

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

MEME KANSERİ TEŞHİSİ VE ALT TIPLENDİRMESİ İÇİN YENİ BİR
DİJİTAL GÖRÜNTÜ İŞLEME TEKNİĞİNİN GELİŞTİRİLMESİ

Marya ELAŞTAR

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

ANKARA
2025

Her hakkı saklıdır

ÖZET

Yüksek Lisans Tezi

MEME KANSERİ TEŞHİSİ VE ALT TİPLENDİRMESİ İÇİN YENİ BİR DİJİTAL GÖRÜNTÜ İŞLEME TEKNİĞİNİN GELİŞTİRİLMESİ

Marya ELAŞTAR

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. İman ASKERBEYLİ

Meme kanseri, hasta sonuçlarını iyileştirmek için erken ve doğru teşhisin önemine işaret eden küresel bir sağlık sorunudur. Tıbbi görüntüleme için yapay zeka (özellikle derin öğrenme) büyük bir potansiyel göstermiştir. Sunulan çalışma, CBIS-DDSM veri setini kullanarak meme lezyonlarını iyi huylu veya kötü huylu olarak sınıflandırmak için en yeni derin öğrenme modellerini (DenseNet121, NASNetLarge, Xception ve Swin Transformer) kullanmanın etkinliğini incelemektedir. Araştırma, ileri düzey hesaplama tekniklerini kullanarak meme kanseri teşhisindeki önemli sorunları ele almayı amaçlamaktadır.

Çalışmada, derin öğrenme modellerinin değerlendirilmesi, doğruluk, hassasiyet, geri çağırma (recall), F1 skoru ve ROC-AUC gibi hassas metrikler kullanılarak yapılmıştır. Ayrıca, modellerin mimarisi ile meme kanseri görüntülemesine uygunlukları da incelenmiştir. Elde edilen sonuçlara göre NASNetLarge, yüksek boyutlu veri değişkenliğine duyarlılığı nedeniyle genelleme konusunda zorluk yaşarken, DenseNet121 ve Xception güçlü özellik çıkarma yetenekleri sergilemiştir. Hiyerarşik dikkat mekanizmaları sayesinde, Swin Transformer, tıbbi görüntülerin karmaşık desenlerine etkili bir şekilde uyum sağlamıştır.

Yanlış sınıflandırma durumlarının araştırılması, sunulan çalışmanın bir diğer önemli bileşenidir. Model hataları, belirsiz lezyon sınırları, kötü huylu lezyonların iyi huylu özellikleri taklit etmesi ve veri seti artefaktları gibi faktörlerden kaynaklanmaktadır. Çalışmada, kontrast artırma ve hedeflenmiş veri artırma gibi gelişmiş ön işleme teknikleri bu sorunları çözmek için kullanılmıştır. Bu teknikler, CBIS-DDSM veri setinde yanlışlığı azaltmış ve modellerin dayanıklılığını artırmıştır.

Bu çalışma, derin öğrenmenin meme kanseri teşhisindeki dönüştürücü potansiyelini vurgulamakta ve Swin Transformer'ı doğruluk ve sağlamlık açısından bir kıyaslama modeli olarak öne çıkarmaktadır. Çalışma, umut verici ilerlemeler kaydederken, veri seti değişkenliği ve gerçek dünyada uygulanabilirliği gibi zorlukların daha fazla incelenmesine odaklanmaktadır. Bu çalışma, klinisyenler ve yapay zeka araştırmacıları arasında işbirlikçi çabaların teşvik edilmesiyle, yapay zeka ile klinik uygulama arasındaki farkı kapatma amacına katkıda bulunmaktadır. Sonuç olarak, bu çalışma tanı sonuçlarını ve hasta bakımını iyileştirecektir.

Temmuz 2025, 88 sayfa

Anahtar Kelimeler: derin öğrenme, transfer öğrenme, meme kanseri klasifikasyonu, evrimsel sinir ağıları, dikkat mekanizmaları.

ABSTRACT

Master Thesis

DEVELOPMENT OF A NEW IMAGE PROCESSING METHOD FOR DETECTION AND SUBCLASSIFICATION OF BREAST CANCER

MARYA ELAŞTAR

Ankara University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering

Supervisor: Prof. Dr. İman ASKERBEYLİ

Breast cancer continues to pose a significant global health challenge, underlining the importance of early and accurate diagnosis in improving patient outcomes. Advances in artificial intelligence, particularly deep learning, have demonstrated considerable promise in medical imaging. This study explores the application of state-of-the-art deep learning models—DenseNet121, NASNetLarge, Xception, and Swin Transformer—for the classification of breast lesions as benign or malignant using the CBIS-DDSM dataset. The research aims to address critical challenges in breast cancer diagnosis by leveraging advanced computational techniques.

The evaluation of these models was conducted using rigorous metrics, including accuracy, precision, recall, F1 score, and ROC-AUC, with a detailed focus on model architecture and their suitability for breast cancer imaging. DenseNet121 and Xception demonstrated robust feature extraction capabilities but exhibited minor overfitting, whereas NASNetLarge struggled with generalization due to its sensitivity to high-dimensional data variability. The Swin Transformer emerged as a standout model, owing to its hierarchical attention mechanisms that adapt effectively to the complex patterns of medical images.

Another critical aspect of this study was the investigation of misclassification scenarios. Factors such as indistinct lesion boundaries, malignant lesions mimicking benign features, and dataset artifacts were identified as primary contributors to model errors. To address these challenges, advanced preprocessing techniques, including contrast enhancement and targeted data augmentation, were employed. These strategies improved the models' robustness and reduced biases inherent in the CBIS-DDSM dataset.

This research underscores the transformative potential of deep learning in breast cancer diagnosis, highlighting the Swin Transformer as a benchmark model for accuracy and robustness in classifying breast lesions. While the study identifies promising advancements, it also emphasizes the need for further exploration of challenges such as dataset variability and real-world applicability. By advocating for collaborative efforts between AI researchers and clinicians, this study contributes to the broader goal of bridging the gap between artificial intelligence and clinical practice, ultimately enhancing diagnostic outcomes and patient care.

July 2025, 88 pages

Key Words: deep learning, transfer learning, breast cancer classification, convolutional neural networks, attention mechanisms

TEŞEKKÜR

Sunulan çalışma boyunca yardımlarını ve desteklerini esirgemeyen saygıdeğer danışmanım ve Ankara Üniversitesi Bilgisayar Mühendisliği Bölüm Başkanı Prof. Dr. İman ASKERBEYLİ hocama teşekkürü bir borç bilirim.

Marya ELAŞTAR
Ankara, Temmuz 2025



İÇİNDEKİLER

TEZ ONAYI	
ETİK.....	i
ÖZET.....	ii
ABSTRACT	iii
TEŞEKKÜR	iv
KISALTMALAR DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
ÇİZELGELER DİZİNİ	x
1. GİRİŞ	1
1.1 Çalışmanın Amacı	3
1.2 Çalışmanın Aşamaları	4
2. LİTERATÜR TARAMASI	5
2.1 Meme Kanseri.....	5
2.1.1 Meme kanseri tespiti ve tanısı.....	6
2.1.1.1 Görüntüleme sistemleri	6
2.1.1.2 Meme kanseri tanısında bilgisayar destekli tespit (CAD) sistemleri	7
2.1.2 Meme kanseri sınıflandırmasında makine öğrenmesi	9
2.1.2.1 Geleneksel makine öğrenimi modelleri	10
2.1.2.2 Topluluklar modelleri.....	11
2.1.3 Derin öğrenme ve meme kanseri klasifikasyonu.....	12
2.1.3.1 Meme kanseri görüntülemeye CNN'ler	12
2.1.3.1.1 CNN mimarisinin ana bileşenleri	13
2.1.3.1.2 CNN mimarisinin limitasyonları	15
2.1.3.1.3 Gelişmiş özellik öğrenimi için ileri düzey CNN mimarileri	15
2.1.3.2 Medikal görüntülemeye transformer tabanlı modeller.....	16
2.1.3.2.1 Görsel (vision) transformer ve kendiliğinden dikkat mekanizmaları.....	17
2.1.4 Meme kanseri klasifikasyonunda değerlendirme metrikleri	18
2.2 Medikal Görüntülemeye Veri Kalitesi ve Zorluklar	20
2.3 Sağlıkta Yapay Zeka Uygulamalarında Etik Hususlar	22
2.4 Örnek Literatür Çalışmaları.....	24
2.4.1 Geleneksel makine öğrenimi yaklaşımları ile meme kanseri sınıflandırması	24
2.4.2 Derin öğrenmeye geçiş	24
2.4.3 Önceden eğitilmiş modeller ve transfer öğrenme.....	25
2.4.4 Meme kanseri klasifikasyonunda transformerlar	26

3. MATERİYAL VE METOT	28
3.1 Veri seti	28
3.1.1 Veri seti tanımı	28
3.1.2 CBIS-DDSM'nin araştırmalardaki önemi.....	29
3.1.3 Veri seti bileşenleri ve yapısı	29
3.1.4 Tam ve kırılmış mamogramlar	30
3.2 Keşifsel Veri Analizi (EDA)	32
3.2.1 DICOM bilgisi	32
3.2.2 Görüntü boyutu ve çözünürlüğü	32
3.2.3 Veri görselleştirme	33
3.2.3.1 Patoloji dağılımları	33
3.2.3.2 Meme yoğunluğu ile patoloji arasındaki ilişki	34
3.3 Görüntü önileme	36
3.3.1 Görüntü yükleme ve standartlaştırma	36
3.3.2 Görüntü yeniden boyutlandırma	37
3.3.3 Kontrast artırma	38
3.3.4 Negatif dönüşüm	38
3.3.5 Normalizasyon	39
3.3.6 Veri çoğaltma.....	39
3.3.7 Etiket eşleştirme	40
3.3.8 Veri setinin bölünmesi	40
3.3.9 Çoklu yama stratejisi	40
3.3.10 Önileme hattı uygulaması	41
3.4 Model mimarileri, seçimi ve gerekçesi	42
3.4.1 Tıbbi görüntülemelerde mimari seçiminin önemi	42
3.4.2 DenseNet121.....	43
3.4.3 NASNetLarge.....	45
3.4.4 Xception	48
3.4.5 Swin Transformer	50
3.4.6 Karşılaştırmalı analiz	53
3.5 Eğitim süreci	53
3.5.1 Hesaplama kaynakları	53
3.5.2 Komut-liste (batch)boyutu	54
3.5.3 Optimizer	54
3.5.4 Kayıp fonksiyonu	55
3.5.5 Düzenleme teknikleri	56

3.5.6 Öğrenme hızı planlaması.....	56
3.5.7 Erken sonlandırma	56
3.5.8 Eğitim ve doğrulama döngüsü	57
4. BULGULAR VE TARTIŞMA.....	58
4.1 Model Değerlendirme Ölçütlerinin Genel Görünümü	58
4.2 Model Performans Analizi	59
4.2.1 DenseNet121.....	59
4.2.2 NASNetLarge.....	61
4.2.3 Xception	63
4.2.4 Swin transformer	65
4.3 Karşılaştırmalı Performans Analizi	67
4.4 Aşırı Uydurma ve Yetersiz Uydurma Analizi	69
4.5 Yanlış Sınıflandırılan Örneklerin Analizi.....	69
4.5.1 Yanlış negatifler	70
4.5.1.1 Düşük kontrastlı lezyonlar	70
4.5.1.2 Benign benzeri özellikler	71
4.5.1.3 Nadir malign alt tipler	72
4.5.2 Yanlış pozitifler	72
4.5.2.1 Kalsifikasyon benzeri bölgeler	72
4.5.2.2 Düzensiz doku desenleri	73
4.6 Literatür Kıyaslaması.....	73
5. SONUÇ.....	77
6. ÖNERİLER, SINIRLILIKLAR VE GELECEK ÇALIŞMALAR.....	78
KAYNAKLAR	81
ÖZGEÇMİŞ.....	88

KISALTMALAR DİZİNİ

ABUS	Otomatik meme ultrasonu
AUC	Eğri altındaki alan
CAD	Bilgisayar destekli tespit
CADe	Bilgisayarla desteklenen tespit
CADx	Bilgisayarla desteklenen teşhis
CBIS-DDSM	Dijital Meme Tarama Veritabanı için Küratörlü Meme Görüntüleme Alt Kümesi
CC	Kraniokaudal
CLAHE	Kontrast Sınırlı Adaptif Histogram Eşitleme
CNN	Konvolüsyonel sinir ağları
DBT	Dijital meme tomosentezi
DCIS	Duktal karsinoma <i>in situ</i>
EDA	Keşifsel veri analizi
GA	Genetik Algoritmalar
GAN	Çekişmeli Üretici Ağlar
GBM	Gradyan Artırma Makineleri
GDPR	Genel Veri Koruma Yönetmeliği
HOG	Yönlendirilmiş Gradyanların Histogramı
IDC	İnvaziv duktal karsinom
ILC	İnvaziv lobüler karsinom
k-NN	k-En Yakın Komşu
LBP	Yerel İkili Desen
MBG	Moleküler meme görüntüleme
MRI	Magnetik Rezonans Görüntüleme
NAS	Sinirsel Mimari Arama
NB	Naive Bayes
NLP	Doğal dil işleme
PET	Pozitron emisyon tomografisi
ReLU	Düzeltilmiş Doğrusal Birim
RF	Rastgele Ormanlar
ROC	Alıcı İşletim Karakteristiği
SVM	Destek Vektör Makineleri
TNM	Tümör boyutu, lenf nodu, metastaz
ViT	Vision transformer
XAI	Açıklanabilir yapay zeka

ŞEKİLLER DİZİNİ

Şekil 2.1 Geleneksel makine öğrenme modellerinin farklı meme kanseri verisetlerindeki kıyaslamalı analizi	11
Şekil 2.2 Meme kanseri klasifikasyonu için geliştirilen yığın tabanlı topluluk öğrenme çerçevesi	12
Şekil 2.3 CNN konvülsiyonel katmanları.....	13
Şekil 2.4 CNN havuzlama katmanları.....	14
Şekil 2.5 CNN aktivasyon fonksiyonları	14
Şekil 2.6 Kümülatif CNN mimarisi	15
Şekil 2.7 ViT mimarisi.....	18
Şekil 2.8 Duyarlılık-özgüllük değişimini gösteren ROC eğrisi	20
Şekil 2.9 Yeterli ve yetersiz mamogram imajlarının kıyaslanması.....	21
Şekil 2.10 Bir mamografi görüntüsünde model tahminine katkı sağlayan çıkıntı (saliency) haritaları	23
Şekil 2.11 Hibrit CNN-transformer model örneği	27
Şekil 3.1 Ful ve kırılmış mamogram kıyaslaması (CBIS-DDSM dataset.....	30
Şekil 3.2 Meme kanseri tipleri	33
Şekil 3.3 Meme yoğunluğu ile patoloji arasındaki ilişki.....	35
Şekil 3.4 DenseNet121 mimarisi	43
Şekil 3.5 NASNetLarge mimarisi	46
Şekil 3.6 Xception mimarisi.....	49
Şekil 3.7 Swin Transformer mimarisi	51
Şekil 4.1 DenseNet121 karışıklık matrisi	60
Şekil 4.2 DenseNet121 ROC eğrisi.....	61
Şekil 4.3 NASNetLarge karışıklık matrisi	62
Şekil 4.4 NASNetLarge ROC eğrisi	63
Şekil 4.5 Xception karışıklık matrisi.....	64
Şekil 4.6 Xception ROC eğrisi.....	65
Şekil 4.7 Swin Transformer karışıklık matrisi	66
Şekil 4.8 Swin Transformer ROC eğrisi	67
Şekil 4.9 Swin Transformer ile yanlış sınıflandırılan mamogramlar	70

ÇİZELGELER DİZİNİ

Çizelge 2.1 Meme kanseri evreleri.....	6
Çizelge 3.1 Veri setinin istatistikleri.....	28
Çizelge 3.2 DenseNet121 mimari özeti	45
Çizelge 3.3 NASNetLarge mimarisi özeti	48
Çizelge 3.4 Xception mimari özeti	50
Çizelge 3.5 Swin Transformer V2 mimari özeti	52
Çizelge 3.6 Model parametrelerinin karşılaştırmalı analizi	53
Çizelge 4.1 DenseNet121 sonuç özeti.....	59
Çizelge 4.2 NASNetLarge sonuç özeti	61
Çizelge 4.3 Xception sonuç özeti.....	63
Çizelge 4.4 Swin Transformer sınıflandırma raporu.....	65
Çizelge 4.5 Model performanslarının metrik bazın kıyaslama tablosu.....	68
Çizelge 4.6 CBIS-DDSM veri seti kullanılarak gerçekleştirilen önceki çalışmalar ve sonuçları	74

1. GİRİŞ

2024'te, kanser önemli bir küresel sağlık sorunu olmaya devam etmektedir. Son verilere göre, 2024 yılında Amerika Birleşik Devletleri'nde 2.001.140 yeni kanser vakası ve 611.720 kanser ölümü gerçekleşmesi beklenmektedir (Siegel vd., 2024). Dünya Sağlık Örgütü'ne göre, kanser 2018'de en yaygın ölüm nedenleri arasında ikinci sırada yer almış ve dünya genelinde yaklaşık 9,6 milyon ölümle sonuçlanmıştır (Li, 2022). Son veriler, 2022 yılında dünya genelinde yaklaşık 20 milyon yeni kanser teşhisi konulduğunu ve bunların 9,7 milyondan fazlasının ölümle sonuçlandığını tahmin etmektedir (Bray vd., 2024).

Meme kanseri dünya genelinde en sık teşhis edilen kanserlerdendir ve kadınlar arasında kanserle ilgili ölümlerin başlıca nedenidir (Ferlay vd., 2021). Meme kanseri görülme sıklığı, belirgin küresel farklılıklar göstermiştir. Yüksek gelirli ülkelerde, her 12 kadından biri yaşamı boyunca meme kanseri teşhisi alırken, ölüm oranı her 71 kadından biridir. Bu arada, daha düşük sosyoekonomik gelişime sahip ülkelerde, insidans daha düşüktür (her 27 kadından biri), ancak mortalite riski daha yüksektir; her 48 kadından biri hastalığa yenik düşmektedir (Lyon, 2024). Bu artan ölüm oranı, büyük ölçüde geç evre teşhis ve/veya kaynak sınırlı ortamlarda sınırlı tedavi seçeneklerine atfedilmektedir.

Meme kanseriyle mücadelede birçok ülke, başarılı tedavi şansının daha yüksek olduğu erken evrelerde hastalığı tespit etmeyi amaçlayarak meme kanseri için mamografi taramasını başlatmıştır. Ancak, meme kanserlerinin önemli bir kısmı belirtiler ortaya çıkana kadar tespit edilmez ve bu da daha kötü sonuçlara yol açabilir (Houssami ve Hunter, 2017).

ABD'de, meme kanseri tarama kılavuzları yakın zamanda güncellenmiştir ve artık kadınların kanserleri daha erken tespit etmelerine ve sonuçları iyileştirmelerine yardımcı olmak için 40 yaşında düzenli mamografi yaptırmaları önerilmiştir (AACR Cancer Progress Report, 2024). Farklı popülasyonlar arasında meme kanseri mortalitesini azaltmada, genişletilmiş tarama programları da dahil olmak üzere, önleme ve erken teşhis çabaları kritik öneme sahiptir.

Son yıllarda, yapay zeka (YZ) ve derin öğrenme önemli ilerlemeler kaydetmiştir ve geniş bir uygulama alanına kavuşmuştur. Ancak, sağlık sektöründe, yapay zeka sistemlerinin işlevselliğini ve performansını doğrulama standartları diğer sektörlerle göre daha katıdır ve gelişime açıktır.

Yapay zekanın dikkate değer ilgi çektiği sağlık alanlarından biri meme kanseri taramasıdır. Bu durumun nedeni, on yıllar süren meme kanseri araştırmalarında toplanan büyük veri setlerinin mevcut olması ve tarama görevlerinin tekrarlayıcı doğası nedeniyle, otomasyona uygun olmalarıdır. Yapay zeka gelişimindeki ilerlemelere rağmen, bu sistemlerin gerçek dünya klinik ortamlarındaki performansını titizlikle değerlendirmek, standart tıbbi uygulamalara entegre edilmeden önce gereklidir.

Yapay zeka ve derin öğrenmedeki ilerlemeler, meme kanserinin erken tespiti ve sınıflandırılması için benzeri görülmemiş fırsatlar sunarak, tanı doğruluğu ve verimliliğinin artırılması yoluyla ölüm oranlarını azaltma vaadinde bulunmaktadır (Lehman vd., 2017). Tıbbi görüntülemelerde derin öğrenme modellerinin uygulanması dönüştürücü olmuştur, sistemlerin insan gözünün algılayamayabileceği ince desenleri görüntülemelerde tanınmasını sağlamıştır (Langlotz vd., 2019). Bu durum, özellikle meme kanseri taramasında, malign ve benign lezyonlar arasındaki ayrımın kritik olduğu durumlarda son derece değerlidir.

Meme kanseri sınıflandırması genellikle ikili bir problem şeklinde ele alınır: acil müdahale gerektirebilecek malign lezyonları tespit etmek ve genellikle acil müdahale gerektirmeyen benign lezyonlardan malign lezyonları ayırmak. Bu türler arasında doğru bir şekilde ayırım yapmak, gereksiz tedavileri önlemek ve kötü huylu vakalar için zamanında müdahale sağlamak açısından esastır. Önemli ilerlemelere rağmen, mevcut tanı çerçevelerinde yanlış negatifler ve pozitifler hala zorluklar oluşturarak optimize edilmiş yapay zeka destekli çözümlere olan ihtiyacı vurgulamaktadır.

Sunulan araştırmanın ele aldığı sorun, özellikle iyi (benign) ve kötü huylu (malign) lezyonlar arasında ayırım yaparken ileri düzey derin öğrenme modellerini kullanarak meme kanserinin daha doğru ve güvenilir bir şekilde sınıflandırılmasına olan ihtiyaca

yönelik çözümler üretmektir. Mevcut tanı yöntemleri etkili olsalar da genellikle radyologun deneyimine büyük ölçüde dayanmaktadır ve insan hatasına ve/veya manipülasyonuna yatkın olabilmektedir. Sunulan çalışma, DenseNet121, NasNet, Xception ve görsel görevlerde güçlü performansı ile bilinen yeni bir mimari olan Swin Transformer gibi modellerin, meme kanseri sınıflandırmasında tanısallık doğruluğu ve tutarlılığı artırıp artırmayacağını araştırmaktadır.

1.1 Çalışmanın Amacı

Sunulan çalışmanın birincil amaçları:

1. DenseNet121, NasNet, Xception ve Swin Transformer dahil olmak üzere çeşitli derin öğrenme modellerinin, iyi ve kötü huylu meme lezyonlarını sınıflandırmadaki etkinliğini değerlendirmek,
2. Belirtilen modellerin sınıflandırma doğruluğunu, duyarlılığını ve özgüllüğünü karşılaştırarak meme kanseri taraması için en etkili mimariyi belirlemek,
3. Seçilen modellerin genel geçerliliğini, kamuya açık ve klinik olarak ilgili veri setlerini kullanarak değerlendirerek, modellerin farklı popülasyonlar ve görüntüleme koşulları arasında sağlam bir performansa sahip olmasını sağlamak ve
4. Meme kanseri teşhisinde derin öğrenmenin kullanımındaki pratik zorluklar ve sınırlamalar hakkında görüşler sağlayarak, klinik iş akışlarında yapay zeka entegrasyonunu savunan araştırma literatürüne katkıda bulunmak şeklinde sıralanabilir.

Sunulan çalışma, dijital mamografi görüntüleri kullanarak meme lezyonlarının iyi ya da kötü huylu olmak üzere kategorilere ayrılmasına odaklanmaktadır. MRI veya ultrason gibi diğer görüntüleme yöntemleri, bu araştırmanın kapsamının dışındadır. Kullanılan veri seti, etiketlenmiş meme kanseri verileri sağlayan Dijital Meme Tarama Veritabanı'nın bir alt kümesi olan CBIS-DDSM'dir.

1.2 Çalışmanın Aşamaları

Sunulan tez çalışması 5 ana bölüm halinde sunulmaktadır. Bunlar

- Bölüm 1 (Giriş): Çalışmanın genel bir görünümünü, arka planını, problem ifadesini, hedeflerini, kapsamını ve yapısını içermektedir.
- Bölüm 2 (Literatür Taraması): Meme kanseri tespiti ve sınıflandırması üzerine mevcut araştırmaları, yapay zeka ve derin öğrenme uygulamalarına vurgu yaparak özetlemektedir.
- Bölüm 3 (Metodoloji): Çalışmada kullanılan veri ön işleme adımlarını, model mimarilerini, eğitim protokollerini ve değerlendirme metriklerini açıklamaktadır.
- Bölüm 4 (Sonuçlar ve Tartışma): Bulguları sunmaktadır, model performansını çeşitli metrikler üzerinden karşılaştırmaktadır ve yanlış sınıflandırmaları analiz etmektedir. Sonuçların, modelin sınırlamalarının ve klinik uygulama potansiyelinin sonuçlarını tartışmaktadır.
- Bölüm 5 (Sonuç): Bu araştırmanın katkılarını özetlemektedir, sınırlamalarını vurgulamaktadır ve gelecekteki çalışmalar için önerilerde bulunmaktadır.

2. LİTERATÜR TARAMASI

2.1 Meme Kanseri

Meme kanseri, birden fazla türü olan heterojen bir hastalıktır ve genel olarak invaziv ve invaziv olmayan kanser olarak sınıflandırılabilir. İnvaziv olmayan meme kanseri, örneğin duktal karsinoma *in situ* (DCIS), meme kanallarında kalır ve çevre dokulara yayılmamıştır. Buna karşılık, invaziv meme kanseri vücudun diğer bölgelerine metastaz yapabilme yeteneğine sahiptir ve bu durum onu daha ölümcül hale getirir (Malhotra, 2010).

En yaygın invaziv meme kanseri türleri arasında invaziv duktal karsinom (IDC) ve invaziv lobüler karsinom (ILC) bulunmaktadır. IDC, süt kanallarında başlar ve tüm meme kanserlerinin yaklaşık %80'ini temsil eder. Lobülerde başlayan ILC, en yaygın ikinci türdür ve genellikle difüz büyüme desenleri nedeniyle görüntülemelerde tespit edilmesi daha zordur (Weigelt vd., 2005). Bu alt tipleri anlamak, model geliştirme için esastır, çünkü farklı kanser türleri tanısal doğruluğu etkileyen belirgin özellikler gösterebilir.

Meme kanseri evreleri, prognoz ve tedavi planlaması için çok önemlidir. Evreler, tümör boyutu, lenf nodu tutulumu ve metastaz temelinde (TNM sistemi) 0'dan 4'e kadar değişir (Çizelge2.1). Erken evre kanserler (evre 0, 1 ve 2) genellikle lokalize olmuş ve daha tedavi edilebilirken, ileri evreler (evre 3 ve 4) bölgesel veya uzak yayılım gösterir ve genellikle daha agresif tedaviler gerektirir (Edge ve Compton, 2010). Evrelerin doğru bir şekilde belirlenmesi, erken müdahale ile daha iyi sonuçların ilişkili olması nedeniyle hastanın hayatta kalma oranlarını artırabilir. Bu nedenle, evreleri ayırt edebilen derin öğrenme modelleri, olası tedavi yöntemlerine etki edebilmektedir.

Çizelge 2.1 Meme kanseri evreleri (Mahmood, 2023)

Evre	Tanım
Evre 0	DCIS: Kanser hücreleri duktal olarak lokalizedir ve yayılmamıştır.
Evre 1A	Tümör ≤ 2 cm'dir ve lenf nodlarına yayılmamıştır.
Evre 1B	Tümör ≤ 2 cm'dir ve lenf nodlarına yayılmıştır.
Evre 2	Tümör ≤ 2 cm'dir ve 1-3 lenf nodu etkilenmiştir ya da tümör > 5 cm'dir.
Evre 3A	Tümör boyutu önemsizdir. 4-9 aksiller lenf nodu ya da meme içerisindeki lenf nodu etkilenmiştir.
Evre 3B	Kanser 9 lenf nodunu etkileyecek şekilde göğüs duvarına yayılmıştır.
Evre 3C	Koltuk altında, köprücük kemiği altında ya da memede en az 10 lenf nodu etkilenmiştir.
Evre 4	Metastatik meme kanseri: Tümör boyutundan bağımsız bir şekilde kanser hücreleri yakındaki lenf nodlarına ve diğer organlara yayılmıştır.

2.1.1 Meme kanseri tespiti ve tanısı

2.1.1.1 Görüntüleme sistemleri

Meme kanseri tespiti için birincil görüntüleme yöntemleri arasında mamografi, ultrason, manyetik rezonans görüntüleme (MRG) ve daha yakın zamanda moleküler meme görüntüleme (MBG) ve tomosentez yer almaktadır.

Mamografi, yüksek hassasiyeti ve genellikle malignitenin erken göstergeleri olan küçük kalsifikasyonları tespit etme yeteneği nedeniyle, meme kanseri taramasında altın standart olmaya devam etmektedir. Ancak, yoğun meme dokusuna sahip kadınlarda mamografinin hassasiyeti azalabilir ve bu da önemli bir oranda yanlış negatif sonuçlara yol açabilir (Mann vd., 2022). Bu sınırlamayı aşmak için, dijital meme tomosentezi (DBT), diğer adıyla üç boyutlu (3D mamografi) tanıtılmıştır. DBT, farklı açılardan birden fazla görüntü alarak memenin üç boyutlu bir görüntüsünü oluşturur. Böylece, doku örtüşmesinin etkisi azaltılır ve özellikle yoğun memelerde tespit oranlarını artırılır (Gao vd., 2021).

Ultrason, özellikle mamografinin daha az etkili olduđu yoğun meme dokusuna sahip hastalarda, sıklıkla ek bir görüntüleme aracı olarak kullanılır. Ultrason, kistik kütleleri katı kütlelerden ayırt edebilir ve yaygın olarak erişilebilir olduğundan, anormal bir mamogramdan sonra daha ileri değerlendirme için kullanılan yaygın bir araçtır. (Rebolj vd., 2018). Ayrıca, çalışmalar otomatik meme ultrasonunun (ABUS) geleneksel elde taşınan ultrason için gereken operatör uzmanlığına ihtiyaç duymadan kanser tespit oranlarını artırabileceğini göstermektedir ve bu sayede tekrarlanabilir ve verimli bir alternatif sunmaktadır (Boca Bene vd., 2021).

Manyetik Rezonans Görüntüleme (MRG), yüksek hassasiyet sunar ve genellikle yüksek riskli hastalar için, özellikle meme kanseri veya *BRCA* gen mutasyonları açısından güçlü bir aile öyküsü olanlar için kullanılır. MR'nin kontrast maddelerinin kullanımı, tümörlerle ilişkili artmış damar yapısı ve kan akışına sahip bölgeleri vurgulayarak, özellikle mamografi ve ultrasonun yetersiz kalabileceği yoğun dokularda tespit hassasiyetini artırabilir (W. L., 2023). Çalışmalar, MRG'nin mamogramlarda ve ultrasonografide gizli olan kanserleri tespit edebileceğini göstermiştir, ancak yüksek maliyeti ve sınırlı erişilebilirliği, genel popülasyonda rutin kullanımını kısıtlamaktadır (Sardanelli, F., Magni, V. Ve Rossini, G., 2024).

Moleküler Meme Görüntüleme (MBI) ve pozitron emisyon tomografisi (PET), özellikle zor vakaların değerlendirilmesi veya tedavi yanıtının izlenmesi için faydalı olan yeni tekniklerdir. MBI, kanser hücreleri tarafından normal hücrelerden daha yüksek oranda alınan bir radyo-takipçinin enjekte edilmesini içerir ve böylece potansiyel maligniteleri vurgular. Genel tarama için yaygın olarak kullanılırsa da MBI yoğun meme dokusu olan veya belirsiz mamografi sonuçları bulunan kadınlar için bir seçenek sunabilir (O'Connor, 2015). PET, metastatik kanserin değerlendirilmesinde daha yaygın olarak kullanılsa da bazı meme kanseri vakaları için de değerli işlevsel bilgiler sağlayabilir (Z.-Y. J., 2023).

2.1.1.2 Meme kanseri tanısında bilgisayar destekli tespit (CAD) sistemleri

Bilgisayar destekli tespit (CAD) sistemleri, mamogramları yorumlayan radyologlara daha yakından incelenmesi gereken bölgeleri vurgulayarak destek olmak amacıyla

tanıtılmıştır. 1990’larda popülerlik kazanmaya başlayan CAD sistemleri, kural tabanlıydı ve şüpheli alanları belirlemek için doku, şekil ve yoğunluk gibi el yapımı özelliklere dayanıyordu (Sahiner vd., 2019). Bu sistemler, “ikinci okuyucu” olarak hareket ederek gözden kaçırma hatalarını azaltmayı amaçlamıştır ve özellikle daha az deneyimli radyologlar arasında tespit oranlarının artışıyla ilişkilendirilmiştir.

Faydalarına rağmen, geleneksel CAD sistemlerinde birkaç zorluğa çıkmıştır. İlk CAD sistemlerinde, yüksek yanlış pozitif oranları yaygındı, CAD sistemleri genellikle iyi huylu alanları şüpheli olarak işaretliyordu ve bu durum da gereksiz takipler ve hasta kaygısına yol açıyordu (Lehman vd., 2015). Bu dezavantajlar, CAD sistemlerinin yaygın benimsenmesini engellemiştir ve duyarlılık ile özgüllük arasındaki dengeye ilişkin endişeleri artırmıştır.

Derin öğrenme tabanlı CAD sistemleri, geleneksel sistemlere göre önemli bir ilerlemeyi temsil etmektedir. Geleneksel CAD sistemlerinin önceden tanımlanmış özelliklere dayanmasının aksinederin öğrenme yöntemleri ve özellikle konvolüsyonel sinir ağları (CNN’ler), görüntü verilerinden karmaşık ve hiyerarşik özellikleri doğrudan öğrenebilmektedir. Böylece, bu unsur, modelin açık özellik mühendisliği gerektirmeden malignite ile ilişkili ince desenleri yakalamasını sağlamıştır. Çalışmalar, derin öğrenme tabanlı CAD sistemlerinin hem duyarlılık hem de özgüllük açısından geleneksel CAD sistemlerinden daha iyi performans gösterdiğini ve yanlış pozitif oranlarını azalttığını göstermiştir (Yamashita vd., 2018). Örneğin, Jafari ve Karami tarafından geliştirilen bir CNN tabanlı CAD sistemi (2023), büyük bir mamografi veri setinde meme kanseri taramasında radyolog seviyesinde performans sergilenebildiğini göstermiştir.

Birçok derin öğrenme tabanlı CAD sistemi, birden fazla görüntüleme modunda çalışacak şekilde tasarlanmıştır. Örneğin, bir CAD sistemi hem mamogramları hem de ultrason görüntülerini birleştirerek, mamografinin yüksek duyarlılığını ve ultrasonun yoğun meme dokusunda kitleleri tespit etme yeteneği ile birleştirebilmiştir. Atrey ve arkadaşlarının (2023) yaptığı bir çalışma, multimodal derin öğrenme yaklaşımının her görüntüleme tekniğinin güçlü yönlerinden yararlanarak tek modlu CAD sistemlerine göre tanılabilirliği artırdığını göstermiştir.

Derin öğrenme CAD sistemlerinin performansı, transfer öğrenme ve veri artırma ile de geliştirilebilmektedir. Transfer öğrenimi, büyük ölçekli veri setlerinde önceden eğitilmiş modellerden yararlanarak, modelin alanına özgü görüntüler üzerinde ince ayar yapmadan önce genel görsel özelliklerin sağlam bir anlayışıyla başlamasını sağlayarak sınırlı tıbbi görüntüleme verisi zorluğunu aşmaya yardımcı olmuştur(Alruwaili vd., 2022). Veri artırma, özellikle eğitim verisi sınırlı olduğunda, rastgele döndürmeler, çeviriler ve yoğunluk değişiklikleri ile modelin genelleştirilebilirliğini ve dayanıklılığını artırmada kritik öneme sahiptir (Goceri, 2023).

CAD sistemlerinde yapay zeka, radyologlara yorumlamada yardım sağlayarak tanı süreçlerinin iyileştirilmesi potansiyelini de beraberinde getirmiştir. Dikkat haritaları gibi teknikler, yapay zeka modellerinin kararlarına en çok katkıda bulunan bölgeleri göstermesine olanak tanımaktadır ve bu da dikkat haritalarını klinik ortamlarda daha yorumlanabilir ve uygulanabilir hale getirmiştir (Pacal vd., 2024). Bu yorumlanabilirlik, sağlık hizmetlerinde benimseme için güven ve şeffaflığın hayati olduğu durumlarda çok önemlidir.

Tarama, teşhis ve prognoz tahmini gibi belirli görevlere yönelik olarak özelleştirilmiş CAD sistemlerinin geliştirilmesi, devam eden araştırmaların bir diğer alanıdır. Örneğin, prognostik CAD sistemleri, bir hastanın risk profilini ve muhtemel sonuçlarını değerlendirmek için görüntüleme verilerini klinik değişkenlerle entegre edebilir ve bu sayede tedavi planlamasına yardımcı olunabilir (Ce vd., 2022). Bu görev odaklı CAD sistemleri, yapay zekanın yalnızca tespit değil aynı zamanda hasta idaresinin daha geniş yönlerini desteklemede de potansiyelini göstermektedir.

2.1.2 Meme kanseri sınıflandırmasında makine öğrenmesi

Makine öğrenimi, yapılandırılmış görüntüleme ve histopatolojik verilerin analizini mümkün kılarak meme kanseri sınıflandırmasında önemli bir rol oynamaktadır. Öncü çalışmalar, Destek Vektör Makineleri (SVM'ler), Karar Ağaçları, k-En Yakın Komşu (k-NN) ve Rastgele Ormanlar gibi topluluk yöntemlerini içeren geleneksel makine öğrenimi

tekniklerine dayanmıştır. Bu modeller, alan bilgisinden türetilen doku, şekil ve renk gibi mühendislik özelliklerine odaklanmıştır.

Bu yaklaşımlar öncü olsa da birtakım limitasyonlara sahiptir:

- **Özellik Mühendisliği Bağımlılığı:** Özellik çıkarımı, geniş bir alan bilgisi gerektiriyordu ve genellikle karmaşık görüntü verileri için pratik değildi.
- **Veri Dengesizliği:** Benign örneklerin daha yüksek oranda bulunduğu dengesiz veri setleri, özellikle Karar Ağaçları gibi geleneksel modellerde önyargılı tahminler oluşturdu. SMOTE gibi dengeleme teknikleri, sadece belirli bir ölçüde yardımcı olabildi.
- **Yüksek Boyutlu Verilerde Aşırı Uydurma:** Yüksek boyutlu tıbbi görüntüleme verileri, topluluk yöntemleri gibi azaltma stratejilerine rağmen, Karar Ağaçları ve Rastgele Orman gibi modellerde genellikle aşırı uydurmaya neden oldu.

Bu öncü yöntemlerin limitasyonları, araştırmacıları topluluk teknikleri de dahil olmak üzere daha sofistike modellere ve nihayetinde otomatik özellik çıkarımı sunan derin öğrenmeye yönlendirdi.


2.1.2.1 Geleneksel makine öğrenimi modelleri

Erken dönem makine öğrenimi modelleri, meme kanseri sınıflandırması için manuel olarak tasarlanmış özelliklere dayanmaktadır (Şekil 2.1). Yaygın teknikler şunları içermekteydi:


- **Destek Vektör Makineleri (SVM'ler):** Klinik özellikler gibi yapılandırılmış veri setleri için etkili ancak sınırlı özellik temsili nedeniyle görüntüleme için daha az uygundur (Rejani vd., 2009).
- **Karar Ağaçları ve Rastgele Ormanlar:** Yapılandırılmış veriler için doğru olsa da bu modeller yüksek boyutlu görüntü verileri ve aşırı uyum problemleri yaşamıştır (Octaviani ve Rustam, 2019).

- k-En Yakın Komşu (k-NN): Basit ve yorumlanabilir ancak yüksek boyutlu veri setleri için hesaplama açısından zorlayıcıdır.
- Naif Bayes: Bağımsız özelliklere sahip küçük veri setleri için yararlıdır ancak genellikle görüntüleme görevleri için daha az etkilidir.

Algorithm	Dataset 1	Dataset 2	Dataset 3	Dataset 4
Random Forest	95.20%	95.91%	87%	86%
KNN	95.90%	91.77%	88.90%	83.60%
Naïve Bayes	92.40%	92.54%	83.30%	54.50%
Support Vector Machine	94.50%	97.22%	68.50%	80.00%



(a) Malignant and Benign




(b) Recurrence and non-recurrence

Şekil 2.1 Geleneksel makine öğrenme modellerinin farklı meme kanseri verisetlerindeki kıyaslamalı analizi (Aishwarja vd., 2021)

2.1.2.2 Topluluklar modelleri

AdaBoost ve Gradyan Artırma Makineleri (GBM) gibi topluluklar, geleneksel yaklaşımları geliştirmiştir ancak özellik mühendisliği gereksinimleri ve hesaplama karmaşıklığı açısından sınırlı kalmıştır (Hosni, 2019). Yine de Şekil 2.2’de özetlendiği üzere meme kanseri klasifikasyonunda kullanılabilmektedir.



Şekil 2.2 Meme kanseri klasifikasyonu için geliştirilen yığın tabanlı topluluk öğrenme çerçevesi (Jakhar vd., 2020)

2.1.3 Derin öğrenme ve meme kanseri klasifikasyonu

Derin öğrenmenin meme kanseri sınıflandırmasındaki uygulaması, tanı doğruluğunda önemli ilerlemeler göstermiştir. Geleneksel makine öğrenimi modellerinin manuel özellik mühendisliği gerektirmesinin aksine, derin öğrenme modelleri karmaşık desenleri doğrudan görüntü verilerinden öğrenebilmektedir. Bu alanda özellikle başarılı olan iki ana mimari vardır: Konvolüsyonel Sinir Ağları (CNN'ler) ve daha yakın zamanda dikkat mekanizmalarını içeren transformer tabanlı modeller. Bu bölüm, bu mimarileri, temel prensiplerini, uygulamalarını ve meme kanseri sınıflandırması üzerindeki etkilerini incelemektedir.

2.1.3.1 Meme kanseri görüntülemeye CNN'ler


Konvolüsyonel Sinir Ağları (CNN'ler), tıbbi görüntüleme için görüntü tabanlı tanı araçlarının geliştirilmesinde, meme kanseri sınıflandırması da dahil olmak üzere, temel bir rol oynamıştır. CNN'ler, görüntülerdeki özellikleri çıkarmak ve sınıflandırmak için birden fazla katmanlı konvolüsyonel filtreler, havuzlama ve tam bağlantılı katmanlar kullanarak çalışır ve bu durum uçtan uca öğrenmeyi mümkün kılar.

2.1.3.1.1 CNN mimarisinin ana bileşenleri

CNN'ler, her biri özellik çıkarımında belirli bir role sahip çeşitli katmanlardan oluşur. Ana bileşenler şunlardır:


Konvolüsyonel Katmanlar:

Konvolüsyonel katman, bir CNN'nin belkemiğidir (Şekil 2.3); filtreler (kerneller) giriş görüntüsü üzerinde kayarak kenarlar, dokular ve şekiller gibi özellikleri tespit eder. Her konvolüsyon işlemi, belirli özellikleri vurgulayan bir özellik haritası üretir ve bu haritalar daha derin özellik çıkarımı için sonraki katmanlara geçirilir. Bu hiyerarşik çıkarım süreci, ince desenler maligniteyi gösterebildiğinden meme kanseri sınıflandırmasında kritik öneme sahiptir (Krizhevsky vd., 2012).




Şekil 2.3 CNN konvölasyonel katmanları (Zhou vd., 2022)

Havuzlama (Pooling) Katmanları: Havuzlama katmanları (Şekil 2.4), özellik haritalarının uzamsal boyutlarını azaltarak, hesaplama karmaşıklığını en aza indirirken temel özellikleri korumaktadır. Maks ve ortalama havuzlama gibi teknikler, CNN'lerin her bölgeden baskın özellikleri yakalamasını sağlarken daha az ilgili detayları göz ardı eder. Bu alt örnekleme işlemi, aşırı uyumu ve hesaplama taleplerini azaltmak için tıbbi görüntüleme görevlerinde çok önemlidir (Yamashita vd., 2018).




Şekil 2.4 CNN havuzlama katmanları (Minfei vd., 2022)

AktivasyonFonksiyonları: Düzeltilmiş Doğrusal Birim (ReLU) gibi doğrusal olmayan aktivasyon fonksiyonları, ağda doğrusal olmayanlık (non-linearity) eklemek için kullanılır. Bu, CNN'lerin karmaşık eşlemeleri öğrenmesini sağlar ve meme dokusu görüntülerindeki ince desenleri ayırt etmek için gereklidir (Şekil 2.5).



Şekil 2.5 CNN aktivasyon fonksiyonları (Yamashita et al., 2018)

Tam Bağlantılı Katmanlar: Ağın sonundaki tam bağlantılı katmanlar, öğrenilen özellikleri bir araya getirerek nihai sınıflandırmayı gerçekleştirir (Şekil 2.6). Bu katmanlar, ağın meme kanseri sınıflandırma görevleri için iyi huylu veya kötü huylu gibi bir tanı çıkardığı yerlerdir.



Şekil 2.6 Kümülatif CNN mimarisi (Yamashita et al., 201)

2.1.3.1.2 CNN mimarisinin limitasyonları

Başarılarına rağmen, CNN'lerin, özellikle de görüntülerdeki küresel bağımlılıkları yakalamak söz konusu olduğunda birtakım sınırlamaları vardır. CNN'ler esas olarak yerel özelliklere odaklanır, bu da bir görüntüde daha geniş bağlamsal ilişkileri anlamayı zorlaştırır. Ayrıca, CNN'ler küçük veri setleri üzerinde eğitildiğinde aşırı uyum sağlamaya yatkındır ve bu durum tıbbi görüntülemede yaygın bir sorundur. Sönümlleme, veri artırma ve düzenleme gibi teknikler bu zorlukları aşmak için yaygın olarak kullanılır.

2.1.3.1.3 Gelişmiş özellik öğrenimi için ileri düzey CNN mimarileri

ResNet, Inception ve VGG Ağları gibi yenilikler, kaybolan gradyanlar ve çok ölçekli özellik çıkarımı gibi sorunları ele almak için CNN yeteneklerini genişletmiştir.

Rezidüel Ağlar (ResNet): Kaybolan gradyanları ele almakta etkilidir ve karmaşık özellik öğrenimi için daha derin mimarilerin kullanılmasını sağlar (He vd., 2016). ResNet'in meme kanseri görüntülemedeki performansı, katmanlar arasında karmaşık detayları yakalama yeteneğini vurgulayan birçok çalışmada doğrulanmıştır (Esteva vd., 2017).

Başlangıç (Inception) Ağları: Çok ölçekli özellikleri yakalamalarıyla bilinen inception modelleri, özellikle InceptionV3, yüksek çözünürlüklü mamografi görüntülerindeki ince desenleri ayırt etmede önemli bir rol oynamıştır (Litjens vd., 2017).

VGG Ağları: Hesaplama maliyetlerine rağmen, VGG mimarileri basitlikleri ve özellik çıkarma görevlerindeki yüksek doğrulukları nedeniyle önem arz etmektedir (Kooi vd., 2017).

2.1.3.2 Medikal görüntülemeye transformer tabanlı modeller

Başlangıçta doğal dil işleme (NLP) görevleri için tasarlanan transformer tabanlı modeller, olağanüstü esneklik ve etkinlik göstermiştir ve günümüzde tıbbi görüntüleme uygulamalarında önemli bir ivme kazanmaktadır. Transformerların gücü, tüm bir veri kümesi boyunca uzun vadeli bağımlılıkları ve bağlamsal ilişkileri yakalama konusundaki benzersiz yeteneklerinde yatmaktadır; bu özelliğin, karmaşık tıbbi görüntülerin analizinde faydalı olduğu kanıtlanmıştır.

Sabit boyutlu filtreler aracılığıyla öncelikle yerel özelliklere odaklanan konvolüsyonel sinir ağlarının (CNN'ler) aksine transformerlar, bir görüntünün çeşitli parçalarının birbirine göre önemini değerlendirmek için kendiliğinden (self) dikkat mekanizmaları kullanarak verinin daha bütünsel bir görünümünü sağlar. Bu geniş uzamsal bağlamda ilgili özellikleri ve korelasyonları belirleme yeteneği, patolojik özelliklerin ince, dağılmış veya büyük doku alanlarını kapsayabileceği tıbbi görüntülemeye özellikle değerlidir.

Meme kanseri sınıflandırmasında, iyi huylu lezyonları kötü huylulardan ayırmanın zorluğu, onların çeşitli morfolojileri ve dağınık varlıkları nedeniyle, transformerlar CNN'lere göre gelişmiş bir alternatif sunar. Kendiliğinden dikkat mekanizmasını kullanarak, transformerlar bir görüntünün hangi bölgelerinin tanı için kritik olduğunu dinamik olarak belirleyebilir ve bu da modelin hem ince ayrıntılı detayları hem de görüntü genelindeki daha geniş bağlamsal desenleri sentezlemesine olanak tanır. Bu özellik, kanserli bölgelerin yalnızca daha geniş bir anatomik bağlam içinde görüntülendiğinde


tanımlanabileceği karmaşık meme dokusu anormalliklerini belirlemede özellikle faydalıdır.

2.1.3.2.1 Görsel (vision) transformer ve kendiliğinden dikkat mekanizmaları

Vision transformer (ViT), Dosovitskiy ve arkadaşları (2020) tarafından tanıtılmıştır (Şekil 2.7). ViT, doğal dil işleme alanından görüntü analizine dönüştürücü mimarisini uyarlayarak, görüntüler arasındaki küresel bağımlılıkları yakalamak için benzersiz yetenekler sunan bir mimaridir. CNN'lerin öncelikle yerel özellikleri çıkarmaya odaklanmasının aksine ViT'ler tüm görüntü boyunca ilişkileri anlamak için kendiliğinden dikkati kullanır. Bu yaklaşım, dağınık anormalliklerin birden fazla bölgeden bağlam gerektirdiği tıbbi görüntülemede özellikle faydalıdır.

ViT'ler bir görüntüyü, cümledeki kelimelere benzer şekilde her biri bağımsız bir giriş token'ı olarak ele alınan, sabit boyutlu bir dizi parçaya böler. Bu parçalar, her parçanın temel bilgilerini koruyarak gömme vektörlerine dönüştürülür. Gömülü temsiller, ViT'lerin görüntüyü yalnızca yerel bölgelere odaklanmak yerine bütünsel olarak analiz etmelerini sağlayarak transformer tarafından topluca işlenir.

ViT mimarisinin temeli, görüntüdeki her bir parçanın diğerlerine göre önemini hesaplayan kendiliğinden (self) dikkat mekanizmasıdır. Bu mekanizma, modelin etkileşimlerine göre çeşitli görüntü bölgelerini değerlendirmesine olanak tanır ve böylece meme kanseri görüntülemesi gibi yaygın anormallikleri belirlemede kritik olan hem yerel detayları hem de küresel uzamsal ilişkileri öğrenmesini sağlar.



Şekil 2.7 ViT mimarisi (Abimouloud vd., 2024)

2.1.4 Meme kanseri klasifikasyonunda değerlendirme metrikleri

Değerlendirme metrikleri, meme kanseri sınıflandırmasında kullanılan modellerin etkinliğini değerlendirmede esastır. Model performansının çeşitli yönlerine, özellikle de malign ve benign vakaları doğru bir şekilde tespit etme açısından içgörü sağlarlar. Meme kanseri sınıflandırmasında kullanılan başlıca metrikler doğruluk, duyarlılık (veya geri çağırma; recall), özgüllük ve F1 skorudur. Bu metriklerin her biri, modelin meme kanseri vakalarını doğru ve güvenilir bir şekilde sınıflandırma yeteneğinin farklı yönlerini ele alır.

Doğruluk: Doğruluk, doğru sınıflandırılan vakaların toplam vaka sayısına oranı olarak tanımlanır ve şu şekilde hesaplanır:

$$Accuracy = \frac{True\ Positives\ (TP) + True\ Negatives\ (TN)}{Total\ Number\ of\ Cases}$$

Doğruluk, model performansının genel bir değerlendirmesini sağlarken, medikal görüntülemelerde yaygın olan ve özellikle sınıflar arasında yüksek dengesizlik bulunan veri setlerinde yanıltıcı olabilir. Örneğin, meme kanseri sınıflandırmasında, iyi huylu vakalar

genellikle kötü huylu olanlardan daha fazladır ve bu da nadir ama kritik maligniteleri tespit etme kapasitesini yansıtmayan abartılı doğruluk puanlarına yol açabilir.

Duyarlılık: Duyarlılık, aynı zamanda geri çağırma (recall) olarak da bilinir ve modelin gerçek pozitif vakaları tanımlamadaki etkinliğini ölçer. Duyarlılık şu formülle hesaplanır:

$$Sensitivity = \frac{True\ Positives\ (TP)}{True\ Positives\ (TP) + False\ Negatives\ (FN)}$$

Yüksek duyarlılık, meme kanseri tespitinde özellikle kritiktir, çünkü malign bir tümörün gözden kaçması (yanlış negatif) hastada ciddi sonuçlara yol açabilir. Aslında, sağlık uygulamalarında genellikle duyarlılık, tespit edilemeyen kanserlerin riskini en aza indirmek için önceliklendirilir.

Yüksek duyarlılıklı bir model, kanserli vakaların çoğunluğunun doğru bir şekilde tespit edilmesini sağlar ki bu da erken teşhis ve tedavi için hayati öneme sahiptir. Örneğin, Anichini ve arkadaşları (2024) tarafından yapılan çalışmalar, duyarlılık için optimize edilmiş modellerin mamogramlarda malign vakaların tespitinde önemli iyileştirmeler sağladığını göstermiştir.


Özgüllük

Özgüllük, bir modelin negatif durumları doğru bir şekilde tanımlama yeteneğinin ölçüsüdür ve aşağıdaki formülle hesaplanır:

$$Specificity = \frac{True\ Negatives\ (TN)}{True\ Negatives\ (TN) + False\ Positives\ (FP)}$$

Yüksek özgüllük, hastalar için gereksiz tedavilere, kaygıya ve invaziv prosedürlere yol açabilecek yanlış pozitiflerin oluşumunu azaltır. Sağlık hizmeti sağlayıcıları için, dengeli duyarlılık ve özgüllüğe sahip bir model, yanlış tespitlerle hasta ve sağlık sistemini bunaltmadan klinik karar vermeyi destekleyen güvenilir sonuçlar sağlar.

Duyarlılık ve özgüllük arasındaki denge, farklı eşik seviyeleri arasındaki duyarlılık-özgüllük ilişkisini gösteren bir Alıcı İşletim Karakteristiği (ROC) eğrisi (Şekil 2.8) kullanılarak görsel olarak temsil edilebilir.



Şekil 2.8 Duyarlılık-özgüllük değişimini gösteren ROC eğrisi (Sahiner et al., 2019)

F1 skoru

F1 Skoru, duyarlılığı ve hassasiyeti birleştirerek dengeli bir ölçüm sağlar ve bu sayede genellikle dengesiz veri setlerinde kritik öneme sahiptir. F1 skoru şu şekilde hesaplanır:

$$F1\ Score = 2 \times \frac{Precision \times Sensitivity}{Precision + Sensitivity}$$

F1 skoru, genellikle tıbbi görüntülemelerde olduğu gibi yanlış pozitiflerin ve negatiflerin önemli sonuçlar doğurduğu durumlarda özellikle faydalıdır. Son araştırmalar, (örneğin Hicks vd., 2022), ham doğruluk yerine F1 skorunu optimize etmenin tıbbi uygulamalarda daha güvenilir sınıflandırma modellerine katkı sağlayabileceğini göstermektedir.


2.2 Medikal Görüntülemelerde Veri Kalitesi ve Zorluklar

Tıbbi görüntülemedeki veri kalitesi, özellikle meme kanseri sınıflandırmasında model performansını etkileyen kritik bir faktördür. Görüntü çözünürlüğü, anotasyon kalitesi ve sınıf dengesizliği, araştırmacıların etkili makine öğrenimi modelleri oluştururken

karşılaştıkları başlıca zorluklar arasındadır. Yüksek kaliteli veriler, modellerin kötü ve iyi huylu desenler arasındaki ince farklılıkları öğrenmesini sağlar, ancak kötü bir şekilde etiketlenmiş veya düşük çözünürlüklü görüntüler gibi düşük kaliteli veriler, modelin eğitim sırasında yanıltılmasına neden olabilir.

Görüntü kalitesi, modelin öğrenme sürecini doğrudan etkiler. Yüksek çözünürlüklü görüntüler, mamografik taramalardaki ince ayrıntıların tespit edilmesini sağlar ve böylece kanserlerin erken evre tespiti mümkün olur. Kim ve diğerleri (2021) tarafından yapılan çalışmalar, gürültülü veya yanlış etiketlenmiş görüntülerin yanlış model tahminlerine ve kötü genelleştirmeye yol açabileceği için kaliteli verilere duyulan ihtiyacı vurgulamaktadır.

Örnek bir çalışmada, Şekil 2.9, yeterli (sağ görünüm) ve yetersiz görüntü (sol görünüm) örneğini göstermektedir; sağ CC görünümü yeterli olarak kabul edilir, ancak küçük bir katlanma görünmektedir. Sol CC görünümü, ciddi bir katlanma nedeniyle yetersizdir ve yeniden çekilmelidir.



Şekil 2.9 Yeterli ve yetersiz mamogram imajlarının kıyaslanması (Landsveld-Verhoeven vd., 2015)

Sınıf dengesizliği, iyi huylu vakaların kötü huylu olanlardan çok daha fazla olduğu için tıbbi görüntülemede yaygın bir sorundur. Bu dengesizlik, modeli benign vakaları tahmin

etmeye yönlendirebilir ve bu nedenle malign vakalar için duyarlılık azalır. Bu sorunu çözmek için çeşitli teknikler uygulanmaktadır.Örneğin:

Veri Çoğaltma: Dönme, ölçekleme ve kırpma gibi dönüşümler, eğitim verilerinin çeşitliliğini artırarak dengesizliği etkili bir şekilde ele alabilir.

Sentetik Veri Üretimi: Çekişmeli Üretici Ağlar (GAN) gibi teknikler, modelin çeşitli veriler arasında genelleme yeteneğini artıran sentetik görüntüler oluşturmak için kullanılmıştır.


Artırılmış veri setleri, Zama ve diğerleri (2023) tarafından sunulan çalışmalarda olduğu, gerçek verileri tamamlamak için GAN tarafından üretilen mamografi görüntülerinin kullanıldığı yerlerde, modelin hassasiyetini ve özgüllüğünü artırarak geliştirilmiş performans göstermiştir.

2.3 Sağlıkta Yapay Zeka Uygulamalarında Etik Hususlar

Yapay zeka, özellikle meme kanseri tespiti gibi hassas alanlarda sağlık hizmetlerine entegre oldukça, gizlilik, hasta onayı ve şeffaflık gibi etik hususlar giderek daha önemli hale gelmektedir. Yapay zeka modelleri, karmaşık verileri işleme yetenekleri ile meme kanseri sınıflandırmasında etkilidir, ancak hasta güvenini korumak için sorumlu bir şekilde uygulanmalıdır.

Bir büyük etik endişe, hasta verilerinin gizliliğidir. Makine öğrenimi modelleri, genellikle hassas hasta bilgilerini içeren büyük veri setlerine dayanır. Herington ve diğerlerinin (2023) vurguladığı gibi, hasta rızasının sağlanması ve verilerin anonimleştirilmesi kritik öneme sahiptir. Genel Veri Koruma Yönetmeliği (GDPR) gibi politikalar, hasta verilerinin nasıl kullanılabileceği konusunda katı yönergeler uygular ve bu standartlara uyum, sağlık alanındaki herhangi bir yapay zeka modeli için gereklidir.

Yapay zeka modelleri, özellikle transformerlar gibi karmaşık olanlar, karar verme süreçleri yorumlanması zor olduğu için genellikle "kara kutu" olarak kabul edilir. Ancak sağlık hizmetlerinde, klinisyenlerin model çıktılarını anlaması ve güvenmesi için şeffaflığa ihtiyaçları vardır. Çıkıntı (saliency) haritaları (Şekil 2.10) ve açıklanabilir yapay zeka (XAI) araçları gibi teknikler, modellerin tahminleri nasıl yaptığını görselleştirmeyi sağlar ve böylece klinisyenlerin güveni artırılabilir ve modelin zayıf yönlerine dair içgörüler sunulabilir.



Şekil 2.10 Bir mamografi görüntüsünde model tahminine katkı sağlayan çıkıntı (saliency) haritaları (Goergen vd., 2022)

Subhan ve arkadaşlarının (2023) gerçekleştirmiş olduğu gibi çalışmalar, sağlık hizmetlerinde etik yapay zeka uygulamalarını teşvik etmek için açıklanabilir modellerin önemini vurgulamakta ve yalnızca iyi performans göstermeyen aynı zamanda karar verme süreçlerine dair içgörüler sağlayan modelleri savunmaktadır.

2.4 Örnek Literatür Çalışmaları

2.4.1 Geleneksel makine öğrenimi yaklaşımları ile meme kanseri sınıflandırması

Amrane ve diğerleri(2018) dünya genelinde kadınlar arasında önde gelen ölüm nedenlerinden biri olan meme kanseri sınıflandırmasının zorluğunu ele almıştır. Meme kanseri, gen mutasyonları, ağrı ve meme görünümündeki değişikliklerle karakterizedir. Çalışma, meme kanseri sınıflandırması için iki makine öğrenimi sınıflandırıcısını, Naive Bayes (NB) ve k-en yakın komşu (KNN), karşılaştırmıştır. Çalışma, sınıflandırıcıların doğruluğunu değerlendirmek için çapraz doğrulama kullanarak, KNN'nin en yüksek doğruluğu (%97,51) ve en düşük hata oranını elde ettiğini, böylece NB sınıflandırıcısını geride bıraktığını ve NB sınıflandırıcısının ise %96,19 doğruluk sağladığını göstermiştir. Bu çalışma, meme kanseri sınıflandırması için makine öğrenmesi tekniklerinin etkinliğini göstermesi açısından önem arz etmektedir.

Rabiei ve diğerleri (2022) demografik, laboratuvar ve mamografik verileri kullanarak çeşitli makine öğrenimi yaklaşımlarını kullanarak meme kanserini tahmin etmeye odaklanmıştır. Çalışmada, %25'i meme kanseri hastası olan 5.178 kayıt içeren bir veritabanını kullanmıştır ve Rastgele Ormanlar (RF), Sinir Ağı (MLP), Gradyan Artırma Ağaçları(GBT) ve Genetik Algoritmalar (GA) gibi modeller uygulanmıştır. Başlangıçta, modeller demografik ve laboratuvar özellikleri ile eğitilmiş ve ardından tahmin edici etkinliğini değerlendirmek için mamografik verileri de içerecek şekilde genişletilmiştir. Sonuçlar, RF modelinin %80 doğruluk, %95 duyarlılık, %80 özgüllük ve 0.56 AUC ile diğerlerinden daha iyi performans gösterdiğini ortaya koymuştur. GBT modeli, sinir ağını geride bırakarak 0.59 AUC göstermiştir.

2.4.2 Derin öğrenmeye geçiş

Sutong Wang ve diğerleri (2020) meme kanseri görüntüleme görevlerinde hibrit özellik çıkarım tekniklerinin sınırlamalarını göstermiştir. Bulguları, özellik çıkarımını

otomatikleştiren ve sınıflandırma doğruluğunu önemli ölçüde artıran derin öğrenme yaklaşımlarının gerekliliğini vurgulamıştır.

Shen ve diğerleri (2019) mamografi analizi için Konvolüsyonel Sinir Ağları (CNN'ler) kullanmıştır ve kalsifikasyonlar gibi erken göstergeleri tespit etmede yüksek doğruluk elde etmiştir. Etkililiklerine rağmen, modeller aşırı uyumdan kaçınmak için dikkatli bir şekilde ayarlanmalıdır.

Alanazi ve diğerleri (2021) tüm kaydırma görüntülerinde duktal karsinom doku bölgelerini analiz ederek meme kanserinin otomatik tespitini geliştirmek için bir konvolüsyonel sinir ağı (CNN) yöntemi önermiştir. Çalışma, yaklaşık 275.000 adet 50×50 piksel RGB görüntü yaması içeren bir veri seti kullanarak, meme kanseri tespiti için çeşitli CNN mimarilerini makine öğrenimi algoritmaları ile karşılaştırmıştır. CNN tabanlı sistem, makine öğrenme algoritmalarının %78 doğruluğunu %9 farkla geçerek %87 doğruluk elde etmiştir. Önerilen sistem, tanı sürecinde insan hatasını azaltma potansiyelini göstererek meme kanseri tespitinde önemli bir iyileşme sağlamıştır.

2.4.3 Önceden eğitilmiş modeller ve transfer öğrenme

Simonyan ve Zisserman (2015) meme kanseri sınıflandırması için önceden eğitilmiş ImageNet modellerinin uygulanmasında öncü olmuşlardır. Bu modelleri medikal görevler için ince ayar yaparak ve şekiller ve dokular gibi öğrenilmiş özellikleri etkili bir şekilde kullanarak hesaplama taleplerini azaltmış ve sınıflandırma doğruluğunu artırmışlardır.

Sajid ve Khan (2023) mamogramları kullanarak derin öğrenme özelliklerini el yapımı özelliklerle birleştiren yenilikçi bir meme kanseri sınıflandırma çerçevesi önermişlerdir. Çerçeve, özellikleri çıkarmak için bir CNN kullanır ve bunları Yönlendirilmiş Gradyanların Histogramı (HOG) ve Yerel İkili Desen (LBP) özellikleriyle birleştirerek şeffaflığı artırmak için alan uzmanı bilgisini entegre eder. Transfer öğrenimini kullanarak, önerilen çerçeve sağlam temel sonuçlar elde etme konusunda etkinliğini göstermiştir.

CBIS-DDSM veri seti üzerinde yapılan deneyler, çerçevenin meme kanseri sınıflandırmasında en son yöntemleri geride bıraktığını göstermiştir.

Ali ve diğerleri (2023) çoklu konvolüsyonel sinir ağları ile birleştirilmiş meta-öğrenme topluluk tekniklerini kullanarak verimli bir meme kanseri sınıflandırma modeli önermişlerdir. Model, lezyonları iyi veya kötü huylu olarak erken tespit amacıyla sınıflandırmayı hedefleyen Meme Ultrason Görüntüleri (BUSI) veri setini kullanmıştır. Karmaşık ve çeşitli lezyon türlerinin getirdiği zorlukları aşmak için model, öğrenme sürecini optimize etmek amacıyla meta-öğrenmeyi, özellik çıkarımını geliştirmek için Inception, ResNet50 ve DenseNet121 gibi önceden eğitilmiş modellerle transfer öğrenmeyi ve veri seti boyutunu ve çeşitliliğini artırmak için veri artırmayı entegre etmiştir. Toplu öğrenme tekniği, birden fazla CNN'nin çıktılarının birleştirilmesiyle sınıflandırma doğruluğunu artırmıştır. Deneysel sonuçlar, modelin yüksek doğruluk sağladığını ve doğruluk, kesinlik, hatırlama ve F1 skoru açısından mevcut sistemleri geride bıraktığını göstermiştir.


2.4.4 Meme kanseri klasifikasyonunda transformerlar

Chen ve diğerleri (2021) ViT'leri mamografik görüntülere uygulayarak, kendiliğinden dikkat mekanizmalarını kullanarak teşhis için ana bölgelere odaklanmışlardır. ViT'lerin ince ayarı, maligniteyi gösteren düzensiz doku yapılarının tanımlanmasında yüksek doğruluk sağlamıştır.

Lee ve diğerleri (2023) komşu görüntü bölümlerinden bağlamı dahil ederek dijital meme tomosentezi (DBT) görüntülerinde meme kanserini tespit etmek için bir transformer mimarisi kullanarak verimli bir derin sinir ağı modeli geliştirmişlerdir. Önerilen yöntem, bir 3D konvolüsyon tabanlı mimari ve her bir bölümü ayrı ayrı analiz eden bir 2D modeli ile karşılaştırılmıştır. Modeller, 5.174 dört-görünümlü DBT çalışması üzerinde eğitilmiştir, 1000 çalışma üzerinde doğrulanmıştır ve dokuz ABD kurumundan 655 çalışma üzerinde test edilmiştir. Değerlendirme metrikleri arasında alıcı işletim karakteristik eğrisi (AUC) altındaki alan, sabit özgüllükte duyarlılık ve sabit duyarlılıkta

özgüllük yer almıştır. Transformer tabanlı model, DBT görüntülerinde meme kanseri tespiti için umut verici sonuçlar göstermiştir.

Wang ve diğerleri(2024) CNN'lerin yerel özellik çıkarma güçlerini, transformerların küresel bağlamsal anlayışıyla birleştiren hibrit CNN-transformer modelleri önermişlerdir (Şekil 2.11). Bu yaklaşım, meme kanseri tespitinde verimli işlem ve geliştirilmiş doğruluk için dengeli bir yöntem sağlamıştır. Bu hibrit modeller, hesaplama zorluklarını aşmada umut vaat etmiştir ve veri erişilebilirliği ve hesaplama kaynakları geliştikçe tıbbi görüntülemelerde giderek daha kritik bir rol oynaması beklenmektedir.



Şekil 2.11 Hibrit CNN-transformer model örneği (Wang vd., 2024)

3. MATERYAL VE METOT

Bu bölüm, en son derin öğrenme modellerini kullanarak meme kanseri görüntülerini sınıflandırma araştırma hedeflerine ulaşmak için kullanılan metodolojik çerçeveyi açıklamaktadır. Metodoloji, veri setinin, ön işleme tekniklerinin, veri artırma stratejilerinin, model seçim kriterlerinin ve eğitim stratejilerinin ayrıntılı tanımlarını içermektedir.

3.1 Veri seti

Bu çalışmada kullanılan veri seti, Dijital Meme Tarama Veritabanı için Küratörlü Meme Görüntüleme Alt Kümesi (CBIS-DDSM; Lee vd., 2017) olup, Kaggle'da barındırılan ve ilk olarak The Cancer Imaging Archive (TCIA) aracılığıyla yayımlanan açık bir kaynaktır. Bu veri seti, mamografi araştırmalarında, özellikle bilgisayarla desteklenen tespit (CADE) ve teşhis (CADx) sistemlerinin geliştirilmesi ve test edilmesinde yaygın olarak benimsenmiştir.

3.1.1 Veri seti tanımı

CBIS-DDSM, DDSM veri setinin güncellenmiş ve standartlaştırılmış bir versiyonudur. Eğitilmiş mamografi teknisyenleri tarafından düzenlenmiş dijitalleştirilmiş mamografik görüntüler içerir ve benign ve malign vakalara odaklanarak doğrulanmış patoloji bilgileri sunar. Veri setine yönelik tanımlayıcı istatistik bilgileri Çizelge 3.1'de sunulmuştur.

Çizelge 3.1 Veri setinin istatistikleri

Çalışma sayısı	6.775
İmaj sayısı	10.239 (JPG format)
Katılımcı sayısı	1.566
Seri sayısı	6.775
Dosya boyutu	~6 GB (JPG format)
Modalite	Mamografi

Veri seti, her katılımcının farklı taramalara karşılık gelen birden fazla hasta kimliği ile ilişkilendirildiği şekilde yapılandırılmıştır. Örneğin, hasta ID 00038, Calc-Test_P_00038_LEFT_CC ve Calc-Test_P_00038_RIGHT_CC_1 gibi farklı görünümüleri ve taramaları temsil eden birden fazla girişi içerir. DICOM meta verileri 6.671 katılımcının varlığını önerebilirken, bu organizasyonel yaklaşım nedeniyle yalnızca 1.566 benzersiz katılımcı bulunmaktadır.

3.1.2 CBIS-DDSM'nin araştırmalardaki önemi

CBIS-DDSM veri seti, önceki sürüm olan DDSM'nin birkaç sınırlamasını aşmıştır:

Standartlaştırma: Görüntüler, DICOM formatında sıkıştırılmamıştır ve tutarlı çözünürlükte düzenlenmiştir.

Geliştirilmiş Notlar: Orijinal veri setindeki belirsiz notları ele alarak lezyonlar için güncellenmiş ilgilenilen bölge(ROI) segmentasyonu ve sınırlayıcı kutular sağlar.

Patoloji Doğrulaması: Patoloji onaylı tanıları içerir ve bu durum örnekleri makine öğrenimi modellerinin eğitimi ve testi için uygun hale getirir.

Erişilebilirlik: Veri seti düşük boyutta (6 GB), modern formatlara dönüştürülmüş ve kolayca erişilebilirdir.

Bu özellikler, CBIS-DDSM'yi CAdE ve CAdx sistemlerini değerlendirmek ve karşılaştırmak için değerli bir kaynak haline getirmiştir.

3.1.3 Veri seti bileşenleri ve yapısı

Veri seti, dört ana kategoriye ayrılmış mamografik görüntülerden oluşmaktadır:


1. Normal Vakalar: Görünür lezyon veya anormallik içermeyen görüntüler.

- 2.İyi Huylu Vakalar: Malign olmayan anormalliklere sahip görüntüler.
3. Malign Vakalar: Kanserli lezyonları onaylanmış görüntüler.
- 4.Arka Plan veya ROI Dışı Bölgeler: Doğru sınıflandırmayı kolaylaştırmak için dahil edilmiştir.

Her bir görüntü, görünümü (örneğin, kraniokaudal [CC] veya mediolateral oblique [MLO]), lateraliteyi (örneğin, sol veya sağ meme) ve çalışma türünü (örneğin, Calc-Test or Mass-Test) tanımlayan meta verilerle etiketlenmiştir. Bu meta veriler, eğitim sırasında verilerin ön işlenmesi ve katmanlandırılması için kritik öneme sahiptir.

3.1.4 Tam ve kırpılmış mamogramlar

CBIS-DDSM veri seti, meme kanseri tespit sistemlerinin geliştirilmesinde farklı amaçlara hizmet eden hem tam hem de kesilmiş (kırpılmış) meme grafiğini içermektedir (Şekil 3.1).



Şekil 3.1 Ful ve kırpılmış mamogram kıyaslaması (CBIS-DDSM dataset [Lee et al., 2017])

Tam Mamogramlar: Çevre dokularla birlikte tüm meme anatomisini içeren tam mamografik görüntülerdir. Tam mamogramlar genellikle daha geniş anatomik bağlamda

anormallikleri tespit etmek gibi bütünsel analizler için kullanılır. Meme şekli ve yoğunluğu gibi önemli bağlamsal bilgiler sağlarlar ve bu da maligniteyi gösteren ince desenlerin teşhisinde yardımcı olabilir.

Kırpılmış Mamogramlar: Tam mamogramlardan çıkarılan daha küçük, odaklanmış bölgeler olup genellikle potansiyel anormallikler içeren ilgi alanlarına karşılık gelir. Kırpılmış mamogramlar, lezyon sınıflandırması ve segmentasyonu gibi görevler için özellikle faydalıdır çünkü anormalliklerin bulunduğu belirli alanlara odaklanırlar. Bu yaklaşım, hesaplama yükünü azaltır ve modelin dikkatini tanısal olarak önemli bölgelere odaklar.

Her iki tür görüntünün de dahil edilmesi, araştırmacıların mamografi alanındaki farklı zorluklarla başa çıkmalarını sağlar:

1. **Tespit Görevleri:** Tam mamogramlar, şüpheli alanları tespit etmek için CADe sistemlerinde sıklıkla kullanılır.
2. **Teşhis Görevleri:** Kırpılmış mamogramlar, belirli lezyonların iyi veya kötü huylu olarak sınıflandırılması için ayrıntılı analiz yapılmasını sağlar.

Tam mamogramlar, memenin genel bağlamını sağlar. Çok odaklı veya bilateral anormallikleri tespit etmek için faydalıdır. Radyologların iş akışını taklit etmek için tasarlanmış algoritmalar için girdi olarak hizmet eder.

Kırpılmış mamogramlar, küçük ROI'ler için hassas özellik çıkarımı ve model öğrenimini kolaylaştırır. Tam görüntülerde bulunan gürültü ve alakasız bilgileri azaltır. Lezyon türlerinin dengeli bir veri setini oluşturmak için artırma tekniklerine izin verir.

3.2 Keşifsel Veri Analizi (EDA)

Keşifsel Veri Analizi (EDA), veri kümesini anlamak ve modellemeden önce anlamlı içgörüler çıkarmak için kritik bir adımdır. Bu bölümde, CBIS-DDSM veri setini yapısını incelemek, anahtar özellikleri belirlemek ve veri kalitesini değerlendirmek için incelemekteyiz.

3.2.1 DICOM bilgisi

dicom_info.csv dosyası, her bir görüntü hakkında çözünürlük, piksel derinliği ve görüntü türü gibi ek bilgiler sağlar. Dosya 10.237 giriş içermektedir ve ana bulgular şunlardır:

- BitsAllocated ve BitsStored alanları, görüntülerin 16-bit gri tonlama temsilini kullandığını doğrular.
- Veri seti, boyut ve görüş alanı açısından farklılık gösteren hem kesilmiş hem de tam mamogram görüntüleri içerir.

3.2.2 Görüntü boyutu ve çözünürlüğü

dicom_info.csv dosyasındaki “Satırlar” ve “Sütunlar” alanları, görüntü boyutlarındaki farklılıkları gösterir:


- Tam mamografi görüntüleri genellikle 3526 x 351 piksel gibi daha yüksek çözünürlüğe sahiptir.
- Kırpılmış görüntüler daha küçük boyutlara sahiptir ve belirli alanları vurgulamak için özelleştirilmiştir.

3.2.3 Veri görselleştirme

Veri görselleştirme, veri kümesinin yapısını anlamada ve anahtar özelliklerden anlamlı içgörüler çıkarmada kritik bir rol oynar. Sunulan çalışma için iki ana görselleştirmeye odaklanılmıştır: patoloji dağılımları ve meme yoğunluğu ile patoloji arasındaki ilişki. Bu görselleştirmeler, verilerdeki desenleri, dengeyi ve ilişkileri ortaya çıkararak sonraki modelleme süreci için bir temel sağlar.

3.2.3.1 Patoloji dağılımları

İlk görselleştirme, veri setindeki patoloji türlerinin dağılımını göstermeyi amaçlamaktadır. Bunu başarmak için, her patoloji kategorisinin oranlarını sunmak üzere bir pasta grafiği kullanılmıştır. Bu kategoriler malign, benign ve geri arama olmadan benign şeklindedir (Şekil 3.2).



Şekil 3.2 Meme kanseri tipleri

Analiz, veri setinin %48,3'ü kötü huylu vakalardan, %43,8'i iyi huylu vakalardan ve %7,9'u geri arama gerektirmeyen iyi huylu vakalardan oluştuğunu ortaya koymaktadır. Bu oranlar, veri setinin nispeten dengeli olduğunu göstermektedir. Bu denge, derin öğrenme görevleri için özellikle ikili sınıflandırmada kritik bir faktördür. Dengeli bir veri

seti, modelin çoğunluk sınıfına yönelik önyargı olasılığını en aza indirir ve adil model değerlendirmesini sağlar.

Gözlemlenen dengeli sınıf dağılımı, sağlam eğitim ve değerlendirme için hayati öneme sahiptir. Veri seti önemli ölçüde dengesiz olsaydı (örneğin, bir sınıf verilerin %80'inden fazlasını oluşturuyorsa) model baskın sınıfa aşırı uyum sağlayabilir ve azınlık sınıfını göz ardı edebilirdi. Bu veri setinde gözlemlenen oranlar, bu tür riskleri azaltarak bir sınıflandırma modeli eğitimi için sağlam bir temel sağlar.

Ayrıca, "geri arama olmadan benign" adlı ayrı bir kategorinin eklenmesi, veri setini ek nüanslar sağlayarak zenginleştirir. Bu kategori, başlangıç değerlendirmesinden sonra benign olarak değerlendirilen ancak daha fazla takip gerektirmeyen vakaları temsil eder. Bu durum, bu verileri standart benign vakalardan ayırır. Bu tür ayrımları anlamak, modeli ince patolojik farklılıkları ayırt etmek için optimize etmeye yardımcı olabilir.


3.2.3.2 Meme yoğunluğu ile patoloji arasındaki ilişki

İkinci görselleştirme, meme yoğunluğu dereceleri ile patoloji türleri arasındaki ilişkiyi inceleyerek veri setine daha derinlemesine bakılmasına olanak sağlamaktadır. Bu analiz için, x ekseninde meme yoğunluk dereceleri ve patoloji kategorileri renk kodlu tonlarla gösterilen bir sayım grafiği kullanılmıştır (Şekil 3.3). Bu tür bir grafik, kategorik ilişkileri ve dağılım desenlerini anlamak için özellikle etkilidir.

Meme yoğunluğu dört dereceye ayrılır: i) Derece 1: Yağlı, ii) Derece 2: Dağınık fibroglandüler yoğunluk, iii) Derece 3: Heterojen olarak yoğun ve iv) Derece 4: Aşırı yoğun.

Şekil 3.3, belirli meme yoğunluk derecelerinin malign veya benign vakalarla daha sık ilişkilendirilip ilişkilendirilmediğini ortaya koymaktadır. Örneğin, daha yüksek meme yoğunluğu (3. ve 4. dereceler), malign vakalarla daha güçlü bir korelasyon gösterebilir ve

bu durum yoğun meme dokusunun görüntülemeye kitleleri gizleyebileceği ve kanser riskini artırabileceği bilinen klinik gözlemleri yansıtır.



Şekil 3.3 Meme yoğunluğu ile patoloji arasındaki ilişki

Sayım grafiğinde gözlemlenen ana desenler şunlardır:

- Malign vakaların dağılımı, meme yoğunluğu derecelerine göre önemli ölçüde değişiklik göstermektedir; 2. ve 3. derecelerde malign vakaların daha büyük bir oranı görülmektedir.
- İyi huylu vakalar tüm derecelere daha eşit şekilde dağılmıştır ancak 4. derecede daha az sıklıkta görünmektedir.
- Geri arama olmadan benign kategorisi, veri setindeki daha küçük oranını yansıtarak tüm derecelerde nispeten seyrekler.

Bu görselleştirme, hem sınıflandırma performansını hem de model yanlılığını etkileyebilecek potansiyel eğilimleri vurgulamaktadır. Örneğin, belirli yoğunluk

dereceleri bir patoloji kategorisinde aşırı temsil ediliyorsa, model bu derecelere yönelik önyargılı özellikler öğrenebilir. Bu tür eğilimleri tanımak, model eğitimi sırasında önyargıyı azaltmak ve çeşitli hasta popülasyonlarına genellenebilirliği sağlamak için esastır.

3.3 Görüntü ön işleme

Görüntü ön işleme, tıbbi görüntü analizi sürecinde, özellikle meme kanseri tespiti görevlerinde kritik bir adımdır. Modelin içine beslenen verilerin kalitesini, tutarlılığını ve yorumlanabilirliğini etkilediği için derin öğrenme modellerinin performansını doğrudan etkiler. Tıbbi görüntüleme ön işleme, görüntü çözünürlüğündeki değişiklikler, gürültü ve yoğunluk dağılımı gibi yaygın sorunların üstesinden gelmeye yardımcı olur. Bu zorluklar, uygun şekilde yönetilmezse, model performansını önemli ölçüde engelleyebilir. Bu bölüm, DenseNet121 ve Swin Transformer gibi derin öğrenme mimarileri için giriş verilerini optimize etmeye odaklanarak, bu çalışmada uygulanan ön işleme tekniklerini özetlemektedir. Bu yöntemler, görüntülerin uygun şekilde işlenmesini ve modellerin meme kanserini doğru bir şekilde sınıflandırma kapasitesinin en üst düzeye çıkarılmasını sağlar.

3.3.1 Görüntü yükleme ve standartlaştırma

Önişlem hattı, OpenCV kütüphanesini kullanarak mamografi görüntülerini yükleyerek başlatılmıştır. OpenCV, verimliliği ve esnekliği nedeniyle görüntü manipülasyonu için yaygın olarak kullanılmaktadır. Veri setindeki görüntüler başlangıçta OpenCV'de varsayılan olan BGR (Mavi, Yeşil, Kırmızı) renk formatında saklanmaktaydı. Ancak, çoğu konvolüsyonel sinir ağı (CNN) için giriş gereksinimlerine uyum sağlamak amacıyla, görüntüler RGB(Kırmızı, Yeşil, Mavi) formatına dönüştürülmüştür.

Görüntü formatını standartlaştırmak çok önemlidir çünkü DenseNet121 ve Swin Transformer gibi derin öğrenme modelleri genellikle tutarlı bir giriş yapısı beklemektedir. Renk kanallarındaki veya görüntü formatındaki herhangi bir varyasyon, eğitim süreci

sırasında hatalara veya verimsizliklere yol açabilir. Tüm görüntülerin RGB formatında olmasını sağlamak, bu tür tutarsızlıkları ortadan kaldırır ve giriş verilerini standartlaştırır. Böylece, modellerin etkili bir şekilde öğrenmesi sağlanmış olunur.

3.3.2 Görüntü yeniden boyutlandırma

Veri seti, farklı çözünürlüklere sahip görüntülerden oluşmaktadır. Bu durum yeniden boyutlandırmayı gerekli bir ön işleme adımı haline getirmektedir. Tutarlılığı sağlamak için tüm görüntüler 224×224 piksel sabit çözünürlüğe yeniden boyutlandırılmıştır. Bu yeniden boyutlandırma, genellikle bu boyutta kare görüntüler bekleyen CNN modellerinin giriş boyutu gereksinimini karşılamak için yapılmıştır.

224×224 piksel seçimi, DenseNet121 de dahil olmak üzere birçok yerleşik derin öğrenme modelinin bu çözünürlükteki görüntüler üzerinde eğitilmiş olması gerçeğine dayanmaktadır; bu da uyumluluğu sağlar ve önceden eğitilmiş ağırlıkların kullanılmasına olanak tanır ve böylece eğitimi hızlandırır.

Standart 224×224 çözünürlüğüne ek olarak, çoklu çözünürlük yaklaşımı kullanılmıştır. Görüntüler ayrıca daha küçük boyutlara, özellikle 112×112 ve 56×56 piksel boyutlarına yeniden boyutlandırılmıştır. Bu çoklu çözünürlük stratejisi, giriş görüntüsünün ölçeğinin model performansını nasıl etkilediğinin incelenmesine olanak tanımaktadır.

Farklı görüntü çözünürlüklerinin etkisini inceleyerek, değişen uzamsal ölçeklerin modelin görüntülerden özellikleri çıkarma yeteneğini nasıl etkileyebileceğini anlamak amaçlanmıştır. Bu yaklaşım, lezyonlar ve tümörlerin farklı boyutlarda ve detay seviyelerinde görünebileceği tıbbi görüntülemelerde özellikle faydalıdır ve modelin çeşitli ölçeklerde genelleme yapması gerekir.

3.3.3 Kontrast artırma

Mammografi görüntülerindeki zorluklardan biri, erken evre malignitelerin göstergesi olan mikrokalsifikasyonlar gibi ince yapıların görünürlüğüdür. Bu sorunu çözmek için Kontrast Sınırlı Adaptif Histogram Eşitleme (CLAHE) uygulanmıştır. CLAHE, bir görüntünün kontrastını artırırken yerel özellikleri koruyan ve geleneksel histogram eşitleme yöntemlerinde yaygın bir sorun olan gürültünün amplifikasyonunu önleyen sofistike bir tekniktir.

CLAHE’de, görüntü önce LAB renk alanına dönüştürülür. Burada L kanalı aydınlatmayı temsil eder. Geliştirme, L kanalına uygulanarak yoğunluk değerlerini yeniden dağıtır ve yerel kontrastı artırır. Bu yöntem, tıbbi görüntülemelerde özellikle faydalıdır, çünkü mikrokalsifikasyonlar gibi ince anormalliklerin istenmeyen artefaktlar veya gürültü eklenmeden daha görünür olmasını sağlar. Bu kritik özelliklerin görünürlüğünü artırarak CLAHE, derin öğrenme modellerinin erken aşamalarda maligniteleri tespit etme yeteneğini geliştirir.

3.3.4 Negatif dönüşüm

Negatif dönüşüm, ters dönüşüm olarak da bilinir ve ön işleme hattına ek bir adım olarak entegre edilmiştir. Bu teknik, görüntüdeki piksel değerlerini tersine çevirerek, parlak alanların karanlık ve tersine dönüştüğü alternatif bir temsil oluşturur. Negatif dönüşüm, orijinal görüntüde tespit edilmesi zor olabilecek yüksek kontrastlı alanları vurgulamak için tıbbi görüntülemelerde özellikle faydalıdır. Örneğin, normal görüntülerde karanlık görünen doku yapıları negatif dönüşümlü görüntüde daha belirgin hale gelebilir ve bu durum derin öğrenme modellerinin maligniteyi gösteren özellikleri tanımasını kolaylaştırır.

Tamamlayıcı temsiller sağlayarak negatif dönüşüm, modellerin sağlamlığını artırır ve modellerin eğitim sırasında daha geniş bir özellik yelpazesini çıkarmalarına olanak tanır.

Bu dönüşüm, özellikle gözden kaçabilecek ince doku anormalliklerini tespit etmede özellikle faydalıdır.

3.3.5 Normalizasyon

Normalizasyon, piksel yoğunluk değerlerini genellikle [0-1] aralığına ölçeklendiren temel bir ön işleme adıdır. Normalizasyon, derin öğrenme modellerinin verileri verimli bir şekilde işlemesini sağlar, çünkü sinir ağları girdiler normalize edildiğinde daha iyi performans gösterir. Normalizasyon olmadan modeller, veri kümesindeki büyük yoğunluk varyasyonları nedeniyle eğitim sırasında yakınsama sağlamakta zorlanabilir.

Bu çalışmada, aydınlatma ve tarayıcı ayarları gibi görüntü elde etme koşullarındaki farklılıkları hesaba katmak için tüm görüntülerde normalizasyon yapılmıştır. Piksellerin değerlerini ölçeklendirerek, normalizasyon, bu faktörler tarafından ortaya çıkan herhangi bir yanlılığı ortadan kaldırır ve modelin eğitim sürecinin daha kararlı olmasını sağlar. Ayrıca, normalizasyon, modelin yakınsamasını engelleyebilecek ve eğitim verimliliğini azaltabilecek kaybolan veya patlayan gradyanlar gibi sorunları önlemeye yardımcı olur.

3.3.6 Veri çoğaltma

Veri setindeki sınıf dengesizliğini gidermek ve model genellemesini iyileştirmek için Keras'tan ImageDataGenerator kullanılarak veri artırma teknikleri uygulanmıştır. Veri artırımı, mevcut görüntülerin yeni varyasyonlarını oluşturarak eğitim veri setinin çeşitliliğini yapay olarak artırır. Böylece, etiketli verilerin az ve dengesiz olabileceği tıbbi görüntülemelerde fayda sağlanır.

Bu çalışmada kullanılan artırma teknikleri arasında rastgele döndürmeler, yakınlaştırma, yatay ve dikey çevirme ve kaydırma yer almaktadır. Bu dönüşümlerin her biri, görüntülerdeki lezyonların yönlendirilmesi, ölçeği ve konumlandırılması gibi gerçek dünya varyasyonlarını simüle etmektedir. Bu tür varyasyonlar tanıtılarak, model daha geniş bir olası görüntü konfigürasyonu yelpazesine maruz kalır, görünmeyen verilere

genelleme yapma yeteneğini artırır ve sınırlı eğitim setine aşırı uyum sağlama riskini azaltır.

3.3.7 Etiket eşleştirme

İkili sınıflandırma için, veri seti üç sınıf içermektedir: Malign, Benign ve Geri arama olmadan benign. Ancak, bu çalışmanın ana odak noktası malign ve benign vakaları ayırt etmek olduğundan, üç sınıf ikili bir formata dönüştürüldü. Malign görüntülere 1 etiketi verilirken hem Benign hem de Geri arama olmadan benign görüntüleri 0'a eşlenmiştir.

Bu ikili kodlama, sınıflandırma görevini basitleştirir ve çalışmanın malign vakaları belirleme amacına uygun hale getirir. Modelin, meme kanseri tespitinde birincil klinik öneme sahip olan bu iki geniş kategori arasında ayırım yapmaya odaklanmasını sağlar.

3.3.8 Veri setinin bölünmesi

Veri seti, modelin performansını etkili bir şekilde değerlendirmek için eğitim ve test setlerine ayrılmıştır. %80-20 oranı kullanılmış ve görüntülerin %80'i eğitim ve %20'si test için ayrılmıştır. Bu bölme ile modelin verilerin büyük bir kısmı üzerinde eğitilmesini sağlarken, test seti modelin genelleme yeteneğinin tarafsız bir tahminini sağlar.

Ayrı bir test setinin kullanılması, modelin görülmemiş veriler üzerindeki performansını değerlendirmede kritik öneme sahiptir; bu, aşırı uyum sağlamayı önlemeye yardımcı olur ve modelin gerçek dünya uygulamalarındaki geçerliliğinin daha güvenilir bir değerlendirmesini sağlar.

3.3.9 Çoklu yama stratejisi

Görüntülerin standart çözünürlüklere yeniden boyutlandırılmasının yanı sıra çoklu yama yaklaşımı uygulanmıştır. Bu strateji, görüntüleri farklı boyutlarda daha küçük parçalara (224×224 , 112×112 ve 56×56 piksel) ayırmayı ve her bir parçayı ayrı ayrı işlemeyi

içermekteydi. Çoklu yama yaklaşımı, farklı uzamsal çözünürlüklerdeki özellikleri yakalamak için avantajlıdır ve bu durum modelin farklı boyutlardaki lezyonları ve anormallikleri daha iyi tanımlamasını sağlar.

Yama kullanımı, modelin görüntünün yerleşmiş bölgelerine odaklanmasını sağlar. Bu yaklaşım, tümörler veya mikro kalsifikasyonlar gibi anormalliklerin küçük ve yerleşmiş alanlarda görünebileceği tıbbi görüntülemede özellikle faydalıdır. Bu teknik, aynı görüntünün birden fazla perspektifini tanıtarak veri setini zenginleştirir ve nihayetinde modelin anormal doku yapılarını tespit etme ve sınıflandırma yeteneğini geliştirir.

3.3.10 Önişlem hattı uygulaması

Önişlem hattı, farklı önişlem tekniklerinin sorunsuz entegrasyonuna olanak tanıyan modüler ve esnek olacak şekilde tasarlanmıştır. Hattaki her adım, derin öğrenme modellerinin performansı üzerindeki etkisi için doğrulanmıştır ve en etkili tekniklerin kullanıldığından emin olunmuştur. Bu modülerlik, farklı ön işleme yöntemlerinin kombinasyonlarıyla deney yapmayı da kolaylaştırarak, DenseNet121, Nasnet, Xception ve Swin Transformer mimarileri için önişleme iş akışının ince ayarını yapmayı sağlamıştır.

Kapsamlı ve sistematik bir ön işleme hattı uygulayarak, bu çalışma giriş görüntülerinin derin öğrenme modelleri için en iyi şekilde hazırlığını sağlamıştır. Görüntü yükleme, yeniden boyutlandırma, kontrast artırma ve artırma işlemlerinin dikkatli bir şekilde ele alınması, sınıflandırma sonuçlarının sağlamlığına ve güvenilirliğine katkıda bulunmuştur. Bu çalışmada kullanılan ön işleme teknikleri, tıbbi görüntülemenin doğasında bulunan zorlukların üstesinden gelinmesinde ve derin öğrenme modellerinin meme kanserini doğru bir şekilde tespit etme ve sınıflandırma kapasitesinin artırılmasında hayati öneme sahip olmuştur.

3.4 Model mimarileri, seçimi ve gerekçesi

Derin öğrenme alanı hızlı ilerlemeler kaydetmiştir ve bu da karmaşık görüntü tanıma görevlerine yönelik mimarilerin geliştirilmesine yol açmıştır. Bu bölüm, DenseNet121, NASNetLarge, Xception ve Swin Transformer V2'nin teorik temellerini, yapısal yeniliklerini ve pratik uygulamalarını sunmaktadır. Bu mimariler, yoğun bağlantılı katmanlardan hiyerarşik dönüştürücülere kadar uzanan sinir ağı tasarımında çeşitli felsefeleri temsil eder ve meme kanseri sınıflandırma görevlerine uygunlukları nedeniyle seçilmiştir.

3.4.1 Tıbbi görüntülemede mimari seçiminin önemi

Tıbbi görüntüleme yoluyla meme kanseri teşhisinde, birkaç kritik zorluk görülmektedir:

- Hastalar arası değişkenlik: Meme yoğunluğu, tümör morfolojisi ve bireysel anatomik yapılardaki farklılıklar, mamografik görüntülerde değişkenlik yaratır.
- Görüntü ekipmanlarındaki farklılıklar: Farklı mamografi sistemlerinin kullanılması, görüntü kalitesi, çözünürlük ve gürültü seviyelerinde farklılıklara yol açar.
- Yüksek çözünürlüklü görüntüleme: Mamogramlar genellikle 2.000 x 2.000 pikseli aşar ve bu da uzamsal detayları korurken hesaplama verimliliğini sağlamak için mimariler gerektirir.
- Özellik granülaritesi: Mikrokalsifikasyonlar ve mimari bozulmalar gibi ince göstergeler, ince ayrıntıları yakalamak için çok ölçekli özellik çıkarımı gerektirir.


Bu zorlukların üstesinden gelmek, çeşitli görüntüleme koşullarında sağlam genelleme yapabilen model mimarileri gerektirir. DenseNet121'in verimli özellik yeniden kullanımı, NASNetLarge'ın otomatik hücre tasarımı, Xception'ın hesaplama basitliği ve Swin Transformer'ın küresel dikkat mekanizmaları bu gereksinimlerle uyumludur.

3.4.2 DenseNet121

DenseNet, Huang ve diğerleri (2017) tarafından önerilen ve geleneksel CNN'lerden bir paradigma değişikliği olarak ortaya çıkmıştır. Yoğun bağlantısı, derin ağlarda kaybolan gradyanlar ve gereksiz özellik çıkarımı gibi sorunları ele alır. DenseNet121, 121 katmanlı daha hafif bir varyant, kompaktlık ve verimlilik sağlayarak bu yeniliği örnekler.

DenseNet'in ana yeniliği, her katmanda kaç yeni özellik haritasının ekleneceğini belirleyen büyüme oranında (k) yatmaktadır. Darboğaz (1x1 konvolüsyonlar) ve geçiş katmanlarının (sıkıştırma katmanları) kullanımı, verimli hesaplamayı sağlar.

DenseNet'in bileşenleri: i) Sıkı Bloklar: Her blok, önceki tüm katmanlara bağlı birden fazla katman içerir, ii) Geçiş Katmanları: Aşırı bellek kullanımını önlemek için uzamsal boyutları ve özellik haritalarını azaltır ve iii) Özellik Yeniden Kullanımı: Ağ boyunca çok ölçekli özelliklerin birleştirilmesini kolaylaştırır.



Şekil 3.4 DenseNet121 mimarisi (Huang et al., 2017)

Sunulan çalışmada, DenseNet121, özellikleri verimli bir şekilde yeniden kullanma yeteneği sayesinde, aşırı derin ağlara olan ihtiyacı azaltması nedeniyle seçilmiştir. Kompakt tasarımı, mamografi gibi yüksek çözünürlüklü tıbbi görüntülerle çalışırken kritik olan bellek kullanımını da en aza indirir.

Mimari yapının güçlü özellik yayılım yeteneği, mikrokalsifikasyonlar ve kitleler gibi maligniteyi gösteren ince özelliklerin etkili bir şekilde yakalanmasını sağlar. Bu durum,

DenseNet121'i meme kanseri tespiti gibi incelikli bir görev için özellikle uygun hale getirir.

Bu çalışmada, önceden eğitilmiş DenseNet121, meme kanseri tespiti için ikili sınıflandırma görevine uyum sağlamak amacıyla üst katmanları değiştirilerek ince ayar yapılmıştır (Çizelge 3.2).

Temel Model: ImageNet üzerinde önceden eğitilmiş ağırlıklarla başlatılan DenseNet121 mimarisi, tam bağlantılı katmanlar olmadan kullanılmıştır. Bu kesme, görev spesifik katmanların entegrasyonuna olanak sağlamıştır.

Özel Katmanlar:

- Küresel Ortalama Havuzlama Katmanı: Uzamsal bilgiyi korurken boyut azaltma için tam bağlantılı katmanların yerini alır.
- Tam Bağlantılı Yoğun Katman: Aşırı uyumu önlemek için L1 ve L2 düzenlemesi içeren ve 1024 nöron ve ReLU aktivasyonu olan yoğun bir katman eklenmiştir.
- Dropout Katmanı: Aşırı uyumu önlemek için %0.5'lik bir dropout oranı uygulanmıştır.
- Final Çıkış Katmanı: İkili sınıflandırma(malignant/benign) için olasılıkları tahmin etmek üzere sigmoid aktivasyonlu tek bir nöron.

Derlenen model, 0,0001 başlangıç öğrenme oranına sahip Adam optimizasyonunu, ikili çapraz entropi kayıp fonksiyonunu ve birincil değerlendirme metriği olarak doğruluğu kullanmıştır.

Çizelge 3.2 DenseNet121 mimari özeti

Katman Tipi	Çıktı Şekli	Parametre
DenseNet121 (base)	(7, 7, 1024)	7,978,856
Global Ortalama Havuzlama 2D	(1024)	0
Yoğun (1024, ReLU)	(1024)	1,049,600
Dropout (p=0.5)	(1024)	0
Yoğun (1, Sigmoid)	(1)	1

Eğitim Teknikleri:

- Geri Çağırımlar: Doğrulama kaybı durakladığında eğitimi durdurmak için erken durdurma (patience=5) ve üç dönem duraklamadan sonra öğrenme oranını 0,5 kat azaltan bir öğrenme planlayıcısı uygulanmıştır.
- Artırma: Modelin dayanıklılığını artırmak için veri artırma (örneğin, döndürmeler, ters çevirme ve yakınlaştırmalar) uygulanmıştır.

3.4.3 NASNetLarge

NASNetLarge, Zoph ve arkadaşları (2018) tarafından tanıtılan, Sinirsel Mimari Arama (NAS) aracılığıyla otomatik sinir mimarisi tasarımında önemli bir sıçramayı temsil etmektedir. NASNet, optimal konfigürasyonlar tasarlamak için pekiştirmeli öğrenmeyi kullanarak manuel mimari mühendisliğine bir çözüm olarak ortaya çıkmıştır. Mimari, hesaplama birimlerinin yeniden kullanılmasına ve kolay ölçeklenmeye olanak tanıyan hücre tabanlı bir yapıya dayanır.

NASNet'teki yenilik, NAS aracılığıyla tanımlanan iki tür hücrenin—normal hücreler ve azaltma hücreleri—kullanımında yatmaktadır (Şekil 3.4). Bu hücreler, hesaplama verimliliği ve performans arasında bir denge kurar ve modüler tasarımları görevler arasında aktarılabilirliği destekler. Bu otomatik ve ölçeklenebilir mimari tasarım


yaklaşımı, NASNetLarge'ı karmaşık görüntü tanıma görevleri için bir kıyaslama modeli olarak konumlandırmıştır.

Normal Hücreler: Uzamsal boyutları korur ve özellik iyileştirmeye odaklanır.

Azaltma Hücreleri: Girdi boyutunu azaltarak uzamsal boyutları küçültürken hiyerarşik bilgiyi yakalar.

Ayrılabilir Konvolüsyonlar: Hesaplama açısından verimli bir mekanizma olan bu yöntem, konvolüsyon işlemlerini uzamsal ve derinlik bileşenlerine ayırarak performansı artırır ve hesaplama maliyetini artırmadan çalışır.

Atlama Bağlantıları: DenseNet'e benzer şekilde, NASNet gradyan akışını kolaylaştırmak ve kaybolan gradyan sorununu hafifletmek için atlama bağlantılarını kullanır.



Şekil 3.5 NASNetLarge mimarisi (Xing vd., 2022)

Sunulan çalışmada, NASNetLarge, yüksek çözünürlüklü görüntü verilerini işleme konusundaki son teknoloji performansı nedeniyle seçilmiştir. Meme kanseri için imaj süreçlendirmede, otomatik tasarım, mamogramların heterojenliğine iyi uyum sağlar ve mimari bozulmalar ve kalsifikasyonlar gibi maligniteyi gösteren ince dokuları ve anormallikleri yakalar. Ayrıca, ölçeklenebilir tasarımı, farklı giriş çözünürlüklerinin

verimli bir şekilde işlenmesini sağlar ve bu durum mamogramları çeşitli uzamsal boyutlar için ideal hale getirir.

Önceden eğitilmiş NASNetLarge modeline, ikili sınıflandırma görevine uyum sağlamak için ince ayar yapılmıştır (Çizelge 3.3).

Temel Model: ImageNet üzerinde önceden eğitilmiş ağırlıklarla başlatılan NASNetLarge mimarisi, görev özelinde özelleştirme sağlamak için tam bağlantılı katmanları olmadan kullanılmıştır.

Özel Katmanlar:

- Küresel Ortalama Havuzlama: Tam bağlantılı katmanların yerini alarak uzamsal bilgiyi tek bir vektörde toplamıştır.
- Tam Bağlantılı Yoğun Katman: Karmaşık özellik etkileşimlerini öğrenmek için 256 nöronlu ve ReLU aktivasyonlu bir yoğun katman eklenmiştir.
- Dropout Düzenlemesi: Aşırı uyumu azaltmak için %0,5'lik bir dropout oranı uygulanmıştır.
- Çıkış Katmanı: Tek bir nöron, sigmoid aktivasyon ile görüntüleri malign veya benign olarak sınıflandırmıştır.

Eğitim Teknikleri:

- Optimizer: Başlangıç öğrenme oranı 0,0001 olan Adam optimizasyonu.
- Geri çağırımlar: Erken durdurma (patience= 5) ve üç dönem duraklamadan sonra öğrenme oranını yarıya indiren bir öğrenme oranı zamanlayıcısı.
- Artırma: Genelleştirmeyi iyileştirmek için rotasyonlar, döndürmeler ve yakınlaştırmalar gibi veri artırma stratejileri kullanılmıştır.

Çizelge 3.3 NASNetLarge mimarisi özeti

Katman Tipi	Çıktı Şekli	Parametre
Girdi Katmanı	(224, 224, 3)	0
NASNetLarge (base)	(7, 7, 4032)	84,916,818
Global Ortalama Havuzlama 2D	(4032)	0
Yoğun (256, ReLU)	(256)	1,032,448
Dropout (p=0.5)	(256)	0
Yoğun (1, Sigmoid)	(1)	257


3.4.4 Xception

Xception (Extreme Inception), Chollet tarafından tanıtılmış (2017) ve derinlik benzeri ayrılabilir konvolüsyonları tamamen benimseyerek Inception mimarisinden geliştirilmiştir. Bu yenilik, yüksek temsil gücünü korurken modeli basitleştirmiştir. Xception, özellik haritalarındaki uzamsal korelasyonlar ve kanallar arası korelasyonların bağımsız olarak öğrenilebileceği ilkesine dayanarak çalışır ve böylece hem verimliliği hem de performansı optimize eder. Mimari, ayrılabilir konvolüsyonların CNN'lerde geleneksel konvolüsyonların yerini alabileceği hipotezine dayanarak (Şekil 3.5), doğruluktan ödün vermeden hesaplama karmaşıklığını önemli ölçüde azaltır.

Derinlik Ayrılabilir Konvolüsyonlar: Standart konvolüsyonları, hesaplama verimliliği için iki aşamaya ayırır—derinlik bazlı (uzamsal filtreleme) ve nokta bazlı (kanal bazlı projeksiyon).

Artık Bağlantılar: Derin ağların etkili bir şekilde eğitilmesini sağlayarak gradyan akışını iyileştirir.

Doğrusal Darboğazlar: Temel özellikleri korurken boyut azaltımını sağlar.



Şekil 3.6 Xception mimarisi (Chollet, 2017)

Sunulan çalışmada, Xception, verimliliği ve yüksek boyutlu verileri etkili bir şekilde işleme yeteneği nedeniyle seçilmiştir. Derinlikten ayrılabilir konvolüsyonların kullanımı, modelin yüksek çözünürlüklü mamogramları işlerken bile hesaplama açısından verimli kalmasını sağlar. Mimari yapının güçlü özellik çıkarım yeteneği, asimetri ve mimari bozulmalar gibi meme kanseri ile ilişkili desenleri tanımlamada özellikle faydalıdır.

Önceden eğitilmiş Xception temel modeli, üst katmanları özel bileşenlerle değiştirerek uyarlanmıştır (Çizelge 3.4).

Temel Model: Tam bağlantılı katmanlar hariç olmak üzere, ImageNet ağırlıklarıyla başlatılmıştır.

Özel Katmanlar:

- Global Ortalama Havuzlama: Uzamsal özellikleri tek bir vektöre yoğunlaştırmıştır.
- Sıkı Katman: 256 nöronlu, ReLU aktivasyonu ve L2 düzenlemesi ile tamamen bağlı bir katman eklenmiştir.

- Dropout Düzenleme: Aşırı uyumu azaltmak için %0,5'lik bir dropout oranı eklenmiştir.
- Çıkış Katmanı: Sigmoid aktivasyonlu tek bir nöron, ikili sınıflandırmaları tahmin etmiştir.

Eğitim Teknikleri:

- Optimizer: Başlangıç öğrenme oranı 0,0001 olan Adam optimizasyonu.
- Artırma: Dayanıklılığı artırmak için rastgele dönüşümler uygulanmıştır.
- Geri Çağrılar: Erken durdurma ve öğrenme oranı planlaması.

Çizelge 3.4 Xception mimari özeti

Katman Tipi	Çıktı Şekli	Parametre
Girdi Katmanı	(224, 224, 3)	0
Xception (base)	(7, 7, 2048)	20,861,480
Global Ortalama Havuzlama 2D	(2048)	0
Yoğunluk (256, ReLU)	(256)	524,544
Dropout (p=0.5)	(256)	0
Yoğunluk (1, Sigmoid)	(1)	257

3.4.5 Swin Transformer


Swin Transformer, Liu ve diğerleri tarafından (2021) yılında tanıtılmıştır ve kaydırılmış pencere kendiliğinden dikkat mekanizmalarını entegre ederek yüksek çözünürlüklü görüntüler için verimli ve ölçeklenebilir özellik çıkarımı sağlamıştır. Böylece görsel dönüştürücüleri yeniden tanımlamıştır. Yerel alıcı alanlarına dayanan CNN'lerin aksine, Swin Transformer'lar küresel-yerel özellik öğrenimi için hiyerarşik yapılar kullanır (Şekil 3.6). Modelin yeniliği, çapraz pencere bilgi paylaşımını artıran ve hesaplama yükünü azaltan kaydırılmış pencereleme stratejisindedir. Bu durum, modeli mamografi analizi gibi yüksek çözünürlüklü görevler için özellikle uygun hale getirir.

Yama Bölme: Girdi görüntülerini işleme için örtüşmeyen yamalara dönüştürür.

Kaydırılmış Pencere Dikkati: Yerel pencereler içinde kendiliğinden dikkati hesaplar ve bunları katmanlar arasında kaydırarak küresel bağlamı yakalar.

Hiyerarşik Özellik Temsili: Çok ölçekli özellik öğrenimini sağlar.

MLP Katmanları: Karmaşık etkileşimleri yakalamak için token gömme işlemlerini işler.



Şekil 3.7 Swin Transformer mimarisi (Liu et al., 2021)

Sunulan çalışmada Swin Transformer V2, görsel görevlerdeki performansı ve farklı ölçeklerdeki görüntüleri işleme yeteneği nedeniyle seçilmiştir. Modelin hiyerarşik temsili, hem küresel bağlamı (tümör morfolojisi) hem de yerel desenleri (doku gradyanları) yakalamasını sağlar.

Özelleştirilmiş bir Swin Transformer V2 aşağıdaki gibi uygulanmıştır (Çizelge 3.5).

Temel Model: Mamografik özelliklere uyarlanmış önceden eğitilmiş Swin Tiny.

Çift Görüntü İşleme: Ayrı Swin modelleri, hem makro hem de mikro özellikleri yakalayıp tam mamogramları ve kesilmiş bölgeleri işlemiştir.

Özellik Birleştirme: İki Swin örneğinden gelen çıktılar, kapsamlı özellik entegrasyonu için birleştirilmiştir.

Özel Katmanlar:

- Dropout Düzenleme: Her aşamada %0,5 oranında dropout katmanları.
- Tam Bağlantılı Katman: Yoğun bir katman kullanarak entegre edilmiş birleştirilmiş özellikler ve çıktı olasılıkları.

Eğitim Teknikleri:

- Optimizer: $1e-5$ öğrenme oranı ve $1e-4$ ağırlık çürümesi ile Adam.
- Zamanlayıcı: Bir öğrenme oranı zamanlayıcısı, doğrulama kaybı durakladığında öğrenme oranını azaltmıştır.
- Kayıp Fonksiyonu: Kötü huylu sınıflandırmadaki dengesizlikleri ele almak için ikili çapraz entropi kaybı.

Çizelge 3.5 Swin Transformer V2 mimari özeti

Katman Tipi	Çıktı Şekli	Parametre
Girdi Katmanı (Tam İmaj)	(224, 224, 3)	0
Swin Tiny Patch4 Window7	(768)	~29,000,000
Dropout (p=0.5)	(768)	0
Girdi Katmanı (Kesikli İmaj)	(224, 224, 3)	0
Swin Tiny Patch4 Window7	(768)	~29,000,000
Dropout (p=0.5)	(768)	0
Bitiştirme (Concatenation)	(1536)	0
Dropout (p=0.5)	(768)	0
Tamamen Birleşmiş Katmanlar	(2)	3,074

3.4.6 Karşılaştırmalı analiz

Her bir mimaride yapılan değişiklikler, yüksek çözünürlüklü mamogramların getirdiği özel zorluklara en uygun şekilde uyum sağlamalarını sağlamıştır. Bu özelleştirme, modellerin hesaplama verimliliği ile yüksek doğruluğu dengelemesine olanak sağlamıştır. Model kıyaslaması Çizelge 3.6’da verilmiştir.

Çizelge 3.6 Model parametrelerinin karşılaştırmalı analizi

Model	Total Parametre	Eğitilebilir Parametre
DenseNet121	~8M	~1.05M
NASNetLarge	~88M	~1.03M
Xception	~22M	~1.01M
Swin Transformer	~29M (görünüm başına)	~2.2M

3.5 Eğitim süreci

Eğitim süreci, makine öğrenimi modellerinin performansını optimize etmede kritik bir adımdır. Bu durum, dikkatli hiperparametre ayarlamaları, hesaplama kaynaklarının kullanımı ve aşırı uyumdan kaçınmak için düzenleme tekniklerinin uygulanmasını içerir. Bu bölüm, kullanılan hesaplama kurulumu, kayıp fonksiyonları, optimizasyon stratejileri ve düzenleme yöntemleri hakkında ayrıntılı bir genel bakış sunar.

3.5.1 Hesaplama kaynakları

Deneyler, derin sinir ağlarının eğitimini önemli ölçüde hızlandıran NVIDIA Tesla P100 GPU ile donatılmış bir sanal makinede gerçekleştirilmiştir.

Çerçeveler:

- PyTorch: Swin Transformer tabanlı modelin uygulanması için kullanılmıştır.
- TensorFlow/Keras: DenseNet121, Xception ve NASNetLarge gibi modellerin eğitimi için kullanılmıştır.

GPU hızlandırması, özellikle yüksek boyutlu giriş verilerini ve karmaşık mimarileri işlemek için kritik öneme sahip olmuştur ve hesaplama süresini azaltarak verimliliği artırmıştır.

3.5.2 Komut-liste (batch)boyutu

Hesaplama verimliliği ve bellek kısıtlamalarını dengelemek için 32'lik bir batch boyutu seçilmiştir. Batch büyüklüğü, eğitim sürecinin kararlılığını ve hızını etkiler. Daha büyük batch'ler: Eğitimi istikrara kavuşturma eğilimindedir ancak daha fazla bellek gerektirir. Daha küçük batch'ler: Gradyan tahmininde gürültüye neden olabilir ancak daha hızlı yakınsama sağlayabilir.

3.5.3 Optimizer

Her bir parametre için öğrenme oranlarını uyumlu bir şekilde ayarlama yeteneği sayesinde daha hızlı yakınsama sağladığı için çalışmada Adam optimizasyon algoritması seçilmiştir. Adam algoritması, Momentum ve RMSProp'un faydalarını birleştirir ve bu da derin sinir ağlarını eğitmek için son derece etkili hale getirir. Her bir parametre için öğrenme oranını, gradyanların birinci ve ikinci moment tahminlerine göre uyarlamalı olarak ayarlar.

Adam için güncelleme kuralı şu şekildedir:

1. Kayıp fonksiyonunun gradyanını (θ) parametreler açısından hesaplar:

$$g_t = \nabla_{\theta} L(\theta_t)$$

2. Yanlı (biased) ilk (m_t) ve ikinci moment (v_t) tahminini günceller:

$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t &= \beta_2 v_{t-1} - 1 + (1 - \beta_2) g_t^2 \end{aligned}$$

Denklemden β_1 ve β_2 moment tahminleri için eksponansiyel düşüş oranlarıdır ve genellikle $\beta_1 = 0.9$ $\beta_2 = 0.999$ 'dir.

3. Başlangıcı sıfırda tutmak için m_t ve v_t için yanlılığı düzeltir:

$$\widehat{m}_t = \frac{m_t}{1 - \beta_1^t}, \widehat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

4. Parametreleri günceller:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\widehat{v}_t} + \epsilon} \widehat{m}_t$$

Denklemden η öğrenme oranı ve ϵ sıfıra bölünmeyi önlemek için küçük (örneğin 10^{-8}) bir sabittir.

PyTorch tabanlı uygulamada, L2 düzenlemesini dahil etmek için Adam optimizasyonu 1×10^{-5} öğrenme oranı ve 1×10^{-4} tercih azalması (decay) ile kullanılmıştır. Bu da optimizasyon sırasında büyük tercihleri dışlayarak genelleştirmeyi iyileştirmiştir.

3.5.4 Kayıp fonksiyonu

DenseNet121, NASNet ve Xception modelleri için, tahmin edilen olasılıklar (p) ile gerçek ikili etiketler (y) arasındaki farkı ölçmek için ikili çapraz entropi kayıp fonksiyonu kullanılmıştır. Tek bir veri noktası için kayıp fonksiyonu şu şekilde ifade edilebilir:

$$L_{BCE}(y, p) = -[y \log(p) + (1 - y) \log(1 - p)]$$

Swin Transformer'da çok sınıflı problemler için iyi genelleşen ancak bu uygulamada ikili sınıflandırma görevlerine özel olarak uyarlanmış olan Cross Entropy Loss kullanılmıştır.

3.5.5 Düzenleme teknikleri

Aşırı uyumu azaltmak için aşağıdaki düzenleme yöntemleri uygulanmıştır:

L1 ve L2 Düzenleme: Yoğun katman, büyük katsayıları önlemek için modelin tercihlerine kısıtlamalar ekleyen L1 ve L2 cezalarını (her biri 1×10^{-3}) içermektedir.

$$L_{regularized} = L_{BCE} + \lambda_1 \sum |w| + \lambda_2 \sum w^2$$

Dropout: Tam bağlantılı katmanlardan sonra eğitim sırasında rastgele nöronlar dışlayarak modelin sağlam olması ve çeşitli özellikler öğrenmesi teşvik eden %0,5'lik bir dropout oranı uygulanmıştır.

3.5.6 Öğrenme hızı planlaması

Bir öğrenme oranı zamanlayıcısı, doğrulama performansına göre öğrenme oranını dinamik olarak ayarlamıştır:

TensorFlow/Keras (DenseNet121, Xception ve NASNet): ReduceLROnPlateau geri çağırma işlevi, doğrulama kaybı üç ardışık dönem boyunca sabit kalırsa öğrenme oranını 0,5 kat azaltmıştır:

$$New\ LR = Current\ LR \times Factor$$

PyTorch (Swin Transformer): İyileşme olmadan iki dönemden sonra öğrenme oranı 0,1 kat azaltılmıştır.

3.5.7 Erken sonlandırma

Erken sonlandırma, doğrulama performansı iyileşmeyi durdurduğunda eğitimi durdurmak için uygulanmıştır. Sabır (patience) parametresi 5 dönem olarak ayarlanmıştır. Geri çağırma, doğrulama kaybını izlemiş ve modelin tercihlerini en düşük doğrulama

kaybına sahip olan devreden/andan geri yüklemiştir. Bu yaklaşım, gereksiz hesaplamaları azaltmıştır ve aşırı uyumu hafifletmiştir.

3.5.8 Eğitim ve doğrulama döngüsü

PyTorch (Swin Transformer): Aşağıdaki modülleri içleyen özel bir eğitim döngüsü oluşturulmuştur:

- İleri Yayılma: Girdi verileri, tahminleri hesaplamak için modelden geçirilmiştir.
- Geri Yayılım: Model parametrelerine göre kayıp fonksiyonunun gradyanları hesaplanmış ve tercihleri güncellemek için kullanılmıştır.
- Metriklerin Takibi: Eğitim ve doğrulama kaybı, doğruluk ve F1 skoru gerçek zamanlı olarak izlendi.
- Zamanlayıcı Güncellemeleri: Öğrenme oranı ayarlamaları, doğrulama kaybı eğilimlerine göre dinamik olarak gerçekleştirilmiştir.

DenseNet121, Xception ve NASNet: Eğitim ve doğrulama süreçlerini kolaylaştırmak için önceden tanımlanmış geri çağırımlarla birlikte fit API kullanılmıştır.

Bu sistematik eğitim yaklaşımı, aşırı uyum sağlamayı ve hesaplama yükünü en aza indirirken yüksek kaliteli model performansını garanti etmiştir.

4. BULGULAR VE TARTIŞMA

Bu bölüm, meme kanseri sınıflandırma modellerinden elde edilen deneysel sonuçların ayrıntılı bir tartışmasını sunmaktadır. Dört ileri düzey modelin—DenseNet121, NASNetLarge, Xception ve Swin Transformer—performansı değerlendirilmiştir ve karşılaştırılmıştır. Model performansını değerlendirmek için doğruluk, kesinlik, hatırlama, F1 skoru, karışıklık matrisi ve ROC-AUC gibi metrikler kullanılmıştır. Bölüm ayrıca ön işleme ve hiperparametre ayarlamasının etkisini incelemektedir, aşırı ve yetersiz öğrenme belirtilerini tartışmaktadır ve sonuçları önceki araştırmalarla karşılaştırmaktadır.

4.1 Model Değerlendirme Ölçütlerinin Genel Görünümü

Modellerin iyi huylu ve kötü huylu vakaları ayırt etme performansını değerlendirmek için altı temel metrik kullanılmıştır:

Doğruluk: Doğru sınıflandırılan vakaların oranını ölçer ancak dengesiz veri setlerinde yanıltıcı olabilir.

Kesinlik: Tüm pozitif tahminler arasındaki doğru pozitiflerin oranını yansıtır ve klinik teşhislerde yanlış pozitifleri en aza indirmek için kritik öneme sahiptir.

Duyarlılık: Doğru bir şekilde tanımlanan gerçek pozitiflerin oranını temsil eder ve kötü huylu vakaları yakalamak için kritik öneme sahiptir.

F1 Skoru: Kesinlik ve duyarlılığı dengeleyerek, dengeyi değerlendirmek için tek bir ölçüt sağlar.

Karışıklık Matrisi: Yanlış pozitif ve negatifler hakkında bilgi sunarak sınıflandırma hatalarını anlamaya yardımcı olur.

ROC-AUC: Modelin sınıflar arasında ayırım yapma yeteneğini değerlendirir ve eşikten bağımsız bir ölçüt sağlar.

4.2 Model Performans Analizi

4.2.1 DenseNet121

DenseNet121, iyi huylu ve kötü huylu vakaları ayırt etmedeki sağlamlığını gösteren %71,47 doğruluk ve %81 gibi nispeten yüksek bir ROC-AUC elde etmiştir. Aşağıdaki tablo, modelin performansını özetlemektedir. Karışıklık matrisi Şekil 4.1’de sunulmuştur. ROC eğrisi Şekil 4.2’de verilmiştir.


Çizelge 4.1 DenseNet121 sonuç özeti

Metrik	Yüzde
Doğruluk	71,47
Kesinlik	69,38
Geri Çağırma (recall)	66,23
F1 Skoru	67,77

Modelin F1 skoru (%67,77), kesinlik (%69,39) ve geri çağırma (%66,23) arasında makul bir dengeyi yansıtsa da geri çağırma değeri kötü huylu tümörleri doğru bir şekilde tanımlamada zorlukları vurgulamaktadır.


Yanlış Negatifler: 52 malign vaka, benign olarak yanlış sınıflandırılmıştır ve bu durum yanlış teşhis riskini artırmaktadır.

Yanlış Pozitifler: 45 iyi huylu vaka kötü huylu olarak yanlış sınıflandırılmıştır ve bu da gereksiz müdahalelere yol açabilir.



Şekil 4.1 DenseNet121 karışıklık matrisi

DenseNet121, yüksek kesinlik oranlarının geri çağırılardan daha fazla olması sayesinde kötü huylu vakalara kıyasla iyi huylu vakaları daha iyi tanıyabilmiştir. Bu dengesizlik, modelin duyarlılık yerine özgüllüğü tercih ettiğini göstermektedir. Ancak bu durum, malign vakaların tanımlanmasının kritik olduğu tıbbi uygulamalarda optimal değildir. İyileştirmeler, karar eşiğinin ayarlanmasını veya yanlış negatifleri daha ağır şekilde cezalandırmak için maliyet duyarlı öğrenmenin kullanılmasını içerebilir.




Şekil 4.2 DenseNet121 ROC eğrisi

4.2.2 NASNetLarge

NASNetLarge, tüm modeller arasında en yüksek hassasiyeti (%90,24) sergileyerek, tahmin edildiğinde malign vakaları doğru bir şekilde sınıflandırma konusunda güçlü bir yeteneğe sahip olduğunu göstermiştir. Ancak, geri çağırma oranı son derece düşüktür (%24,02), bu da düşük bir F1 skoru olan %37,94'e yol açmıştır (Çizelge4.2). Doğruluk da %64,41 ile düşüktür ve ROC-AUC 75 olarak tespit edilmiştir. Karışıklık matrisi Şekil 4.3'te ve ROC eğrisi Şekil 4.4'te sunulmuştur.

Çizelge 4.2 NASNetLarge sonuç özeti

Metrik	Yüzde
Doğruluk	64,41
Kesinlik	90,24
Geri Çağırma (recall)	24,02
F1 Skoru	37,94




Şekil 4.3 NASNetLarge karışıklık matrisi

Yanlış Negatifler: Şaşırtıcı bir şekilde 117 malign vaka, benign olarak yanlış sınıflandırılmıştır.

Yanlış Pozitifler: Sadece 4 benign vaka malign olarak yanlış sınıflandırılmıştır ve bu modelin temkinli yaklaşımını yansıtmaktadır.

NASNetLarge'ın yüksek hassasiyeti, yanlış pozitifleri en aza indirmenin öncelikli olduğu durumlar için kritiktir. Ancak, düşük geri çağırma oranı, kötü huylu vakaların atlanmasının ciddi sonuçlar doğurabileceği klinik uygulamalar için uygun değildir. Yetersiz performans, kötü huylu vakaları etkili bir şekilde genelleme yeteneğindeki eksiklikle kanıtlandığı gibi aşırı uyum sağlamamaya atfedilebilir. Gelecek çabalar, daha odaklanmış veri artırımı veya modelin malign örnekler üzerinde ince ayar yapılmasını içerebilir.




Şekil 4.4 NASNetLarge ROC eğrisi

4.2.3 Xception

Xception, orta derecede yüksek bir hassasiyet (%77,78) ve geri çağırma (%54,54) ile %72,35 doğruluk ve %64,12 F1 puanı elde etmiştir (Çizelge4.3). ROC-AUC puanı olan 79, sınıflar arasında ayırt etme konusunda güvenilir bir yaklaşım olduğunu göstermektedir. Karışıklık matrisi Şekil 4.5'te ve ROC eğrisi Şekil 4.6'da sunulmuştur.

Çizelge 4.3 Xception sonuç özeti

Metrik	Yüzde
Doğruluk	72.35
Kesinlik	77.77
Geri Çağırma (recall)	54.54
F1 Skoru	64.12




Şekil 4.5 Xception karışıklık matrisi

Xception, NASNetLarge'a kıyasla yanlış pozitifler ve yanlış negatifler arasında daha iyi bir denge göstermiştir.

Yanlış Negatifler: 70 malign vaka yanlışlıkla benign olarak sınıflandırılmıştır.

Yanlış Pozitifler: 24 benign vaka malign olarak yanlış sınıflandırılmıştır.

Xception, NASNetLarge'a kıyasla yanlış pozitifler ve yanlış negatifler arasında daha iyi bir denge sağlamıştır. DenseNet121'den daha yüksek bir geri çağırma oranı elde etme yeteneği, kötü huylu vakaları tanımlamada nispeten daha iyi olduğunu göstermektedir. Ancak, 70 yanlış negatifin varlığı, daha fazla iyileştirme gereksinimini vurgulamaktadır. Toplu tekniklerin dahil edilmesi veya eğitim veri setinin yeniden dengelenmesi, duyarlılığını artırabilir.




Şekil 4.6 Xception ROC eğrisi

4.2.4 Swin transformer

Swin Transformer, en yüksek doğruluğu (%76) ve ROC-AUC'yi (%85,9) elde ederek CNN tabanlı modelleri geride bırakmıştır. İyi huylu vakalar için hassasiyet (%86,00) ve duyarlılık (%72,00) ile dengeli bir performans sergilemiştir. Kötü huylu vakalar için ise bu oranlar sırasıyla %65,00 ve %82,00'dir (Çizelge4.4).Karışıklık matrisi Şekil 4.7'de ve ROC eğrisi Şekil 4.8'de verilmiştir.

Çizelge 4.4 Swin Transformer sınıflandırma raporu

Metrik	Benign	Malignant	Makro Ort	Ağırlıklı Ort
Kesinlik	%86,00	%65,00	%76,00	%78,00
Geri Çağırma	%72,00	%82,00	%77,00	%76,00
F1 Skoru	%78,00	%73,00	%76,00	%76,00




Şekil 4.7 Swin Transformer karışıklık matrisi

Yanlış Negatifler: Sadece 26 malign vaka benign olarak yanlış sınıflandırılmıştır ve bu tüm modeller arasında en düşük olanıdır.

Yanlış Pozitifler: 65 iyi huylu vaka kötü huylu olarak yanlış sınıflandırılmıştır.

Swin Transformer, hem yerel hem de küresel özellikleri etkili bir şekilde yakalamak için hiyerarşik dikkat mekanizmasını kullanmıştır ve bu sayede üstün performans sağlamıştır. Yüksek ROC-AUC'si, klinik uygunluğunu ve sağlamlığını vurgulamaktadır. Gelecekteki araştırmalar, tanısal doğruluğu daha da artırmak için alan bilgisiyle entegrasyonunu keşfedebilir.



Şekil 4.8 Swin Transformer ROC eğrisi

4.3 Karşılaştırmalı Performans Analizi

Karşılaştırmalı analiz, meme kanseri sınıflandırması için değerlendirilen modellerin çeşitli yeteneklerini vurgulamaktadır. Her bir model, klinik uygulamalar için uygunluklarına dair içgörüler sağlayarak, çeşitli metrikler arasında belirgin güçlü ve zayıf yönler sergilemiştir (Çizelge 4.5).

Swin Transformer, sürekli olarak üstün performans sergileyerek en yüksek doğruluğu (%76) ve ROC-AUC'yi (85,9) elde etmiştir. Hassasiyet ve geri çağırma metrikleri, hem yanlış pozitifleri hem de yanlış negatifleri minimize etme konusundaki dengeli yeteneğini göstermektedir. Bu durum, Swin Transformer'i klinik uygulama için sağlam bir seçim haline getirmektedir.

Metrikler Arasındaki Performans Eğilimleri

DenseNet121 ve Xception: Her iki model de kesinlik ve hatırlama arasında iyi bir denge sunmuştur. Xception doğruluk ve F1 puanında DenseNet121'i az da olsa geride bırakmıştır.

NASNetLarge: Kesinlikte (%90,24) mükemmel olmasına rağmen, en düşük geri çağırma oranını (%24,02) sergileyerek, malign vakaları atlama eğilimi göstermiştir. Bu, onu kanser teşhisi gibi hassasiyetin kritik olduğu yüksek riskli uygulamalar için uygunsuz hale getirmektedir.

Swin Transformer: Çoğu metrikte diğer tüm modelleri geride bırakmıştır ve dikkat mekanizmalarını kullanarak hiyerarşik görüntü özelliklerini yakalamadaki etkinliğini göstermiştir.

Çizelge 4.5 Model performanslarının metrik bazın kıyaslama tablosu

Metrik	DenseNet121	NASNetLarge	Xception	Swin Transformer
Doğruluk	%71,47	%64,41	%72,35	%76,00
Kesinlik	%69,39	%90,24	%77,78	%86,00
Geri Çağırma	%66,23	%24,02	%54,54	%82,00
F1 Skoru	%67,77	%37,95	%64,12	%76,00
ROC-AUC	81	75	79	85.9

4.4 Aşırı Uydurma ve Yetersiz Uydurma Analizi

Modellerin eğitim dinamiklerine daha derinlemesine bir bakış kazanmak için eğitim ve doğrulama kayıp ve doğruluk eğrileri analiz edilmiştir.

NASNetLarge:

- Yüksek eğitim doğruluğu ve neredeyse sabit doğrulama doğruluğu ile aşırı öğrenme belirtileri göstermiştir.
- Olası nedenler arasında aşırı agresif düzenleme ve CBIS-DDSM veri setinin karmaşıklığına uygun olmayan bir mimari bulunmaktadır.

DenseNet121 ve Xception:

- Eğitim doğruluğu, doğrulama doğruluğunu önemli ölçüde aşmıştır ve aşırı öğrenmenin hafif belirtilerini göstermiştir.
- Bu davranış, özellikle düzenleme veya veri artırma yetersiz olduğunda derin mimarilerinin eğitim verilerini ezberleme eğiliminde olduğuna işaret etmektedir.


Swin Transformer:

- Eğitim ve doğrulama eğrileri arasında minimal sapma ile dengeli öğrenme dinamikleri sergilemiştir.
- Daha düzgün eğriler ve daha düşük genelleme farkı, etkili özellik çıkarımı ve sağlam genelleme kapasitesini vurgular.

4.5 Yanlış Sınıflandırılan Örneklerin Analizi

Mammografik görüntülerin doğru sınıflandırılması, etkili meme kanseri tespiti için kritik öneme sahiptir. Ancak, hiçbir model mükemmelliği başaramaz ve yanlış sınıflandırmalar, yanlış pozitiflik ve negatiflik, modellerin ve veri setlerinin sınırlamaları hakkında değerli bilgiler sağlar. Swin Transformer tarafından yanlış sınıflandırılan örneklerin kapsamlı bir analizi, tekrarlayan kalıpları, potansiyel veri seti sınırlamalarını ve iyileştirme

stratejilerini belirlemek için gerçekleştirilmiştir. Yanlış sınıflandırılan mamografi görüntüleri Şekil 4.9’da sunulmuştur.



Şekil 4.9 Swin Transformer ile yanlış sınıflandırılan mamogramlar

4.5.1 Yanlış negatifler

Yanlış negatifler, malign vakaların iyi huylu olarak yanlış sınıflandırıldığı durumlar, tıbbi teşhislerdeki en kritik hatalardan biridir. Bu hatalar, meme kanserinin teşhis ve tedavisini geciktirebilir ve bu da hastalar için ciddi sonuçlara yol açabilir. Bu vakaların daha yakından incelenmesi aşağıdaki zorluklara ve olası problemlere işaret etmiştir.

4.5.1.1 Düşük kontrastlı lezyonlar

Düşük kontrastlı malign lezyonlar genellikle çevresindeki meme dokusuna karışır ve bu da hem radyologlar hem de makine öğrenimi modelleri için tespit edilmesini zorlaştırır. Bu lezyonlar genellikle şunları sergiler:

İnce yoğunluk farkları: Malign bölge, çevre dokudan yalnızca hafifçe daha yoğun görünür.

Difüz sınırlar: Lezyonun kenarları kötü tanımlanmış olup lokalizasyon konusunda belirsizliğe yol açar.

Gürültü müdahalesi: Görüntüleme artefaktları veya gürültü, malign bölgeyi daha da belirsizleştirerek özellik çıkarımını zorlaştırabilir.

Önerilen çözümler şu şekildedir:

Kontrast Artırıcı Artırmalar: Eğitim görüntülerine yerel parlaklık ve kontrast ayarlamaları uygulamak, modellerin ince varyasyonları tespit etmeyi öğrenmesine yardımcı olabilir.

Çok Ölçekli Analiz: Çoklu çözünürlüklerde görüntüleri işleyen mimarilerin kullanılması, modelin ince ayrıntılı özellikleri tanıma yeteneğini artırabilir.

4.5.1.2 Benign benzeri özellikler

Bazı malign lezyonlar görünüm olarak benign kitlelere benzer. Örneğin, i) Düzgün Kenarlar: Bazı malign lezyonlar, iyi sınırlı, düzgün kenarlara sahip olup, iyi huylu özellikleri taklit eder ve ii) Homojen Doku: Malign lezyonlar, kanserli büyümelerle tipik olarak ilişkili olan heterojenliği yoksun bırakabilir ve bu durum kafa karışıklığına yol açabilir.

Önerilen çözümler şu şekildedir:

Özellik-Özel Eğitim: Mikro kalsifikasyonlar veya düzensiz kenarlar gibi ayırt edici özelliklere odaklanan dikkat mekanizmalarının tanıtılması performansı artırabilir.

Veri Setinin Genişletilmesi: Eğitim setine benign benzeri özelliklere sahip daha fazla malign vakayı dahil etmek modelin bu vakaları ayırt etme yeteneğini artırabilir.

4.5.1.3 Nadir malign alt tipler

Veri setinde daha az sıklıkla meydana gelen malign alt türlerin, eğitim sırasında sınırlı temsil edilmeleri nedeniyle yanlış sınıflandırılma olasılığı daha yüksektir.

Önerilen çözümler şu şekildedir:

Nadir Vakalar için Veri Artırma: Sentetik aşırı örnekleme ve üretici karşıt ağlar (GAN) gibi teknikler nadir alt türlerin ek örneklerini oluşturmak için kullanılabilir.

4.5.2 Yanlış pozitifler

Yanlış pozitifler, iyi huylu vakaların kötü huylu olarak sınıflandırılması, gereksiz biyopsilere ve hastalar için duygusal sıkıntılara yol açar. Bu hatalar genellikle kötü huylu özelliklere benzeyen bazı iyi huylu desenlerden kaynaklanır.

4.5.2.1 Kalsifikasyon benzeri bölgeler

Bazı benign bölgeler kalsifikasyonlar içerir veya parlak noktalar olarak görünür. Bunun sonucunda, model bu tür imajları malign mikro kalsifikasyonlar olarak yanlış yorumlayabilir.

Örnek vakalar:

Yağ Nekrozu: İyi huylu yara dokusu veya yağ nekrozu kalsifikasyonlara benzeyebilir.

Artefaktlar: Görüntüleme artefaktları, örneğin basınç izleri, şüpheli bölgeleri taklit edebilir.

Önerilen çözümler şu şekildedir:

Güçlü Önileme: Artefakt kaldırma gibi geliştirilmiş ön işleme teknikleri, görüntüleme gürültüsünden kaynaklanan yanlış pozitifleri azaltabilir.

Sınıf-Spesifik Dikkat Katmanları: Benign yapılar ile kalsifikasyonları ayırt etmek için özel olarak dikkat modüllerinin uygulanması özellik ayırımını artırabilir.

4.5.2.2 Düzensiz doku desenleri

Radyal yaralar gibi benign doku bozulmaları, malign mimari bozulmalara benzer görünebilir. Bu desenler, iyi huylu vakalarda sınırlı çeşitliliğe sahip veri setleri üzerinde eğitilmiş modeller için özellikle zorlayıcıdır.

Önerilen çözümler şu şekildedir:

Domainsel Özel Artırma: Radyal izleri veya iyi huylu bozulmaları simüle etmek gibi domainsel özel artırmaların tanıtılması modelin dayanıklılığını artırabilir.

Özellik Piramidi Ağları: Farklı ölçeklerde doku desenlerini analiz etmek için özellik piramidi ağlarını kullanmak, iyi ve kötü huylu vakalar arasındaki ince farkların tespitini artırabilir.

4.6 Literatür Kıyaslaması

Sunulan çalışmada kullanılan modellerin sonuçları, CBIS-DDSM veri setindeki önceki çalışmalarla kapsamlı bir şekilde karşılaştırılmıştır (Çizelge 4.6). Test edilen mimariler arasında, Swin Transformer en son teknoloji performansını sergileyerek %85,9'luk bir ROC-AUC elde etmiştir ve daha önce bildirilen tüm kıyaslamaları önemli ölçüde geride bırakmıştır. Bu durum, görüntü dönüştürücülerinin meme kanseri teşhisi alanındaki potansiyelini vurgulamaktadır.

Çizelge 4.6 CBIS-DDSM veri seti kullanılarak gerçekleştirilen önceki çalışmalar ve sonuçları

Sıra	Model	AUC	Yayın Adı	Kaynak
1	Swin Transformer	0,859		2025
2	Multi-yama size DenseNet-121	0,810		2025
3	Multi-yama size DenseNet-121	0,809	Exploiting Patch Sizes and Resolutions for Multi-Scale Deep Learning in Mammogram Image Classification	Quintanavd., 2023
4	Multi-rezolüsyon DenseNet-121	0,789		
5	Özellik Piramit Ağı DenseNet-121	0,788		
6	Yama Tabanlı DenseNet-121	0,784		
7	MorphHR-ResNet18_S896	0,796	Beyond Fine-tuning: Classifying High Resolution Mammograms using Function-Preserving Transformations	Wei vd., 2022
8	ResNet18_S896	0,795		
9	ResNet18_S448	0,788		
10	MorphHR-ResNet18_S448	0,783		
11	EfficientNet-B0	0,795	Breast Cancer Diagnosis in Two-View Mammography Using End-to-End Trained EfficientNet-Based Convolutional Network	Petrini vd., 2022
12	EfficientNet-B1	0,794		

Çalışma bulguları ve literatür çalışmaları dikkate alındığında;

Swin Transformer: Yeni Bir Standart

Swin Transformer, önceki modeller olan DenseNet-121 (0,809), MorphHR-ResNet18_S896 (0,796) ve EfficientNet-B0 (0.795)'ı önemli ölçüde geride bırakarak %85,9'luk en yüksek ROC-AUC puanını elde etmiştir. Yerel ve küresel bağlamsal bilgileri hiyerarşik bir dikkat mekanizması aracılığıyla yakalama yeteneği, kötü ve iyi huylu vakaları ayırt etmede mükemmel performans göstermesini sağlamıştır ve mamografi sınıflandırmasındaki önemli bir zorluğun üstesinden gelebilmiştir.

Swin Transformer'ın üstün performansı birkaç ana faktöre atfedilebilir:

Hiyerarşik Dikkat Mekanizması: Kaydırılmış pencereleri dahil ederek, model mamogramlardan hem ince ayrıntılı hem de bütünsel özellikleri verimli bir şekilde yakalar ve küçük ve dağınık maligniteleri tespit etme zorluğunu aşar.

Yüksek Çözünürlüklü Verilere Dayanıklılık: Transformerin ölçeklenebilirliği, büyük görüntüleri ölçeklendirmeden işleyebilmesini ve bu durum kritik tanısal özelliklerin korunmasını sağlar.

Genelleme Yeteneği: Geniş veri artırımı, Swin Transformer mimarisi ile birleştirildiğinde, dayanıklılığını artırarak CNN tabanlı modellere kıyasla daha yüksek hassasiyet ve özgüllük sağlamıştır.

DenseNet-121: Artan İyileşme

DenseNet-121 modeli, AUC'si 0.809 olan daha önceki en yüksek rapor edilen DenseNet uygulamasına kıyasla hafif bir iyileşme göstererek 0.81 ROC-AUC değerine ulaşmıştır. Bu küçük bir kazanç sağlasa da çoklu yama boyutu yaklaşımının ve gelişmiş veri artırma tekniklerinin etkinliğini doğrulamaktadır. DenseNet-121, meme kanseri sınıflandırması

için güvenilir bir model olmaya devam etmektedir, ancak Swin Transformer ile karşılaştırıldığında geliştirilmesi gerekmektedir.

DenseNet-121 modelindeki ve Swin Transformer'daki iyileştirmeler, birkaç metodolojik yeniliğe atfedilebilir:

Çoklu Yama Boyutu Ön İşleme: Yama boyutlarını (örneğin 224x224, 112x112 ve 56x56) kullanmak, modellerin çoklu çözünürlüklerde özellikler öğrenmesini sağlamıştır. Böylece, mamogram görüntülerindeki ince desenleri tespit etmek için kritik bir adım atılmıştır.

Veri Artırma: Rastgele döndürmeler, çevirme ve CLAHE histogram eşitleme gibi tekniklerin dahil edilmesi, modelin dayanıklılığını artırmıştır ve özellik öğrenimini geliştirmiştir.

Gelişmiş Mimariler: DenseNet-121, verimli özellik yayılımı için yoğun bağlantılı katmanlara dayanırken, Swin Transformer kendi kendine dikkat mekanizması sayesinde uzun menzilli bağımlılıkları modelleme yeteneğinden faydalanmıştır.

Hiper Parametre Ayarlama: Öğrenme oranları, batch boyutları ve dropout gibi düzenleme tekniklerinin kapsamlı ayarlanması, aşırı uyum risklerini en aza indirerek optimal performansa katkıda bulunmuştur.

5. SONUÇ

Sunulan çalışma, CBIS-DDSM veri setini kullanarak meme kanseri sınıflandırması için gelişmiş derin öğrenme modellerinin potansiyelini araştırmıştır. DenseNet121, NASNetLarge, Xception ve Swin Transformer'ın performansı doğruluk, kesinlik, hatırlama, F1 skoru ve ROC-AUC gibi metrikler üzerinde değerlendirilmiştir. Bu modeller arasında, Swin Transformer en etkili olanı olarak öne çıkmıştır ve %76 doğruluk ile %85,9 ROC-AUC elde etmiştir. Hiyerarşik dikkat mekanizmaları, özellikle zorlu vakalarda karmaşık mamografik özellikleri yakalamasını sağlamıştır.

Araştırmanın temel katkıları arasında, ikili meme kanseri sınıflandırması için en son teknoloji modellerinin kapsamlı bir değerlendirmesi yer almakta olup Swin Transformer'ın üstün hiyerarşik özellik çıkarım yetenekleri vurgulanmaktadır. Yanlış sınıflandırma analizi, düşük kontrastlı lezyonlar ve kalsifikasyon benzeri bölgeler gibi zorluklara ışık tutarak, tıbbi görüntü analizinde hedeflenmiş iyileştirmelerin yolunu açmıştır. Ayrıca, mamografik görüntülere yönelik önerilen artırma stratejileri, kritik veri seti sınırlamalarını ele alarak meme kanseri tanısında duyarlılığı ve özgüllüğü artırmaktadır.

Bulgular, ileri düzey derin öğrenme modellerinin dönüştürücü potansiyelini gösterirken, birkaç sınırlama da kaydedilmiştir. CBIS-DDSM veri setinin çeşitlilik eksikliği ve demografik önyargısı, genelleştirilebilirliği sınırlamıştır ve Swin Transformer'ın tahminleri klinik benimseme için daha iyi bir açıklanabilirlik gerektirmektedir. Bu zorluklar, önyargı, hesap verebilirlik ve veri sahipliği gibi etik hususlarla birlikte, adil ve güvenli dağıtımın sağlanması için disiplinler arası yaklaşımların gerekliliğini vurgulamaktadır.

Bu çalışma, yapay zeka destekli tanıların ilerletilmesi, hasta sonuçlarının iyileştirilmesi ve meme kanserinin küresel yükünün azaltılması için bir temel oluşturmaktadır. Araştırmacılar, klinik uzmanlar ve politika yapıcılar arasındaki işbirlikçi çabalar, klinik entegrasyon engellerinin aşılmasında ve bu teknolojilerin erişilebilir, adil ve etik bir şekilde uygulanmasını sağlamada belirleyici olacaktır.

6. ÖNERİLER, SINIRLILIKLAR VE GELECEK ÇALIŞMALAR

Ümit vaat eden sonuçlarına rağmen, sunulan çalışmanın birkaç sınırlaması vardır:

1. Veri Seti Kısıtlamaları: CBIS-DDSM veri seti, gerçek dünya meme kanseri vakalarının tam yelpazesini temsil etmek için gereken çeşitliliği sağlamamaktadır.

2. Demografik Önyargı: Farklı popülasyonlar arasında temsil eksikliği, modellerin genellenebilirliğini sınırlayabilir.

3. Sınırlı Yorumlanabilirlik: Etkili olmasına rağmen, Swin Transformer'ın tahminleri nispeten belirsiz kalmakta ve bu da açıklanabilirlik araçlarını gerektirmektedir.

Klinik Kullanım İçin Sonuçlar

Yüksek performanslı Swin Transformer modeli, aşağıdaki özellikleri sayesinde meme kanseri teşhisinde devrim yaratma potansiyeline sahiptir:

Teşhis Doğruluğunu Artırma: Sağlam duyarlılığı ve özgüllüğü, yanlış negatifleri ve pozitifleri azaltarak zamanında ve doğru teşhisler sağlanmasını mümkün kılabilir.

Radyologları Desteklemek: Yardımcı bir araç olarak model, radyologların uzmanlığını artırabilir, daha verimli iş akışları sağlayabilir ve tanısal yorgunluğu azaltabilir.

Yine de başarılı klinik entegrasyon için birkaç engelin üstesinden gelinmelidir:

1. Düzenleyici Onay: Tıbbi cihaz düzenlemeleri ve standartlarına uyum sağlamak kritik öneme sahiptir.

2. Veri Gizliliği: Model dağıtımı sırasında hasta verilerinin gizliliğinin sağlanması çok önemlidir.

3. Model Dayanıklılığı: Görüntüleme protokollerindeki, ekipmandaki ve hasta demografilerindeki gerçek dünya değişkenliği, çeşitli veri setlerinde kapsamlı doğrulama gerektirir.

4. İş Akışı Entegrasyonu: Mevcut klinik iş akışlarına sorunsuz entegrasyon, kullanıcı dostu arayüzler ve hastane sistemleriyle birlikte çalışabilirlik gerektirir.

Etik Hususlar

Sağlık hizmetlerinde yapay zeka modellerinin kullanımı, birkaç etik endişeyi beraberinde getirir:

1. Önyargı ve Adalet: Modellerin farklı demografik gruplar arasında eşit şekilde performans göstermesini sağlamak, sağlık hizmetlerinde eşitsizlikleri önlemek için gereklidir.

2. Sorumluluk: Tanı hataları durumunda hesap verebilirlik için net protokoller oluşturmak, hasta güvenliği için çok önemlidir.

3. Bilgilendirilmiş Onam: Hastalar, tanı süreçlerinde yapay zekanın kullanımı hakkında bilgilendirilmelidir ve bu sayede şeffaflık ve güven sağlanabilir.

4. Veri Sahipliği: Hasta haklarına saygı göstermek ve yasal çerçevelere uymak için veri sahipliği ve kullanımı konusunda net politikalar gereklidir.

Gelecek Yönelimleri

Bu araştırmanın bulgularına dayanarak, gelecekteki çalışmalar için birkaç yol önerilmektedir:

1. Çok Sınıflı Sınıflandırma: Modellerin, duktal karsinom in situ (DCIS) veya atipik hiperplazi gibi ek meme lezyon alt tiplerini sınıflandıracak şekilde genişletilmesi gerekir.
2. Çok Modlu Verilerin Entegrasyonu: Mamografik verileri diğer görüntüleme modları veya klinik bilgilerle birleştirerek tanısal doğruluğu artırmak gerekir.
3. Açıklanabilir Yapay Zeka (XAI): Klinikler için tahminlerin yorumlanabilirliğini artırmak amacıyla Grad-CAM veya SHAP gibi araçlar geliştirmek gerekir.
4. Sentetik Veri Üretimi: Sınıf dengesizliği ve nadir alt tür eksikliğini ele alarak gerçekçi veri setleri oluşturmak için GAN'ları kullanmak önerilebilir.
5. Gerçek Dünya Doğrulaması: Modelleri gerçek dünya koşullarında değerlendirmek için klinik ortamlarda prospektif çalışmalar yürütmek gereklidir.
6. Kenar Cihazı Optimizasyonu: Uzak bölgelerde erişilebilirliği artırmak için taşınabilir tanı araçlarında kullanılmak üzere model mimarilerini uyarlamak yararlı olacaktır.
7. İşbirlikçi Araştırma: Disiplinler arası zorlukları ele almak için yapay zeka araştırmacıları, klinik uzmanlar ve etik uzmanları arasında ortaklıkları teşvik etmek şarttır.
8. Dayanıklılık Testi: Modelleri, güvenilirliği sağlamak için düşmanca saldırılara ve görüntüleme koşullarındaki aşırı değişikliklere karşı değerlendirmek gerekir.
9. Dinamik Öğrenme: Modellerin yeni verilerle evrimleşmesini sağlayan sürekli öğrenme çerçevelerinin uygulanması, zamanla alaka düzeyini korumasını sağlamak önem arz eder.

KAYNAKLAR

- AACR Cancer Progress Report. (2024). (American Association for Cancer Research) Retrieved from <https://cancerprogressreport.aacr.org/progress/>
- ABIMOULOUD, M.L., BENSID, K., & Elleuch, M. (2024). Vision transformer based convolutional neural network for breast cancer histopathological images classification. *Multimed Tools Appl.*
- Aidossov, N., Zarikas, Vasilios, Mashekova, Aigerim, Zhao, Michael , Ng, Eddie, Midlenko, Anna, & Mukhmetov, Olzhas. (2023). Evaluation of Integrated CNN, Transfer Learning, and BN with Thermography for Breast Cancer Detection. *Applied Sciences*, 13.
- Aishwarja, Anika, Eva, Nusrat, Mushtary, Shakira, Tasnim, Zarin, Imtiaz Khan, & Muhammad Nazrul. (2021). Exploring the Machine Learning Algorithms to Find the Best Features for Predicting the Breast Cancer and Its Recurrence. In *Intelligent Computing and Optimization* (pp. 546-558).
- Alanazi et al. (2021). Boosting Breast Cancer Detection Using Convolutional Neural Network. *Journal of Healthcare Engineering*, 1-11.
- Alexey Dosovitskiy, Lucas Beyer, Alexander Kolesnikov, Dirk Weissenborn, Xiaohua Zhai, & Thomas Unterthiner. (2020). An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale. *ArXiv*, abs/2010.11929.
- Ali et al. (2023). Breast Cancer Classification through Meta-Learning Ensemble Technique Using Convolution Neural Networks. *Diagnostics*.
- Alruwaili, M., & Gouda, W. (2022). Automated Breast Cancer Detection Models Based on Transfer Learning. *Sensors*, 22(3), 876.
- Amrane et al. (2018). Breast cancer classification using machine learning. *Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)*.
- Anichini, G., Natali, C., & Cabitza, F. (2024). Invisible to Machines: Designing AI that Supports Vision Work in Radiology. *Comput Supported Coop Work*.
- Atrey, Kushangi, Singh, Bikesh, Bodhey, Narendra, & Pachori, Ram. (2023). Mammography and ultrasound based dual modality classification of breast cancer using a hybrid deep learning approach. *Biomedical Signal Processing and Control*, 86.
- Boca Bene, I., Ciurea, A. I., Ciortea, C. A., & Dudea, S. M. (2021). Pros and Cons for Automated Breast Ultrasound (ABUS): A Narrative Review. *Journal of personalized medicine*, 11(8), 703.
- Bray F, Laversanne M, Sung H, Ferlay J, Siegel RL, Soerjomataram I, & Jemal A. (2024). Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality

worldwide for 36 cancers in 185 countries. *CA Cancer J Clin.* doi:doi: 10.3322/caac.21834.

- C, Shanker, & M, Vadivel. (2022). Hybrid Transfer Learning of Mammogram Images for Screening of Micro-Calcifications. *International Journal of Electrical and Electronics Engineering*, 9, 40-47.
- C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens, & Z. Wojna. (2016). Rethinking the Inception Architecture for Computer Vision. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), (pp. 2818-2826). Las Vegas.
- Cè, M., Caloro, E., Pellegrino, M. E., Basile, M., Sorce, A., Fazzini, D., . . . Cellina, M. (2022). Artificial intelligence in breast cancer imaging: risk stratification, lesion detection and classification, treatment planning and prognosis-a narrative review. *Exploration of targeted anti-tumor therapy*, 3(6), 795–816.
- Chen, Jieneng, Lu, Yongyi, Yu, Qihang, Luo, Xiangde, Adeli, Ehsan, Wang, Yan, . . . Zhou, Yuyin. (2021). TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation. *arXiv*.
- Chollet, Francois. (2017). Xception: Deep Learning with Depthwise Separable Convolutions. 1800-1807. doi:CVPR.2017.195.
- Edge, S. B., & Compton, C. C. (2010). The American Joint Committee on Cancer: the 7th edition of the AJCC cancer staging manual and the future of TNM. *Annals of surgical oncology*, 17(6), 1471–1474.
- Esteva, A., Kuprel, B., & Novoa, R. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542, 15–118.
- Ferlay, J., Colombet, M., Soerjomataram, I., Parkin, D. M., Piñeros, M., Znaor, A., & Bray, F. (2021). Cancer statistics for the year 2020: An overview. *International journal of cancer*. doi:doi: 10.1002/ijc.33588.
- Gao, Y., Moy, L., & Heller, S. L. (2021). Digital Breast Tomosynthesis: Update on Technology, Evidence, and Clinical Practice. *Radiographics : a review publication of the Radiological Society of North America*, 41(2), 321–337.
- Goceri, E. (2023). Medical image data augmentation: techniques, comparisons and interpretations. *Artif Intell Rev*, 56, 12561–12605.
- Goergen, Stacy, Frazer, Helen, & Reddy, Sandeep. (2022). Quality use of artificial intelligence in medical imaging: What do radiologists need to know?. *Journal of Medical Imaging and Radiation Oncology*, 66, 225-232.
- 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*, (pp. 770-778). Las Vegas.

- Herington J, McCradden MD, & Creel K. (2023). Ethical Considerations for Artificial Intelligence in Medical Imaging: Data Collection, Development, and Evaluation. *Journal of nuclear medicine : official publication, Society of Nuclear Medicine*, 64,12, 1848-1854.
- Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific reports*, 12(1).
- Hosni, M. e. (2019). Reviewing ensemble classification methods in breast cancer. *Computer methods and programs in biomedicine*, 177, 89–112.
- Houssami N, & Hunter K. (2017). he epidemiology, radiology and biological characteristics of interval breast cancers in population mammography screening. *NPJ Breast Cancer*, 3:12. doi:doi: 10.1038/s41523-017-0014-x
- Huang, Gao, Liu, Zhuang, van der Maaten, Laurens, & Weinberger, Kilian. (2017). Densely Connected Convolutional Networks. doi:10.1109/CVPR.2017.243
- J., Z.-Y. (2023). State of the Art in 2022 PET/CT in Breast Cancer: A Review. *Journal of clinical medicine*, 12(3), 968.
- Jafari Z, & Karami E. (2023). Breast Cancer Detection in Mammography Images: A CNN-Based Approach with Feature Selection. *Information*, 14(7), 410.
- Jakhar, A.K., Gupta, A. , & Singh, M. (2024). SELF: a stacked-based ensemble learning framework for breast cancer classification. *Evol. Intel.*, 17, 1341–1356.
- Kooi, T., Litjens, G., van Ginneken, B., Gubern-Mérida, A., Sánchez, C. I., Mann, R., & den Heeten, A. (2017). Large scale deep learning for computer aided detection of mammographic lesions. *Medical image analysis*, 35, 303–312.
- Krizhevsky, Alex, Sutskever, Ilya, & Hinton, Geoffrey E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. In *Advances in Neural Information Processing Systems* (Vol. 25).
- Kyoung Min, Kim, Heo, Tae-Young, Kim, Aesul, Kim, Joohee, Han, Kyu, Yun, Jaesuk, & Min, Jung Kee. (2021). Development of a Fundus Image-Based Deep Learning Diagnostic Tool for Various Retinal Diseases. *Journal of Personalized Medicine*, 11.
- L., W. (2023). Microwave Imaging and Sensing Techniques for Breast Cancer Detection. *Micromachines*, 14(7), 1462.
- Landsveld-Verhoeven, Cary, Heeten, Gerard, Timmers, Janine, & Broeders, Mireille. (2015). Mammographic positioning quality of newly trained versus experienced radiographers in the Dutch breast cancer screening programme. *European radiology*, 25.

- Langlotz, C. P., Allen, B., Erickson, B. J., Kalpathy-Cramer, J., Bigelow, K., Cook, T. S., . . . Kandarpa, K. (2019). A Roadmap for Foundational Research on Artificial Intelligence in Medical Imaging: From the 2018 NIH/RSNA/ACR/The Academy Workshop. *Radiology*, 291(3), 781–791.
- Lee et al. (2023). Transformer-based Deep Neural Network for Breast Cancer Classification on Digital Breast Tomosynthesis Images. *Radiol Artif Intell*.
- Lee, R. S., Gimenez, F., Hoogi, A., Miyake, K. K., Gorovoy, M., & Rubin, D. L. (2017). A curated mammography data set for use in computer-aided detection and diagnosis research. *Scientific data*, 4.
- Lehman, C. D., Arao, R. F., Sprague, B. L., Lee, J. M., Buist, D. S., Kerlikowske, K., . . . Miglioretti, D. L. (2017). National Performance Benchmarks for Modern Screening Digital Mammography: Update from the Breast Cancer Surveillance Consortium. *Radiology*, 283(1), 49–58.
- Lehman, C. D., Wellman, R. D., Buist, D. S., Kerlikowske, K., Tosteson, A. N., & Miglioretti, D. L. (2015). Diagnostic Accuracy of Digital Screening Mammography With and Without Computer-Aided Detection. *JAMA internal medicine*, 175(11), 1828–1837.
- Li J. (2022). Digestive cancer incidence and mortality among young adults worldwide in 2020: A population-based study. *World journal of gastrointestinal oncology*, 14(1), 278–294.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., . . . Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 42, 60–88.
- Liu, Z., Lin, Y., & Cao, Y. (2021). Hierarchical Vision Transformer Using Shifted Windows. *Proceedings of the IEEE/CVF International Conference on Computer Vision*, (pp. 10012-10022). Montreal.
- Lyon, F. (2024, 2). Global cancer burden growing, amidst mounting need for services. (the World Health Organization) Retrieved from <https://www.who.int/news/item/01-02-2024-global-cancer-burden-growing--amidst-mounting-need-for-services#:~:text=In%20countries%20with%20a%20very,women%20will%20die%20from%20it>.
- M. Sharifujjaman, Z. Ferdousee, N. U. Sadad, & B. Ahmed. (2023). Transfer Learning Based Approaches for Breast Cancer Classification using Mammogram Images. 2023 26th International Conference on Computer and Information Technology (ICCIT), (pp. 1-6). Cox's Bazar, Bangladesh.
- Mahmood, F. (2023). A comparison of rural and urbans women's knowledge and attitudes . *Journal of Population Therapeutics and Clinical Pharmacology*, 30(3), 515-521 .

- Malhotra, G. K. (2010). Histological, molecular and functional subtypes of breast cancers. *Cancer biology & therapy*, 10(10), 955–960. doi:<https://doi.org/10.4161/cbt.10.10.13879>
- Mann, R. M., Athanasiou, A., Baltzer, P. A. T., Camps-Herrero, Clauser, P., Fallenberg, E. M., & Forrai, G. (2022). Breast cancer screening in women with extremely dense breasts recommendations of the European Society of Breast Imaging (EUSOBI). *European radiology*, 32, 6, 4036–4045. doi:[doi:10.1007/s00330-022-08617-6](https://doi.org/10.1007/s00330-022-08617-6)
- Menaouer, Brahami, El-Houda, Kebir, Zoulikha, Dermane, Sabri, Mohammed, & Nada, Matta. (2022). Detection and Classification of Brain Tumors From MRI Images Using a Deep Convolutional Neural Network Approach. *International Journal of Software Engineering*, 10, 1–23.
- Minfei, Liang, Gan, Yidong, Chang, Ze, Wan, Zhi, Schlangen, Erik, & Šavija, Branko. (2022). Microstructure-informed deep convolutional neural network for predicting short-term creep modulus of cement paste. *Cement and Concrete Research*.
- Naveed Urr Rehman, Junfeng Wang, Hou Weiyan, Ijaz Ali, Arslan Akbar, Muhammad Assam, . . . Abdulmohsen Algarni. (2024). Edge of discovery: Enhancing breast tumor MRI analysis with boundary-driven deep learning. *Biomedical Signal Processing and Control*, Volume 95, Part A.
- O'Connor M. K. (2015). Molecular breast imaging: an emerging modality for breast cancer screening. *Breast cancer management*, 4(1), 33–40.
- Octaviani, T. L. , & Rustam, Z. (2019). Random forest for breast cancer prediction. *AIP Conf. Proc.*
- Pacal, I., Celik, O., & Bayram, B. (2024). Enhancing EfficientNetv2 with global and efficient channel attention mechanisms for accurate MRI-Based brain tumor classification. *Cluster Comput*, 27, 11187–11212.
- Petrini, Daniel, Shimizu, Carlos, Roela, Rosimeire, Valente, Gabriel, Folgueira, Maria Aparecida, & Kim, Hae. (2022). Breast Cancer Diagnosis in Two-View Mammography Using End-to-End Trained EfficientNet-Based Convolutional Network. *IEEE Access*.
- Quintana, G. I., Li, Z., Vancamberg, L., Mougeot, M., Desolneux, A., & Muller, S. (2023). Exploiting Patch Sizes and Resolutions for Multi-Scale Deep Learning in Mammogram Image Classification. *Bioengineering*, 10(5).
- Rabiei et al. (2022). Prediction of Breast Cancer using Machine Learning Approaches. *Biomed Phys Eng*.
- Rebolj, M., Assi, V., Brentnall, A., Parmar, D., & Duffy, S. W. (2018). Addition of ultrasound to mammography in the case of dense breast tissue: systematic review and meta-analysis. *British journal of cancer*, 118(12), 1559–1570.

- Rejani, Y.Ireaneus, & Dr.S.Thamarai, Selvi. (2009). Early Detection of Breast Cancer using SVM Classifier Technique. *International Journal on Computer Science and Engineering*.
- Sahiner, B., Pezeshk, A., Hadjiiski, L. M., Wang, X., Drukker, K., Cha, K. H., . . . Giger, M. L. (2019). Deep learning in medical imaging and radiation therapy. *Medical physics*, 46(1), e1–e36.
- Sajid, & Khan. (2023). Breast cancer classification using deep learned features boosted with handcrafted features. *Biomedical Signal Processing and Control*, 86.
- Sardanelli, F., Magni, V., & Rossini, G. (Insights Imaging). The paradox of MRI for breast cancer screening: high-risk and dense breasts—available evidence and current practice. *Insights Imaging*, 15, 96.
- Shen et al. (2019). Deep Learning to Improve Breast Cancer Detection on Screening Mammography. *Sci Rep*, 9, 12495.
- Siegel, R. L., Giaquinto, A. N., & Jemal, A. (2024). Cancer statistics. *a cancer journal for clinicians*, 74(1), 12–49.
- Simonyan, K., & Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. *3rd International Conference on Learning Representations (ICLR 2015)*, 1-14.
- Subhan Ali, Filza Akhlaq, Ali Shariq Imran, Zenun Kastrati, Sher Muhammad Daudpota, & Muhammad Moosa. (2023). The enlightening role of explainable artificial intelligence in medical & healthcare domains: A systematic literature review. *Computers in Biology and Medicine*, 166.
- Sutong Wang, Yuyan Wang, Dujuan Wang, Yunqiang Yin, Yanzhang Wang, & Yaochu Jin. (2020). An improved random forest-based rule extraction method for breast cancer diagnosis. *Applied Soft Computing*, 86.
- Szegedy, C. (2015). Going deeper with convolutions. *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, (pp. 1-9). Boston.
- Tauhidul Islam, Md. Sadman Hafiz, Jamin Rahman Jim, Md. Mohsin Kabir, & M.F. Mridha. (2024). A systematic review of deep learning data augmentation in medical imaging: Recent advances and future research directions. *Healthcare Analytics*, 5.
- Wang L, Zhang C, & Li J. (2024). A Hybrid CNN-Transformer Model for Predicting N Staging and Survival in Non-Small Cell Lung Cancer Patients Based on CT-Scan. *Tomography*, 10(10), 1676-1693.
- Wei, T., Aviles-Rivero, A. I., Wang, S., Huang, Y., Gilbert, F. J., Schönlieb, C. B., & Chen, C. W. (2022). Beyond fine-tuning: Classifying high resolution mammograms using function-preserving transformations. *Medical image analysis*, 82.

- Weigelt, B., Peterse, J. L., & van 't Veer, L. J. . (2005). Breast cancer metastasis: markers and models. *Nature reviews. Cancer*, 5(8), 591–602.
- Xing, Baixi, Cao, Hanfei, Shi, Lei, Si, Huahao, & Zhao, Lina. (2022). AI-driven user aesthetics preference prediction for UI layouts via deep convolutional neural networks. *Cognitive Computation and Systems*, 4.
- Yamashita, R., Nishio, M., & Do, R.K.G. (2018). Convolutional neural networks: an overview and application in radiology. *Insights Imaging*, 9, 611–629.
- Yamashita, R., Nishio, M., & Do, R.K.G. (2018). Convolutional neural networks: an overview and application in radiology. *Insights Imaging*, 9, 611–629.
- Yang, Jialiang, Ju, Jie, Guo, Lei, Ji, Binbin, Shi, Shufang, Yang, Zixuan, . . . Yuan, Xu. (2022). Prediction of HER2-positive breast cancer recurrence and metastasis risk from histopathological images and clinical information via multimodal deep learning. *Computational and Structural Biotechnology Journal*.
- Zama, S., Fujioka, T., Yamaga, E., Kubota, K., Mori, M., Katsuta, L., . . . Kawauchi, M. (2023). Clinical Utility of Breast Ultrasound Images Synthesized by a Generative Adversarial Network. *Medicina (Kaunas, Lithuania)*, 60,1.
- Zhou, X., Haijun Liu, Cong Shi, & Ji Liu. (2022). *Deep Learning on Edge Computing Devices*. Elsevier.
- Zoph, Barret, Vasudevan, Vijay, Shlens, Jonathon, & Le, Quoc. (n.d.). Learning Transferable Architectures for Scalable Image Recognition. 8697-8710. doi:10.1109/CVPR.2018.00907. Ahmed, M., Khan, H. U., & Munir, E. U. (2023). Conversational AI: An Explication of Few-Shot Learning Problem in Transformers-Based Chatbot Systems. *IEEE Transactions on Computational Social Systems*.