretimi yapan bezlerdir. Bu bezler, memenin iç kısmındaki lobüller adı verilen yapılarda yer alır. Lobüller, süt üretiminden sorumludur ve her bir lobül, sütü meme başına taşıyan süt kanallarıyla birbirine bağlanır. Süt kanalları, süt bezlerinden başlar ve meme başına kadar uzanır, böylece sütü taşıyan tüp şeklinde yapılardır. Meme kanseri, genellikle bu süt kanallarında başlar ve bu nedenle kanallar, kanserin en yaygın gelişim alanlarından biridir (Ellis ve Mahadevan 2013).

Meme dokusunun bir diğer önemli bileşeni ise yağ dokusudur. Yağ dokusu, meme hacmini oluşturur ve meme yapısının yumuşaklığını sağlar. Yağ dokusu, aynı zamanda kanser hücrelerinin hızla yayılabileceği bir ortam oluşturur. Yağ dokusunun içerisinde bulunan hücreler, kanserin hücresel düzeyde yayılarak çevre dokulara sızmasına olanak tanıyabilir. Bu nedenle, yağ dokusunun yapısı, kanserin yayılma hızını etkileyebilir. Lenf nodları ise vücudun bağışıklık sistemiyle ilişkili küçük, fasulye şeklindeki yapılardır. Meme çevresinde yer alan lenf nodları, kanser hücrelerinin vücuda yayılmasında önemli bir rol oynar. Kanser hücreleri, ilk önce bu lenf nodlarına yerleşebilir ve burada çoğalabilir (Darlington 2015). Lenf nodlarına yerleşen kanser, kanserin evrelerini belirler ve tedavi stratejilerinin şekillendirilmesinde yardımcı olur.

Meme ayrıca, göğüs duvarına bağlanan kaslar ve bağ dokusu ile desteklenir. Göğüs duvarı, meme için fiziksel bir destek sağlarken, aynı zamanda kas yapıları, meme dokusunun doğru bir şekilde yerinde kalmasını sağlar. Kaslar, memenin sabitlenmesine yardımcı olur ve meme sağlığının korunmasında önemli bir rol oynar. Göğüs kaslarının yapısı, kanserin yayılma potansiyelini etkileyebilir. Kaburgalar ise, memeyi çevreleyen ve onu koruyan yapı taşlarıdır. Kaburgalar, meme dokusunun travmalara karşı korunmasına ve sağlam bir yapıya sahip olmasına yardımcı olur. Göğüs kasları ve kaburgalar, meme organını çevreleyerek koruyucu bir fonksiyon üstlenir (Bazira vd. 2022).

Meme anatomisinin her bir bileşeni, vücudun genel işleyişi ve meme kanserinin gelişimi açısından kritik bir rol oynamaktadır. Memenin her bir yapısı, kanserin başlangıç noktasını ve yayılma potansiyelini belirler. Meme kanseri, erken evrelerde genellikle

belirgin semptomlar göstermez, bu nedenle bu anatomik yapıların doğru bir şekilde anlaşılması, kanserin doğru bir şekilde teşhis edilmesine olanak tanır. Ayrıca, modern görüntüleme yöntemlerinin kullanımı, bu anatomik yapıları inceleyerek, kanserin hangi bölgeden başladığını, ne kadar yayıldığını ve tedavi sürecinde nasıl bir yaklaşım sergileneceğini belirlemek için büyük önem taşır.

2.2 Meme Kanseri Tanı Yöntemleri

Meme kanseri tanısının erken evrelerde doğru bir şekilde teşhis edilebilmesi son derece önemlidir. Meme kanseri tanıtımında kullanılan yöntemler, hızlı ve doğru tanı koyma açısından hayati bir rol üstlenmektedir. Meme kanserini tespit etmek için çeşitli seçenekler mevcuttur. En yaygın olarak tercih edilen sonuçlar arasında mamografi, ultrasonografi ve manyetik rezonans görüntüleme bulunmaktadır. Ayrıca son yıllarda yapay zeka ve derin öğrenme alanındaki gelişmeler, bu geleneksel tekniklerin işleyişini artırmış ve daha isabetli sonuçlar elde edilmesi olanaklarını tanımıştır.

2.2.1 Mamografi

Mamografi, meme kanserinin teşhisi için en yaygın olarak kullanılan görüntüleme tekniklerinden biridir. Bu yöntem, düşük dozda X-ışınları kullanılarak meme donanımının ayrıntılı görüntülerini elde edilmesini sağlar. Programsal rutin tarama amacıyla uygulanan mamografi, özellikle 40 yaş ve üzerindeki kadınlar için, erken evrelerde belirgin seyreden kanserlerin tespitinde büyük bir öneme sahiptir. Mamografinin en önemli avantajı, kanser belirtilerinin henüz ortaya çıkmadığı erken evrelerinde bile meme dokusundaki küçük bozulma ve kitleleri tespit edebilmesidir (Coffey ve Jochelson 2022).

Mamografi, özellikle invaziv duktal karsinom gibi yaygın meme kanser türlerinin belirlenmesinde etkilidir. Mamografik görüntüler, kitleler, mikrokalsifikasyonlar (küçük kalsiyum birikintileri) ve doku yoğunluğundaki anormalliklerin tespitinde kullanılır. Ayrıca yoğun meme dokusuna sahip olan kanser görülme oranlarını artırmak için de önem taşır. Ancak mamografinin bazı sınırlamaları mevcuttur. Özellikle yoğun meme dokusuna sahip olan hücreler, normal doku ile kanserli dokular arasındaki farklar bazen

belirgin olmayabilir, bu da yanlış negatif işlemlere yol açabilir. Mamografide tespit edilen herhangi bir anormallik, önleyici veya ek testlerle doğrulanmalıdır (Carney vd. 2003).

Teknolojinin ilerlemesi ile mamografinin dijital formatıyla geçmiştir, bu da daha net bölümlerin bir araya getirilmesini sağlar. Dijital mamografi, geleneksel film yerine ışık sensörleri kullanılarak dijital görüntüler elde edilir ve bilgisayar aracılığıyla daha ayrıntılı analizler yapılabilir (Tilanus-Linthorst vd. 2000). Ayrıca, 3D mamografi (tomosentez), görüntüleme taramasının daha ayrıntılı üç boyutlu kesitler sunarak meme kanserinin daha hassas bir şekilde tespit edilmesi olanaklarını tanıır. Mamografi görüntülenmesine bir örnek Resim 2.1’de verilmiştir.



Resim 2.1 Mamografi Cihazı: Meme kanseri tespiti için kullanılan X-ışını temelli görüntüleme cihazı (İnt. Kay. 2).

2.2.2 Ultrasonografi

Ultrasonografi (US), yüksek frekanslı ses dalgalarının dokulardan yansıması prensibine dayanan non-invazif bir görüntüleme yöntemidir. Meme patolojilerinin değerlendirilmesinde tek başına veya mamografiye tamamlayıcı bir modalite olarak kullanılabilir. Özellikle yoğun meme dokusuna sahip olgularda mamografinin sensitivitesinin düşmesi nedeniyle, ultrasonografi bu hasta grubunda tanısal açıdan avantaj sağlamaktadır (Gordon 2002).

Ultrasonografinin klinik uygulamaları arasında solid kitlelerin kistik lezyonlardan ayırt edilmesi, fibroadenomlar gibi benign lezyonların karakterizasyonu ve malign tümörlerin

lokalizasyonu yer almaktadır. Ayrıca, US eşliğinde gerçekleştirilen ince iğne aspirasyon biyopsisi ve tru-cut biyopsi gibi girişimsel işlemlerde hedef lezyonun doğru şekilde lokalize edilmesini sağlayarak tanısal doğruluğu artırmaktadır (Irwig, Houssami, ve van Vliet 2004).

Resim 2.2’de de gösterildiği gibi bu yöntemin başlıca avantajları arasında iyonize radyasyon içermemesi, dinamik değerlendirme imkanı sunması ve hasta konforunun yüksek olması sayılabilir. Özellikle gebelerde ve genç hastalarda güvenle kullanılabilen bir tekniktir. Ancak, ultrasonografinin bazı limitasyonları bulunmaktadır: Mikrokalsifikasyonların saptanmasında yetersiz kalabilmesi, operatör bağımlılığı göstermesi ve derin yerleşimli lezyonlarda görüntüleme kalitesinin düşmesi bu sınırlamalardan bazılarıdır (Irwig vd. 2004). Ayrıca, ultrasonografik bulguların malignite açısından değerlendirilmesinde BI-RADS sınıflandırması kullanılmakta olup, bu sistem deneyimli radyologlar tarafından yorumlanmalıdır.

Sonuç olarak, meme ultrasonografisi özellikle yoğun meme dokusu olan hastalarda birinci basamak tarama yöntemi olmamakla birlikte, tamamlayıcı bir tanı aracı olarak önemli bir rol oynamaktadır. Tekniğin optimal kullanımı için klinik endikasyonların doğru belirlenmesi ve multidisipliner yaklaşımın benimsenmesi gerekmektedir.



Resim 2.2 Ultrasonografi Cihazı: Meme dokusundaki kist ve lezyonların tespiti için kullanılan ses dalgalarıyla görüntüleme yöntemi (İnt. Kay. 3)

2.2.3 Manyetik Rezonans Görüntüleme

Manyetik rezonans görüntüleme (MRI), meme kanseri tanısında kullanılan ileri düzey bir görüntüleme yöntemidir. Güçlü manyetik alanlar ve radyo dalgaları kullanarak yüksek çözünürlüklü kesitsel görüntüler elde eden bu teknik, özellikle meme dokusunun derin bölgelerindeki tümör yayılımının değerlendirilmesinde ve multifokal lezyonların saptanmasında etkilidir. MRI, mamografi ve ultrasonografinin tanısız belirsizlik taşıdığı durumlarda, tümör evrelemesi ve lokal invazyonun belirlenmesinde kritik bir tamamlayıcı yöntem olarak kullanılmaktadır (Warner vd. 2004).

MRI, yüksek risk grubundaki hastalarda (örneğin, mutasyon taşıyıcıları) ve mamografide belirsiz bulguların varlığında ek görüntüleme modalitesi olarak önerilmektedir. Ayrıca, cerrahi rezeke edilebilirliğin değerlendirilmesi, neoadjuvan kemoterapiye yanıtın izlenmesi ve rezidü tümör dokusunun tespiti gibi klinik senaryolarda önemli bir tanısız araçtır (Tilanus-Linthorst vd. 2000). Bununla birlikte, MRI'nın yüksek duyarlılığına rağmen, özgüllüğünün nispeten düşük olması, benign lezyonların malign olarak yorumlanmasına (yanlış pozitif sonuçlara) yol açabilmektedir. Bu nedenle, MRI bulgularının histopatolojik doğrulama ile desteklenmesi gereklidir.

MRI'nın klinik kullanımını sınırlayan faktörler arasında yüksek maliyet, uzun çekim süresi ve hasta uyumu ile ilgili teknik kısıtlamalar bulunmaktadır. Manyetik alana duyarlı implant taşıyan hastalar veya klostrofobisi olan bireyler için uygun olmayabilir. Sonuç olarak, MRI meme kanseri tanı ve yönetim algoritmasında önemli bir rol oynamakla birlikte, kullanımının hasta bazlı endikasyonlarla sınırlandırılması ve multidisipliner yaklaşımla yorumlanması gerekmektedir. Şekil 2.2'de MRI cihazı ve görüntüsü verilmiştir.



Şekil 2.2 a) Manyetik Rezonans Görüntüleme Cihazı: Meme kanseri tanısı için kullanılan yüksek çözünürlüklü görüntüleme cihazı, b) MRI görüntüsü: Meme kanserinin derin bölgelerdeki yayılımını gösteren yüksek çözünürlüklü görüntü (İnt Kay. 4)

2.2.4 Görüntüleme Eşliğinde Biyopsi Yöntemleri

Biyopsi, meme kanseri tanısının histopatolojik olarak doğrulanmasında altın standart yöntem olup, şüpheli lezyonlardan doku örneği alınarak patolojik inceleme yapılmasını sağlar. Görüntüleme kılavuzluğunda gerçekleştirilen biyopsi prosedürleri, lezyonların anatomik lokalizasyonunun kesin olarak belirlenmesine ve hedefli örnekleme yapılmasına olanak tanıyarak tanısal doğruluğu artırır.

Ultrasonografi rehberliğinde yapılan tru-cut biyopsi, özellikle solid meme kitlelerinin değerlendirilmesinde yaygın olarak kullanılan bir yöntemdir. Bu teknik, yüksek duyarlılık ve özgüllük oranları ile güvenilir tanısal sonuçlar sunar (Guo vd. 2018). MRI kılavuzluğunda biyopsi ise, yalnızca kontrastlı MRI incelemesinde belirginleşen şüpheli lezyonların tanısında kullanılan önemli bir yöntemdir (Mieke vd. 2025).

Biyopsi işlemleri, otomatik ve yarı otomatik biyopsi sistemleri kullanılarak gerçekleştirilmekte olup, lokal anestezi altında minimal invaziv bir şekilde uygulanır. Bu yöntemlerin komplikasyon oranları düşük olmakla birlikte, hasta konforu ve güvenliği ön planda tutulur. Alınan doku örneklerinin patolojik analizi sonucunda; tümörün histolojik tipi, histolojik grade'i, hormon reseptör (östrojen ve progesteron reseptörü) ekspresyon durumu ve HER2/neu amplifikasyonu gibi prognostik ve prediktif faktörler değerlendirilir (McMasters vd. 2001). Bu veriler, tedavi stratejisinin belirlenmesinde kritik rol oynar. Şekil 2.3'te ultrasonografi ile birlikte yapılan biyopsi işlemi gösterilmektedir.




Şekil 2.3 Ultrasonografi ile biyopsi (İnt. Kay. 5).

2.2.5 Nükleer Tıp Yöntemleri

Nükleer tıp görüntüleme teknikleri, meme kanserinin tanısall süreçlerinde, evrelendirilmesinde ve tedavi yanıtının izlenmesinde önemli bir tanısall araç olarak kullanılmaktadır. Bu yöntemler, tümörün biyolojik aktivitesini moleküler düzeyde değerlendirme olanağı sağlayarak, konvansiyonel anatomik görüntüleme tekniklerinin sınırlılıklarını aşmaktadır.

Sentinel Lenf Nodu Görüntülemesi, meme kanserinde lenfatik yayılımın değerlendirilmesinde altın standart yöntemlerden biridir. Bu teknikte, tümör çevresine enjekte edilen radyoaktif izleyici lenfatik drenaj yoluyla ilk drene olan lenf noduna (sentinel lenf nodu) ulaşır ve gama kamera ile görselleştirilir. Sentinel lenf nodu biyopsisi sayesinde, gereksiz aksiller lenf nodu diseksiyonunun önüne geçilerek postoperatif morbidite (lenfödem, duyu kaybı gibi) riski azaltılmaktadır (Giammarile vd. 2022). Şekil 2.4’de Sentiell lenf nodu biyopsisi örneği verilmiştir.



Şekil 2.4 Sentiell lenf nodu biyopsisi (İnt. Kay. 6).

2.3 Meme Kanseri Tanısında Yapay Zeka Yöntemleri

Meme kanseri tanısı, doğru ve hızlı bir şekilde konması gereken bir hastalıktır. Ancak, geleneksel görüntüleme yöntemleri bazen karmaşık vakalarda, özellikle erken evrelerde ve yoğun meme dokusuna sahip hastalarda, yetersiz kalabilir. Bu nedenle, son yıllarda yapay zeka ve derin öğrenme teknolojilerinin meme kanseri tanısındaki potansiyeli büyük bir ilgiyle araştırılmaktadır. Bu teknolojiler, büyük veri setleri üzerinde çalışarak, küçük ve bazen gözden kaçabilecek anormallikleri tanımakta ve bunları doğru bir şekilde sınıflandırmaktadır.

2.3.1 Yapay Zeka

Yapay zeka, bilgisayar sistemlerinin insan bilişsel fonksiyonlarını taklit edebilme yeteneğini inceleyen disiplinlerarası bir bilim dalıdır. Bu teknoloji, makine öğrenmesi ve derin öğrenme gibi alt disiplinler aracılığıyla sistemlerin verilerden öğrenme, mantıksal çıkarım yapma ve karmaşık problemleri çözme becerilerini geliştirmeyi hedefler. Yapay zeka genel olarak iki ana kategoride incelenir: dar yapay zeka ve genel yapay zeka. Dar yapay zeka, belirli görevlerde uzmanlaşmış sistemleri kapsar ve günümüzde en yaygın kullanılan yapay zeka türüdür. Örneğin, tıbbi görüntülemede meme kanseri teşhisi için geliştirilen yapay zeka modelleri, yalnızca radyolojik görüntülerdeki patolojik bulguları tanımlamada uzmanlaşmıştır. Buna karşılık, genel yapay zeka teorik olarak insan zekasının tüm boyutlarını kapsayan bir yaklaşımı temsil eder, ancak henüz pratik uygulamaları mevcut değildir.

Tıp alanında yapay zeka uygulamaları, özellikle erken tanı ve teşhis süreçlerinde devrim niteliğinde gelişmelere yol açmıştır. Mamografi, ultrason ve MR gibi görüntüleme tekniklerinden elde edilen verilerin analizinde kullanılan yapay zeka algoritmaları, insan gözünün algılayamayacağı mikro düzeydeki patolojik değişiklikleri tespit edebilmektedir. CNN gibi derin öğrenme modelleri, görüntülerdeki malign lezyonları yüksek doğruluk oranlarıyla sınıflandırabilmekte ve radyologların tanı sürecini desteklemektedir (Ongsulee 2017). Bu teknolojinin en önemli avantajlarından biri, erken evre kanser bulgularının tespit edilmesine olanak sağlayarak tedavi başarısını artırmasıdır. Ayrıca, yapay zeka destekli tanı sistemleri yanlış pozitif ve negatif oranlarını azaltarak klinik karar verme sürecinin güvenilirliğini artırmaktadır.

Yapay zekanın sağlık alanındaki etkileri yalnızca tanıyla sınırlı değildir. Prognostik modelleme, tedavi planlaması ve hasta takibi gibi süreçlerde de yapay zeka teknolojileri giderek daha fazla kullanılmaktadır. Bununla birlikte, bu teknolojilerin klinik uygulamaya entegrasyonunda veri güvenliği, algoritmik şeffaflık ve etik sorunlar gibi çeşitli zorluklar bulunmaktadır. Gelecekte, yapay zeka ve insan uzmanlığının sinerjistik bir şekilde birleştirildiği hibrit sistemlerin, tıbbi tanı ve tedavide yeni standartlar oluşturması beklenmektedir. Bu bağlamda, yapay zeka teknolojilerinin sağlık hizmetlerinde daha geniş ölçekte benimsenmesi için disiplinlerarası işbirliğine dayalı

araştırma ve geliştirme çalışmalarının sürdürülmesi büyük önem taşımaktadır. Şekil 2.5’de yapay zeka ve alt dallarının şeması verilmiştir.



Şekil 2.5 Yapay zekanın alt dalları

2.3.2 Makine Öğrenmesi


Makine öğrenmesi, yapay zekanın veriye dayalı öğrenme yeteneğine odaklanan önemli bir alt disiplindir ve özellikle meme kanseri teşhisinde devrim niteliğinde uygulamalara olanak sağlamaktadır. Bu teknoloji, mamografi, ultrason ve MR gibi görüntüleme yöntemlerinden elde edilen büyük ölçekli tıbbi verileri analiz ederek, insan gözünün algılayamayacağı mikro düzeydeki patolojik bulguları tespit edebilen sofistike algoritmalarından oluşur.

Temelde denetimli öğrenme yöntemleri kullanılarak eğitilen bu sistemler, binlerce etiketli görüntü üzerinden kanserli ve sağlıklı dokuları ayırt etmeyi öğrenirken, CNN gibi derin öğrenme modülleri sayesinde lezyonların boyut, şekil ve dokusal özelliklerini multidisipliner bir yaklaşımla değerlendirir(Habeeb, Vuksanovic, ve Al-Zaydi 2023). Meme kanseri tanısında makine öğrenmesinin en kritik katkısı, özellikle erken evre asemptomatik lezyonların tespitinde radyologların tanı doğruluğunu artırması ve yanlış pozitif/negatif oranlarını düşürmesidir.

Bunun yanı sıra, denetimsiz öğrenme teknikleri hastaların risk profillerini segmentasyon yoluyla analiz ederken, pekiştirmeli öğrenme ise dinamik görüntü serilerindeki tümör progresyonunu takip edebilmektedir. Ancak bu sistemlerin klinik uygulamaya entegrasyonunda veri gizliliği, algoritmik şeffaflık ve etik sorunlar gibi önemli engeller

bulunmaktadır. Güncel araştırmalar, makine öğrenmesinin prognostik biomarker keşfi, kişiselleştirilmiş tedavi planlaması ve hasta takip süreçlerinde de kullanımını genişleterek, radyoloji-patoloji-klinik bulguların entegre analizine dayanan bütüncül bir kanser yönetim sistemi oluşturmayı hedeflemektedir (Houssein vd. 2021). Bu bağlamda, yapay zeka destekli tanı sistemlerinin gelecekte standart klinik protokollerin ayrılmaz bir parçası olacağı öngörülmektedir.

Makine öğrenmesi, meme kanseri teşhisinde üç temel yaklaşımla öne çıkar: Denetimli öğrenme, radyologların etiketlediği binlerce mamografi görüntüsünden öğrenerek malign/benign lezyonları %94 doğrulukla ayırt edebilir; denetimsiz öğrenme K-means gibi algoritmalarla etiketsiz verilerdeki anormal doku kümelerini tespit eder; pekiştirmeli öğrenme ise bir algoritma, görüntü verisi aldığı doğru teşhis puanına göre dinamik MR serilerinde tümör evrimini analiz eder (Guo vd. 2018). Bu yöntemlerin entegrasyonu, özellikle CNN ile mikro-kalsifikasyonların yorumlanmasında kullanılarak, erken evre tespit hassasiyetini %15'e kadar artırırken, mevcut görüntü verisi ve model arasındaki etkileşim, klinik protokollere nesnel bir destek sağlar. Şekil 2.6'da makine öğrenimi alt dalları gösterilmektedir.



Şekil 2.6 Makine öğrenmesi yöntemleri (İnt. Kay. 7).

2.3.3 Derin Öğrenme

Derin öğrenme, makine öğrenmesinin özel bir formu olarak, çok katmanlı yapay sinir

ağları kullanarak verilerin hiyerarşik özellik temsillerini otomatik olarak öğrenen güçlü bir algoritmik yaklaşımdır. Bu yöntemin temel farklılığı, geleneksel makine öğrenmesi tekniklerinin aksine, ham veriden soyut özelliklerin otomatik çıkarımına olanak tanıyan çok katmanlı mimari yapısında yatmaktadır. Özellikle CNN, tekrarlayan sinir ağları ve transformatör mimarileri gibi gelişmiş modeller, görüntü işleme, doğal dil işleme ve ses tanıma gibi karmaşık görevlerde insan seviyesine yakın performans sergilemektedir (Pillai vd. 2022).

Derin öğrenmenin en önemli avantajı, büyük ölçekli veri kümeleri karşısında ölçeklenebilir olması ve veri miktarı arttıkça performansının iyileşme eğilimi göstermesidir. Bu teknoloji, tıbbi görüntülemede (özellikle meme kanseri teşhisinde), otonom araçlarda, finansal tahmin modellerinde ve endüstriyel kalite kontrol sistemlerinde yaygın olarak kullanılmaktadır. Ancak, derin öğrenme modellerinin başarılı uygulanabilmesi için yüksek hesaplama gücü, büyük miktarda etiketli eğitim verisi ve uzmanlık gerektirmektedir. Ayrıca, model kararlarının yorumlanabilirliği bu alandaki önemli araştırma konuları arasında yer almaktadır.

2.3.3.1 Evrimsel Sinir Ağları

Derin öğrenme alanındaki en önemli ve yaygın kullanılan mimarilerden biridir. CNN'ler, özellikle görüntü işleme için geliştirilmiş sinir ağlarıdır ve tıbbi görüntülerdeki kanserli dokuların tespiti için son derece etkilidir. CNN'ler, görüntü verilerini analiz ederken, özellik çıkarımı ve desen tanıma görevlerini başarıyla yerine getirir.


2.3.3.2 CNN Yapısı ve Katmanları

CNN'ler, derin öğrenme tabanlı bir model olarak, geleneksel manuel özellik çıkarımı yöntemlerine gerek duymadan doğrudan ham verilerden anlamlı örüntüleri öğrenebilen güçlü bir mimaridir. Özellikle tıbbi görüntü analizi alanında, bu mimari, görüntülerdeki yerel ve global özelliklerin otomatik olarak tanımlanmasını sağlayarak tanısal süreçlerin optimizasyonuna önemli katkılar sunmaktadır. CNN'ler, radyolojik incelemelerde patolojik bulguların tespiti, semantik segmentasyon, nesne lokalizasyonu ve görüntü sınıflandırma gibi çeşitli bilgisayarlı görü görevlerinde yüksek doğruluk oranlarıyla

performans göstermektedir. Bu bağlamda, özellikle kanser tanısı gibi kritik klinik karar süreçlerinde, yanlış pozitiflik oranlarını minimize etme potansiyeliyle radyologlara destek sağlamaktadır.

CNN'ler, özellikle görüntü sınıflandırma, bilgisayarlı görü ve tıbbi görüntü analizi gibi alanlarda yaygın olarak tercih edilen derin öğrenme modellerinden biridir. Bu tercihin temel nedeni, evrişim işlemleri sayesinde görüntülerin uzamsal yapısını koruyabilme yeteneğidir. Bu özellik, malign ve benign dokular arasındaki ince ayrımların belirlenmesinde kullanılmaktadır. Örneğin, meme kanseri teşhisinde, mikrokalsifikasyon kümeleri veya lezyonların morfolojik özellikleri gibi radyolojik bulguların otomatik segmentasyonunda CNN'lerin üstün başarısı kanıtlanmıştır (Hamed vd. 2020). Mimarinin temel bileşenleri olan evrişim katmanları, non-lineer aktivasyon fonksiyonları, havuzlama katmanları ve tam bağlı katmanlar, hiyerarşik özellik öğrenimini mümkün kılarak son sınıflandırma aşamasında yüksek güce ulaşılmasını sağlamaktadır (Balve ve Hendrix 2024).

Şekil 2.7'de görüleceği üzere, CNN mimarisi; evrişim katmanı, doğrusal olmayan aktivasyon fonksiyonlarından ReLU (Doğrultulmuş Lineer Birim), öznitelik boyutunu azaltmaya yönelik havuzlama katmanı ve nihai sınıflandırmanın gerçekleştirildiği tam bağlı katman gibi birbirini tamamlayan çok katmanlı bir yapıdan oluşmaktadır (Yamashita vd. 2018).




Şekil 2.7 CNN mimari yapısı

2.3.3.3 Evrişimsel Katman

Evrişimsel katman, derin öğrenme ağlarında temel bir yapı taşı olarak, giriş olarak alınan görüntü matrisine çok boyutlu filtreler (çekirdekler) uygulayarak düşük seviyeli görsel özelliklerin çıkarılmasında önemli bir rol oynar. Bu katman, görüntülerin temel görsel bileşenlerini, örneğin kenarları, köşeleri ve dokusal örüntüleri tanımada kullanılır ve bu özelliklerin her biri, ağın sonraki katmanları için daha karmaşık desenlerin öğrenilmesine olanak tanır. Evrişim işlemi, çekirdeklerin görüntü üzerinde kaydırılmasıyla gerçekleştirilir. Bu kaydırma işlemi, genellikle adım parametresiyle belirlenen adım aralıklarıyla yapılır. Her bir kaydırma adımında, yerel bölgedeki piksellerin değerleri, parametrik filtrelerle noktasal çarpım işlemi gerçekleştirilerek işlenir (Sharma, Jain, ve Mishra 2018). Bu işlem sonucunda, görüntüdeki belirli öznitelikleri temsil eden aktivasyon haritaları ortaya çıkar. Bu süreç, iki temel sonuç doğurur: İlk olarak, boyutsal indirgeme söz konusu olur.

Şekil 2.8’de, bir evrişim katmanının temel çalışma prensibi gösterilmektedir. Sol kısımdaki renkli matris giriş görüntüsünü temsil eder. Ortadaki mavi filtre (kernel), bu görüntü üzerinde kaydırılarak (stride ile) yerel bölgelerle çarpım yapar. Her bir konumda, filtre ve girişin çakışan değerlerinin çarpımı alınır ve toplamı hesaplanarak sağdaki çıkış matrisi içerisine yerleştirilir. Bu işlem, girişin uzamsal özelliklerini yakalayarak anlamlı özellik haritaları oluşturur.



Şekil 2.8 Evrişim işlemi (İnt. Kay. 8).

Evrişimsel işlemler, çekirdek boyutu ve adım değeri gibi parametrelerle yönlendirilen uzamsal çözünürlükte belirli bir oranda azalma sağlar. Bu indirgeme, daha büyük boyutlu

veri üzerinde işlem yapılmasını mümkün kılarken, aynı zamanda hesaplama verimliliğini artırır. İkinci olarak, yerel bağlamsal koruma sağlanır. Evrişimsel katmanda, pikseller arasındaki uzamsal ilişkiler korunarak, görüntüdeki önemli özelliklerin hiyerarşik olarak öğrenilmesi sağlanır. Bu, ağın daha derin katmanlarında daha soyut ve anlamlı özelliklerin öğrenilmesine imkan tanır. Eşitlik 2.1’de iki boyutlu evrişim verilmiştir.

$$Y(i, j) = \sum_{m=0}^{M-1} \sum_{n=0}^{N-1} X(i + m, j + n) \cdot K(m, n) \quad (2.1)$$


X, giriş görüntüsünü yani modelin işlemeye başladığı ham veri kümesini temsil eder ve bu giriş verisi üzerinde evrişim filtresi kaydırılarak işlem yapılır. K, evrişim filtresi veya kernel olarak adlandırılan ve modelin belirli desenleri ya da kenar gibi öznitelikleri algılamasını sağlayan küçük boyutlu bir matristir. Bu filtre, giriş görüntüsü üzerinde gezdirilerek yerel alanlardan öznitelik çıkarımı yapılmasına olanak tanır. Y, evrişim işlemi sonucunda elde edilen ve giriş görüntüsünden çıkarılan öznitelikleri barındıran çıktı görüntüsünü ifade eder. (i, j) ifadesi, çıktı matrisinde belirli bir konumu belirtir ve her konum, filtre ile girişin çakıştığı bölgedeki hesaplamaların sonucunu içerir. Son olarak, M ve N değerleri, kullanılan filtrenin satır ve sütun sayısını, yani boyutlarını ifade eder; örneğin 3x3 boyutunda bir filtre için M=3 ve N=3 olarak tanımlanır.

Evrişimsel katmanın sağladığı bu boyut küçültme işlemi, hesaplamaların daha verimli yapılabilmesi için temel bir yapı oluştururken, aynı zamanda ağın derin katmanlarında daha karmaşık ve soyut özelliklerin öğrenilmesine olanak sağlar. Özellikle tıbbi görüntü analizi gibi karmaşık ve yüksek çözünürlüklü verilerin işlenmesi gereken durumlarda, bu mekanizma oldukça kritik bir rol oynar. Patolojik lezyonların tespiti ve morfometrik özelliklerinin korunarak çıkarım yapılması, bu süreç sayesinde daha doğru ve etkili bir şekilde gerçekleştirilebilir.

2.3.3.4 Havuzlama Katmanı

Havuzlama katmanı, konvolüsyonel sinir ağlarında boyutsal indirgeme işlemi gerçekleştiren ve ağın hesaplama karmaşıklığını azaltmada kritik rol oynayan önemli bir

bileşendir. Bu katman, temel olarak öznitelik haritalarının uzamsal boyutlarını küçültürken, ağın verimliliğini artırmayı ve daha hızlı işlem yapmayı sağlar. En yaygın kullanılan iki havuzlama yöntemi maksimum havuzlama (max pooling) ve ortalama havuzlama (average pooling) olup, maksimum havuzlama, belirtilen penceredeki en yüksek aktivasyon değerini seçerek öne çıkan öznitelikleri korurken, ortalama havuzlama ise ilgili bölgedeki tüm aktivasyonların ortalamasını alarak daha genel bir özellik temsili sunar. Şekil 2.9’da maksimum ve ortalama havuzlama işlemleri verilmiştir.



Şekil 2.9 Maksimum ve ortalama havuzlama (İnt. Kay. 9).

Havuzlama katmanının matematiksel ifadelerinde yer alan semboller, işlemin temel bileşenlerini tanımlamak için kullanılır. X , giriş özelliği haritasını yani havuzlama işleminin uygulanacağı veri matrisini ifade ederken; Y , bu işlem sonucunda elde edilen çıkış özelliği haritasını temsil eder. i ve j değişkenleri, çıkış matrisindeki satır ve sütun konumlarını belirtir. R_{ij} , giriş matrisi üzerinde çıkıştaki i,j konumuna karşılık gelen pencereyi (örneğin 2×2 bir bölge) ifade eder. Bu pencere, giriş matrisi üzerinde kaydırılarak yerel değerleri işler. Maksimum havuzlama işleminde, bu pencere içindeki en büyük değer alınarak $Y(i,j)$ konumuna aktarılır. Ortalama havuzlamada ise aynı bölgedeki tüm değerlerin aritmetik ortalaması alınır. Bu durumda $|R_{ij}|$, pencere içerisindeki eleman sayısını yani örneğin 2×2 bir havuzlama için 4 değerini ifade eder. Eşitlik 2.2 ve 2.3’ de maksimum ve ortalama havuzlama verilmiştir.

$$Y(i,j) = \max_{(m,n) \in R_{i,j}} X(m,n) \quad (2.2)$$

$$Y(i,j) = \frac{1}{|R_{i,j}|} \sum_{(m,n) \in R_{i,j}} X(m,n) \quad (2.3)$$

Havuzlama katmanı, tipik olarak bir konvolüsyonel katman ve doğrusal olmayan aktivasyon fonksiyonu (ReLU) arasına yerleştirilir ve bu yapı ağıın daha derin katmanlarında daha soyut özelliklerin öğrenilmesine olanak tanır. Boyutsal indirgeme işlemi sırasında bazı bilgilerin kaybolması kaçınılmaz olsada, havuzlama katmanı önemli avantajlar sunar: hesaplama verimliliğini artırma, model karmaşıklığını kontrol etme, aşırı öğrenme riskini azaltma ve özniteliklerin pozisyonel değişimlere karşı toleranslı hale getirilmesini sağlama. Özellikle tıbbi görüntü analizi gibi yüksek çözünürlüklü verilerle çalışılan alanlarda, havuzlama katmanı yerel örüntülerin korunmasına ve gereksiz detayların elenmesine olanak tanır. Bu sayede, havuzlama katmanı, tıbbi görüntüleme uygulamalarında daha hızlı ve doğru sonuçlar elde edilmesini sağlar.


2.3.3.5 Doğrultulmuş Lineer Birim (ReLU) Aktivasyon Fonksiyonu

Negatif giriş değerlerini sıfırlayarak, pozitif değerleri olduğu gibi ileten temel bir işlevsel yapıdır. ReLU, sinir ağlarına doğrusal olmama (non-linearity) özelliği kazandırarak, modelin karmaşık ilişkileri öğrenmesini sağlar ve derin öğrenme ağlarında sıklıkla tercih edilen bir aktivasyon fonksiyonu olmuştur. Basit matematiksel yapısı nedeniyle, ReLU, sigmoid veya tanh gibi diğer aktivasyon fonksiyonlarına kıyasla daha az hesaplama kaynağı gerektirir, bu da ağıın eğitim sürecini hızlandırır ve hesaplama verimliliğini artırır (Rawat ve Wang 2017). ReLU fonksiyonunun matematiksel formülü Eşitlik 2.4’de verilmiştir.

$$f(x) = \max(0, x) \quad (2.4)$$

ReLU, ayrıca kaybolan gradyan problemini önemli ölçüde ortadan kaldırarak, derin ağların etkili bir şekilde eğitilmesine olanak tanır. Bu özellik, derin ağların daha verimli öğrenmesine yardımcı olur, çünkü ReLU, negatif giriş değerlerini sıfır yaparak gradyanın kaybolmasını engeller ve öğrenme sürecini hızlandırır. Diğer bir avantajı ise, ReLU'nun negatif değerleri sıfırlayarak, ağda seyrek aktivasyonlar oluşturmastır. Bu durum, gereksiz verilerin ağda işlenmesini engeller, öne çıkan özniteliklerin öğrenilmesini teşvik

eder ve modelin genelleme yeteneğini artırır. Şekil 2.10’da ReLU aktivasyon fonksiyonu verilmiştir.



Şekil 2.10 ReLU aktivasyon fonksiyonu (İnt. Kay. 10).

Konvolüsyonel sinir ağlarında, her evrimsel işlem sonrasında ReLU uygulaması, öğrenilen özelliklerin daha anlamlı hale gelmesini sağlar, modelin öğrenme kapasitesini artırır ve ağı daha hızlı yakınsamasına yardımcı olur. ReLU’nun bu işlevselliği, özellikle tıbbi görüntü analizi gibi büyük veri setleriyle çalışılan uygulamalarda önemli bir avantaj sunar, çünkü büyük ve yüksek çözünürlüklü verilerle çalışırken hesaplama verimliliği sağlanır. Ancak, ReLU’nun bazı sınırlamaları da bulunmaktadır; bunlardan en belirginini, ölü ReLU problemi olarak da bilinir. Bu problem, negatif girişlerin sıfırlanması nedeniyle bazı ağ katmanlarında öğrenmenin durmasına yol açabilir. Bu sorunu aşmak için Leaky ReLU ve Parametric ReLU gibi varyasyonlar geliştirilmiş olup, negatif değerlerin küçük bir kısmını sıfır yerine küçük bir negatif değerle ileterek, ağı öğrenmeye karşı duyarsız hale gelmesinin önüne geçer ve modelin verimli öğrenmesini sağlar (Pak ve Kim 2017).

2.3.3.6 Tam Bağlı Katman

Tam bağlı katman, ağı son katmanlarından biri olarak genellikle sınıflandırma görevini üstlenen kritik bir bileşen olarak karşımıza çıkar. Bu katman, genellikle konvolüsyonel ve havuzlama katmanlarından elde edilen çok boyutlu öznitelik haritalarını, tek boyutlu bir vektöre dönüştürerek düzleştirme (flattening) işlemi gerçekleştirir. Düzleştirme işlemi, konvolüsyonel ağlarda öğrenilen yerel özelliklerin, ağı daha derin katmanlarında global bir temsil haline getirilmesini sağlar. Yapısal açıdan, tam bağlı katmandaki her bir

nöron, bir önceki katmandaki tüm nöronlarla bağlanarak, her bir özneliliğin küresel bir bakış açısıyla değerlendirilmesine olanak tanır. Bu bağlantı yapısı, ağı karmaşık öğrenme süreçlerinde, tüm yerel özelliklerin birbirleriyle etkileşime girerek daha anlamlı ve soyut bir seviyeye taşınmasını sağlar.

Tam bağlı katmanın başlıca işlevleri arasında özellik entegrasyonu ve sınıflandırma yer alır. İlk olarak, konvolüsyonel katmanlardan çıkarılan yerel özellikler, tam bağlı katman aracılığıyla global bir temsile dönüştürülür. Bu entegrasyon işlemi, her bir yerel özelliğin global ölçekte daha yüksek seviyede bir anlam kazanmasını sağlar. İkinci olarak, sınıflandırma görevinde, SoftMax aktivasyon fonksiyonu kullanılarak, modelin çıktısı olan sınıflara ait olasılık dağılımı hesaplanır. SoftMax fonksiyonu, çok sınıflı sınıflandırma problemlerinde her bir sınıf için 0 ile 1 arasında bir olasılık değeri üretir ve tüm sınıfların toplamını 1 olacak şekilde normalize eder. Böylece, her bir sınıfın model tarafından kabul edilme olasılığı hesaplanır ve sınıflandırma sonucu, en yüksek olasılığa sahip sınıfa atanır. SoftMax, önceki katmanlardan öğrenilen tüm özelliklerin nihai kararda eşit derecede katkı sağlamasına olanak tanır (Sharma vd. 2018).

$$Softmax(z_i) = \frac{e^{z_i}}{\sum_{j=1}^K e^{z_j}} \quad (2.5)$$


Eşitlik 2.5’de verilen Softmax fonksiyonu, bir sınıfa ait aktivasyon değeri olan z_i ’yi, tüm sınıf skorlarının (toplam K adet) üstel değerlerine bölerek normalize eder. Burada z_i , modelin i. sınıf için hesapladığı ham skor değerini ifade eder. Bu işlem sonucunda elde edilen $Softmax(z_i)$, i. sınıfa ait tahmini olasılıktır ve tüm sınıflar için elde edilen softmax çıktıların toplamı 1 olur.

Bu katman, özellikle tıbbi görüntü analizi gibi görevlerde, örneğin patolojik ve normal doku ayrımı gibi kritik sınıflandırma problemlerinde, büyük bir öneme sahiptir. Görüntülerdeki kanserli ve sağlıklı dokular arasındaki ayrımın yapılmasında, tam bağlı katman son derece hassas kararlar verir. Ancak, günümüzde modern CNN mimarilerinde, tam bağlı katmanların yerini giderek daha verimli yöntemler almaktadır. Öne çıkan bu yöntemlerden biri global ortalama havuzlama olup, bu yaklaşım modelin parametre sayısını önemli ölçüde azaltarak hesaplama yükünü hafifletir. Ayrıca, daha düşük

parametre sayısı, aşırı öğrenme riskinin de minimize edilmesine yardımcı olur.

2.3.4 Transfer Öğrenme

Transfer öğrenme, önceden büyük ölçekli veri kümeleri üzerinde eğitilmiş bir modelin, belirli bir göreve uyarlanarak yeniden kullanılması prensibine dayanan bir derin öğrenme yöntemidir. Transfer öğrenme yöntemi, eğitim süresini kısaltarak hesaplama maliyetlerini düşürmekte ve küçük veri setleriyle yüksek performans elde edilmesini mümkün kılmaktadır. Transfer öğrenme sürecinde, genellikle önceden eğitilmiş modellerin erken katmanları dondurularak korunurken, yalnızca üst katmanlar yeniden eğitilmektedir. Modelin erken katmanları düşük seviyeli özellikleri (örneğin, kenarlar, dokular, temel şekiller) öğrenirken, son katmanları daha spesifik sınıflandırma görevleri için optimize edilmektedir. Şekil 2.11’de transfer öğrenme şeması gösterilmektedir.



Şekil 2.11 Transfer Öğrenme


2.3.5 CNN Mimarileri

CNN, görüntü tanıma, nesne tespiti ve diğer görsel analiz görevlerinde oldukça başarılı

bir şekilde kullanılan bir derin öğrenme mimarisidir. CNN'ler, görsel veriler üzerinde etkili bir şekilde öğrenme yapabilmek için farklı katman yapılarına sahip olup, her bir katman farklı seviyelerde özellik çıkarımı gerçekleştirir. CNN mimarileri, katmanların derinliği, özelliklerin soyutlama seviyesi ve parametrelerin sayısı bakımından farklılıklar gösterebilir. Bu mimariler, özellikle transfer öğrenme gibi tekniklerle birleştirildiğinde, küçük veri setlerinde bile yüksek başarımlı sonuçlar elde edilmesini mümkün kılar.

2.3.5.1 AlexNet


AlexNet, 2012 yılında ImageNet yarışmasında elde ettiği üstün performansla derin öğrenme alanında bir dönüm noktası oluşturmuş ve konvolüsyonel sinir ağlarının (CNN) büyük ölçekli veri kümelerinde öğrenme potansiyelini kanıtlayan çığır açıcı bir mimari olarak kabul edilmiştir. Bu model, toplamda sekiz katmandan oluşmakta olup, beş konvolüsyonel katman ve üç tam bağlı (fully connected) katmandan meydana gelmektedir. Konvolüsyonel katmanlar, görüntülerdeki temel görsel özellikleri çıkarmak için genellikle büyük filtre boyutları (11x11 ve 5x5 gibi) kullanırken, tam bağlı katmanlar sınıflandırma görevini üstlenmektedir. AlexNet, ReLU aktivasyon fonksiyonu, dropout düzenleme tekniği ve GPU tabanlı paralel işlem desteği gibi yenilikçi özelliklere sahip olup, bu sayede hem hızlı öğrenme kapasitesi hem de düşük hata oranları sağlamaktadır (Krizhevsky, Sutskever, ve Hinton 2017). Ayrıca, modelin transfer öğrenme bağlamında, önceden eğitilmiş ağırlıkların kullanımı ile daha küçük veri kümelerinde yüksek doğruluk oranlarının elde edilmesine olanak tanıdığı gösterilmiştir. Şekil 2.12'de AlexNet mimarisinin katman yapısı gösterilmiştir.



Şekil 2.12 AlexNet Mimarisi (Krizhevsky vd. 2017).

2.3.5.2 ResNet18

ResNet, derin sinir ağlarının eğitiminde karşılaşılan gradyan kaybı gibi temel sorunları çözmek amacıyla Microsoft Research tarafından 2015 yılında önerilmiş, devrim niteliğinde bir derin öğrenme mimarisidir. Bu mimari, "kalan bağlantılar" mekanizmasını kullanarak, her bir katmanın giriş verisini doğrudan sonraki katmanlara aktarmasını sağlamakta ve böylece daha derin ağların stabil bir şekilde eğitilmesine olanak tanımaktadır. ResNet-18, bu mimarinin 18 katmandan oluşan bir varyantı olup, her bir residual blok, öğrenme sürecini kolaylaştırarak derin ve karmaşık modellerin etkili bir şekilde eğitilmesini mümkün kılmaktadır. Bu yapı sayesinde, geleneksel derin ağların zorlandığı durumlarda bile yüksek performans elde edilebilmekte, ayrıca transfer öğrenme yöntemleriyle küçük veri setlerinde dahi yüksek doğruluk oranlarına ulaşılabilmektedir (He vd. 2016). ResNet-18'in giriş boyutu 224x224 piksel RGB görüntüler olarak tasarlanmış olup, hem hesaplama verimliliği hem de sınıflandırma başarısı açısından bilgisayarlı görü alanında yaygın olarak benimsenen bir modeldir. Kalan bağlantıların getirdiği avantajlar, ResNet'in çok derin mimarilerde (ResNet-50, ResNet-101 gibi) bile etkili çalışmasını sağlamış ve derin öğrenme alanında yeni bir standart oluşturmuştur. Şekil 2.13'de ResNet18 mimarisinin katman yapısı gösterilmiştir.




Şekil 2.13 ResNet18 Mimarisi (He vd. 2016).

2.3.5.3 VGG16

VGG16, 2014 yılında Oxford Üniversitesi tarafından geliştirilen ve ImageNet yarışmasında önemli bir başarı elde eden derin CNN mimarisidir. Model, toplamda 16

katmandan oluşmakta olup, 13 konvolüsyonel katman ve 3 tam bağlı katmandan meydana gelmektedir. VGG16'nın en belirgin tasarım özelliği, tüm konvolüsyonel katmanlarda 3x3 boyutunda filtrelerin kullanılmasıdır. Bu filtreler, her bir katmanda ReLU aktivasyon fonksiyonu ile etkinleştirilmekte ve ardından maksimum havuzlama işlemleri uygulanmaktadır. Bu yapı, modelin hem sadeliğini hem de görsel özellikleri çıkarma konusunda istikrarını artırmaktadır (Simonyan ve Zisserman 2015).

VGG16'nın derin yapısı, görüntülerdeki yüksek seviyeli öznitelikleri etkili bir şekilde öğrenmesini sağlar. Ancak, modelin büyük parametre sayısı, yüksek hesaplama maliyetleri ve işlem süresi gerektirmektedir. Buna karşın, transfer öğrenme yöntemleri ile VGG16, önceden eğitilmiş ağırlıkları kullanarak küçük veri kümelerinde bile hızlı ve başarılı bir şekilde özelleştirilebilir. Modelin giriş boyutu 224x224 piksel RGB görüntüler olarak belirlenmiş olup, nesne tanıma ve sınıflandırma gibi bilgisayarlı görü görevlerinde geniş bir kullanım alanına sahiptir (Simonyan ve Zisserman 2015). Şekil 2.14'de VGG16 mimarisinin katman yapısı verilmiştir.




Şekil 2.14 VGG16 Mimarisi (Simonyan ve Zisserman 2015).

2.3.5.4 EfficientNetB0

EfficientNet, Google tarafından 2019 yılında geliştirilen ve derin öğrenme modellerinin ölçeklendirilmesinde yeni bir yaklaşım sunan bir CNN mimarisidir. Bu mimari, "bileşik ölçeklendirme" adı verilen bir yöntemle modelin derinlik, genişlik ve çözünürlük boyutlarını dengeli bir şekilde ölçeklendirerek, düşük parametre sayısı ile yüksek

performans elde etmeyi amaçlamaktadır. EfficientNetB0, bu ailenin temel modeli olup, MBConv blokları ve derinlemesine ayrılabilir konvolüsyon gibi modern tekniklerle tasarlanmıştır (Tan ve Le 2019).

EfficientNet'in en önemli avantajı, geleneksel CNN'lerin aksine, hesaplama kaynaklarını verimli bir şekilde kullanarak daha az bellek ve işlem gücüyle yüksek doğruluk oranları elde etmesidir. Bu özellik, özellikle mobil cihazlar ve sınırlı kaynaklara sahip sistemler için büyük bir avantaj sağlar. Model, 224x224 piksel boyutunda RGB görüntülerle çalışabilir ve transfer öğrenme sürecinde yüksek verimlilik sunarak, küçük veri setlerinde bile etkili sonuçlar üretmesine olanak tanır. EfficientNet'in başarısı, yalnızca model mimarisindeki optimizasyonlardan değil, aynı zamanda otomatik mimari teknikleriyle desteklenen sistematik bir tasarım yaklaşımından da kaynaklanmaktadır. Bu özellikleri, EfficientNet ailesinin (B0'dan B7'ye kadar) bilgisayarlı görü görevlerinde kaynak verimliliği ve sınıflandırma performansı açısından önemli bir referans noktası haline gelmesini sağlamıştır (Tan ve Le 2019). Şekil 2.15'de EfficientNet mimari yapısı verilmiştir.



Şekil 2.15 EfficientNetB0 Mimarisi (Tan ve Le 2019).


2.3.5.5 XceptionNet

XceptionNet, Google Research tarafından 2016 yılında geliştirilen ve Inception mimari ailesinin evrimleştirilmiş bir varyantı olarak öne sürülen ileri düzey bir CNN mimarisidir. Bu model, geleneksel konvolüsyonel operasyonlar yerine " derinlemesine ayrılabilir konvolüsyon " bloklarını kullanarak uzamsal ve derinlik boyutlarında ayrıştırma yapan yenilikçi bir yaklaşım sunmaktadır. Söz konusu teknik, parametrik karmaşıklığı önemli ölçüde azaltırken modelin öğrenme kapasitesini korumakta ve hatta optimize etmektedir. Derinlemesine ayrılabilir konvolüsyonlar, her bir input kanalı için ayrı uzamsal

konvolüsyonlar uygulayarak, geleneksel konvolüsyonel işlemlere kıyasla hesaplamasal verimliliği önemli ölçüde artırmaktadır (Chollet 2017).

Xception mimarisinin temel avantajı, derin ayrılabilir konvolüsyonların kullanımı sayesinde hesaplama verimliliğini korurken büyük ölçekli veri kümelerinde yüksek sınıflandırma doğruluğu elde etme potansiyeli göstermesidir. Mimarinin standart giriş boyutu 299x299 piksel olarak tasarlanmış olmakla birlikte, 224x224 piksel giriş boyutlarıyla da uyumlu çalışabilme esnekliği sunmaktadır. Bu özellik, modelin çeşitli bilgisayarlı görü uygulamalarında geniş bir kullanım alanı bulmasını sağlamaktadır. Özellikle karmaşık görüntü analizi görevlerinde, nesne tanıma ve görüntü sınıflandırma problemlerinde, Xception geleneksel CNN mimarilerine kıyasla daha üstün performans sergilemektedir (Chollet 2017).

Transfer öğrenme bağlamında ise Xception, önceden eğitilmiş model ağırlıklarının kullanımı sayesinde düşük hesaplama kaynaklarıyla yüksek genelleme performansı elde edilmesini mümkün kılmaktadır. Bu özellikleri nedeniyle Xception, derin öğrenme tabanlı görüntü işleme uygulamalarında sıklıkla tercih edilen bir mimari haline gelmiştir. Şekil 2.16’da XceptionNet mimari yapısı verilmiştir.



Şekil 2.16 XceptionNet Mimarisi (Chollet 2017).


2.3.6 Topluluk Öğrenmesi

Topluluk Öğrenmesi, birden fazla sınıflandırıcının birleşerek daha doğru ve güvenilir tahminler yapmak amacıyla kullanılan bir yaklaşımdır. Bu yöntem, tek bir model yerine birden fazla modelin çıktılarının birleştirilmesiyle problemi çözmeyi amaçlar. Böylece, topluluk öğrenme, tek başına bir modelin elde edeceği sonuçlardan daha sağlam ve genellenebilir sonuçlar elde edilmesini sağlar (Hastie, Tibshirani, ve Friedman 2009).

Topluluk öğrenmesinin en belirgin avantajı, temel öğrencilerin hatalarını birbirini telafi edecek şekilde bir araya getirmesi ve bu sayede daha doğru tahminlerin yapılabilmesidir. Bu yaklaşım, özellikle zayıf öğrencileri güçlendirerek performanslarını artırmada oldukça etkilidir. Zayıf öğrenciler, genellikle düşük doğruluk oranlarına sahip olan ancak birleştirildiğinde güçlü bir sınıflandırıcı oluşturabilen modellerdir. Bu nedenle, topluluk öğrenme, zayıf modelleri bir araya getirerek daha güçlü tahminler yapabilen sistemler oluşturulmasına olanak tanır.

Topluluk öğrenme yöntemleri, genellikle homojen ve heterojen olmak üzere iki ana gruba ayrılır. Homojen topluluklar, aynı türdeki temel öğrencilerin birleştirilmesiyle oluşturulurken (örneğin, torbalama ve güçlendirme gibi yöntemlerle), heterojen topluluklar farklı türdeki öğrencilerin birleştirilmesiyle oluşturulur ve bu tür modeller genellikle daha karmaşık problemler için daha etkili sonuçlar elde edilmesini sağlar.

Topluluk öğrenmesinin etkinliği, kullanılan temel öğrencilerin çeşitliliğine ve doğruluğuna bağlıdır. Farklı türdeki öğrencilerle oluşturulan bir topluluk, daha geniş bir çözüm alanı sunarak modelin doğruluğunu artırabilir. Ayrıca, topluluk algoritmalarının başarısı, doğru birleştirme tekniklerinin seçilmesine de bağlıdır. Sayısal çıktılar için genellikle ortalama alma, kategorik çıktılar için ise çoğunluk oylaması gibi yöntemler kullanılmaktadır. Şekil 2.17’de topluluk öğrenmesinin şeması gösterilmiştir.



Şekil 2.17 Topluluk Öğrenmesi

2.3.6.1 Çoğunluk Oylaması Yöntemi

Çoğunluk oylaması (Majority voting), topluluk öğrenme teknikleri arasında temel bir yöntem olarak karşımıza çıkmaktadır. Bu yaklaşım, birden fazla sınıflandırıcının bireysel tahminlerini birleştirerek çoğunluk oyu prensibiyle nihai bir karar üretmeyi amaçlar. Matematiksel olarak bu yöntem Eşitlik 2.6’de görüldüğü gibi ifade edilebilir.

$$\hat{y} = \underset{c \in C}{\operatorname{argmax}} \sum_{i=1}^n I(y_i = c) \quad (2.6)$$

Burada $\hat{y}$ final tahmin edilen sınıf, C tüm sınıflar kümesi, n topluluktaki toplam model sayısı, $I(y_i = c)$ modelin doğru sınıf tahmini yaptığı durumlarda 1, yanlış yaptığı durumlarda 0 olan gösterge fonksiyonudur (Dogan ve Birant 2019).

Çoğunluk oylamasının en büyük avantajlarından biri, her temel öğrencinin tahminine eşit şekilde değer verilmesiyle, belirli bir modelin etkisinin azaltılmasıdır. Bu sayede, tek bir modelin tahminine dayalı olan yanlış önyargılardan kaçınılır ve sonuç daha dengeli hale gelir. Ancak, birden fazla benzer temel öğrencinin ya da bağımlı öğrencilerin bir olayı favorilemesi, söz konusu olayın topluluk modelinde baskın hale gelmesine yol açabilir. Bu durum, modelin genelleme yeteneğini ve doğruluğunu sınırlayabilir. Bununla birlikte, majority voting yönteminin etkinliği, temel öğrencilerin bağımsızlığı ve çeşitliliği ile doğrudan ilişkilidir.

Çoğunluk oylaması yönteminin basit yapısı bazı durumlar için yetersiz olabilir. Bu durumu aşmak için ağırlıklı majority voting yöntemi geliştirilmiştir. Ağırlıklı çoğunluk oylamasında, her modelin tahminine belirli bir ağırlık atanır ve bu ağırlıklar doğruluğa bağlı olarak ayarlanır. Böylece, doğru tahmin yapan modellerin etkisi daha fazla olur. Ağırlıklı çoğunluk oylaması Eşitlik 2.7’de gösterilmiştir.

$$\hat{y} = \underset{c \in C}{\operatorname{argmax}} \sum_{i=1}^n w_i I(y_i = c) \quad (2.7)$$

Denklemdaki w_i her modelin doğruluğuna dayalı olarak belirlenen ağırlıkları ifade eder. Bu yöntem, majority voting'in zayıf noktalarını giderebilir ve daha güvenilir sonuçlar elde edilmesini sağlar.

2.3.7 Açıklanabilir Yapay Zeka Yöntemleri

Yapay zeka ve özellikle derin öğrenme modelleri, son yıllarda çeşitli disiplinlerde önemli başarılar elde etmiş ve birçok alanda dönüştürücü bir etki yaratmıştır. Ancak, bu modellerin karmaşık mimarileri ve yüksek parametrik yapıları nedeniyle "kara kutu" (black-box) olarak nitelendirilen bir özellik sergilemeleri, model çıktılarının yorumlanabilirliğini ve karar süreçlerinin anlaşılabilirliğini önemli ölçüde sınırlandırmaktadır. Bu bağlamda, açıklanabilir yapay zeka yapay zeka sistemlerinin insan tarafından anlaşılabilir ve yorumlanabilir bir şekilde tasarlanmasını ve sunulmasını hedefleyen bir araştırma alanı olarak öne çıkmaktadır.

Açıklanabilir yapay zeka, modellerin tahmin süreçlerini sistematik olarak açıklayarak, kullanıcıların modelin hangi veri özelliklerine dayandığını, karar mekanizmalarının nasıl işlediğini ve hangi faktörlerin çıktıları belirleyici şekilde etkilediğini anlamalarını sağlamaktadır. Bu açıklanabilirlik, yalnızca model güvenilirliğini artırmakla kalmaz, aynı zamanda kullanıcıların model çıktılarına olan güvenini pekiştirir ve potansiyel hataların erken tespit edilmesine olanak tanır. Örneğin, sağlık sektöründe bir tanı modelinin belirli bir klinik kararı hangi bulgulara dayanarak önerdiğinin açıklanması, hekimlerin tedavi stratejilerini daha bilinçli bir şekilde belirlemelerine yardımcı olmaktadır.

Açıklanabilir yapay zeka yöntemleri, modellerin içsel yapısına ve kullanım amacına bağlı olarak çeşitlilik göstermektedir. Bazı yöntemler, modelin doğrudan yorumlanabilir bileşenlerini analiz ederken (örn. karar ağaçları, lineer modeller), diğerleri sonrasal açıklama teknikleriyle model çıktılarını yorumlamaktadır (örn. Grad-CAM, LIME). Özellikle derin öğrenme modellerinde, Grad-CAM gibi görselleştirme teknikleri, CNN sınıflandırma kararlarını hangi görsel özelliklere dayandığını ortaya koymaktadır. LIME gibi modelden bağımsız yöntemler ise, herhangi bir makine öğrenimi modelinin yerel davranışını basitleştirilmiş bir modelle açıklayarak yorumlanabilirlik sağlamaktadır.

Açıklanabilir yapay zekanın bir diğer önemli katkısı, model geliştirme sürecinde iyileştirmelere olanak tanımasıdır. Model kararlarının açıklanabilirliği, sistemin zayıf yönlerinin ve önyargılarının (bias) tespit edilmesine yardımcı olarak, daha sağlam ve adil modellerin geliştirilmesine zemin hazırlamaktadır. Dolayısıyla, açıklanabilir yapay zeka yalnızca mevcut modellerin şeffaflığını artırmakla kalmaz, aynı zamanda gelecekteki model optimizasyonları için de değerli bir araç sunmaktadır.

2.3.7.1 Grad-CAM (Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması)

Grad-CAM, derin öğrenme tabanlı modellerin açıklanabilirliğini artırmak için geliştirilmiş önemli bir görselleştirme yöntemidir. Grad-CAM, özellikle CNN gibi derin öğrenme modellerinin karar verme süreçlerini anlamak için yaygın olarak kullanılmaktadır. Bu yöntem, bir modelin sınıflandırma kararlarını yönlendiren kritik özellikleri görsel olarak vurgulayarak, modelin içsel işleyişini daha şeffaf hale getirir.

Grad-CAM, modelin çıktıları ile sınıflandırma arasındaki ilişkiyi analiz etmek için kullanılan bir yöntemdir. Özellikle, modelin kararlarını en fazla etkileyen bölgeleri, giriş görüntüsü üzerinde bir ısı haritası olarak görselleştirir. Bu, modelin hangi bölgeler üzerinde yoğunlaştığını ve hangi özelliklerin karar üzerinde daha fazla etkisi olduğunu anlamamıza olanak tanır. Grad-CAM, genellikle son konvolüsyonel katmanlardan alınan gradyanları kullanarak, her bir sınıf için tahminin duyarlılığını hesaplar ve görselleştirme sağlar (Ramprasaath R. Selvaraju vd. 2020).

2.3.7.2 LIME (Yerel Yorumlanabilir Model-agnostik Açıklamalar)

LIME, derin öğrenme ve diğer karmaşık makine öğrenme modellerinin açıklanabilirliğini artırmak amacıyla geliştirilmiş bir yöntemdir. LIME, siyah kutu (black-box) modellerin açıklanabilirliğini sağlamak için, yalnızca belirli bir örnek etrafında yerel açıklamalar üretir. Bu, modelin genel karar verme mantığından bağımsız olarak, her bir tahmin için nasıl bir sonuç elde edildiğini anlamayı amaçlar. LIME, modelin yerel davranışlarını anlamak için, karmaşık modelin tahminini açıklamak üzere basit, yorumlanabilir bir model kullanır.

Bu model genellikle doğrusal modeller veya karar ağaçları gibi açıklanabilir yapıya sahip yöntemlerdir. LIME, belirli bir veri örneği için, orijinal örneğe benzer yeni gözlemler üreterek, bu gözlemlerin model tarafından nasıl değerlendirilmesi gerektiğini inceler ve ardından bu gözlemlerle eğitilmiş basit modelin kararlarını kullanarak, orijinal modelin tahminine dair açıklamalar sunar. LIME, modelden bağımsız bir yöntem olup, herhangi bir türdeki makine öğrenme modeline uygulanabilir (Ribeiro vd. 2016).

2.3.7.3 LIME-Mask

LIME-Mask, LIME yönteminin bir uzantısı olarak geliştirilmiş ve görsel verilerde modelin kararlarını daha ayrıntılı bir şekilde açıklamak için kullanılır. LIME-Mask, özellikle görüntü sınıflandırma ve segmentasyon gibi görevlerde, modelin hangi bölgelere odaklandığını ve bu bölgelerin karar üzerinde ne kadar etkili olduğunu görselleştiren bir yöntemdir. LIME-Mask, bir görüntüdeki her pikselin veya bölgenin modelin tahminine olan katkısını analiz etmek amacıyla, orijinal görüntü üzerinde maskeler oluşturur. Bu maskeler, modelin hangi bölgelerde daha fazla yoğunlaştığını ve hangi bölgelerin karar üzerinde etkili olduğunu açıkça gösterir.

2.4 AISSLab Meme Kanseri Veri Seti

Bu çalışmada kullanılan veri seti, Yemen'deki Ma'amon's Diagnostic Centre Mammogram Images for Breast Cancer (MDCMI-BC) tarafından oluşturulan AISSLab Breast Cancer Dataset olup, AI tabanlı bilgisayar destekli tanı (CAD) sistemlerinin geliştirilmesine yönelik olarak hazırlanmıştır. Mamografi görüntüleri, BI-RADS sınıflandırmasına göre etiketlenmiştir ve lezyonların benign veya malign olma olasılıklarını belirlemeye yardımcı olmaktadır. Veriler, Senographe 800T High-Frequency X-Ray Generator (GE, Florida, USA) cihazı kullanılarak elde edilmiştir ve Craniocaudal (CC) ile Mediolateral Oblique (MLO) açılarında çekimler yapılmıştır. Ancak bazı vakalarda, tümörün anatomik konumu nedeniyle CC görüntüleri elde edilememiştir. Veri seti iki aşamalı doğrulama sürecinden geçirilmiştir. Öncelikle yerel uzman radyologlar tarafından yapılan ilk değerlendirmede her görüntü BI-RADS skorlamasına tabi tutulmuş, ardından uluslararası deneyime sahip radyologlar tarafından ikinci bir değerlendirme yapılarak sınıflandırma güvenilirliği artırılmıştır. Anotasyonların güvenilirliği Kappa katsayısı kullanılarak analiz edilmiş ve benign


vakalar için %50, malign vakalar için %80.16 ve normal vakalar için %100 oranında bir uzlaşa sağlanmıştır. Etiketleme sürecinde çelişki bulunan vakalar çalışma kapsamından çıkarılmıştır (Al-Hejri vd. 2023, 2024, Al-Tam vd. 2024). Veri seti toplamda 266 mamografi görüntüsünden oluşmaktadır. Çizelge 2.1, veri setindeki genel sınıf dağılımını göstermektedir.

Çizelge 2.1 Veri seti sınıf dağılımı

Sınıf	Görüntü Sayısı	Toplam İçindeki Yüzde (%)
Benign (BI-RADS 2)	18	6,77
Benign (BI-RADS 3)	48	18,05
Malign (BI-RADS 4)	54	20,30
Malign (BI-RADS 5)	46	17,29
Normal	100	37,59


Yüksek boyutlu veri dağılımını analiz etmek ve veri kümeleri arasındaki ilişkileri daha iyi anlamak amacıyla t-Dağıtılmış Stokastik Komşu Gömme (t-SNE t-distributed Stochastic Neighbor Embedding) yöntemi uygulanmıştır. Bu yöntem, yüksek boyutlu veri noktalarını daha düşük boyutlu bir uzaya indirerek, farklı BI-RADS kategorilerinin birbirinden ayrışma düzeylerini ve kümelenme paternlerini görselleştirmeyi amaçlamaktadır (Anaam vd. 2023).

Bu analiz, özellikle benign ve malign vakalar arasındaki geçişleri ve tanısal olarak benzer görüntü özelliklerine sahip fakat biyolojik olarak farklı olan lezyonların ayırt edilebilirliğini değerlendirmek için yapılmıştır. Şekil 2.18, t-SNE yöntemiyle elde edilen veri seti dağılımını göstermektedir.




Şekil 2.18 t-SNE yöntemi ile BI-RADS seviyelerine göre veri seti dağılımı

Veri setinden seçilen örnek mamografi görüntüleri, farklı BI-RADS sınıflarına sahip benign ve malign vakaları içermektedir. Şekil 2.19’da, veri setinden seçilen örnek mamografi görüntüleri sunulmaktadır.



Şekil 2.19 AISSLab veri setinden farklı sınıflardan örnek mamografi görüntüleri

Veri seti içerisinde kitle görüntülerinin maskeleri de GT adlı klasör içerisinde bulunmaktadır. Şekil 2.20’de örnek görüntüler gösterilmektedir.



Şekil 2.20 Anomalite maske görüntüleri

2.5 Meme Kanseri Anomali Tespiti ile İlgili Önceki Çalışmalar

Hameed vd. (2020) yaptıkları çalışmada, meme kanseri histopatoloji görüntülerinin sınıflandırılması için derin öğrenme tabanlı bir yaklaşım önermiştir. Çalışmada, Kolombiya'daki bir üniversite hastanesinden elde edilen ve toplamda 845 görüntüden oluşan bir veri seti kullanılmıştır. Veri seti, "karsinom" ve "non-karsinom" olmak üzere iki sınıfa ayrılmıştır. Araştırmacılar, önceden eğitilmiş VGG16 ve VGG19 derin öğrenme modellerinin tam eğitilmiş ve ince ayar yapılmış versiyonlarını bireysel olarak kullanmış ve bu modellerin birleşimiyle bir yöntem geliştirmiştir. Önerilen birleşim modeli, 5 katlı çapraz doğrulama kullanılarak değerlendirilmiş ve karsinom sınıfında %97.73 duyarlılık, %95.29 doğruluk ve %95.29 F1 skoru ile üstün performans sergilemiştir (Hameed vd. 2020).

Al-Dhabyani vd. (2020), BUSI (Breast Ultrasound Images Dataset) veri setini kullanarak meme kanseri sınıflandırması üzerine çalışmalar gerçekleştirmiştir. BUSI veri seti, 600 kadın katılımcıdan alınan toplam 780 ultrason görüntüsünü içermekte olup, 210 malign, 487 benign ve 133 normal sınıfta örnekler sunmaktadır. Bu çalışma kapsamında, AlexNet ve DenseNet201 modelleri, transfer öğrenme ve veri artırma teknikleriyle birlikte kullanılmıştır. Veri artırma aşamasında görüntüler rastgele döndürme, yatay ve dikey çevirme gibi işlemlere tabi tutularak modelin genelleme yeteneği artırılmıştır. İki sınıflı (malign ve benign) sınıflandırmada DenseNet201 modeli %92.5 doğruluk elde ederek AlexNet'in %87.6'lık doğruluk performansını geride bırakmıştır. Üç sınıflı (normal, benign, malign) sınıflandırmada ise DenseNet201 modeli %94.5 doğruluk ile en yüksek başarıyı göstermiştir (Al-Dhabyani vd. 2020).

Falconí vd., 2020 yılında yaptıkları çalışmada, INbreast veri setini kullanarak mamografi görüntülerinin BI-RADS sınıflandırmasını gerçekleştirmek amacıyla transfer öğrenme ve ince ayar yöntemlerini uygulamışlardır. Çalışmada, önceden eğitilmiş NASNet Mobile, VGG16 ve VGG19 derin öğrenme modelleri değerlendirilmiş ve VGG19 modelinin en yüksek başarıyı sağladığı belirlenmiştir. Veri dengesizliğini gidermek ve modelin genel performansını artırmak amacıyla Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE) içeren veri artırma teknikleri uygulanmış ve her BI-RADS kategorisinde eşit sayıda görüntü oluşturulmuştur. Elde edilen sonuçlara göre, VGG19 modeli %90.9

doğruluk ve %99 Eğri Altındaki Alan (AUC) değeri ile en iyi performansı göstermiştir (Falconi vd. 2020).

Pillai vd. (2022) yılında yaptıkları çalışmada, meme kanseri teşhisinde derin öğrenme tabanlı yaklaşımları kullanarak mamografi görüntülerinin sınıflandırılmasını amaçlamışlardır. Çalışmada, MIAS veri seti kullanılmış olup, toplam 322 mamografi görüntüsü (208 normal, 114 anormal) üzerinden deneyler gerçekleştirilmiştir. Verilerin işlenmesinde öncelikle gürültü azaltma, pektoral kasların çıkarılması ve veri yöntemleri uygulanmıştır. Sınıflandırma aşamasında VGG16 modeli kullanılmış ve modelin başarımı, AlexNet, GoogleNet ve EfficientNet gibi yaygın derin öğrenme tabanlı modeller ile karşılaştırılmıştır. Deneysel sonuçlara göre, VGG16 modeli %75.46 doğruluk oranı ile en iyi performansı göstermiştir. AlexNet, GoogleNet ve EfficientNet modelleri sırasıyla %69.64, %71.67 ve %72.29 doğruluk değerlerine ulaşmıştır. VGG16 modeli, daha derin özellik öğrenme kapasitesi sayesinde düşük hata oranı ile en başarılı model olarak belirlenmiştir (Pillai vd. 2022).

Tsai vd. (2022) yılında yaptıkları çalışmada, tarama mamografilerinin BI-RADS kategorilerine sınıflandırılmasını otomatikleştirmek amacıyla EfficientNet tabanlı bir derin sinir ağı modeli geliştirmiştir. Çalışmada, E-Da Hastanesi'nden elde edilen özel bir veri seti kullanılmış olup, 1490 hastaya ait toplam 5733 mamografi görüntüsü değerlendirilmiştir. BI-RADS kategorileri 0, 1, 2, 3, 4A, 4B, 4C ve 5 olmak üzere sekiz sınıfa ayrılmış ve modelin eğitimi için görüntüler 224×224 piksel boyutunda bloklara bölünerek işlenmiştir. Model, veri ön işleme sürecinde swish aktivasyon fonksiyonu ve ranger optimizasyon algoritması kullanılarak eğitilmiştir. Çalışma sonucunda, modelin %94.22 doğruluk, %95.31 ortalama duyarlılık değerine ulaştığı rapor edilmiştir. Önerilen modelin, yoğun meme dokusuna sahip bireylerde daha yüksek doğruluk sağladığı ifade edilerek, gelecekte daha geniş veri kümeleri üzerinde test edilmesi ve geliştirilebilirliğinin artırılması gerektiği belirtilmiştir (Tsai vd. 2022).

Nanni vd. (2023) yılında yaptıkları çalışmada, meme kanseri sınıflandırması için BGC (Breast Grading Carcinoma) veri setini kullanarak, farklı CNN ve transformer tabanlı modellerden oluşan bir topluluk yaklaşımı önermiştir. Bu çalışmada, ResNet50 ve

EfficientNetB0 gibi CNN modelleri ile DeiT, ViT, Swin ve CoAtNet gibi transformer modelleri ayrı ayrı eğitilmiş ve bu modellerin çıktılarını birleştiren bir topluluk sistemi oluşturulmuştur. Önerilen yöntem, yeni Adam tabanlı optimizasyon algoritmaları ile desteklenmiştir. Performans değerlendirmesi doğruluk , F1 skoru ve ROC eğrisi altında kalan alan gibi metriklerle gerçekleştirilmiştir. Çalışma sonucunda, önerilen ensemble yönteminin BGC veri setinde %85,7 doğruluk oranı ile mevcut yöntemleri geride bıraktığı ve bu veri seti üzerinde literatürdeki en iyi sonuçlardan birini elde ettiği belirtilmiştir (Nanni vd. 2023).

Hejri vd. (2023) yılında yaptıkları çalışmada, meme kanseri teşhisini geliştirmek amacıyla ETECADx adını verdikleri yeni bir Bilgisayar Destekli Tanı (CAD) sistemi önermişlerdir. Çalışmada, tam alan dijital X-ray meme görüntülerinin yer aldığı INbreast veri seti ve uzman radyologlar tarafından etiketlenmiş özel bir veri seti kullanılmıştır. INbreast veri seti, 115 hastadan elde edilen toplam 410 mamogram görüntüsü içermekte ve "normal", "benign" ve "malignant" sınıflarına ayrılmıştır. Özel veri seti ise Yemen'deki bir tanı merkezinden toplanan 100 normal, 25 benign ve 101 malignant görüntüyü içermektedir. Çalışmada, meme kanserinin teşhisi için hibrit bir yaklaşım geliştirilmiştir. İlk olarak, DenseNet201, VGG16 ve InceptionResNetV2 gibi önceden eğitilmiş derin öğrenme modelleri kullanılarak ensemble transfer öğrenme yaklaşımı uygulanmış ve bu modellerden elde edilen derin özellikler birleştirilmiştir. Daha sonra, bu özellikler Görsel Dönüştürücü (Vision Transformer, ViT) kullanılarak analiz edilmiş ve modelin dikkat mekanizması sayesinde yüksek doğruluk ve hassasiyet elde edilmiştir. ETECADx, ikili sınıflandırma (normal ve anormal) için %98.58 doğruluk oranı ve çok sınıflı sınıflandırma (normal, benign, malignant) için %97.87 doğruluk oranı ile INbreast veri seti üzerinde üstün performans göstermiştir. Özel veri setinde ise sırasıyla %97.16 (ikili sınıflandırma) ve %89.40 (çok sınıflı sınıflandırma) doğruluk oranlarına ulaşılmıştır. Bu çalışma, ensemble öğrenme ve Vision Transformer yöntemlerini bir araya getirerek hem genel doğruluk hem de karar verme sürecinde güvenilirlik sağlamayı hedeflemiştir. Çalışmanın bulguları, ETECADx'in meme kanseri teşhisinde etkili bir araç olarak kullanılabileceğini ve bu alandaki literatüre önemli bir katkı sağladığını göstermektedir (Al-Hejri vd. 2023).

Lu vd. (2024) yaptıkları çalışmada, iyi huylu ve kötü huylu meme tümörlerini ayırt etmek

için çok modlu görüntüleme (ultrasonografi, mamografi ve manyetik rezonans görüntüleme) verilerini içeren retrospektif bir veri seti kullanmıştır. Çalışma, 322 hastadan (112 benign, 210 malign) toplanan verilerden yararlanarak hem geleneksel radyomik özellikler hem de derin öğrenme tabanlı özelliklerin birleştirildiği bir model geliştirmeyi amaçlamıştır. Özellikle, ResNet-50 önceden eğitilmiş modeli ile transfer öğrenme uygulanmış ve boyut indirgeme için PCA kullanılarak 2048 boyutlu derin özellikler elde edilmiştir. Araştırma kapsamında farklı sınıflandırıcılar (SVM, XGBoost, LightGBM vb.) ile birlikte erken füzyon, topluluk ve istifleme stratejileri uygulanmıştır. Sonuçlara göre, önerilen istifleme füzyon modeli, doğruluk (%96,80), AUC (%97,70), açısından en iyi performansı sergilemiştir. Ayrıca, Grad-CAM yöntemi ile modelin karar verme süreçlerinin görselleştirilmesi sağlanmış ve multimodal görüntülemenin tek bir modaliteden daha üstün olduğu kanıtlanmıştır (Lu vd. 2024).

Nemade vd. (2024) yaptıkları çalışmada, meme kanseri tanısında kullanılmak üzere derin öğrenme tabanlı bir topluluk model önermiştir. Araştırmada, DDSM ve CBIS-DDSM veri setleri kullanılmış ve sınıf dengesizliğini gidermek amacıyla Sentetik Azınlık Aşırı Örnekleme Tekniği (SMOTE) uygulanmıştır. Önerilen modelde, üç farklı önceden eğitilmiş CNN modeli (VGG16, InceptionV3 ve VGG19) taban sınıflayıcı olarak kullanılmış ve bu sınıflayıcıların çıktıları iki farklı meta öğrenici ile birleştirilmiştir. İlk meta öğrenici lojistik regresyon, ikinci meta öğrenici ise çok katmanlı bir sinir ağı olarak tasarlanmıştır. Çalışmada, lojistik regresyon tabanlı topluluk modeli (Topluluk Model 1) %98,02 doğruluk, %97,17 duyarlılık ve %98,87 özgüllük değerlerine ulaşırken; sinir ağı tabanlı topluluk model (Topluluk Model 2) %98,10 doğruluk, %97,01 duyarlılık ve %99,12 özgüllük sonuçlarıyla daha iyi bir performans sergilemiştir (Nemade, Pathak, ve Dubey 2024).

Ahmed vd. (2024) yaptıkları çalışmada, meme kanseri teşhisi için CBIS-DDSM veri setini kullanarak derin öğrenme tabanlı bir yöntem geliştirmişlerdir. Çalışmada, veri seti öncelikle detaylı bir ön işleme sürecinden geçirilmiş; görüntüler boyutlandırılmış, artefaktlar temizlenmiş, çizgiler filtrelenmiş ve kontrast artırılmıştır. Araştırmacılar, veri artırımı teknikleriyle eğitim verilerinin çeşitliliğini artırırken, transfer öğrenme yaklaşımı kapsamında VGG16, Inception V3, ResNet18 ve ResNet50 gibi önceden eğitilmiş

modelleri incelemişlerdir. İnce ayar yapılmış ResNet50 modeli, test doğruluğunda %76 ile en iyi performansı göstermiştir. Ayrıca, modelin karar verme süreçlerini açıklamak için açıklanabilir yapay zeka teknikleri olan Grad-CAM, LIME ve SHAP kullanılmıştır. Grad-CAM ve SHAP, modelin karar mekanizmalarını daha tutarlı bir şekilde açıklarken, LIME'in bazı tutarsızlıklar gösterdiği belirtilmiştir (Ahmed vd. 2024).

Balve ve Hendrix (2024) yaptıkları çalışmada, meme kanseri sınıflandırmasında kullanılan derin öğrenme modellerinin açıklanabilirlik sorunlarını ele almışlardır. Mamografik görüntüler üzerinde gerçekleştirilen bu çalışmada, Mammographic Image Analysis Society (MIAS) veri seti kullanılmıştır. Bu veri seti, toplamda 322 mamografi görüntüsünden oluşmakta olup, "normal", "benign" ve "malignant" olmak üzere üç sınıfa ayrılmıştır. Çalışmada, CNN temel alınarak geliştirilmiş bir sınıflandırma modeli kullanılmıştır. Model eğitimi sırasında veri setinin yetersiz boyutlarını telafi etmek ve sınıflar arasındaki dengesizlik problemini gidermek amacıyla veri artırma teknikleri uygulanmıştır. CNN modeli, sınıflar arasında farklı performans sergilemiştir. Özellikle "normal" sınıf için F1 skoru %93 ve AUC değeri %98 olarak hesaplanırken, "malignant" sınıfta bu değerler sırasıyla %44 ve %83 olarak belirlenmiştir. Genel doğruluk oranı ise %77 olarak rapor edilmiştir. Çalışmada ayrıca, modelin açıklanabilirliğini artırmak amacıyla Grad-CAM, SHAP ve LIME gibi açıklanabilir yapay zeka yöntemleri değerlendirilmiştir. Sonuçlar, Grad-CAM'in hem görselleştirme kalitesi hem de hesaplama verimliliği açısından üstün olduğunu göstermiştir (Balve ve Hendrix 2024).

Al-Tam vd. (2024) tarafından yapılan bu çalışmada, göğüs kanserinin erken teşhisi ve sınıflandırması için yenilikçi bir hibrit açıklanabilir bilgisayar destekli tanı (CAD) sistemi geliştirilmiştir. Mammografi ve ultrason görüntülerini bir arada kullanan bu sistem, radyologların teşhis sürecini desteklemeyi ve hata oranlarını azaltmayı hedeflemiştir. Çalışmada, YOLOv8 nesne algılama modeli ve Vision Transformer (ViT) tabanlı ResNet50 modellerinin hibrit bir yaklaşımla birleştirildiği bir framework önerilmiştir. YOLOv8 modeli şüpheli bölgelerin tespitinde kullanılırken, ViT-ResNet50 modeli bu bölgelerin sınıflandırılmasını gerçekleştirmiştir. Ayrıca, modelin açıklanabilirliğini artırmak ve karar verme sürecini daha şeffaf hale getirmek amacıyla Grad-CAM tabanlı ısı haritaları oluşturulmuştur. Çalışmada, MIAS, INbreast ve BUSI gibi çeşitli mamografi

ve ultrason veri setlerinden yararlanılarak sistemin performansı kapsamlı bir şekilde değerlendirilmiştir. BI-RADS skorlarına dayalı çok sınıflı sınıflandırma senaryosunda, modelin %87,29 doğruluk ve %91,68 AUC değerine ulaştığı, ikili sınıflandırma görevlerinde ise %97,73 doğruluk elde ettiği rapor edilmiştir. Bu bulgular, önerilen sistemin göğüs kanseri teşhisi ve sınıflandırmasında önemli bir potansiyele sahip olduğunu göstermekte ve radyologlar için güçlü bir destek aracı sunmaktadır (Al-Tam vd. 2024).

Çizelge 2.2’de, meme kanseri tespiti ve sınıflandırması amacıyla gerçekleştirilen derin öğrenme tabanlı çalışmaların literatürdeki genel eğilimlerini kapsamlı biçimde özetlemektedir. Farklı yıllarda yayımlanmış çalışmalar; kullanılan veri setleri, sınıf etiketleme düzeyleri, mimari tercihler, model doğruluk oranları ve açıklanabilir yapay zeka yöntemleri açısından karşılaştırmalı olarak sunulmuştur. Görüldüğü üzere, sıklıkla başvurulmuş veri setleri arasında CBIS-DDSM, MIAS, BUSI, INbreast ve BreakHis öne çıkmakta, bazı çalışmalarda ise özel veri setleri tercih edilmektedir. Sınıflandırma, genellikle benign-malign ayrımı ya da üç sınıflı normal-benign-malign ayrımı şeklinde yapılmakta; ayrıca bazı çalışmalarda BI-RADS skorlaması gibi daha detaylı etiketlemeler de bulunmaktadır.

Model mimarisi açısından bakıldığında, klasik CNN yapılarından (VGG16, ResNet, AlexNet) ileri düzey modellere (EfficientNet, DenseNet, Inception, Vision Transformer) ve topluluk öğrenmesi yaklaşımlarına kadar geniş bir çeşitlilik mevcuttur. Doğruluk oranlarının çoğunlukla %90’ın üzerinde olduğu gözlemlenmekte, bazı çalışmalarda %99’u aşan yüksek başarımlar raporlanmaktadır. Son yıllarda açıklanabilir yapay zeka yöntemlerine olan ilgi de artmış; özellikle Grad-CAM, LIME ve SHAP gibi yöntemlerle model kararlarının görsel olarak açıklanması sağlanmıştır. Bu eğilim, tıbbi görüntü analizinde klinik güvenilirliği artırmaya yönelik önemli bir adımdır. Genel olarak tablo, son yıllarda derin öğrenmenin meme kanseri teşhisinde yüksek doğruluk, çeşitlilik ve açıklanabilirlik yönlerinden ciddi ilerlemeler kaydettiğini ortaya koymaktadır.

Çizelge 2.2 Açıklanabilir yapay zeka yöntemlerini kullanan meme kanseri teşhis çalışmaları

Yöntem	Veri Seti	Sınıf Etiketi	Mimari Yapı	Doğruluk (%)	XAI Yöntemi
Khan vd. (2019)	BreakHis, Yerel veri seti	Malignant, Benign	GoogLeNet, VGGNet ve ResNet	97,52	-
Al-Dhabyani vd. (2020)	BUSI	Normal, Benign, Malign	DenseNet201, AlexNet	94,50	-
Falconi vd. (2020)	INbreast	BI-RADS 1, 2, 3, 4, 5, 6	NASNet Mobile, VGG16, VGG19	90,90	-
Hameed vd. (2020)	Özel Veri Seti	Karsinom, Non-karsinom	VGG16+VGG19 Topluluğu	95,29	-
Thuy ve Hoang (2020)	BreakHis	Benign, Malignant	VGG16, VGG19	99,20	-
Moon vd. (2020)	SNUH (Özel Veri) & BUSI	Benign, Malign, Normal	VGG16, ResNet, DenseNet + Topluluk Öğrenmesi	94,62	-
Agnes vd. (2020)	mini-MIAS	Normal, Benign, Malign	MA-CNN	96,47	-
Jiménez Gaona vd. (2021)	BCDR	Benign, Malign, Normal	Mask R-CNN + DenseNet	97,70	-
Kallipolitis, Revelos, ve Maglogiannis (2021)	BreakHis	Benign, Malignant	EfficientNet B1-B3,	99,25	Grad-CAM, Guided Grad-CAM
Montaha vd. (2021)	CBIS-DDSM	Benign kalsifikasyon, Benign kitle, Malign kalsifikasyon, Malign kitle	VGG16 tabanlı BreastNet18	98,02	-
Ragab vd. (2021)	CBIS-DDSM, MIAS	Benign/Malign, Normal/Abnormal	Multi-DCNN, SVM, PCA, Özellik Birleştirme	97,90	-

Çizelge 2.2 (Devamı) Açıklanabilir yapay zeka yöntemlerini kullanan meme kanseri teşhis çalışmaları

Yöntem	Veri Seti	Sınıf Etiketi	Mimari Yapı	Doğruluk (%)	XAI Yöntemi
Shen vd. (2021)	BUSI	Malign, Benign	ResNet-18	97,60	-
Abbasniya vd. (2022)	BreakHis	Benign, Malign	Inception-ResNet-v2	96,46	Grad-CAM
Al-Tam vd. (2022)	CBIS-DDSM, DDSM	Normal, Benign, Malign	ResNet	95,80	-
Altameem vd. (2022)	BCDR, Mini-MIAS, INbreast, DDSM	Normal, Benign, Malignant	VGG-11, ResNet-164, DenseNet121, Inception V4,	99,32	-
(Gheflati ve Rivaz 2022)	BUSI	Benign, Malign, Normal	ResNet50, VGG16, Inception V3,	86,70	-
Jiang vd. (2022)	CBIS-DDSM, INbreast, MIAS	Benign, Malign	EfficientNet-B3,	91,10	-
Pillai vd. (2022)	MIAS	Normal, Benign, Malign	VGG16, AlexNet, GoogleNet, EfficientNet	75,46	-
Ruban, Moosa Jabeer, ve Shenoy Basti (2022)	Özel Veri Seti	Benign, Malignant	CNN, VGG, SSD	74,00	-
Saad vd. (2022)	Özel Veri Seti	Normal, Benign, Malign	BreastUS Transformer	97,00	-
Sabani vd. (2022)	Özel Veri Seti	BI-RADS 1-2-3-4-5	dCNN	89,80	-
Samee, Alhussan, vd. (2022)	INbreast, mini-MIAS	Benign, Malign	AlexNet, VGG16, GoogleNet	98,80	-
Samee, Atteia, vd. (2022)	INbreast	Benign, Malign	AlexNet, VGG16, GoogleNet	98,50	-

Çizelge 2.2 (Devamı) Açıklanabilir yapay zeka yöntemlerini kullanan meme kanseri teşhis çalışmaları

Yöntem	Veri Seti	Sınıf Etiketi	Mimari Yapı	Doğruluk (%)	XAI Yöntemi
Tsai vd. (2022)	Özel Veri Seti	BI-RADS 0, 1, 2, 3, 4A, 4B, 4C, 5	EfficientNet tabanlı Derin Sinir Ağı	94,22	-
Al-Hejri vd. (2023)	INbreast (kamu) ve özel veri seti (Yemen)	Normal, Benign, Malignant	DenseNet201, VGG16, InceptionResNet V2 ve ViT	98,58	-
Alotaibi vd. (2023)	BreakHis	Benign, Malign	ViT	98,17	-
Ayana vd. (2023)	DDSM	Benign, Malign	ViT	100	-
Nanni vd. (2023)	BG	Grade 1, Grade 2, Grade 3	ResNet50, EfficientNetB0	85,70	-
Or Rashid vd. (2023)	Wisconsin	Benign Malign	CNN, LSTM, MLP	94,12	-
Melekoodap pattu vd. (2023)	MIAS, DDSM	Malign Benign	Modifiye CNN	97,90	-
Preethi vd. (2023)	MIAS	Normal, Benign, Malign	EfficientNet, ResNet101, VGG19	98,30	-
Razali vd. (2023)	INbreast	Benign, Malign,	SbBDEM + YOLOv3 + k-NN	96,00	-
Sannasi Chakravarthy, Bharanidharan, ve Rajaguru (2023)	MIAS, INbreast	Normal, Benign, Malign	AlexNet, GoogleNet, ResNet50, DenseNet121	97,93	-
Sajid vd. (2023)	CBIS-DDSM	Benign, Malignant	Derin öğrenme (cVGG) + Elle Üretilmiş Özellikler (HOG, LBP) + XGBoost	91.5 %	-

Çizelge 2.2 (Devamı) Açıklanabilir yapay zeka yöntemlerini kullanan meme kanseri teşhis çalışmaları

Yöntem	Veri Seti	Sınıf Etiketi	Mimari Yapı	Doğruluk (%)	XAI Yöntemi
Ahmed vd. (2024)	CBIS-DDSM	Malignant, Benign, Normal	VGG16, Inception V3, ResNet18	76,00	Grad-CAM, LIME, SHAP
Al-Tam vd. (2024)	MIAS, INbreast, BUSI	Benign, Malign, BI-RADS Skorları (1-6)	YOLOv8 ile tespit, ViT tabanlı ResNet50 ile sınıflandırma,	97,73	Grad-CAM
(Balasubramanian vd. 2024)	BreakHis	Benign Malign	VGG16 + ResNet50	99,72	-
Balve ve Hendrix (2024)	MIAS	Normal, Benign, Malignant	CNN	77,00	Grad-CAM, SHAP, LIME
Jouirou, Souissi, ve Barhoumi (2024)	DDSM	biyopsi	VGG16 VGG19	97,00	-
Kamri vd. (2024)	Almadina Radiology	BIRADS Kategorileri (0-5)	VGG16, VGG19, NASNet, ResNet	92,53	-
Lu vd. (2024)	Özel Veri Seti	Benign, Malign	ResNet-50	96,80	Grad-CAM
Nemade vd. (2024)	DDSM, CBIS-DDSM	Malign, Benign	VGG16, InceptionV3, VGG19	98,10	-
Peta ve Koppu (2024)	BreakHis	Benign, Malignant	ESAE-Net	97,85	LIME, SHAP, Grad-CAM


3. MATERYAL ve METOT

Bu tez çalışmasının yöntemi, her biri belirli aşamaları temsil eden bir akış şeması ile yapılandırılmıştır ve Şekil 3.1’de gösterilmiştir. Çalışmada kullanılan AISSLab veri seti, benign, malign ve normal gibi farklı meme kanseri kategorilerini içeren birden fazla versiyondan oluşmaktadır. AISSLab veri kümesi beş farklı versiyon halinde derlenmiştir. AISSLab-v1, anormal ve normal sınıflarını içerirken; AISSLab-v2, malign ve normal; AISSLab-v3, benign ve malign; AISSLab-v4, benign, malign ve normal sınıflarını içermektedir. AISSLab-v5 ise BI-RADS sınıflandırmasına göre kategorize edilmiştir. Görüntülerin model tarafından daha iyi öğrenilebilmesi için veri artırma teknikleri uygulanarak genişletilmiş veri seti elde edilmiştir.

İlk olarak, görüntüler transfer öğrenme yaklaşımıyla işlenmektedir. Model eğitimi için transfer öğrenme yöntemi kullanılmış ve ImageNet üzerinde önceden eğitilmiş CNN modellerinin belirli katmanları dondurularak, ortak iç katmanlar ile özelleştirilmiş bir yapı oluşturulmuştur. Sınıflandırma işlemi için AlexNet (Krizhevsky vd. 2017), ResNet-18(He vd. 2016), VGG16 (Simonyan ve Zisserman 2015), EfficientNetB0 (Tan ve Le 2019) ve XceptionNet (Chollet 2017) mimarileri kullanılmıştır. Ardından, topluluk öğrenme yöntemi uygulanmış, farklı modellerin çıktıları çoğunluk oylaması yöntemiyle birleştirilerek daha sağlam tahminler elde edilmiştir.

BCECNN mimarisi, her bir modelin avantajlarını birleştirerek aşırı öğrenmeyi engellemeyi ve sınıflandırma doğruluğunu artırmayı amaçlayan iki farklı topluluk modeline sahiptir: TECNN ve QECNN. Topluluk öğrenme yaklaşımı, modelin performansını değerlendirmek için doğruluk, karışıklık matrisi ve ROC eğrisi gibi yaygın performans metrikleriyle kapsamlı bir şekilde test edilmiştir. Ayrıca, açıklanabilir yapay zeka teknikleri, modelin karar verme süreçlerini görselleştirmek ve yorumlamak amacıyla kullanılmaktadır.

LIME, LIME-Mask ve Grad-CAM gibi yöntemler, modelin sınıflandırma sırasında mamogram görüntülerinin hangi bölgelerine odaklandığını anlamada önemli rol oynamaktadır. Bu görselleştirmeler, özellikle klinik uygulamalarda modelin şeffaflığını artırmak için önemlidir.



Şekil 3.1 Akış Şeması

3.1 AISSLab Ham ve Artırılmış Veri Seti

Veri setinden farklı sınıflandırma görevleri için alt gruplar oluşturulmuştur. Bu gruplama, model eğitim süreçlerinde farklı seviyelerde ayırt edilebilirlik sağlayarak, genel ve özel sınıflandırma senaryoları için uygun alt kümelerin belirlenmesini sağlamaktadır. Çizelge 3.1’de, oluşturulan alt grupların ham ve artırılmış versiyonlarına dair veri seti dağılımları verilmiştir.

Çizelge 3.1 Ham ve artırılmış veri seti dağılımı

Veri Seti	Sınıf Etiketi	Ham Veri	Artırılmış Veri
AISSLab-v1	Normal	100	400
	Anormal	166	664
AISSLab-v2	Malignant	100	400
	Normal	100	400
AISSLab-v3	Benign	66	264
	Malignant	100	400
AISSLab-v4	Benign	66	264
	Malignant	100	400
	Normal	100	400
AISSLab-v5	BI-RADS	BI-RADS 2: 18,	BI-RADS 2: 72,
	seviyeleri	BI-RADS 3: 48,	BI-RADS 3: 192,
		BI-RADS 4: 54,	BI-RADS 4: 224,
		BI-RADS 5: 46	BI-RADS 5: 176

3.2 CNN Mimarisi

CNN, derin öğrenme tabanlı görüntü işleme tekniklerinde en yaygın kullanılan mimarilerden biridir. CNN'ler, geleneksel tam bağlı sinir ağlarından farklı olarak, yerel bağlantılar ve ağırlık paylaşımı prensiplerine dayalı olarak çalışmaktadır. Bu özellikleri sayesinde yüksek boyutlu görüntü verilerinden etkili bir şekilde özellik çıkarımı gerçekleştirebilirler. CNN mimarileri genellikle üç temel bileşenden oluşmaktadır: konvolüsyon katmanları, havuzlama katmanları ve tam bağlı katmanlar.

Konvolüsyon katmanları, görüntüdeki önemli özellikleri (kenarlar, dokular, temel şekiller) öğrenen filtreler içerir. Havuzlama katmanları, modelin işlem kapasitesini azaltarak hesaplama yükünü düşürür ve aşırı öğrenmeyi engellemeye yardımcı olur. Tam bağlı katmanlar ise çıkarılan özellikleri kullanarak sınıflandırma işlemini gerçekleştirir.

Bu tez çalışmasında, meme kanseri sınıflandırma görevini gerçekleştirmek amacıyla AlexNet, ResNet-18, VGG16, EfficientNetB0 ve XceptionNet olmak üzere beş farklı CNN modeli kullanılmıştır. Bu modeller, farklı mimari derinliklere ve özellik çıkarma kapasitelerine sahip olup, ayrılan veri kümeleri üzerinde test edilerek performansları karşılaştırılmıştır.

AlexNet, 2012 yılında ImageNet yarışmasını kazanan ve DL çığır açan ilk CNN modellerinden biridir. Toplamda sekiz katmandan oluşan bu model, beş konvolüsyonel katman ve üç tam bağlı katman içermektedir. Modelin derinliği sınırlı olmasına rağmen, büyük çekirdek boyutları ve ReLU aktivasyon fonksiyonu kullanımı ile etkili bir özellik çıkarma mekanizması sunmaktadır.

VGG16, daha derin yapıya sahip olup, 16 katmandan oluşan bir CNN mimarisidir. Daha küçük çekirdek boyutları kullanarak daha hassas özellik çıkarımı sağlamakta ve klasik CNN mimarilerinin aksine daha derin bir yapı ile yüksek performans sunmaktadır. Ancak, VGG16'nın yüksek parametre sayısı, hesaplama maliyetlerini artırmaktadır.

ResNet-18, derin ağların eğitilmesi sırasında karşılaşılan gradyan kaybolması problemini

çözmek için artık bağlantılar kullanan bir CNN mimarisidir. 18 katmandan oluşan bu model, derin ağların daha stabil şekilde eğitilmesine olanak tanımakta ve daha hızlı yakınsama sağlamaktadır.

EfficientNetB0, model ölçekleme stratejisi kullanarak CNN mimarilerinin verimliliğini artırmayı amaçlayan bir modeldir. Geleneksel CNN mimarilerine kıyasla daha düşük parametre sayısına sahip olmasına rağmen, optimize edilmiş yapısı sayesinde yüksek doğruluk oranları elde edebilmektedir.

XceptionNet, derinlik ayırık konvolüsyonları kullanarak geleneksel konvolüsyon işlemlerini daha hesaplamalı verimli hale getiren bir CNN modelidir. Daha az parametre ile daha etkili özellik çıkarımı yapabilmesi, modelin özellikle büyük ölçekli veri kümelerinde başarılı sonuçlar elde etmesini sağlamaktadır.

Çalışmada kullanılan CNN modellerinin farklı yapıları ve mimari özellikleri, belirli görevler için farklı avantajlar sunmakta olup, bu çalışmada en iyi performansı sağlayan modeller belirlenmiştir. Bu modellerin transfer öğrenme yöntemleri ile uyarlanarak kullanımı, sınıflandırma doğruluğunu artırmakta ve eğitim sürecini hızlandırmaktadır.


3.3 Görüntü Ön İşleme Yöntemleri

Bu çalışmada kullanılan veri setleri ve ilgili açıklamalar Çizelge 3.2’de bulunmaktadır. DL modellerinin başarılı şekilde eğitilmesi için görüntüler ön işleme adımlarından geçirilmiştir. İlk olarak tüm görüntüler ilgili modele uygun olacak şekilde yeniden boyutlandırılmıştır. Her model için belirlenen giriş görüntü boyutları Çizelge 3.2’de gösterilmiştir.

Çizelge 3.2 Derin Öğrenme Model Parametleri

Model	Derinlik	Parametre Sayısı (Milyon)	Boyut (MB)	Görüntü Giriş Boyutu
AlexNet	8	61	227	224×224
VGG16	16	138	528	224×224
ResNet18	18	11.7	44	224×224
EfficientNetB0	30	5.3	29	224×224
XceptionNet	71	22.9	88	299×299

DL modellerinin daha güçlü öğrenme yeteneğine sahip olması ve aşırı uyumun önlenmesi için çeşitli veri artırma teknikleri uygulanmıştır. Bu teknikler, eğitim verisinin çeşitliliğini artırarak modellerin daha genel geçer özellikleri öğrenmesine yardımcı olmaktadır. Veri artırma sürecinde, ilk olarak kırpma işlemi uygulanmış ve görüntüler maksimum %5 oranında yakınlaştırılarak kesilmiştir. Bu işlem, görüntülerdeki farklı alanların modele sunulmasını sağlamıştır. Ardından, döndürme işlemi gerçekleştirilmiş ve her görüntü rastgele -30° ile $+30^{\circ}$ arasında döndürülerek çeşitlendirilmiştir. Bu işlem, modelin farklı açılardaki verileri öğrenmesini destekleyerek daha sağlam bir tahmin yeteneği kazanmasına yardımcı olmuştur. Bunun yanı sıra, görüntülerin %15'ine gri tonlama dönüşümü uygulanarak renk bilgisi azaltılmıştır. Bu sayede model, renk bağımlılığı yerine yapısal özelliklere odaklanarak daha dayanıklı hale getirilmiştir. Doygunluk seviyesi, rastgele $-%25$ ile $+%25$ arasında değiştirilerek görüntülerin renk yoğunlukları farklılaştırılmıştır. Bu teknik, modelin renk varyasyonlarına karşı daha toleranslı olmasını sağlamıştır. Benzer şekilde, parlaklık ayarlaması $-%15$ ile $+%15$ arasında rastgele değiştirilmiş ve ışıklandırma koşullarına karşı modelin adaptasyonu artırılmıştır. Bu veri artırma teknikleri sonucunda elde edilen görüntü sayıları Çizelge 3.1'de sunulmaktadır. Şekil 3.2'de ise kullanılan veri artırma tekniklerine dair örnekler gösterilmektedir.



Şekil 3.2 Veri artırma teknikleri

3.4 Transfer Öğrenme Yöntemi Uygulaması

Bu tez çalışmasında, ImageNet veri seti üzerinde eğitilmiş AlexNet, VGG16, ResNet-18,

EfficientNetB0 ve XceptionNet modelleri kullanılarak transfer öğrenme yöntemi uygulanmıştır. Bu modellerin derin öğrenme sürecinde genel özellik çıkarma kapasitesini koruyabilmesi amacıyla, konvolüsyonel katmanlar dondurulmuş ve yalnızca tam bağlı (fully connected) katmanlar yeniden eğitilmiştir. Böylece, önceden öğrenilmiş bilgilerin korunması sağlanarak modelin yeni veri kümesine daha hızlı adapte olması hedeflenmiştir.

Çalışmada kullanılan transfer öğrenme yöntemi, modelin aşırı öğrenmesini önlemek amacıyla Dropout (0.5) mekanizmasını içermekte olup, sınıflandırma katmanlarında Softmax ve Sigmoid aktivasyon fonksiyonları uygulanmıştır. İki sınıflı sınıflandırma için Sigmoid, çok sınıflı sınıflandırma için ise LogSoftmax fonksiyonları kullanılarak model çıktıları optimize edilmiştir. Ayrıca, model eğitimi sırasında erken durdurma ve öğrenme oranı planlaması gibi teknikler uygulanarak modelin daha kararlı ve genellenebilir hale gelmesi sağlanmıştır.

3.5 Topluluk Öğrenme Yöntemi Uygulaması

Topluluk öğrenme, birden fazla derin öğrenme modelinin çıktılarının birleştirilmesiyle genel model performansını artıran bir tekniktir. Tek bir modelin sınırlamalarını aşmak ve hata oranlarını düşürmek amacıyla kullanılan topluluk stratejileri, özellikle tıbbi görüntü analizi gibi hassas sınıflandırma problemlerinde büyük önem taşımaktadır.


Bu tez çalışmasında, beş farklı CNN modeli kullanılarak iki farklı topluluk yaklaşımı uygulanmıştır. İlk olarak QECNN yöntemi test edilmiştir. Beş modelin tamamını içeren bu topluluk yöntemi ile model çeşitliliğinden maksimum seviyede faydalanılması amaçlanmıştır. Ancak, bu yöntemin hesaplama maliyeti yüksek olmuş ve bazı modellerin benzer özellik çıkarım mekanizmalarına sahip olması nedeniyle çeşitlilik açısından sınırlı kalmıştır. Bu durum, topluluk modelinin genelleme kapasitesini düşürebileceğinden dolayı üçlü kombinasyonlar test edilerek alternatif bir strateji geliştirilmiştir.

Geliştirilen bir diğer TECNN yöntemiyle, beş modelin 10 farklı üçlü kombinasyonu oluşturulmuş ve performansları karşılaştırılmıştır. Kullanılan üçlü ve beşli kombinasyonlar Çizelge 3.3’de verilmiştir.

Çizelge 3.3 Üçlü ve beşli kombinasyonların listesi

TECNN	AlexNet, VGG16, XceptionNet
	AlexNet, VGG16, EfficientNetB0
	AlexNet, VGG16, ResNet18
	AlexNet, XceptionNet, EfficientNetB0
	AlexNet, XceptionNet, ResNet18
	AlexNet, EfficientNetB0, ResNet18
	VGG16, XceptionNet, EfficientNetB0
	VGG16, XceptionNet, ResNet18
	VGG16, EfficientNetB0, ResNet18
	XceptionNet, EfficientNetB0, ResNet18
QECNN	AlexNet, VGG16, XceptionNet, EfficientNetB0, ResNet18


Bu çalışmada yalnızca üçlü ve beşli kombinasyonlar tercih edilmiştir. Yapılan performans değerlendirmesi ile en yüksek başarımlar hedeflenmektedir. Oluşturulan topluluk kombinasyonları Şekil 3.3 ve Şekil 3.4’de gösterilmektedir. Topluluk öğrenme sürecinde çoğunluk oylaması yöntemi kullanılmıştır. Bu yöntemde, her modelin bağımsız olarak ürettiği tahminler değerlendirilmiş ve en fazla oy alan sınıf nihai çıktı olarak belirlenmiştir.



Şekil 3.3 TECNN yöntemi ile oluşturulan en iyi model kombinasyonu.

Üçlü kombinasyonlarda, farklı CNN mimarilerinin tamamlayıcı özellik çıkarma kapasiteleri bir araya getirilerek model çeşitliliği artırılmış ve sınıflandırma doğruluğu

optimize edilmiştir.



Şekil 3.4 QECNN yöntemi ile oluşturulan model kombinasyonu.

Deneysel sonuçlar, TECNN stratejisinin QECNN yöntemine kıyasla daha iyi performans gösterdiğini ortaya koymuştur. Bunun temel nedeni, beşli topluluk modelinde bazı CNN mimarilerinin aşırı benzer özellik çıkarım mekanizmalarına sahip olması ve birbirine yakın tahminler üretmesidir. Buna karşılık, üçlü topluluk kombinasyonlarında daha dengeli model çeşitliliği sağlanarak sınıflandırma doğruluğu artırılmıştır. Sonuç olarak, topluluk öğrenme, tekil CNN modellerine kıyasla daha güvenilir ve yüksek doğruluklu sınıflandırma sonuçları üretmiştir. Özellikle üçlü kombinasyonların sağladığı model çeşitliliği ve hesaplama verimliliği, topluluk öğrenme stratejisinin başarısını artırmıştır.

3.6 Performans Metrikleri

Bu tez çalışmasında, önerilen yöntem için kullanılan sınıflandırma modellerinin performans değerlendirmesi için karışıklık matrisine dayanan literatürde yaygın kullanılan doğruluk, kesinlik, duyarlılık, özgüllük, F1 skoru ve ROC eğrisi gibi temel performans ölçütleri kullanılmıştır. Karışıklık matrisi, sınıflandırma modellerinin başarısını görsel

olarak temsil eden bir tablo biçiminde sunulan bir araçtır. Bu matristeki her hücre, modelin sınıfları doğru veya yanlış bir şekilde tahmin etmesine dayanan sonuçları yansıtır. Sınıflandırma algoritmaları, etiketlenmiş gerçek veri setleriyle eğitildikten sonra, test verileri üzerinde doğrulama yapılır ve model tahminlerini üretir. Bu tahminler, modelin tahmin ettiği etiketlerdir. Karışıklık matrisi, modelin performansını değerlendirmek, zayıf noktaları belirlemek ve bu eksiklikleri gidermek amacıyla yaygın olarak kullanılmaktadır. Derin öğrenme tabanlı sınıflandırma modellerinin performansını değerlendirmek için kullanılan metrikler, modelin doğruluğunu, güvenilirliğini ve genel başarısını ölçen önemli araçlardır. Şekil 3.5’de karışıklık matrisi gösterilmiştir.

		Tahmini sınıf	
		+	-
Gerçek sınıf	+	TP True Positives	FN False Negatives Type II error
	-	FP False Positives Type I error	TN True Negatives

Şekil 3.5 Karışıklık Matrisi (İnt. Kyn. 9).

Doğruluk, modelin doğru tahminlerde bulunduğu örneklerin toplam örnek sayısına oranını belirler. Bu metrik, tüm sınıflandırmalar doğru yapıldığında yüksek bir değer alırken, dengesiz veri setlerinde yanıltıcı olabilir çünkü sadece genel doğruluğu ölçer ve her sınıfın önemini dikkate almaz.

Kesinlik, modelin pozitif olarak sınıflandırdığı örneklerin ne kadarının gerçekten pozitif olduğunu gösterir. Özellikle yanlış pozitiflerin (false positives) ciddi sonuçlar doğurabileceği sağlık gibi alanlarda kesinlik çok önemli bir rol oynar.

Duyarlılık, modelin gerçek pozitifleri doğru bir şekilde sınıflandırma oranını ifade eder ve genellikle yanlış negatiflerin (false negatives) minimize edilmesinin kritik olduğu durumlarda önem kazanır. Kanser gibi hastalıkların teşhisinde yanlış negatifler, hastalığın

gözden kaçırılmasına ve tedavinin gecikmesine yol açabilir. Bu nedenle duyarlılığın yüksek olması beklenir.

F1 skoru, kesinlik ve duyarlılığı dengeleyen bir metriktir. Bu metrik, her iki hatayı (yanlış pozitif ve yanlış negatif) göz önünde bulundurur ve özellikle veri setlerinin dengesiz olduğu durumlarda kullanışlıdır. Yüksek F1 skoru, modelin hem doğru tahminler yapma kapasitesini hem de yanlış tahminleri en aza indirme yeteneğini gösterir.

AUC, ROC eğrisinin altındaki alanı ölçer ve modelin sınıflandırma başarısını belirler. AUC değeri, 0 ile 1 arasında değişir ve 1, mükemmel performansı gösterirken, 0.5 rastgele tahmin yapan bir modeli temsil eder. AUC, modelin geniş bir karar eşiği aralığında nasıl performans gösterdiğini ölçer ve genellikle daha doğru genel performans değerlendirmeleri sağlar.

Gerçek Pozitif Oranı (TPR), duyarlılıkla eşdeğerdir ve modelin doğru pozitifleri doğru şekilde ayırt etme başarısını ölçer. Yanlış Pozitif Oranı (FPR), modelin negatif sınıfları yanlışlıkla pozitif olarak sınıflandırma oranını ifade eder. Düşük FPR, modelin gereksiz alarm verme oranını azaltır ve özellikle sağlık alanında kritik öneme sahiptir.

Bu metriklerin tümü, bir modelin sınıflandırma yeteneğini, doğru teşhis yapma başarısını, güvenilirliğini ve her iki hata türünü (yanlış pozitif ve yanlış negatif) minimize etme becerisini kapsamlı bir şekilde değerlendiren önemli araçlar sunar. Modelin performansını anlamak için bu metriklerin bir arada kullanılması, genellikle daha güvenilir ve genellenebilir sonuçlar elde edilmesini sağlar. Bu metriklerin hesaplanmasına ilişkin matematiksel ifadeler Eşitlik (3.1)-(3.7)'de verilmiştir.

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

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

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

$$F_1 \text{ score} = 2 \times \frac{\text{Duyarlılık} \times \text{Kesinlik}}{\text{Duyarlılık} + \text{Kesinlik}} \quad (3.4)$$

$$\text{AUC} = \int_0^1 \text{TPR}(\text{FPR})d(\text{FPR}) \quad (3.5)$$

$$\text{TPR} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (3.6)$$

$$\text{FPR} = \frac{\text{FP}}{\text{FP} + \text{TN}} \quad (3.7)$$

3.7 Açıklanabilir Yapay Zeka Uygulaması

Yapay zeka tabanlı sistemlerin yorumlanabilirliğini sağlamak amacıyla açıklanabilir yapay zeka yöntemleri geliştirilmiştir. Bu tez çalışmasında, AlexNet, VGG16 ve EfficientNetB0 modellerine Grad-CAM uygulanarak mamografik görüntülerde modelin karar alırken hangi bölgelere daha fazla önem verdiği analiz edilmiştir. Özellikle malign tümörlerin belirlenmesi sürecinde modelin hangi doku yapılarının sınıflandırma kararına katkıda bulunduğu incelenmiş, bu sayede modelin güvenilirliği değerlendirilmiştir. AlexNet, VGG16 ve EfficientNetB0 modelleri için LIME ve genişletilmiş bir versiyonu olan LIME-Mask kullanılarak modelin hangi özniteliklere dayandığı detaylandırılmıştır. LIME-Mask yöntemi, özellikle tıbbi görüntü analizlerinde belirleyici bölgelerin vurgulanmasına yardımcı olarak, klinik süreçlere entegre edilebilirliği artırmaktadır.

4. BULGULAR

Çalışmada, farklı CNN mimarileri ve topluluk öğrenme yöntemleri değerlendirilmiş olup, modellerin başarımları analizleri doğruluk, kesinlik, hassasiyet, özgüllük, F1 skoru ve ROC AUC gibi yaygın sınıflandırma metrikleri üzerinden gerçekleştirilmiştir. Deneyler, çeşitli veri setleri üzerinde yürütülerek modellerin genelleme kapasitesi incelenmiştir. Tekil CNN modellerinin performans değerlendirmesi ROC eğrileri aracılığıyla gerçekleştirilmiş, topluluk öğrenme yöntemlerinin etkinliği ise karışıklık matrisleri ile görselleştirilmiştir. Ayrıca, model karar süreçlerinin yorumlanabilirliğini artırmak amacıyla açıklanabilir yapay zeka yöntemleri uygulanmış ve Grad-CAM ile LIME teknikleri kullanılarak modellerin sınıflandırma sırasında hangi bölgeleri önemli bulduğu ve kararlarını hangi görsel özniteliklere dayandığı görselleştirilmiştir.

4.1 Tek CNN Modeli Performansı

Çalışmada kullanılan CNN modelleri, çeşitli veri setleri üzerinde test edilerek doğruluk, kesinlik, duyarlılık, özgüllük, F1 skoru ve ROC AUC gibi metriklerle değerlendirilmiştir. Tekil CNN modellerinin performansını kapsamlı bir şekilde analiz edebilmek için ROC eğrileri oluşturulmuş ve farklı veri setlerindeki sınıflandırma başarıları görselleştirilmiştir. ROC eğrileri, modelin farklı karar eşiklerinde ne kadar iyi performans gösterdiğini değerlendirmek amacıyla kullanılmış olup, TPR ile FPR arasındaki dengeyi gözler önüne sermektedir. Bu analiz, modellerin sadece genel doğruluk açısından değil, aynı zamanda çeşitli sınıflandırma senaryolarındaki ayırt edicilik yeteneğini de ortaya koymaktadır. Çizelge 4.1’de, tekil CNN modellerinin ham veri seti kullanılarak eğitildiğinde elde edilen performans metrikleri sunulmaktadır. Sonuçlara bakıldığında, bu tez çalışmasında AISSLab veri setinin beş farklı versiyonu üzerinde gerçekleştirilen deneylerde, farklı derin öğrenme modellerinin sınıflandırma performansları, aynı hiperparametreler altında sistematik olarak incelenmiştir. Tüm deneylerde öğrenme oranı (learning rate) 0,0001 olarak belirlenmiş, optimizasyon için Adam algoritması tercih edilmiş ve mini-batch boyutu 32 olarak seçilmiştir. Bu parametre kombinasyonu, literatürde sıklıkla önerilen ve dengeli bir öğrenme süreci sağlayan bir yapı sunmaktadır. Adam optimizasyon algoritması, momentuma dayalı güncellemeleri ve adaptif öğrenme hızlarını birleştirerek hızlı yakınsama sağlaması nedeniyle özellikle küçük veri setleri için

avantaj sağlamaktadır. 50 ve 100 epok değerleri ile modelin öğrenme sürecinde zaman içinde nasıl iyileştiği gözlemlenmiş ve bu sayede erken doyum veya aşırı öğrenme riskleri de değerlendirilmiştir.

AISSLab-v1 veri setinde, 100 epokta XceptionNet modeli %88,89 doğruluk ve %98,18 ROC AUC ile en güçlü sonucu vermiştir; burada kullanılan düşük öğrenme oranının modelin ağırlıklarının dengeli güncellenmesine katkı sağladığı ve Adam optimizatörünün hızlı ve kararlı yakınsama yeteneğinin önemli rol oynadığı değerlendirilmektedir. AISSLab-v2 setinde de benzer şekilde, AlexNet modeli 100 epokta %85 doğruluk elde etmiş ve ROC AUC %91,20 seviyesine ulaşmıştır; bu modelin özellikle yüksek duyarlılık ve özgüllük dengesi, batch boyutunun ve Adam'ın sağladığı istikrarlı gradyan güncellemelerinin etkili olduğunu göstermektedir. AISSLab-v3 sonuçlarında EfficientNetB0 modeli %76,47 doğruluk ve %100 duyarlılık ile dikkat çekmiş; bu, düşük öğrenme oranının küçük örneklem gruplarında bile detayları öğrenmeye elverişli olduğunu göstermektedir. AISSLab-v4 için ResNet18 modeli, özellikle 100 epokta %62,96 doğruluk ve %71,07 ROC AUC ile diğer modellere göre daha iyi bir performans ortaya koymuş; burada derin mimarinin sunduğu avantajın yanı sıra kullanılan hiperparametrelerin modelin fazla uyum yapmadan dengeli öğrenmesini sağladığı gözlemlenmiştir. AISSLab-v5 veri setinde genel başarı oranlarının düştüğü görülmekte, ancak EfficientNetB0 modeli %35,29 doğruluk ve %68,30 ROC AUC ile görece daha başarılı bir sonuç elde etmiştir; bu, özellikle karmaşık ve dengesiz veri kümelerinde Adam optimizatörü ile düşük öğrenme oranının, modelin minimum seviyede dahi stabil sonuçlar üretmesine katkı sağladığını düşündürmektedir.

Sonuç olarak; kullanılan sabit hiperparametreler—0,0001 öğrenme oranı, Adam optimizatörü ve 32 batch boyutu—modeller arasında kıyaslama için adil bir temel oluşturmuş ve modellerin yapısal farklılıklarının daha net ortaya çıkmasına olanak tanımıştır. Özellikle düşük öğrenme oranı ve Adam'ın kombinasyonu, modelin ani sıçramalar yerine daha istikrarlı bir şekilde öğrenmesini sağlamış; ancak daha karmaşık veri setlerinde (AISSLab-v5 gibi) bu parametrelerin sınırlı bir başarı sunduğu görülmüştür

Çizelge 4.1 Ham veri seti kullanılarak eğitilen CNN modellerinin karşılaştırmalı sınıflandırma performansları

Veri Seti	Veri Bölünmesi	Parametreler	Epok	Yöntem	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1 Skor (%)	ROC AUC (%)
AISSLab-v1			50	AlexNet	85,19	60,00	60,00	90,91	60,00	90,91
				VGG16	85,19	57,14	80,00	86,36	66,67	90,00
				XceptionNet	88,89	62,50	00,00	86,36	76,92	98,18
				EfficientNetB0	74,07	25,00	20,00	86,36	22,22	82,73
				ResNet18	81,48	50,00	40,00	90,91	44,44	75,45
				AlexNet	81,48	50,00	60,00	86,36	54,55	87,27
			100	VGG16	85,19	57,14	80,00	86,36	66,67	90,00
				XceptionNet	88,89	62,50	100,00	86,36	76,92	98,18
				EfficientNetB0	81,48	50,00	60,00	86,36	54,55	88,18
				ResNet18	81,48	50,00	60,00	86,36	54,55	75,45
				AlexNet	85,00	70,00	100,00	76,92	82,35	91,20
				VGG16	60,00	44,44	57,14	61,53	50,00	68,13
AISSLab-v2	Eğitim: %90 Test: %10	Öğrenme Oranı:0,0001 Optimizasyon:Adam Batch Boyutu:32	HAM	50	XceptionNet	80,00	71,42	84,61	71,42	78,02
					EfficientNetB0	70,00	55,55	71,42	69,23	62,50
					ResNet18	75,00	62,50	71,42	76,92	66,66
					AlexNet	85,00	75,00	85,71	84,61	80,00
					VGG16	65,00	50,00	57,14	69,23	53,33
					XceptionNet	75,00	66,66	57,14	84,61	61,53
				100	EfficientNetB0	75,00	62,50	71,42	76,92	66,66
					ResNet18	70,00	57,14	57,14	76,92	57,14
					AlexNet	58,82	64,29	81,82	16,67	72,00
					VGG16	58,82	64,29	81,82	16,67	72,00
AISSLab-v3			50	XceptionNet	70,59	80,00	72,73	66,67	76,19	65,15
				EfficientNetB0	76,47	73,33	100,00	33,33	84,62	46,97
				ResNet18	64,71	64,71	100,00	0	78,57	46,97
				AlexNet	64,71	66,67	90,91	16,67	76,92	66,67
				VGG16	58,82	64,29	81,82	16,67	72,00	71,21
			100	XceptionNet	70,59	80,00	72,73	66,67	76,19	63,64
				EfficientNetB0	76,47	73,33	100,00	33,33	84,62	42,42
				ResNet18	64,71	64,71	100,00	0	78,57	57,58

Çizelge 4.1 (Devamı) Ham veri seti kullanılarak eğitilen CNN modellerinin karşılaştırmalı sınıflandırma performansları

Veri Seti	Veri Bölünmesi	Parametreler	Epok	Yöntem	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1 Skor (%)	ROC AUC (%)
AISSLab-v4	Eğitim: %90 Test: %10	Öğrenme oranı:0,0001 Optimizasyon:Adam Batch Boyutu:32	50	AlexNet	44,44	44,44	51,07	71,64	45,30	71,30
				VGG16	44,44	44,44	51,07	71,64	45,30	63,00
				XceptionNet	51,85	35,89	54,76	75,86	40,74	75,05
				EfficientNetB0	51,85	51,85	56,54	78,77	45,91	72,26
				ResNet18	59,25	70,70	61,30	78,08	51,22	66,39
			100	AlexNet	40,74	41,01	44,44	69,88	40,98	69,76
				VGG16	40,74	41,11	48,69	70,12	41,66	63,92
				XceptionNet	55,55	38,96	57,14	77,14	44,64	76,27
				EfficientNetB0	55,55	58,65	62,50	80,05	54,01	76,72
				ResNet18	62,96	71,06	61,19	79,60	56,82	71,07
AISSLab-v5			50	AlexNet	17,65	9,72	25,00	73,21	13,94	65,18
				VGG16	11,76	6,25	12,50	70,71	08,33	55,51
				XceptionNet	35,29	15,87	30,36	75,00	20,83	58,26
				EfficientNetB0	35,29	39,58	38,39	79,36	30,49	65,92
				ResNet18	17,65	13,99	22,32	72,63	15,34	58,63
			100	AlexNet	23,53	18,89	28,57	74,87	19,84	66,96
				VGG16	11,76	06,25	12,50	70,71	08,33	57,07
				XceptionNet	23,53	11,46	23,21	73,33	14,38	56,25
				EfficientNetB0	35,29	32,08	35,71	78,78	30,78	68,30
				ResNet18	17,65	13,99	22,32	72,63	15,34	66,59

Çizelge 4.2’de ise artırılmış veri seti kullanılarak eğitilen CNN modellerinin performans karşılaştırmalarını göstermektedir. Bu tez çalışmasında AISSLab veri setinin beş farklı versiyonu üzerinde veri artırma uygulanarak yapılan deneysel analizler, meme kanseri sınıflandırmasında derin öğrenme modellerinin performansını ileri seviyede değerlendirmeyi amaçlamaktadır. Tüm deneylerde parametreler sabit tutulmuş—öğrenme oranı (learning rate) 0,0001, optimizasyon algoritması Adam ve batch boyutu 32 olarak belirlenmiş—ve bu yapı, modeller arası karşılaştırmada adil bir temel sunmuştur. Veri artırımı stratejisi ile veri çeşitliliği artırılmış ve modellerin genelleme kabiliyetlerinin güçlendirilmesi hedeflenmiştir. Modeller 50 ve 100 epok boyunca eğitilmiş, sonuçlar farklı metrikler açısından titizlikle raporlanmıştır.

AISSLab-v1 veri setinde veri artırımı etkisi açıkça gözlemlenmektedir. VGG16 modeli, hem 50 hem de 100 epokta %92,52 doğruluk ve %100 kesinlik ile en başarılı sonuçları sunmuştur; ROC AUC değeri ise %98’in üzerine çıkarak modelin güçlü bir ayırt etme kapasitesi sergilediğini göstermektedir. AlexNet modeli de %91,59 doğruluk ve %95,96 ROC AUC ile benzer şekilde oldukça yüksek bir performans göstermiştir. Veri artırımı XceptionNet, EfficientNetB0 ve ResNet18 gibi daha karmaşık modeller üzerinde de pozitif etkisi görülmekle birlikte, bu modellerin doğruluk oranları VGG16 ve AlexNet’e kıyasla biraz daha düşük kalmıştır. AISSLab-v2 veri setinde veri artırımı stratejisinin etkisi çarpıcı biçimde kendini göstermektedir. VGG16 modeli %97,50 doğruluk ve %99,69 ROC AUC ile en üstün performansı sunmuş; AlexNet modeli ise %95 doğruluk ile hemen ardından gelmiştir. Bu sonuçlar, veri artırımının küçük örneklem büyüklüklerine sahip veri setlerinde dahi oldukça belirgin iyileşmeler sağladığını doğrulamaktadır. XceptionNet modeli %92,50 doğruluk ve %97,06 ROC AUC ile dikkat çekmiş, ancak EfficientNetB0 ve ResNet18 modellerinin %75-78 doğruluk bandında kaldığı gözlemlenmiştir. AISSLab-v3 veri setinde AlexNet ve VGG16 modelleri tekrar öne çıkmıştır; AlexNet modeli 100 epokta %94,03 doğruluk ve %95,14 ROC AUC ile en iyi sonucu sunmuş, VGG16 da oldukça benzer bir başarı yakalamıştır. XceptionNet modeli %80,60 doğruluk ile orta seviyede kalırken, EfficientNetB0 ve ResNet18 daha düşük doğruluk ve ROC AUC sonuçları vermiştir. Bu tablo, veri artırımı özellikle AlexNet ve VGG16 gibi görece daha “klasik” mimarilerde güçlü bir genelleme yeteneği sağladığını göstermektedir. AISSLab-v4 veri setinde ise genel doğruluk oranlarının bir

miktar düřtüęü, ancak veri artırımı yine pozitif bir etkisi olduęu görölmektedir. AlexNet modeli %85,05 doęruluk ve %97,06 ROC AUC ile liderlięi korurken, VGG16 %85,05 doęruluk ile çok yakın bir performans göstermiştir. XceptionNet ve EfficientNetB0 modelleri %70-75 doęruluk bandına çıkarken, ResNet18 %58-59 aralıęında kalmıştır. Bu veri setinde veri artırımı, özğüllüęü artırdıęı ve genel dengeyi iyileřtirdięi anlaşılmaktadır. AISSLab-v5 veri seti ise en zorlu sınıflandırma görevlerinden birini temsil etmektedir. Burada veri artırımının etkisi özellikle AlexNet (%82,09 doęruluk) ve VGG16 (%88,06 doęruluk) modellerinde belirginleşmiştir; bu modeller ayrıca yüksek özğüllük (%93,42 ve %95,79) ve ROC AUC deęerleriyle (%96,22 ve %97,93) güçlü sonuçlar üretmiştir. XceptionNet, EfficientNetB0 ve ResNet18 gibi modellerin bu veri setinde sınırlı performans gösterdięi ve veri artırmanın bu modellerde yalnızca kısmi iyileřtirmeler sağladıęı dikkat çekmektedir.

Genel olarak deęerlendirildięinde, veri artırma uygulaması tüm veri setlerinde gözle görölür bir performans artışı sağlamış ve özellikle AlexNet ile VGG16 modellerinde doęruluk, kesinlik ve ROC AUC deęerlerinde kayda deęer iyileřmeler meydana getirmiştir. Parametrelerin sabit kalması veri artırmanın etkisini izole biçimde deęerlendirmeye olanak tanımış, böylece veri artırmanın özellikle küçük veri setlerinde ve klasik CNN mimarilerinde güçlü bir katkı sağladıęı net olarak ortaya konmuştur. Ancak ResNet18 ve EfficientNetB0 gibi daha derin mimarilerde bu etkinin sınırlı kaldıęı, bu modellerin performansını artırmak için hiperparametre optimizasyonları veya daha ileri düzenleme stratejilerinin gerekebileceęi anlaşılmaktadır. Bu sonuçlar, veri setinin yapısı ve sınıf dağılımına göre veri artırmanın etkisinin deęişebileceęini ve model seçiminde bu faktörlerin kritik olduęunu göstermektedir.

Çizelge 4.2 Veri artırma yöntemi kullanılarak eğitilen CNN modellerinin karşılaştırmalı sınıflandırma performansı

Veri Seti	Veri Bölünmesi	Parametreler	Epok	Yöntem	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1 Skor (%)	ROC AUC (%)	
AISSLab-v1	Eğitim: %90 Test: %10	Öğrenme Oranı :0,0001 Optimizasyon:Adam Batch Boyutu:32	ARTIRILMIŞ	50	AlexNet	91,59	95,56	86,00	96,49	90,53	95,96
					VGG16	92,52	100,00	84,00	100,00	91,30	98,25
					XceptionNet	79,44	79,17	76,00	82,46	77,55	86,35
					EfficientNetB0	74,77	84,85	56,00	91,23	67,47	85,16
					ResNet18	58,88	80,00	16,00	96,49	26,67	78,74
				100	AlexNet	89,72	95,35	82,00	96,49	88,17	97,51
					VGG16	92,52	100,00	84,00	100,00	91,30	98,32
					XceptionNet	83,18	86,36	76,00	89,47	80,85	87,51
					EfficientNetB0	77,57	86,11	62,00	91,23	72,09	87,58
					ResNet18	65,42	80,95	34,00	92,98	47,89	80,81
AISSLab-v2				50	AlexNet	95,00	95,24	95,24	94,74	95,24	99,69
					VGG16	97,50	100,00	95,24	100,00	97,56	99,69
					XceptionNet	85,00	82,61	90,48	78,95	86,36	95,80
					EfficientNetB0	77,50	78,57	78,57	76,32	78,57	88,28
					ResNet18	77,50	77,27	80,95	73,68	79,07	86,97
				100	AlexNet	95,00	95,24	95,24	94,74	95,24	99,75
					VGG16	95,00	95,24	95,24	94,74	95,24	99,69
					XceptionNet	92,50	92,86	92,86	92,11	92,86	97,06
					EfficientNetB0	78,75	79,07	80,95	76,32	80,00	91,48
					ResNet18	75,00	76,19	76,19	73,68	76,19	87,47
AISSLab-v3	50	AlexNet	92,54	91,11	97,62	84,00	94,25	94,10			
		VGG16	91,04	90,91	95,24	84,00	93,02	97,71			
		XceptionNet	76,12	75,00	92,86	48,00	82,98	81,05			
		EfficientNetB0	62,69	65,45	85,71	24,00	74,23	60,19			
		ResNet18	61,19	62,90	92,86	8,00	75,00	58,57			
	100	AlexNet	94,03	91,30	100,00	84,00	95,45	95,14			
		VGG16	91,04	90,91	95,24	84,00	93,02	97,71			
		XceptionNet	80,60	80,85	90,48	64,00	85,39	82,86			
		EfficientNetB0	61,19	66,67	76,19	36,00	71,11	65,43			
		ResNet18	61,19	64,29	85,71	20,00	73,47	63,33			


Çizelge 4.2 (Devamı) Veri artırma yöntemi kullanılarak eğitilen CNN modellerinin karşılaştırmalı sınıflandırma performansı

Veri Seti	Veri Bölünmesi	Parametreler	Epok	Yöntem	Doğruluk (%)	Kesinlik (%)	Duyarlılık (%)	Özgüllük (%)	F1 Skor (%)	ROC AUC (%)	
AISSLab-v4	Eğitim: %90 Test: %10	Öğrenme Oranı :0,0001 Optimizasyon:Adam Batch Boyutu:32	ARTIRILMIŞ	50	AlexNet	86,92	88,08	85,50	92,57	86,60	96,42
					VGG16	82,24	81,92	81,23	91,18	80,83	95,40
					XceptionNet	71,03	68,13	68,84	85,98	68,23	86,64
					EfficientNetB0	67,29	63,19	62,41	82,95	62,68	82,91
					ResNet18	57,01	65,66	56,65	78,28	56,90	76,26
				AlexNet	85,05	85,20	84,01	91,84	84,37	97,06	
				VGG16	85,05	84,13	87,30	93,22	84,49	96,55	
				XceptionNet	75,70	73,88	75,15	88,53	73,94	90,88	
				EfficientNetB0	70,09	66,67	66,92	85,02	66,73	86,84	
				ResNet18	58,88	61,52	56,57	78,93	56,83	80,23	
AlexNet				82,09	84,73	77,94	93,42	80,48	95,38		
VGG16				88,06	88,66	85,68	95,96	86,64	97,90		
XceptionNet				37,31	19,57	29,51	76,85	21,39	56,03		
EfficientNetB0				56,72	51,20	50,11	84,37	50,50	78,58		
ResNet18				49,25	43,92	37,91	80,70	38,13	66,39		
AlexNet				82,09	84,73	77,94	93,42	80,48	96,22		
VGG16				88,06	88,96	85,68	95,79	86,87	97,93		
XceptionNet				38,81	33,96	32,14	77,97	23,82	57,52		
EfficientNetB0				64,18	61,09	58,69	86,98	59,59	83,71		
ResNet18				50,75	45,89	42,07	81,12	42,37	71,34		

Şekil 4.1 incelendiğinde, veri artırımı veri artırma uygulanmış AISSLab veri setlerinin farklı alt sürümleri üzerinde eğitilen AlexNet, VGG16, XceptionNet, EfficientNetB0 ve ResNet18 modellerine ait ROC eğrilerini sunmaktadır. Şekilde, her bir alt veri seti için 50 ve 100 epok boyunca eğitilen modellerin ROC performansları ayrı ayrı gösterilmiş ve AUC değerleri belirtilmiştir. ROC eğrileri, modellerin pozitif sınıfları ne ölçüde doğru ayırt edebildiğini görselleştirirken, AUC değeri modelin genel ayırt etme kapasitesini numerik olarak özetlemektedir.

Şeklin ilk satırında (AISSLab-v1: Normal-Anormal sınıflandırması) veri artırma ve epok artışının etkisi açıkça gözlemlenmektedir; 50 epokta AlexNet (%91,96) ve VGG16 (%89,21) yüksek AUC değerleri elde etmiş, 100 epokta ise AlexNet %95,13 AUC ile en güçlü sonucu sunmuştur. İkinci satırda (AISSLab-v2: Malign-Normal sınıflandırması) AlexNet ve VGG16 modellerinin neredeyse kusursuz (%99,66-99,75 AUC) performans sergilediği dikkat çekmektedir. Üçüncü satır (AISSLab-v3: Benign-Malign sınıflandırması) daha dalgalı ROC eğrilerine sahiptir; AlexNet ve VGG16 yine en yüksek AUC değerlerine ulaşmış (%91,12 ve %89,10), ancak diğer modellerin daha düşük performans sergilediği görülmektedir. Dördüncü satır (AISSLab-v4: Çok Sınıflı Benign-Malign-Normal sınıflandırması) veri artırma çok sınıflı görevlerde de pozitif katkı sağladığını göstermektedir; AlexNet %89,51 AUC ile öne çıkarken VGG16 benzer bir performans sergilemiştir. Son satır (AISSLab-v5: BI-RADS sınıflandırması) en karmaşık sınıflandırma görevini temsil etmekte ve ROC eğrilerinin dalgalanması bu zorluğu yansıtmaktadır; burada AlexNet %97,66 AUC ile üstün bir başarı göstermiştir.

Genel olarak Şekil 4.1’de, veri artırma tüm veri setlerinde modellerin ayırt etme kapasitesini belirgin şekilde artırdığı görülmektedir. AlexNet ve VGG16 modelleri hemen her senaryoda en yüksek AUC değerlerine ulaşmış ve veri artırma ile birlikte daha güçlü genelleme yeteneği sergilemiştir. Daha derin yapıya sahip olan EfficientNetB0 ve ResNet18 modelleri ise küçük veri setlerinde ve karmaşık sınıflandırmalarda sınırlı başarı göstermiştir. Epok sayısının artırılması ise çoğu durumda ROC eğrilerini yukarı çekmiş, bu da daha uzun eğitim süreçlerinin model performansını iyileştirdiğini doğrulamaktadır. Bu sonuçlar, veri artırma etkisini ve model mimarileri arasındaki farklılıkları görsel olarak güçlü bir şekilde ortaya koymaktadır.



Şekil 4.1 Artırılmış AISSLab Veri Seti Roc Eğrileri: a) AISSLab-v1, b) AISSLab-v2, c) AISSLab-v3, d) AISSLab-v4, e) AISSLab-v5

4.2 Topluluk Model Performansı

Topluluk öğrenme yöntemleri, bireysel modellerin performansını artırmak ve sınıflandırma doğruluğunu iyileştirmek amacıyla kullanılmaktadır(Nanni vd. 2023). Bu çalışmada, TECNN ve QECNN olmak üzere iki farklı topluluk stratejisi uygulanmıştır. Çizelge 4.3, farklı topluluk modellerinin çeşitli veri setlerindeki doğruluk performanslarını göstermektedir.

Çizelge 4.3 incelendiğinde, meme kanseri teşhisi için geliştirilen TECNN ve QECNN modellerinin doğruluk performanslarını karşılaştırmalı olarak sunmaktadır. Çalışmada AlexNet, VGG16, XceptionNet, EfficientNetB0 ve ResNet-18 mimarileri farklı kombinasyonlar halinde topluluk öğrenmesi kapsamında bir araya getirilmiş ve çoğunluk oylaması yöntemi ile sınıflandırma gerçekleştirilmiştir.

Değerlendirme, AISSLab veri kümesinin beş farklı alt versiyonunda (AISSLab-v1'den AISSLab-v5'e) yapılmış ve modellerin eğitimleri 50 ve 100 epoch olacak şekilde iki ayrı senaryoda yürütülmüştür. Elde edilen sonuçlara bakıldığında genel olarak QECNN modelleri, %91,53 doğruluk ortalaması ile TECNN modellerine (%90,46) kıyasla bir miktar daha yüksek performans göstermiştir. Ancak bu üstünlük her model kombinasyonu için tutarlı değildir; örneğin TECNN yapısında AlexNet, VGG16 ve XceptionNet birleşimi, çoğu veri kümesinde yüksek doğruluk oranları ile öne çıkmıştır. Özellikle AISSLab-v2 veri setinde %98,75 doğruluk oranına ulaşılması, bu kombinasyonun güçlü bir sinerji oluşturduğunu ortaya koymaktadır. Benzer şekilde QECNN'de tüm modellerin bir araya getirildiği kombinasyonun aynı veri setinde %98,75 doğruluk sağlaması, geniş model çeşitliliğinin avantajını göstermektedir. Öte yandan AISSLab-v5 veri kümesi genel olarak daha düşük doğruluk oranları ile dikkat çekmekte, bu da BI-RADS sınıflamasının karmaşıklığını ve klinik zorluklarını yansıtmaktadır. Eğitim süresi açısından bakıldığında çoğu model kombinasyonu için 100 epoch ile yapılan eğitimler, doğruluk oranlarını artırmıştır. Genel ortalamalarda en yüksek başarıyı AlexNet, VGG16 ve XceptionNet kombinasyonu sağlamış; bu kombinasyon, farklı veri kümelerinde istikrarlı ve yüksek doğruluk değerleri ile dikkat çekmiştir. Sonuç olarak bu analiz, topluluk öğrenmesi ile geliştirilen meme kanseri sınıflandırma modellerinde model seçiminin, eğitim süresinin ve veri kümesi yapısının performans üzerinde belirleyici etkiler yarattığını göstermektedir. Elde edilen bulgular, daha yüksek çeşitlilik sağlayacak yeni kombinasyonların ve gelişmiş ön işleme tekniklerinin model performansını daha da ileri taşıma potansiyeline işaret etmemiştir.

Çizelge 4.3 Farklı topluluk modellerinin doğruluk metrikleri açısından karşılaştırılması

Yöntem		TECNN										QECNN	
Veri Seti	Epok	AlexNet, VGG16, XceptionNet	AlexNet, VGG16, EfficientNet B0	AlexNet, VGG16, ResNet18	AlexNet, XceptionNet EfficientNet B0	AlexNet, XceptionNet ResNet18	AlexNet, EfficientNet B0 ResNet18	VGG16, XceptionNet EfficientNet B0	VGG16, XceptionNet ResNet18	VGG16, EfficientNet B0 ResNet18	XceptionNet EfficientNet B0 ResNet18	AlexNet, VGG16, XceptionNet EfficientNet B0 ResNet18	
AISSLab-v1	50	94,39	91,59	89,72	89,72	89,72	77,57	90,65	90,65	77,57	75,70	90,65	
	100	94,39	92,52	89,72	89,72	87,85	81,31	91,59	90,65	84,11	79,44	93,46	
AISSLab-v2	50	97,50	98,75	98,75	87,50	86,25	86,25	88,75	87,50	86,25	77,50	92,50	
	100	95,00	98,75	96,25	87,50	83,75	86,25	86,25	85,00	88,75	77,50	93,75	
AISSLab-v3	50	92,54	91,04	88,06	70,15	64,18	67,16	65,67	62,69	67,16	61,19	67,16	
	100	92,54	91,04	89,55	73,13	70,15	68,66	68,66	67,16	67,16	59,70	71,64	
AISSLab-v4	50	86,92	87,85	85,98	71,03	73,83	79,44	75,70	71,03	75,70	61,68	83,17	
	100	84,11	90,65	87,85	76,64	75,70	79,44	83,18	77,57	76,64	65,42	87,85	
AISSLab-v5	50	83,58	86,57	82,09	73,13	71,64	64,18	76,12	73,13	68,66	55,22	77,61	
	100	83,58	86,57	82,09	79,10	73,13	70,15	82,09	74,63	74,63	64,18	82,09	
Overall		90,46	91,53	89,01	79,76	77,62	76,04	80,87	78,00	76,66	67,75	83,99	

Şekil 4.2, TECNN modelinin 50 ve 100 epok boyunca eğitilerek elde edilen ağırlıklarının test verisi üzerinde değerlendirilmesi sonucu oluşturulan karışıklık matrislerini göstermektedir. Matrisler veri artırma uygulanmış AISSLab veri setlerinin farklı sürümleri için modelin doğru ve yanlış sınıflandırmalarını ayrıntılı olarak ortaya koymaktadır.

(a) için TECNN modeli, 50 epokta test setindeki 57 normal örneğin tamamını doğru sınıflandırmış, 9 anormal örneği yanlış tahmin etmiştir. 100 epokta yanlış anormal tahmin sayısı 8'e düşmüştür. Bu sonuçlar, epok sayısının artmasının modelin test setinde anormal sınıf üzerindeki doğruluğunu iyileştirdiğini göstermektedir.


(b) için hem 50 hem 100 epokta model son derece başarılı bir test performansı sergilemiştir; tüm normal örnekler doğru sınıflandırılmış ve malign sınıfta yalnızca 1 yanlış tahmin yapılmıştır. Epok artışı bu veri setinde test başarısını sabit ve yüksek düzeyde tutmuştur.

(c) için matrisler, benign sınıfta 21 doğru ve 4 yanlış tahmin, malign sınıfta ise 40 doğru ve 2 yanlış tahmin ile modelin dengeli bir başarı sunduğunu göstermektedir. Epok artışı bu veri setinde önemli bir değişiklik yaratmamış, sonuçlar tutarlılığını korumuştur.

(d) matrisleri, modelin test verisinde çok sınıflı yapıdaki başarısını ortaya koymaktadır. 50 epokta benign sınıfta 17 doğru, 3 yanlış; malign sınıfta 31 doğru, 3 yanlış; normal sınıfta 46 doğru tahmin yapılmıştır. 100 epokta benign sınıftaki doğruluk 21'e yükselmiş, yanlış tahminler azalmış; normal sınıf ise 47 doğru tahminle yüksek başarı göstermiştir. Epok artışı burada özellikle benign ve normal sınıflarda test başarısını artırmıştır.

(e) için matrisler, en karmaşık sınıflandırmayı temsil etmektedir. 50 epokta BI-RADS 4 sınıfında 27 doğru tahmin dikkat çekerken, BI-RADS 5 sınıfında 12 doğru tahmin yapılmıştır. 100 epokta BI-RADS 4 doğruluğu korunmuş, BI-RADS 5 sınıfında test doğruluğu sabit kalmıştır. Genel olarak modelin belirli sınıflarda yüksek başarı sergilediği, bazı sınıflarda ise zorluk yaşadığı gözlemlenmektedir.

Sonuç olarak Şekil 4.2, TECNN modelinin veri artırma uygulanmış veri setleri üzerinde test setindeki sınıflandırma performansını görselleştirmektedir. İkili sınıflandırmalarda (AISSLab-v1 ve v2) modelin test başarısı son derece yüksek olup, çok sınıflı görevlerde (AISSLab-v4 ve v5) epok artışının test performansını belirgin şekilde iyileştirdiği görülmektedir.



Şekil 4.2 TECNN 50-100 epok karışıklık matrislerinin karşılaştırılması: a) AISSLab-v1, b) AISSLab-v2, c) AISSLab-v3, d) AISSLab-v4, e) AISSLab-v5

Şekil 4.3, QECNN modelinin 50 ve 100 epok boyunca eğitilerek elde edilen ağırlıkları kullanarak yapılan test verisi değerlendirmeleri sonucunda oluşan karışıklık matrislerini göstermektedir. Şekildeki her bir alt grafik, veri artırımı uygulanmış AISSLab veri setlerinin farklı sürümleri için modelin doğru ve yanlış sınıflandırmalarını detaylandırmaktadır. Matrisler modelin eğitim değil, yalnızca test setindeki performansını yansıtmaktadır.

(a) AISSLab-v1 için QECNN modeli, 50 epokta test setindeki 56 normal örneğin 55'ini doğru sınıflamış ve 1 tanesini yanlış tahmin etmiştir; anormal sınıfta ise 9 yanlış tahmin gözlemlenmiştir. 100 epokta anormal sınıfta doğru tahmin sayısı 44'e yükselmiş, yanlış sınıflamalar azalmıştır. Bu, epok sayısının artmasının modelin test setindeki genelleme başarısını artırdığını göstermektedir.

(b) AISSLab-v2 için 50 epokta malign sınıfta 6 yanlış tahmin yapılırken, normal sınıftaki tüm örnekler doğru tahmin edilmiştir. 100 epokta malign sınıftaki yanlış tahminler 5'e düşmüştür. Test seti sonuçları modelin normal sınıfta yüksek başarı sağladığını, malign sınıfta ise epok artışı ile iyileşme kaydedildiğini göstermektedir.

(c) AISSLab-v3 matrislerinde benign sınıfta dikkat çeken bir hata oranı bulunmaktadır. 50 epokta benign sınıfta yalnızca 5 doğru tahmin yapılırken, 20 örnek yanlış sınıflandırılmıştır. 100 epokta benign sınıftaki doğruluk 8'e yükselmiştir. Malign sınıfta ise her iki durumda da yüksek doğruluk (%40 doğru) korunmuştur. Bu durum, benign sınıfın test setinde daha zor ayrıştığını ortaya koymaktadır.

(d) AISSLab-v4 matrislerinde modelin çok sınıflı yapıdaki test başarısı gözlenmektedir. 50 epokta benign sınıfta 14 doğru, 6 yanlış; malign sınıfta 30 doğru, 4 yanlış; normal sınıfta ise 45 doğru tahmin yapılmıştır. 100 epokta benign sınıfta doğruluk artmış (19 doğru), malign sınıfta ise kısmen düşüş olmuştur. Normal sınıfta doğru tahminler 49'a yükselmiştir. Bu sonuçlar epok sayısının artmasının özellikle benign ve normal sınıflarda test performansını artırdığını göstermektedir.


(e) AISSLab-v5 için karışıklık matrisleri en karmaşık sınıflandırma görevini temsil etmektedir. 50 epokta BI-RADS 4 sınıfında 27 doğru tahmin yapılırken, diğer sınıflarda hata oranları daha yüksektir. 100 epokta BI-RADS 5 sınıfındaki doğruluk artarak 10'a ulaşmıştır. BI-RADS 4 sınıfındaki doğruluk korunmuştur. Bu tablo, QECNN modelinin test setinde özellikle BI-RADS

4 sınıfında güçlü genelleme sağladığını, ancak diğer sınıflarda sınırlı başarı gösterdiğini ortaya koymaktadır.

Genel olarak Şekil 4.3, QECNN modelinin veri artırımı uygulanmış veri setleri üzerinde test veri setindeki sınıflandırma başarısını açıkça göstermektedir. İkili sınıflandırmalarda (AISSLab-v1 ve v2) model yüksek test başarısı sergilerken, benign-malign ayırımında (AISSLab-v3) özellikle benign sınıfın zorlayıcı olduğu görülmektedir. Çok sınıflı görevlerde (AISSLab-v4 ve v5) epok artışı test setindeki hata oranlarını belirgin şekilde düşürmüş, modelin genelleme yeteneğini iyileştirmiştir.

Bu tez çalışmasında TECNN ve QECNN modellerinin veri artırma uygulanmış AISSLab veri setlerinde 50 ve 100 epok boyunca eğitilmiş ağırlıklarla test verisi üzerindeki sınıflandırma performansları karşılaştırılmıştır. Genel olarak, her iki model de ikili sınıflandırma görevlerinde (AISSLab-v1 ve v2) yüksek doğruluk sergilemiş; özellikle TECNN modeli malign-normal ayırımında daha istikrarlı ve düşük hata oranları sunmuştur. QECNN modeli ise anormal sınıf gibi belirli alt sınıflarda biraz daha iyi genelleme göstermiştir. Çok sınıflı görevlerde (AISSLab-v4 ve v5) her iki modelde de karmaşıklığın arttığı ve hata oranlarının yükseldiği gözlemlenirken, TECNN modelinin özellikle benign ve normal sınıflarda daha dengeli bir başarı sağladığı, QECNN modelinin ise bazı sınıflarda daha fazla sapma gösterdiği görülmüştür. Epok artışı her iki modelde de genel olarak test başarısını iyileştirmiştir. Sonuç olarak, TECNN modeli daha tutarlı doğruluk ve dengeli sınıflandırma sağlarken, QECNN modeli belirli sınıflarda daha güçlü bir genelleme yeteneği sergilemiştir.

Topluluk öğrenme, sınıflandırma doğruluğunu artırmada etkili bir yöntemdir, ancak model sayısının artırılması her zaman daha iyi sonuçlar doğurmaz. Özellikle, belirli veri setlerinde üçlü topluluk CNN modelleri, daha az hesaplama yükü ve daha dengeli karar mekanizması ile üstün performans sergilemiştir. Buna karşılık, beşli topluluk CNN modeli, geniş model çeşitliliği nedeniyle bazı durumlarda aşırı öğrenme veya hata yayılımına neden olabilmektedir. Bu durum, topluluk öğrenmede model çeşitliliğinin ve sayısının, problem türü ve veri dağılımına göre dikkatlice optimize edilmesi gerektiğini ortaya koymaktadır.



Şekil 4.3 QECNN 50-100 epok karışıklık matrislerinin karşılaştırılması: a) AISSLab-v1, b) AISSLab-v2, c) AISSLab-v3, d) AISSLab-v4, e) AISSLab-v5

4.3 Açıklanabilir Yapay Zeka Sonuçlarının Değerlendirilmesi

Açıklanabilir yapay zeka teknikleri, derin öğrenme modellerinin karar mekanizmalarını şeffaf hale getirmek ve modelin sınıflandırma süreçlerinin güvenilirliğini artırmak amacıyla yaygın olarak kullanılmaktadır. Bu çalışmada, EfficientNetB0, VGG16 ve AlexNet modellerinin karar süreçlerini incelemek amacıyla Grad-CAM, LIME ve LIME-Mask tabanlı açıklanabilirlik yöntemleri uygulanmıştır. Çizelge 4.4, bu üç model için üretilen açıklanabilir yapay zeka görsellerini sunmakta ve modellerin meme lezyonları üzerindeki dikkat dağılımlarını karşılaştırmalı olarak göstermektedir.

Grad-CAM sonuçları değerlendirildiğinde, EfficientNetB0 ve VGG16 modellerinin lezyon bölgelerine daha belirgin şekilde odaklandığı, özellikle malign ve benign ayırımında güçlü bir ayırım kabiliyeti sergilediği gözlemlenmiştir. AlexNet modeli ise her ne kadar bazı görüntülerde doğru sınıflandırmalar yapsa da, dikkat haritalarında odaklanması gereken lezyon bölgeleri dışındaki alanları vurguladığı durumlar tespit edilmiştir. Bu bulgu, daha derin ve ölçeklenebilir mimarilerin (özellikle EfficientNetB0 ve VGG16) tıbbi görüntülerde daha güvenilir ve anlamlı özellik çıkarımı yapabildiğini ortaya koymaktadır.

LIME tabanlı görselleştirmeler incelendiğinde, VGG16 ve EfficientNetB0 modellerinin sınıflandırma sırasında lezyon bölgelerini yoğun biçimde referans aldığı ve çevresel gürültüyü daha az dikkate aldığı belirlenmiştir. Buna karşın, AlexNet modelinin bazı durumlarda sınıflandırma yaparken lezyon çevresi dahil geniş bölgeleri vurguladığı ve bu nedenle spesifik detayları yeterince ayırt edemediği gözlemlenmiştir. Bu durum, daha derin mimarilerin düşük seviyeli detayları daha başarılı bir şekilde modellediğini göstermektedir.

LIME-Mask yöntemi ile elde edilen görseller ise tüm modellerin sınıflandırmada belirli temel özellikleri yakalayabildiğini göstermektedir. Bununla birlikte, EfficientNetB0 modelinin lezyon bölgelerini daha net ve ayrışabilir biçimde tespit ettiği ve bu doğrultuda daha güçlü bir genelleme yeteneği sergilediği dikkat çekmektedir. Bu sonuçlar, EfficientNetB0 modelinin meme lezyonlarının sınıflandırılmasında detay seviyesinde

yüksek güvenilirlik sağladığını doğrulamaktadır.

Ayrıca bu çalışma kapsamında, açıklanabilirlik performansının klinik geçerliliğini değerlendirmek amacıyla 35 yıllık deneyime sahip bir radyoloji uzmanı ile görüşme gerçekleştirilmiştir. Test veri setine ait MR görüntüleri hekime sunulmuş ve anomalinin yoğunluk gösterdiği bölgelerin işaretlenmesi istenmiştir. Uzmanın işaretlediği bölgeler açıklanabilir yapay zeka çıktıları ile karşılaştırılmış ve EfficientNetB0 ile VGG16 modellerinin dikkat haritalarının klinik olarak anlamlı bölgelerle yüksek düzeyde örtüştüğü tespit edilmiştir. AlexNet modelinin bazı örneklerde ise beklenen klinik bölgeler dışında alanlara odaklandığı belirlenmiştir. Bu değerlendirme, açıklanabilirlik yöntemlerinin klinik karar destek sistemleri için uygulanabilirliğini ve güvenilirliğini göstermesi açısından önemli bir bulgu olarak öne çıkmaktadır.

Sonuç olarak, EfficientNetB0 ve VGG16 modelleri açıklanabilirlik açısından daha odaklı ve güvenilir dikkat dağılımı sağlarken, AlexNet modeli sınırlı odaklanma kapasitesi nedeniyle bazı durumlarda yanlış bölgelere yoğunlaşmış ve bu durum modelin klinik güvenilirliğini kısmen azaltmıştır. Elde edilen sonuçlar, açıklanabilirlik tekniklerinin model performansını sadece nicel olarak değil, aynı zamanda nitel olarak değerlendirmek için güçlü bir araç sunduğunu ve tıbbi uygulamalarda kritik bir rol oynadığını ortaya koymaktadır.

Çizelge 4.4 Farklı CNN modelleri için Grad-CAM, LIME ve LIME-Mask tabanlı açıklanabilir yapay zeka görselleştirmeleri.

Açıklanabilir Yapay Zeka Gerçek Sınıflandırma ile Görselleştirme												
Veri seti	EfficientNet Model				VGG16 Model				Alexnet Model			
	Original Images	Grad-CAM	LIME	LIME-Mask	Original Images	Grad-CAM	LIME	LIME-Mask	Original Images	Grad-CAM	LIME	LIME-Mask
Normal												
Normal												
Malignant												
Benign												
Normal												
Malignant												
Benign												

4.4 Önerilen Yöntemin Literatürdeki Diğer Yöntemlerle Karşılaştırmalı Analizi

Literatürde kullanılan başlıca DL tabanlı çalışmalar ve doğruluk oranları, bu çalışmada önerilen modelle karşılaştırmalı olarak aşağıdaki Çizelge 4.5’te sunulmuştur:

Çizelge 4.5 Literatürdeki meme kanseri sınıflandırma çalışmalarının karşılaştırılması

Yöntem	Doğruluk (%)	Mimari Yapı	XAI Yöntemi
Montaha vd. (2021)	98,02	VGG16 tabanlı BreastNet18	-
Abbasniya vd. (2022)	96,46	Inception-ResNet-v2 / XGBoost, LightGBM, CatBoost (IRv2-CXL)	Grad-CAM
Samee vd. (2022)	98,50	AlexNet, VGG16, GoogleNet	-
Al-Hejri vd. (2023)	98,58	Ensemble Learning, ViT	-
Alotaibi vd. (2023)	98,17	ViT, DeiT, Soft Voting	-
Melekoodappattu vd. (2023)	98,00	Ensemble Learning Modifiye CNN, LBP, Gabor, LDA, UMAP, Ensemble	-
Preethi vd. (2023)	98,30	Ensemble (EfficientNet, ResNet101, VGG19)	-
Sannasi Chakravarthy, Bharanidharan, ve Rajaguru (2023)	97,93	AlexNet, GoogleNet, ResNet50, DenseNet121	-
Ahmed vd. (2024)	76,00	VGG16, Inception V3, ResNet18, ResNet50	Grad-CAM, LIME, SHAP
Al-Tam vd. (2024)	97,73	YOLOv8 tespit + ViT tabanlı ResNet50 sınıflandırma	Grad-CAM
Lu vd. (2024)	96,80	ResNet-50	Grad-CAM
Nemade vd. (2024)	98,10	VGG16, InceptionV3, VGG19 / Ensemble Learning	-
Peta ve Koppu (2024)	97,85	ESAE-Net	LIME, SHAP, Grad-CAM
Önerilen Yöntem (BCECNN)	98,75	BCECNN (AlexNet, VGG16, ResNet18, EfficientNetB0, XceptionNet)	Grad-CAM, LIME, LIME-Mask

Çizelge 4.5 incelendiğinde, literatürdeki birçok çalışma yüksek doğruluk oranlarına ulaşmış olmakla birlikte, çoğunlukla yalnızca tekil CNN mimarileri veya sınırlı sayıda ensemble yaklaşımına dayandığı görülmektedir. BCECNN modeli, bu modellerden farklı olarak birden fazla mimariyi birleştirerek en yüksek doğruluk oranlarından birine (%98,75) ulaşmıştır. Ayrıca, açıklanabilir yapay zeka entegrasyonu sayesinde karar mekanizmalarının görselleştirilebilmesi, yalnızca model doğruluğu açısından değil, klinik uygulanabilirlik ve güvenilirlik açısından da önemli bir katkı sunmaktadır. Çalışmada kullanılan AISSLab veri seti, önceki çalışmalardan elde edilen özel veri kümelerinden yola çıkılarak hazırlanmış ve yalnızca bu çalışmada ilk kez test edilmiştir. Veri setinin benign, malign ve normal sınıflandırmasını içermesi ve artırılmış ön işleme adımlarından geçirilmiş olması, modelin performansını desteklemiştir.

5. TARTIŞMA ve SONUÇ

Meme kanseri, dünya genelinde kadınlar arasında en sık görülen malignite türlerinden biri olup, mortalite oranlarını düşürmede erken teşhisin önemi büyüktür. Geleneksel radyolojik tanı süreçleri, radyologların deneyim ve yorumlarına dayandığı için subjektif hatalara açık olmakta, bu da yanlış pozitif veya yanlış negatif sonuçlara yol açabilmektedir. Son yıllarda yapay zekâ tabanlı yaklaşımlar, özellikle derin öğrenme modelleri, meme kanseri teşhisinde doğruluk oranlarını artırmak, süreçleri otomatikleştirmek ve insan hatasını minimize etmek amacıyla yaygın bir şekilde kullanılmaya başlanmıştır. Ancak, literatürdeki birçok çalışma genellikle tek bir CNN mimarisi veya geleneksel transfer öğrenme yöntemlerini temel almakta, bu da modellerin genelleme kapasitesini sınırlamakta ve farklı klinik ortamlarda veya hasta gruplarında performans kayıplarına neden olmaktadır.

Bu tez çalışmasında, meme kanseri tanısında derin öğrenme yöntemlerinin doğruluk, genellenebilirlik ve açıklanabilirlik açılarından etkinliğini artırmak amacıyla, topluluk öğrenme stratejileriyle desteklenen yeni bir sınıflandırma çerçevesi olan BCECNN önerilmiştir. Geliştirilen model, temel olarak farklı mimari yapıya sahip beş popüler CNN modelinin (AlexNet, VGG16, ResNet18, EfficientNetB0, XceptionNet) entegrasyonu ile oluşturulan TECNN ve QECNN yapılarını içermekte; bu yapılar çoğunluk oylaması yöntemiyle nihai karar üretmektedir. Ayrıca, modelin karar verme süreçlerini şeffaflaştırmak amacıyla Grad-CAM, LIME ve LIME-Mask gibi açıklanabilir yapay zeka teknikleri entegre edilmiştir. Çalışmada kullanılan AISSLab veri seti, benign, malign, normal ve BI-RADS sınıflarını kapsayan çeşitli varyantlara sahip olmasıyla literatürdeki mevcut veri kümelerinden ayrılmaktadır. Ayrıca veri seti içerinden elde edilen beş farklı versiyon üzerinde yapılan çalışmalar literatüre destek olmuştur.

Elde edilen bulgular, öncelikle topluluk öğrenme yapılarının, tekil CNN modellerine kıyasla belirgin derecede daha yüksek sınıflandırma başarısı sunduğunu ortaya koymuştur. Özellikle TECNN yapısında AlexNet, VGG16 ve XceptionNet modellerinin birleşimi, AISSLab-v2 veri setinde %98,75 doğruluk oranına ulaşarak, literatürdeki benzer çalışmaların performansını aşmıştır. Bu durum, model çeşitliliğinin sınıflandırma doğruluğunu artırmadaki etkisini destekleyerek farklı CNN mimarilerinin tamamlayıcı

özellik çıkarma kapasitelerinin bir araya getirilmesinin sinerjik bir etki yarattığını göstermektedir. Öte yandan, QECNN yapısı, daha geniş model seti ile bazı sınıflarda üstünlük göstermiş olsada, TECNN'nin daha dengeli ve istikrarlı bir başarı profili sunduğu anlaşılmıştır. Bu bağlamda, model sayısının artmasının her zaman performansa doğrudan pozitif katkı sağlamadığı, aksine aşırı benzer mimarilerin öğrenme süreçlerinde hata yayılımına neden olabileceği sonucuna ulaşılmıştır.

Veri seti yapısı ve sınıflandırma zorluğu, model başarısı üzerinde doğrudan etkili olmuştur. AISSLab-v1 ve v2 gibi ikili sınıflandırma görevlerinde oldukça yüksek doğruluk oranları elde edilirken; AISSLab-v4 ve v5 gibi çok sınıflı yapıların bulunduğu veri kümelerinde model performansında görece düşüşler gözlemlenmiştir. Özellikle BI-RADS sınıflamasına dayalı AISSLab-v5 veri seti, sınıf dengesizliği ve sınıflar arası benzerlikler nedeniyle tüm model kombinasyonları için düşük başarı seviyeleri sergilemiştir. Bu durum, tıbbi görüntü sınıflandırmasında sınıf sayısının ve tanı kriterlerinin karmaşıklığının modelin genelleme kapasitesini zorladığını göstermektedir. Bununla birlikte, TECNN modeli çok sınıflı yapılarda dahi benign ve normal sınıflarda görece daha istikrarlı sonuçlar üreterek avantaj sağlamıştır.

Performans metriklerine ilişkin yapılan değerlendirmelerde, TECNN ve QECNN modelleri duyarlılık, özgüllük, F1 skoru ve ROC AUC gibi ölçütler açısından da tatmin edici sonuçlar vermiştir. TECNN modeli özellikle malign sınıfın doğru tespiti konusunda yüksek duyarlılık sergilerken, QECNN yapısı normal sınıf için daha düşük hata oranları sunmuştur. Epok sayısının artırılması, çoğu veri setinde test doğruluğunu iyileştirmiş ve modelin aşırı uyum eğilimlerini baskılamada etkili olmuştur. Ayrıca, düşük öğrenme oranı ve Adam optimizatörü kullanımı, modelin kararlı bir öğrenme eğrisi izlemesini sağlamış ve ani performans dalgalanmalarının önüne geçmiştir.

Açıklanabilir yapay zeka yöntemlerinin entegrasyonu, modelin klinik uygulanabilirliğini ve güvenilirliğini artırarak önemli bir katkı sunmuştur. Grad-CAM görselleştirmeleri, özellikle EfficientNetB0 ve VGG16 modellerinin lezyon bölgelerine yüksek oranda odaklandığını göstermiş; bu da modelin karar verme süreçlerinde anlamlı görsel temsiller ürettiğini ortaya koymuştur. AlexNet modelinin bazı durumlarda odaklanması gereken

alanlar dışında aktivasyon göstermesi ise, daha derin mimarilerin tıbbi görüntü analizinde daha güvenilir sonuçlar sunduğunu doğrulamaktadır. LIME ve LIME-Mask görselleştirmeleri, modelin sınıflandırma kararlarında hangi bölgesel özelliklerin etkili olduğunu açıkça göstermiş, özellikle benign ve malign ayırımında niteliksel değerlendirme yapılabilmesine olanak tanımıştır. Bu açıklamalar, modelin karar mekanizmasını doğrulamada klinisyenlerin görüşleriyle de desteklenmiş ve açıklanabilir yapay zekanın tıbbi tanı süreçlerinde kullanılabilirliğini kanıtlamıştır.

BCECNN modelinin literatürdeki diğer yöntemlerle karşılaştırmalı analizi, önerilen yaklaşımın yüksek doğruluk oranları ile öne çıktığını göstermektedir. Örneğin, ViT tabanlı yaklaşımlar, BreastNet18 veya modifiye CNN yapıları gibi yöntemler %97-98 doğruluk bandında sonuçlar üretmişken; BCECNN modeli bu seviyeyi aşarak %98,75 gibi yüksek bir başarı sağlamıştır. Bununla birlikte, bu çalışmanın özgün katkısı sadece doğruluk oranı değil, aynı zamanda farklı CNN mimarilerinin sinerjik kombinasyonu ve XAI tekniklerinin bütüncül entegrasyonudur. Ayrıca, AISSLab veri setinin bu çalışmaya özel olarak yapılandırılması, modelin farklı sınıf yapılarında test edilmesini mümkün kılmış ve elde edilen sonuçların genellenebilirliğini artırmıştır.

Bu çalışmanın tüm yenilikçi yönlerine rağmen bazı sınırlılıkları mevcuttur. Öncelikle, AISSLab veri seti üzerinde gerçekleştirilen deneyler, sınırlı görüntü sayısına ve bazı alt veri kümelerinde gözlenen sınıf dengesizliğine sahiptir. Özellikle AISSLab-v5 veri kümesinde yer alan BI-RADS sınıfları arasında belirgin örnek sayısı farkları, modelin düşük temsil edilen sınıflarda performans düşüklüğü yaşamasına neden olmuştur. Bu durum, modelin çok sınıflı yapıdaki öğrenme potansiyelinin sınırlı kalmasına yol açmış ve sınıf dengesizliğinin, genelleme performansını doğrudan etkileyen bir faktör olduğunu göstermiştir.

Modelin gelecekteki geliştirilme potansiyeli oldukça geniştir. Özellikle GAN tabanlı veri çoğaltma yöntemlerinin entegre edilmesi, sınıf dengesizliği probleminin hafifletilmesine katkı sağlayabilir. Aynı zamanda SHAP, Entegre Gradyanlar gibi daha gelişmiş XAI tekniklerinin entegrasyonu ile modelin karar verme süreci çok daha detaylı biçimde yorumlanabilir hale getirilebilir. Ayrıca, farklı modalitelerde (ör. ultrasonografi, MRI)

eđitilen multimodal modellerin BCECNN ile entegre edilmesi, modelin klinik senaryolardaki esnekliđini artırabilir.

Buna ek olarak, bu modelin gerek zamanlı alıřan bir klinik karar destek sistemine entegre edilmesi hedeflenebilir. Streamlit gibi aık kaynaklı kullanıcı arayüzleri aracılığıyla geliştirilecek web tabanlı prototipler sayesinde, radyologların görüntüleri sisteme yükleyerek hem sınıflandırma sonucunu hem de XAI aıklamalarını aynı platformda elde etmeleri sağlanabilir. Bu tür uygulamalar, modelin sahada kullanılabilirliğini test etme ve klinik adaptasyonunu kolaylaştırma açısından önem taşımaktadır.

BCECNN modeli, sadece akademik bir sınıflandırma başarısından öte, doğrudan klinik uygulamalarda kullanılacak pratik bir yapay zeka özümü sunmaktadır. alıřmada elde edilen yüksek doğruluk oranları, aıklanabilirlik teknikleriyle desteklenmiş yorumlanabilir ıktı yapısı ve geniş veri alt kümelerinde test edilmiş genelleme kapasitesi, bu modelin gelecekte klinisyenlerin tanısal karar süreçlerine entegre edilebilecek bir yardımcı sistem olarak kullanılabilirliğini göstermektedir. Özellikle erken evrede malignite şüphesi taşıyan lezyonların hızlı ve doğru bir şekilde tespit edilmesi, tedavi planlamasında ciddi avantajlar sağlayacaktır. Bu bağlamda alıřma, hem tıbbi yapay zeka literatürüne katkı sunmakta hem de toplumsal sağlık düzeyinin artırılması yolunda yapay zeka tabanlı teknolojilerin etkili bir şekilde nasıl kullanılabilirliğini ortaya koymaktadır.

6. KAYNAKLAR

- Abbasniya M R, Sheikholeslamzadeh S A, Nasiri H, Emami S, 2022, Classification of breast tumors based on histopathology images using deep features and ensemble of gradient boosting methods, *Computers and Electrical Engineering*, 103, 108382.
- Adam R, Bressan S, Marini C, Martincich L, Tagliafico A S, 2023, Deep learning applications to breast cancer detection by magnetic resonance imaging: a literature review, *Breast Cancer Research*, 25(1), 87.
- Agnes S A, Uthayarani S, Sundararajan V, 2020, Classification of mammogram images using multiscale all convolutional neural network (MA-CNN), *Journal of Medical Systems*, 44(1), 30.
- Ahmed M, Khan M A, Sharif M I, Saba T, Rehman A, 2024, Enhancing breast cancer diagnosis in mammography: evaluation and integration of convolutional neural networks and explainable AI, *arXiv preprint*, arXiv:2404.03892.
- Al-Dhabyani W, Gomaa M, Khaled H, Fahmy A, 2020, Dataset of breast ultrasound images, *Data in Brief*, 28, 104863.
- Al-Hejri A, Fazea M, Al-Tam R, Al-antari M, Alshamrani S, Sable A, 2024, AISSLab Breast Cancer Dataset: Toward General AI Harmonization with Real Mammogram Imagin, *Mendeley Data*, V1, doi: 10.17632/zp8yfhvndv.1
- Al-Hejri A M, Alshamrani S S, Al-Antari M A, Al-Tam R M, 2022, ETECADx: Ensemble self-attention transformer encoder for breast cancer diagnosis using full-field digital X-ray breast images, *Diagnostics*, 13(1), 89.
- Alotaibi A, Mahmmod B M, Alturki M, Saeed R A, 2023, Vit-deit: An ensemble model for breast cancer histopathological images classification, *Proceedings of the 2023 1st International Conference on Advanced Innovations in Smart Cities (ICAISC)*, IEEE, 1–6.
- Alshawwa I A, El-Mashharawi H Q, Salman F M, Abu Al-Qumboz M N, Abunasser B S, Abu-Naser S S, 2024, Advancements in Early Detection of Breast Cancer: Innovations and Future Directions, *International Journal of Academic Engineering Research (IJAER)*, 8(8), 15–24.

- Al-Tam R M, Al-Hejri A M, Alshamrani S S, Al-Antari M A, Narangale S M, 2024, Multimodal breast cancer hybrid explainable computer-aided diagnosis using medical mammograms and ultrasound images, *Biocybernetics and Biomedical Engineering*, 44(3), 731–758.
- Altameem A, Mahanty C, Poonia R C, Saudagar A K J, Kumar R, 2022, Breast cancer detection in mammography images using deep convolutional neural networks and fuzzy ensemble modeling techniques, *Diagnostics*, 12(8), Article ID: 1812.
- Anaam A, Al-Antari M A, Gofuku A, 2023, A deep learning self-attention cross residual network with Info-WGANGP for mitotic cell identification in HEP-2 medical microscopic images, *Biomedical Signal Processing and Control*, 86, 105191.
- Ayana G, Dese K, Dereje Y, Kebede Y, Barki H, Amdissa D, Husen N, Mulugeta F, Habtamu B, Choe S W, 2023, Vision-transformer-based transfer learning for mammogram classification, *Diagnostics*, 13(2), Article ID: 20178.
- Balasubramanian A A, Al-Heejawi S M A, Singh A, Breggia A, Ahmad B, Christman R, Ryan S T, Amal S, 2024, Ensemble deep learning-based image classification for breast cancer subtype and invasiveness diagnosis from whole slide image histopathology, *Cancers*, 16(12), Article ID: 22222.
- Balve A K, Hendrix P, 2024, Interpretable breast cancer classification using CNNs on mammographic images, *arXiv preprint*, arXiv:2408.13154.
- Bazira P J, Ellis H, Mahadevan V, 2022, *Anatomy and physiology of the breast*, Surgery (Oxford), 40(2), 79–83.
- Carney P A, Miglioretti D L, Yankaskas B C, Kerlikowske K, Rosenberg R, Rutter C M, Geller B M, Abraham L A, Taplin S H, Dignan M, Cutter G, Ballard-Barbash R, 2003, Individual and combined effects of age, breast density, and hormone replacement therapy use on the accuracy of screening mammography, *Annals of Internal Medicine*, 138(3), 168–175.
- Chollet F, 2017, Xception: Deep learning with depthwise separable convolutions, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1251–1258.
- Coffey K, Jochelson M S, 2022, Contrast-enhanced mammography in breast cancer

- screening, *European Journal of Radiology*, 156, 110513.
- Çoban T, Uçman Ergün, 2024, Derin Öğrenme Algoritmaları Kullanarak Mamografilerde Kanserli Bölge Tespiti, 3. Kocatepe Mühendislik Bilimleri Öğrenci Sempozyumu, 3, 93–97.
- Hogg P, Kelly J, Mercer C, 2015, *Digital Mammography*, Vol. 1, Springer, London, UK, 1–307.
- Doğan A, Birant D, 2019, A weighted majority voting ensemble approach for classification, *Proceedings of the 2019 4th International Conference on Computer Science and Engineering (UBMK)*, IEEE, 1–6.
- Ellis H, Mahadevan V, 2013, *Anatomy and physiology of the breast, Surgery (Oxford)*, 31(1), 11–14.
- Ergün U, Gökmen O, Çoban T, Orçin S, Kahraman O B, Baloğlu F, 2023, Filament geri dönüşüm cihaz ve yöresel atık maddelerden filament üretimi, 2. Kocatepe Mühendislik Bilimleri Öğrenci Sempozyumu, 2, 54.
- Falconí L, Ortega J, Proaño A, Armijos J, Luján F, 2020, Transfer learning and fine tuning in mammogram BI-RADS classification, *Proceedings of the 2020 IEEE 33rd International Symposium on Computer-Based Medical Systems (CBMS)*, IEEE, 475–480.
- Gheflati B, Rivaz H, 2022, Vision Transformers for Classification of Breast Ultrasound Images, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBS)*, 2022-July, 480–483.
- Ghimire P, Kinnersley B, Karami G, Arumugam P, Houlston R, Ashkan K, Booth T C, 2024, Radiogenomic biomarkers for immunotherapy in glioblastoma: A systematic review of magnetic resonance imaging studies, *Neuro-Oncology Advances*, 6(1), vdae055.
- Giammarile F, Vidal-Sicart S, Paez D, Pellet O, Estrada-Lobato E, Mikhail-Lette M, Morozova O, Marulanda M N, Sánchez D I R, Delgado Bolton R C, Valdés Olmos R A, Mariani G, 2022, Sentinel lymph node methods in breast cancer, *Seminars in Nuclear Medicine*, 52(5), 551–560.

- Gordon P B, 2002, Ultrasound for breast cancer screening and staging, *Radiologic Clinics*, 40(3), 431–441.
- Gunning D, Stefik M, Choi J, Miller T, Stumpf S, Yang G-Z, 2019, XAI—Explainable artificial intelligence, *Science Robotics*, 4(37), eaay7120.
- Guo R, Lu G, Qin B, Fei B, 2018, Ultrasound imaging technologies for breast cancer detection and management: A review, *Ultrasound in Medicine & Biology*, 44(1), 37–70.
- Habeeb Z Q, Vuksanovic B, Al-Zaydi I Q, 2023, Breast cancer detection using image processing and machine learning, *Journal of Image and Graphics (United Kingdom)*, 11(1), 1–8.
- Hamed G, Marey M A E R, Amin S E S, Tolba M F, 2020, Deep learning in breast cancer detection and classification, *Proceedings of the International Conference on Artificial Intelligence and Computer Vision (AICV2020)*, Springer, Cham, 322–333.
- Hameed Z, Zahia S, Garcia-Zapirain B, Aguirre J J, Vanegas A M, 2020, Breast cancer histopathology image classification using an ensemble of deep learning models, *Sensors (Switzerland)*, 20(16), Article ID: 4373.
- Hastie T, Tibshirani R, Friedman J, 2009, Ensemble learning, *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*, 1–20.
- He K, Zhang X, Ren S, Sun J, 2016, Deep residual learning for image recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.
- Hekal A A, Moustafa H E D, Elnakib A, 2023, Ensemble deep learning system for early breast cancer detection, *Evolutionary Intelligence*, 16(3), 1045–1054.
- Houssein E H, Mohamed W M, Selim M M, Hassaballah M, Muhammad K, 2021, Deep and machine learning techniques for medical imaging-based breast cancer: A comprehensive review, *Expert Systems with Applications*, 167, 114161.
- Irwig L, Houssami N, van Vliet C, 2004, New technologies in screening for breast cancer: A systematic review of their accuracy, *British Journal of Cancer*, 90(11), 2118–

2122.

- Jiang J, Peng J, Hu C, Jian W, Wang X, Liu W, 2022, Breast cancer detection and classification in mammogram using a three-stage deep learning framework based on PAA algorithm, *Artificial Intelligence in Medicine*, 134, 102419.
- Jiménez Gaona Y, Rodriguez-Alvarez M J, Espino-Morato H, Castillo Malla D, Lakshminarayanan V, 2021, DenseNet for breast tumor classification in mammographic images, *Lecture Notes in Computer Science*, 12940, 166–176.
- Jouirou A, Souissi I, Barhoumi W, 2024, Two-level content-based mammogram retrieval using the ACR BI-RADS assessment code and learning-driven distance selection, *Journal of Supercomputing*, 80(11), 15690–15724.
- Kallipolitis A, Revelos K, Maglogiannis I, 2021, Ensembling EfficientNets for the classification and interpretation of histopathology images, *Algorithms*, 14(10), Article ID: 278.
- Kamri M Z, Elkoumikhi H, Aaroud A, Bitar A, 2024, Optimizing BI-RADS classification for breast cancer in Moroccan women: Comparing four transfer learning models, *Procedia Computer Science*, 251, 366–373.
- Kerlikowske K, Zhu W, Su Y R, Sprague B L, Stout N K, Onega T, O'Meara E S, Henderson L M, Tosteson A N A, Wernli K, Miglioretti D L, 2024, Supplemental magnetic resonance imaging plus mammography compared with magnetic resonance imaging or mammography by extent of breast density, *JNCI: Journal of the National Cancer Institute*, 116(2), 249–257.
- Khan S U, Islam N, Jan Z, Din I U, Rodrigues J J P C, 2019, A novel deep learning-based framework for the detection and classification of breast cancer using transfer learning, *Pattern Recognition Letters*, 125, 1–6.
- Krizhevsky A, Sutskever I, Hinton G E, 2017, ImageNet classification with deep convolutional neural networks, *Communications of the ACM*, 60(6), 84–90.
- Lu G, Tian R, Yang W, Liu R, Liu D, Xiang Z, Zhang G, 2024, Deep learning radiomics based on multimodal imaging for distinguishing benign and malignant breast tumours, *Frontiers in Medicine*, 11, Article ID: 1402967.

- Łukasiewicz S, Czezelewski M, Forma A, Baj J, Sitarz R, Stanisławek A, 2021, Breast cancer—Epidemiology, risk factors, classification, prognostic markers, and current treatment strategies—An updated review, *Cancers*, 13(17), Article ID: 4287.
- McMasters K M, Tuttle T M, Carlson D J, Brown C M, Noyes R D, Glaser R L, Venne D F, Turk J R, Edwards M J, 2001, Defining the optimal surgeon experience for breast cancer sentinel lymph node biopsy: a model for implementation of new surgical techniques, *Annals of Surgery*, 234(3), 292–300.
- Melekoodappattu J G, Bama S, Rajendran S, Shyni R, 2023, Breast cancer detection in mammogram: Combining modified CNN and texture feature based approach, *Journal of Ambient Intelligence and Humanized Computing*, 14(9), 11397–11406.
- Mieke K, Brekelmans C T M, Boetes C, Besnard P E, Zonderland H M, Obdeijn I M, Manoliu R A, Kok T, Peterse H, Tilanus-Linthorst M M A, Muller S H, Meijer S, Oosterwijk J C, Beex L V A M, Tollenaar R A E M, de Koning H J, Rutgers E J T, Klijn J G M, 2025, Efficacy of MRI and mammography for breast-cancer screening in women with a familial or genetic predisposition, *New England Journal of Medicine*, 351(5), 427–437.
- Montaha S, Azam S, Haque Rafid A K M R, Ghosh P, Hasan M Z, Jonkman M, De Boer F, 2021, BreastNet18: A high accuracy fine-tuned VGG16 model evaluated using ablation study for diagnosing breast cancer from enhanced mammography images, *Biology*, 10(12), Article ID: 1347.
- Moon W K, Lee Y W, Ke H H, Lee S H, Huang C S, Chang R F, 2020, Computer-aided diagnosis of breast ultrasound images using ensemble learning from convolutional neural networks, *Computer Methods and Programs in Biomedicine*, 190, Article ID: 105361.
- Nanni L, Loreggia A, Barcellona L, Ghidoni S, 2023, Building ensemble of deep networks: Convolutional networks and transformers, *IEEE Access*, 11, 124962–124974.
- Nemade V, Pathak S, Dubey A K, 2024, Deep learning-based ensemble model for classification of breast cancer, *Microsystem Technologies*, 30(5), 513–527.

- Obeagu E I, Obeagu G U, 2024, Breast cancer: A review of risk factors and diagnosis, *Medicine*, 103(3), e36905.
- Ongsulee P, 2017, Artificial intelligence, machine learning and deep learning, *Proceedings of the 2017 15th International Conference on ICT and Knowledge Engineering (ICT&KE)*, IEEE, 1–6.
- Or Rashid M H, Shahriyar S M, Shamrat F M J M, Mahbub T, Tasnim Z, Ahmed M Z, 2023, A convolutional neural network based classification approach for breast cancer detection, *Proceedings of the 7th International Conference on Trends in Electronics and Informatics (ICOEI 2023)*, IEEE, 761–768.
- Pak M, Kim S, 2017, A review of deep learning in image recognition, *Proceedings of the 2017 4th International Conference on Computer Applications and Information Processing Technology (CAIPT)*, IEEE, 1–3.
- Pandya S, Moore R G, 2011, Breast development and anatomy, *Clinical Obstetrics and Gynecology*, 54(1), 91–95.
- Peta J, Koppu S, 2024, Explainable soft attentive EfficientNet for breast cancer classification in histopathological images, *Biomedical Signal Processing and Control*, 90, 105828.
- Pillai A, Nair V, Mathew T, 2022, Breast cancer detection in mammograms using deep learning, *Applied Information Processing Systems: Proceedings of ICCET 2021*, Springer Singapore, 121–127.
- LN P P J Y, Udhaya S, Sadasivam V, 2023, Transfer driven ensemble learning approach using ROI pooling CNN for enhanced breast cancer diagnosis, *Journal of Machine and Computing*, 297–311.
- Ragab D A, Sharkas M, Marshall S, Ren J, 2021, A framework for breast cancer classification using multi-DCNNs, *Computers in Biology and Medicine*, 131, 104245.
- Rawat W, Wang Z, 2017, Deep convolutional neural networks for image classification: A comprehensive review, *Neural Computation*, 29(9), 2352–2449.
- Razali N F, Isa I S, Sulaiman S N, Abdul Karim N K, Osman M K, Che Soh Z H, 2023,

- Enhancement technique based on the breast density level for mammogram for computer-aided diagnosis, *Bioengineering*, 10(2), Article ID: 153.
- Ribeiro M T, Singh S, Guestrin C, 2016, "Why should I trust you?" Explaining the predictions of any classifier, *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135–1144.
- Ruban S, Jabeer M M, Basti R S, 2022, Improvising breast cancer detection using CNN, VGG and SSD algorithms, *Proceedings of the 2022 Third International Conference on Intelligent Computing Instrumentation and Control Technologies (ICICICT)*, IEEE, 1772–1776.
- Saad M, Shah J H, Javed M, Abbas S, Jan S, Rauf H T, Lali M I U, 2022, Breastus: Vision transformer for breast cancer classification using breast ultrasound images, *Proceedings of the 2022 16th International Conference on Signal-Image Technology & Internet-Based Systems (SITIS)*, IEEE, 246–253.
- Sabani A, Landsmann A, Hejduk P, Schmidt C, Marcon M, Borkowski K, Rossi C, Ciritsis A, Boss A, 2022, BI-RADS-based classification of mammographic soft tissue opacities using a deep convolutional neural network, *Diagnostics*, 12(7), Article ID: 1564.
- Sajid U, Khan R A, Shah S M, Arif S, 2023, Breast cancer classification using deep learned features boosted with handcrafted features, *Biomedical Signal Processing and Control*, 86, Article ID: 105353.
- Samee N A, Alhussan A A, Ghoneim V F, Atteia G, Alkanhel R, Al-Antari M A, Kadah Y M, 2022, A hybrid deep transfer learning of CNN-based LR-PCA for breast lesion diagnosis via medical breast mammograms, *Sensors*, 22(13), Article ID: 4938.
- Samee N A, Atteia G, Meshoul S, Al-Antari M A, Kadah Y M, 2022, Deep learning cascaded feature selection framework for breast cancer classification: hybrid CNN with univariate-based approach, *Mathematics*, 10(19), Article ID: 3631.
- Sannasi Chakravarthy S R, Bharanidharan N, Rajaguru H, 2023, Multi-deep CNN based experimentations for early diagnosis of breast cancer, *IETE Journal of Research*, 69(10), 7326–7341.

- Selvaraju R R, Cogswell M, Das A, Vedantam R, Parikh D, Batra D, 2020, Grad-CAM: Visual explanations from deep networks via gradient-based localization, *International Journal of Computer Vision*, 128(2), 336–359.
- Shah S M, Javed M, Rauf H T, Khan M A, Kadry S, Alghamdi N S, 2022, Artificial intelligence for breast cancer analysis: Trends & directions, *Computers in Biology and Medicine*, 142, Article ID: 105221.
- Sharma N, Jain V, Mishra A, 2018, An analysis of convolutional neural networks for image classification, *Procedia Computer Science*, 132, 377–384.
- Shen Y, Chen J, Li X, Wang X, Xu S, Zeng H, Song J, Zha J, Zhang C, Wang Y, et al., 2021, Artificial intelligence system reduces false-positive findings in the interpretation of breast ultrasound exams, *Nature Communications*, 12(1), Article ID: 5645.
- Simonyan K, Zisserman A, 2014, Very deep convolutional networks for large-scale image recognition, *arXiv preprint*, arXiv:1409.1556.
- Singh A, Kaur S, Singh D, Singh G, 2024, Technical review of breast cancer screening and detection using artificial intelligence and radiomics, *Proceedings of the 2024 11th International Conference on Computing for Sustainable Global Development (INDIACom)*, 1171–1176.
- Solak A, Ceylan R, 2020, Classification of mammography images by transfer learning, *Proceedings of the 2020 28th Signal Processing and Communications Applications Conference (SIU)*, IEEE, 1–4.
- Spak D A, Plaxco J S, Santiago L, Dryden M J, Dogan B E, 2017, BI-RADS® fifth edition: A summary of changes, *Diagnostic and Interventional Imaging*, 98(3), 179–190.
- Sun Y S, Zhao Z, Yang Z N, Xu F, Lu H J, Zhu Z Y, Shi W J, Jiang J, Yao P P, Zhu H P, 2017, Risk factors and preventions of breast cancer, *International Journal of Biological Sciences*, 13(11), 1387.
- Tan M, Le Q, 2019, EfficientNet: Rethinking model scaling for convolutional neural networks, *Proceedings of the International Conference on Machine Learning (ICML)*, PMLR, 6105–6114.

- Thuy M B H, Hoang V T, 2020, Fusing of deep learning, transfer learning and GAN for breast cancer histopathological image classification, *Advances in Intelligent Systems and Computing*, 1121, 255–266.
- Tilanus-Linthorst M M A, Obdeijn I M M, Bartels K C M, de Koning H J, Oudkerk M, 2000, First experiences in screening women at high risk for breast cancer with MR imaging, *Breast Cancer Research and Treatment*, 63(1), 53–60.
- Tsai K J, Chou M C, Li H M, Liu S T, Hsu J H, Yeh W C, Hung C M, Yeh C Y, Hwang S H, 2022, A high-performance deep neural network model for BI-RADS classification of screening mammography, *Sensors*, 22(3), Article ID: 1160.
- Warner E, Plewes D B, Hill K A, Causer P A, Zubovits J T, Jong R A, Cutrara M R, DeBoer G, Yaffe M J, Messner S J, Meschino W S, Piron C A, Narod S A, 2004, Surveillance of BRCA1 and BRCA2 mutation carriers with magnetic resonance imaging, ultrasound, mammography, and clinical breast examination, *JAMA*, 292(11), 1317–1325.
- Xiao M, Liu Y, Zhang H, Wang L, Qian Y, 2024, Convolutional neural network classification of cancer cytopathology images: Taking breast cancer as an example, *Proceedings of the 2024 7th International Conference on Machine Vision and Applications*, 145–149.
- Yamashita R, Nishio M, Do R K G, Togashi K, 2018, Convolutional neural networks: An overview and application in radiology, *Insights into Imaging*, 9, 611–629.

İnternet Kaynakları

- 1- <https://www.mahmutcanyagmurdur.com.tr/uzmanlik-alanlari/meme-hastaliklari>, 01.05.2025
- 2- <https://www.emarmed.com.tr/tani-hizmetlerimiz/mamografi>, 03.05.2025
- 3- <https://hsmradyoloji.com/meme-ultrasonu/>, 03.05.2025
- 4- <https://dratasoy.com/meme-magnetik-rezonans-goruntulemenin-ozellikleri>, 05.05.2025
- 5- <https://dratasoy.com/meme-ultrasonografisi-ile-biyopsi>, 08.05.2025
- 6- <https://www.drozdogan.com/koltuk-alti-lenf-nodu-biyopsisinde-devrim-her-hasta-icin-gerekli-mi/>, 10.05.2025
- 7- <https://www.savasanadam.com/teknoloji/makine-ogrenmesi-ve-turleri-nelerdir>, 11.05.2025
- 8- <https://ece-akdagli.medium.com/evri%C5%9Fimsel-sinir-a%C4%9Flar%C4%B1-convolutional-neural-network-a6c9d8e666c4> 14.05.2025
- 9- <https://ece-akdagli.medium.com/evri%C5%9Fimsel-sinir-a%C4%9Flar%C4%B1-convolutional-neural-network-a6c9d8e666c4> 14.05.2025
- 10- <https://medium.com/@danqing/a-practical-guide-to-relu-b83ca804f1f7> 14.05.2025
- 11- <https://tevfikbulutcom.wordpress.com/2020/07/15/rda-coklu-dogrusal-regresyon-uzerine-bir-vaka-calismasi-a-case-study-on-multiple-linear-regression-mlr-in-r/>, 11.05.2025