



T.C.

TOKAT GAZİOSMANPAŞA ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

BİLGİSAYAR MÜHENDİSLİĞİ YÜKSEK LİSANS PROGRAMI

**Histopatolojik Görüntüler Kullanılarak Dikkat Tabanlı Transfer Öğrenme
Yöntemiyle Meme Kanseri Sınıflandırması**

Yüksek Lisans Tezi

Abubakir Ali Hammood

Danışman: Doç. Dr. Mahir Kaya

TOKAT

Ağustos, 2025

ETİK SÖZLEŞME

Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü'nün yönerge ve ilkelerine tam olarak uygun olarak, başlıklı yüksek lisans tezinin, Doç. Dr. Mahir Kaya'nın saygıdeğer danışmanlığında hazırlanmış ve sunulmuş olduğunu beyan ederim. “Histopatolojik Görüntüler Kullanılarak Dikkat Tabanlı Transfer Öğrenme Yöntemiyle Meme Kanseri Sınıflandırması”. adlı Yüksek Lisans tezinin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

20 /08/ 2025

Abubakir Ali Hammood

JÜRİNİN KABULÜ VE ONAYI

Abubakir Ali Hammood tarafından hazırlanan “**Histopatolojik Görüntüler Kullanılarak Dikkat Tabanlı Transfer Öğrenme Yöntemiyle Meme Kanseri Sınıflandırması**” adlı tez çalışmasının savunma sınavı 20/08/2025 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği ile Tokat Gaziosmanpaşa Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Üye (Başkan):

Üye:

Üye:

ONAY

...../...../.....

Lisansüstü Eğitim Enstitüsü Müdürü

ÖNSÖZ

Bu tez çalışmamda bana her zaman yardımlarını esirgemeyen tez danışmanım Doç. Dr. MAHİR KAYA'ya ve eğitim hayatım boyunca bana katkı sağlayan tüm hocalarıma teşekkürlerimi sunarım.

Bu süreçte, hayatımın her alanında olduğu gibi, destek ve çabalarını esirgemeyen babama, anneme, eşime, kardeşlerime ve arkadaşım Ameen'e sonsuz şükranlarımı sunarım.

Abubakir Ali Hammood

Tokat-2025

ÖZET

HISTOPATOLOJİK GÖRÜNTÜLER KULLANILARAK DIKKAT TABANLI TRANSFER ÖĞRENME YÖNTEMİYLE MEME KANSERİ SINIFLANDIRMASI

Hammood, Abubakir Ali

Yüksek Lisans, Bilgisayar Mühendisliği Bölümü

Danışman: Doç. Dr. Mahir Kaya

Ağustos 2025, XIX + 121 Sayfa

Meme kanseri, dünya çapında kadınları etkileyen en yaygın ve ölümcül kanser türlerinden biridir. Erken ve doğru tanı, hayatta kalma oranlarını artırmada ve etkili tedavi stratejileri belirlemede çok önemli bir rol oynar. Bu araştırma, gelişmiş derin öğrenme modellerini uygulayarak ve optimize ederek doğru meme kanseri alt tip sınıflandırmasının zorluklarını ele almayı ve nihayetinde dikkat mekanizmaları ve kapsamlı veri artırma kullanarak tanı güvenilirliğini artıran etkili bir çözüm sunmayı amaçlamaktadır. Histopatolojik görüntüler kullanarak meme kanseri alt tiplerinin çok sınıflı sınıflandırması için derin öğrenme tabanlı yaklaşım öneriyor ve kapsamlı bir şekilde değerlendiriyoruz.

Deneyler, başlangıçta benign ve malignant meme tümörlerinin sekiz alt tipine ayrılmış 7.909 histopatolojik görüntü içeren BreakHis veri seti üzerinde gerçekleştirildi. Eğitim verilerinin çeşitliliğini ve sağlamlığını artırmak için veri artırma teknikleri kullanıldı ve toplam eğitim görüntüsü sayısı 19.960'ya çıkarıldı. Bu çalışmadaki tüm deneyler için veri setini 80/20 oranında böldük, görüntülerin %80'ini eğitime ayırdık ve kalan %20'sini test için ayırdık. Bu yaklaşım, her modelin aynı koşullar altında değerlendirilmesini sağladı.

ResNet152V2, SE-ResNet152V2, MobileNetV2 ve Squeeze-and-Excitation (SE) ve Convolutional Block Attention Module (CBAM) gibi dikkat modülleri içeren bu modellerin

versiyonları da dahil olmak üzere birkaç gelişmiş Convolutional Neural Network (CNN) modeli araştırıldı. Her model, veri artırımı ile ve veri artırımı olmadan eğitildi. Eğitimden sonra, performansları her tümör türü için ayrı ayrı bir dizi metrik doğruluk, kesinlik, duyarlılık, F1 puanı ve karışıklık matrisleri kullanılarak ölçüldü.

Dikkat mekanizmaları eklemek ve veri artırımı kullanmak, test edilen model veya sınıftan bağımsız olarak neredeyse her zaman daha iyi doğruluk sağladı. Tüm modeller arasında CBAM-MobileNetV2, %98.35 ile en yüksek test doğruluğunu elde ederek öne çıktı. Ayrıca, farklı tümör alt tiplerini ne kadar iyi genelleştirdiği ve işlediği açısından diğer modellerden daha iyi performans gösterdi. Bu çalışma, derin öğrenmenin ve özellikle dikkat mekanizmalarına sahip CNN'lerin, patoloji görüntülerinden meme kanseri alt tiplerini doğru ve otomatik olarak sınıflandırmak için ne kadar güçlü araçlar olabileceğini göstermektedir. Bulgular ayrıca, etkili veri artırma ve veri bölme stratejileri kullanmanın ne kadar önemli olduğunu vurgulamaktadır, çünkü bu adımlar sınıf dengesizliği sorunlarını gidermeye yardımcı olur ve modelleri daha güvenilir hale getirir, bu da bu araçların gerçek dünya tıbbi ortamlarında kullanılması durumunda özellikle önemlidir.

Anahtar kelimeler: Meme Kanseri, Histopatoloji, Dikkat Mekanizmaları, Transfer Öğrenme, CNN.

ABSTRACT
**BREAST CANCER CLASSIFICATION USING ATTENTION-BASED TRANSFER
LEARNING ON HISTOPATHOLOGICAL IMAGES**

Hammood, Abubakir Ali

Master's Thesis, Department of Computer Engineering

Advisor: Assoc. Prof. Dr. Mahir Kaya

August 2025, XIX + 121 Pages

Breast cancer is one of the most prevalent and deadly cancers affecting women worldwide. Early and accurate diagnosis plays a crucial role in improving survival rates and guiding effective treatment strategies. This research aims to tackle the challenges of accurate breast cancer subtype classification by applying and optimizing advanced deep learning models, ultimately providing an effective solution that improves diagnostic reliability through the use of attention mechanisms and comprehensive data augmentation. We propose and comprehensively evaluate deep learning-based approaches for the multiclass classification of breast cancer subtypes using histopathological images.

The experiments were conducted on the BreakHis dataset, which originally contained 7,909 histopathological images categorized into eight subtypes of benign and malignant breast tumors. To enhance the diversity and robustness of the training data, data augmentation techniques were employed, increasing the total number of training images to 19,960. For all experiments in this study, we used an 80/20 split of the dataset, assigning 80% of the images for training and reserving the remaining 20% for testing. This approach ensured that every model was evaluated under the same conditions.

Several advanced Convolutional Neural Network (CNN) models were explored, including ResNet152V2, MobileNetV2, and versions of these models that included attention modules like Squeeze-and-Excitation (SE) and Convolutional Block Attention Module (CBAM). Each model was trained both with and without data augmentation. After training, their performance was measured using a range of metrics accuracy, precision, recall, F1-score, and confusion matrices broken down for each tumor type.

The results were clear: adding attention mechanisms and using data augmentation almost always led to better accuracy, regardless of the model or class being tested. Out of all the models, CBAM-MobileNetV2 stood out, achieving the highest test accuracy of %98.35. It also performed better than the other models in terms of how well it generalized and handled the different tumor subtypes. This work shows how deep learning and especially CNNs with attention mechanisms can be powerful tools for accurately and automatically classifying breast cancer subtypes from pathology images. The findings also highlight how crucial it is to use effective data augmentation and thoughtful data splitting strategies, since these steps help address issues with class imbalance and make the models more reliable, which is especially important if these tools are to be used in real-world medical settings.

Keywords: Breast Cancer, Histopathology, Attention Mechanisms, Transfer Learning Rate, CNNs.

İÇİNDEKİLER

ETİK SÖZLEŞME.....	I
JÜRİNİN KABULÜ VE ONAYI.....	II
ÖNSÖZ	III
ÖZET	IV
ABSTRACT.....	VI
İÇİNDEKİLER	VIII
TABLolar LİSTESİ	XIII
ŞEKİL LİSTESİ.....	XV
KISALTMALAR	XVIII
1 GİRİŞ	1
1.1 Meme Kanseri.....	1
1.2 Meme Kanseriinde Görüntüleme Teknikleri.....	2
1.3 Hassas Tıp ve Genetik Yenilikler	3
1.4 CNN Kullanarak Meme Kanseri Tespitinde Gelecek Yönelimler	4
1.5 Araştırma Hedefi.....	5
2 LİTERATÜR TARAMASI	6
2.1 Meme Kanseri Histopatolojisi Görüntü Sınıflandırmasında Geleneksel ve Erken Otomatik Yaklaşımlar	6
2.2 Derin Öğrenmenin Doğuşu: Meme Kanseri Histopatolojik Görüntü Sınıflandırmasının Dönüşümü	7

2.3 Derin Öğrenme Tabanlı Histopatolojik Görüntü Analizinde Transfer Öğrenme ve Veri Artırımı	8
2.4 Histopatolojik Görüntü Analizi için Derin Öğrenmede Dikkat Mekanizmaları	10
3 EVRİŞİMSEL SINIR AĞI (CNN) YAPISININ ARKA PLANI.....	15
3.1 Giriş.....	15
3.2 Evrişimsel Sinir Ağları (CNN'ler).....	15
3.2.1 Evrişimli Katmanlar	15
3.2.2 Aktivasyon Fonksiyonları	16
3.2.3 Havuzlama Katmanları	16
3.2.4 Tam Bağlantılı Katmanlar	16
3.2.5 Ağırlık Paylaşımı ve Yerel Bağlantı.....	16
3.2.6 Eğitim ve Optimizasyon	17
3.2.7 Gelişmeler ve Modern Mimariler	17
3.4 Bu Çalışmada Kullanılan CNN Mimarileri	18
3.4.1 ResNet152V2.....	18
3.4.2 SE-ResNet152V2	18
3.4.3 CBAM-ResNet152V2.....	18
3.4.4 MobileNetV2	19
3.4.5 CBAM-MobileNetV2	19
3.4.6 SE-MobileNetV2	19

3.5 CNN'lerde Dikkat Mekanizmaları	19
3.5.1 Squeeze-and-Excitation (SE).....	19
3.5.2 Evrişimsel Blok Dikkat Modülü (CBAM).....	20
3.6 CNN'ler Histopatolojik Görüntü Sınıflandırması için Neden Uygun?	20
3.7 Seçim Gerekçesi.....	20
4 MATERYAL VE METOT.....	22
4.1 Deneyisel Kurulum	22
4.2 Önerilen Yöntem.....	22
4.3 Veri Seti Açıklaması.....	23
4.5 Veri Ön İşleme	27
4.6 Veri Büyütme	29
4.7 Transfer Öğrenimi	31
4.8 Model Mimarileri.....	33
4.8.1 ResNet152V2.....	33
4.8.2 SE-ResNet152V2.....	34
4.8.3 CBAM-ResNet152V2.....	34
4.8.4 MobileNetV2	35
4.8.5 CBAM-MobileNetV2	36
4.8.6 SE-MobileNetV2	37
4.9 Eğitim Metodolojisi	37

4.10 Değerlendirme Metrikleri	39
5 DENEY VE SONUÇLAR	40
5.1 Deneysel.....	40
5.2 ResNet152V2.....	41
5.3 ResNet152V2, artırma olmadan.....	44
5.4 CBAM-ResNet152V2.....	48
5.5 CBAM-ResNet152V2 Augmentasyon Olmadan	51
5.6 SE-ResNet152V2.....	55
5.7 SE-ResNet152V2 Augmentasyon Olmadan	58
5.8 MobileNetV2	62
5.9 Mobilenetv2 Artırma Olmadan	65
5.10 CBAM-MobileNetV2	68
5.11 CBAM-MobileNetV2 Artırma Olmadan	72
5.12 SE-MobileNetV2	75
5.13 SE-MobileNetV2 Artırma Olmadan	79
5.14 İkili Sınıflandırma Sonuçları.....	82
5.15 Zoom ile Çok Sınıflı Sınıflandırma Sonuçları	89
5.15.1 CBAM-MobileNetV2	91
5.15.2 CBAM-ResNet152V2.....	95
5.15.3 SE-ResNet152V2.....	99

4.16 Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM).....	105
5.17 Tartışma.....	108
6 SONUÇ VE GELECEK ÇALIŞMALAR	112
6.1 Sonuçlar	112
6.2 Zorluklar ve Sınırlamalar	113
6.3 Gelecekteki Çalışmalar	114
7 KAYNAKLAR.....	115
ÖZGEÇMİŞ	121

TABLÖLAR LİSTESİ

Tablo 4.1. Breakhis veri setindeki görüntülerin meme kanseri kategorilerine göre bölünmesi.....	24
Tablo 4.2. Veri artırmada kullanılan dönüşümler.....	29
Tablo 4.3. Breakhis veri setindeki görüntülerin büyütme sonrası kanser kategorilerine göre bölünmesi.....	30
Tablo 4.4. Eğitim metodolojisinin özellikleri	39
Tablo 4.5. Değerlendirme matrisleri	39
Tablo 5.1. ResNet152v2 için performans istatistikleri.....	43
Tablo 5.2. ResNet152V2 için büyütme olmadan performans istatistikleri	47
Tablo 5.3. CBAM-ResNet152V2 için performans istatistikleri.....	50
Tablo 5.4. CBAM-ResNet152V2 için artırma olmadan performans istatistikleri	54
Tablo 5.5. SE-ResNet152V2 için performans istatistikleri.....	57
Tablo 5.6. SE-Resnet152v2 için güçlendirme olmadan performans istatistikleri.....	61
Tablo 5.7. MobileNetV2 için performans istatistikleri	64
Tablo 5.8. MobileNetV2 için büyütme olmadan performans istatistikleri	67
Tablo 5.9. CBAM-MobileNetV2 için performans istatistikleri	71
Tablo 5.10. CBAM-MobileNetV2 için büyütme olmadan performans istatistikleri	74
Tablo 5.11. SE-MobileNetV2 için performans istatistikleri	78
Tablo 5.12. SE-MobileNetV2 için büyütme olmadan performans istatistikleri	81
Tablo 5.13. 40X Görüntüler üzerinde eğitilmiş CNN'lerin performans istatistikleri.....	83
Tablo 5.14. 100X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri.....	84
Tablo 5.15. 200X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri.....	85
Tablo 5.16. 400G Görüntülerle eğitilmiş CNN'lerin performans istatistikleri.....	86
Tablo 5.17. Çok sınıflı sınıflandırma için genel test doğruluğu	90
Tablo 5.18. 40X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performans istatistikleri.....	91
Tablo 5.19. 100X Görüntülerde eğitilen CBAM-MobileNetV2 için performans istatistikleri.....	92

Tablo 5.20:200X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performans istatistikleri.....	93
Tablo 5.21. 400X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performans istatistikleri.....	94
Tablo 5.22. 40X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri.....	95
Tablo 5.23. 100X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri.....	96
Tablo 5.24. 200X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri.....	97
Tablo 5.25. 400X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri.....	98
Tablo 5.26. 40X Görüntüler üzerinde eğitilmiş Se-ResNet152V2'nin performans istatistikleri.....	99
Tablo 5.27. 100X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performans istatistikleri.....	100
Tablo 5.28. 200X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performans istatistikleri.....	101
Tablo 5.29. 400X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performans istatistikleri.....	102
Tablo 5.30. Tüm Modeller için Performans İstatistikleri.....	110
Tablo 5.31. Meme kanseri histopatolojik görüntü sınıflandırması için derin öğrenme modellerinin önceki çalışmalar ve önerilen çalışma ile karşılaştırmalı performansı.....	111

ŞEKİL LİSTESİ

Şekil 4.1. Meme kanseri histopatolojik görüntü sınıflandırması için önerilen yöntemi gösteren iş akışı diyagramı.....	23
Şekil 4.2. Çoklu büyütme altında adenosiz meme tümörü örnekleri	25
Şekil 4.3. Çoklu büyütme altında tubular adenoma meme tümörü örnekleri	25
Şekil 4.5. Çoklu büyütme altında phyllodes tumor meme tümörü örnekleri.....	25
Şekil 4.4. Fibroadenom meme tümörü örnekleri çoklu büyütme altında	25
Şekil 4.9. Ductal carcinoma meme tümörü örneklerinin çoklu büyütme altında incelenmesi	26
Şekil 4.8. Lobular carcinoma meme tümörü örneklerinin çoklu büyütme altında incelenmesi	26
Şekil 4.7. Çoklu büyütme altında papillary carcinoma meme tümörü örnekleri	26
Şekil 4.6. Çoklu büyütme altında mucinous carcinoma meme tümörü örnekleri.....	26
Şekil 4.10: Veri artırımının gösterimi	30
Şekil 5.1. RESNET152V2 için doğruluk ve kayıp grafikleri	43
Şekil 5.2. ResNet152V2 için karışıklık matrisleri	44
Şekil 5.3. Güçlendirme olmadan ResNet152V2 için doğruluk ve kayıp grafikleri	47
Şekil 5.4. Güçlendirme olmadan ResNet152V2 için karışıklık matrisleri.....	48
Şekil 5.5. CBAM-ResNet152V2 için doğruluk ve kayıp grafikleri.....	51
Şekil 5.6. CBAM-ResNet152V2 için karışıklık matrisleri	51
Şekil 5.7. CBAM-ResNet152V2 için artırma olmadan doğruluk ve kayıp grafikleri	54
Şekil 5.8. CBAM-ResNet152V2 için büyütme olmadan karışıklık matrisleri	55
Şekil 5.9. SE-Resnet152v2 için doğruluk ve kayıp grafikleri	58
Şekil 5.10. SE-ResNet152V2 için karışıklık matrisleri	58
Şekil 5.11. SE-ResNet152V2 için büyütme olmadan doğruluk ve kayıp grafikleri	61
Şekil 5.12. SE-ResNet152V2 için karışıklık matrisleri güçlendirme olmadan	62
Şekil 5.13. MobileNetV2 için doğruluk ve kayıp grafikleri	64
Şekil 5.14. MobileNetV2 için karışıklık matrisleri.....	65
Şekil 5.15. MobileNetV2 için artırım olmadan doğruluk ve kayıp grafikleri	68
Şekil 5.16. MobileNetV2 için büyütme olmadan karışıklık matrisleri.....	68
Şekil 5.17. CBAM-MobileNetV2 için doğruluk ve kayıp grafikleri	71

Şekil 5.18. CBAM-MobileNetV2 için karışıklık matrisleri.....	71
Şekil 5.19. CBAM-MobileNetV2 için artırım olmadan doğruluk ve kayıp grafikleri	74
Şekil 5.20. CBAM-MobileNetV2 için büyütme olmadan karışıklık matrisleri.....	75
Şekil 5.21. SE-MobileNetV2 için doğruluk ve kayıp grafikleri	78
Şekil 5.22. Se-MobileNetV2 için karışıklık matrisleri	78
Şekil 5.23. SE-MobileNetV2 için artırım olmadan doğruluk ve kayıp grafikleri	81
Şekil 5.24. SE-MobileNetV2 için büyütme olmadan karışıklık matrisleri.....	82
Şekil 5.25. 40X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri	84
Şekil 5.26. 100X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri	85
Şekil 5.27. 200X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri	85
Şekil 5.28. 400X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri	86
Şekil 5.29. Farklı büyütme oranları için SE-ResNet152V2'nin karışıklık matrisleri	87
Şekil 5.30. Farklı büyütme oranları için CBAM-ResNet152V2'nin karışıklık matrisleri	88
Şekil 5.31. Farklı büyütme oranları için CBAM-MobileNetV2'nin karışıklık matrisleri	89
Şekil 5.32. Çoklu sınıf için tüm modellerde test doğruluğunu karşılaştıran grafik	91
Şekil 5.33. 40X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performansının karşılaştırılması	92
Şekil 5.34. 100X Görüntülerde eğitilen CBAM-MobileNetV2'nin performansının karşılaştırılması	93
Şekil 5.35. 200X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performansının karşılaştırılması	94
Şekil 5.36. 400X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performansının karşılaştırılması	95
Şekil 5.37. 40X Görüntüler üzerinde eğitilmiş CBAM-CBAM-ResNet152V2'nin performansının karşılaştırılması.....	96
Şekil 5.38. 100X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri.....	97
Şekil 5.39. 200X Görüntüler üzerinde eğitilmiş CBAM-CBAM-ResNet152V2'nin performansının karşılaştırılması.....	98
Şekil 5.40. 400X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performansının karşılaştırılması	99

Şekil 5.41. 40X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması	100
Şekil 5.42. 100X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması	101
Şekil 5.43. 200X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması	102
Şekil 5.44. 400X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması	103
Şekil 5.45: Tüm yakınlaştırma oranları için SE-RESNET152V2'nin karışıklık matrisleri	103
Şekil 5.46. Tüm yakınlaştırma düzeyleri için CBAM-MobileNetV2'nin karışıklık matrisleri	104
Şekil 5.47. Tüm yakınlaştırma düzeyleri için CBAM-ResNet152V2'nin karışıklık matrisleri	104
Şekil 5.48. Meme kanseri histopatolojik görüntülerinin Grade-Cam'i	107
Şekil 5.49. Eğitim ve Test doğruluk karşılaştırması	110

KISALTMALAR

A:	Adenosis
AI:	Artificial Intelligence
ANN:	Artificial Neural Network
AUC:	Area Under Curve
BRCA:	Breast Cancer Gene (BRCA1/BRCA2)
CBAM:	Convolutional Block Attention Module
CNN:	Convolutional Neural Network
DC:	Ductal Carcinoma
DCNN:	Deep Convolutional Neural Network
F:	Fibroadenoma
F1:	F1 Score
FN:	False Negative
FP:	False Positive
GPU:	Graphics Processing Unit
LC:	Lobular Carcinoma
MC:	Mucinous Carcinoma
MRI:	Magnetic Resonance Imaging
PC:	Papillary Carcinoma
PT:	Phyllodes Tumor
ReLU:	Rectified Linear Unit

ROI:	Region of Interest
SE:	Squeeze-and-Excitation
SGD:	Stochastic Gradient Descent
TA:	Tubular Adenoma
TN:	True Negative
TP:	True Positive



1 GİRİŞ

1.1 Meme Kanseri

Meme kanseri tüm dünyada kadınlar için her zaman büyük bir endişe kaynağı olmuştur. Rakamlara bakarsak, neden her yıl milyonlarca kadının bu teşhisi aldığı açıktır ve ne yazık ki hala kadınlar arasında en çok can alan kanserdir (Sung ve ark., 2021; WHO, 2023). Sayılar artmaya devam ediyor ve bu durum, sağlık sistemlerinin her yerde çözmek için hala mücadele ettiği bir sorun haline geliyor.

Tüm bu modern teknolojiyle şimdiye kadar bunu kontrol altına almış olacağımızı düşünebiliriz, ancak erken teşhis hala daha iyi hayatta kalma ve sonuçların anahtarıdır. Doktorlar kanseri mümkün olan en kısa sürede tespit etmek için genellikle tıbbi görüntülere başvururlar. Mamogramlar her yerde kullanılıyor ve standart olarak kabul ediliyor, ancak özellikle yoğun meme dokusuna sahip kadınlar için mükemmel değiller. Bazı durumlarda kanser tespit edilmeden geçebilir (Perry ve ark., 2008; Smith ve ark., 2004). İşte bu noktada ultrason işe yarar. Radyasyon kullanmaz ve katı büyümeler ile zararsız kistler arasındaki farkı söylemek için gerçekten iyidir (Shams Rana ve ark., 2024). Bu arada MR, memeye süper ayrıntılı bir görünüm verir ve diğer taramalar net olmadığında veya bir kadın kanser için daha yüksek risk altında olduğunda gerçekten yararlıdır (Weinstein, 2009).

Ancak tüm bu seçeneklere rağmen doktorlar bazen zararsız bulguları tehlikeli olanlardan ayırmakta zorlanabiliyor. Bazen aynı görüntü iki farklı radyolog tarafından farklı yorumlanıyor (Cömert ve ark., 2023). Ve bu testlere veya uzman doktorlara erişimin sınırlı olduğu yerlerde durum daha da kötüleşiyor (World Cancer Research Fund International, 2022).

İşte bu yüzden Yapay Zeka (YZ) tıpta dalga yaratmaya başladı. YZ ile, özellikle de Evrişimli Sinir Ağları veya CNN'ler olarak adlandırılan derin öğrenme türü ile bilgisayarlar görüntülerde insanların gözden kaçırabileceği şeyleri “görebilir” ve hatta insan gözü için çok ince olan desenleri bile tespit edebilir (Jiang ve ark., 2024; Johnson, ve ark., 2023). Daha da iyisi, bu yapay zeka sistemlerinin yorulmaması ya da kötü günler geçirmemesi. Doktorlar arasındaki anlaşmazlıkları azaltmaya yardımcı olabilir ve daha tutarlı, güvenilir teşhisleri destekleyebilirler (Patel, ve ark., 2023). Günümüzde, bu bilgisayar destekli tanı sistemleri radyologların büyük iş yüklerini yönetmelerine yardımcı oluyor ve hatta çok fazla uzmanı olmayan yerlere bile yardımcı olabiliyor (Tian ve ark., 2023).

Yine de YZ’i günlük klinik uygulamalara dahil etmek kolay bir iş değil. Teknoloji yalnızca üzerinde eğitildiği veriler kadar iyi çalışır ve veriler zayıf veya önyargılıysa sonuçlar da öyle olabilir. Ayrıca, doktorların (ve hastaların!) bir YZ’nin neden belirli bir tahminde bulunduğunu anlamaları gerekir; bu nedenle açıklanabilirlik ve tıp, mühendislik, bilgisayar bilimleri gibi farklı alanlar arasında işbirliği, bu araçların gerçekten yardımcı olmasını sağlamanın bir parçasıdır (Hossain ve ark., 2025). Bu çalışmanın amaçlarından biri, modern derin öğrenme yöntemlerinin mikroskop görüntülerini kullanarak farklı meme kanseri alt türlerini sınıflandırmanın karmaşık zorluğunun üstesinden nasıl gelebileceği ve belki de erken teşhisi bir adım öteye taşımaya yardımcı olabileceğidir.

1.2 Meme Kanserinde Görüntüleme Teknikleri

Doktorlar meme dokusundaki sorunları kontrol etmek için mamogram, ultrason, MR gibi araçların bir karışımını kullanırlar. Mamogramlar hala çoğu kadın için rutin testtir ve tümörleri erken yakalayıp birçok hayat kurtarmıştır. Ancak, özellikle genç kadınlarda veya yoğun göğüslere

sahip kişilerde, her şeyin net bir şekilde görünmediği durumlarda mükemmel değildirler (Kaplan ve ark., 2020).

Bu nedenle ultrason bu kadar faydalı bir destektir, güvenlidir, radyasyon içermez ve bir şeyin katı bir tümör mü yoksa sadece bir kist mi olduğunu anlamaya çalışırken gerçekten yardımcı olur (Shams Rana ve ark., 2024). MRI, görüntülemeyi yepyeni bir seviyeye taşımak gibidir. En zorlu vakaları bile görebilir ve özellikle diğer yöntemler doğru bir cevap vermediğinde önemlidir (Weinstein, 2009).

Teknoloji de gelişmeye devam ediyor. Yeni dijital teknikler daha iyi resimler, daha keskin ayrıntılar ve son zamanlarda bu resimleri okumaya yardımcı olan bilgisayarlar anlamına geliyor. Derin öğrenmeyi kullanan bu bilgisayar modelleri binlerce görüntüyü tarayabilir ve deneyimli doktorlar için bile açık olmayan sorunları işaretleyebilir (Johnson, ve ark., 2023).

Çalışmamız, hücre düzeyinde neler olduğunu görmenizi sağlayan meme dokusunun yakın, mikroskopik görüntüleri olan histopatolojiye odaklandı. Bunlar olağan taramalar değildir, ancak kanseri doğrulamak ve ne tür olduğunu anlamak için kritik öneme sahiptir (Ragab ve ark., 2021). Kullandığımız BreakHis veri kümesi, farklı yakınlaştırma seviyelerinde hem benign hem de malignant tümörleri gösteren bu yüksek çözünürlüklü görüntülerle doludur. Bunlar üzerinde derin öğrenme modellerini eğiterek, tümörlerin ne kadar farklı görünebileceğine dair zorluğun üstesinden gelmeyi ve patologlar için alt tip sınıflandırmasını daha doğru hale getirmeye yardımcı olmayı planlıyoruz.

1.3 Hassas Tıp ve Genetik Yenilikler

Meme kanseri tedavisinin hassas tıp çağına girdiğini söylemek abartı olmaz. Tedaviler sadece tümör tipine göre değil, aynı zamanda hastanın benzersiz genetik yapısına göre de

uyarlanmaktadır. Modern genomik profillemeye sayesinde doktorlar, PARP inhibitörleri gibi belirli ilaçlara ihtiyaç duyanları seçebilir veya belirli mutasyonlara sahip kadınlara ameliyat önerebilir (Carels ve ark., 2016; Terry & McLeod, 2019).

Yeni nesil dizileme, klinisyenlerin birçok geni aynı anda hızlı bir şekilde taramasını sağlayarak riski anlamalarına ve tedaviyi planlamalarına yardımcı olur. Bu sadece sonuçları iyileştirmekle kalmıyor; aynı zamanda gereksiz tedavileri önleyerek hastaları ihtiyaç duymadıkları yan etkilerden koruyor (Ross ve ark., 2015).

İleriye bakıldığında, hassas tıbbın, tedavilerin gerçek zamanlı izlenmesi ve ince ayarlanmasıyla daha da karmaşık hale gelmesi muhtemeldir. Ancak bu sadece laboratuvar bilimcileri, doktorlar ve veri uzmanları arasındaki yakın işbirliği ile çalışır ve her hastanın kendi durumu için en iyi planı almasını sağlar.

1.4 CNN Kullanarak Meme Kanseri Tespitinde Gelecek Yönelimler

Yapay zeka, özellikle de CNN'ler, doktorların meme kanserini bulma ve teşhis etme şeklini değiştiriyor. Daha fazla veri kullanılabilir hale geldikçe ve bilgisayarlar hızlandıkça, bu modeller görüntüleri okumada daha iyi hale geliyor ve bazen hiçbir insanın fark edemeyeceği sorunları tespit ediyor (Shen ve ark., 2019).

En heyecan verici trendlerden biri, daha eksiksiz bir resim için farklı tarama ve görüntü türlerinin birleştirildiği multimodal öğrenmedir. Bu, modellerin yalnızca bir tarama türü kullanıldığında görünmez olabilecek şeyleri yakalamasına yardımcı olur (Cheng ve ark., 2021).

GAN'lar gibi üretken modeller tarafından oluşturulan sentetik veriler, araştırmacıların özellikle nadir kanser alt tipleri için çok az örnek sorununun üstesinden gelmelerine yardımcı oluyor. Daha fazla veri, daha iyi eğitim ve umarız daha doğru modeller anlamına gelir (Frid-Adar ve ark., 2018).

Açıklanabilir yapay zeka da artık büyük bir mesele. Doktorlar, bir bilgisayarın neden belirli bir karar verdiğini bilmek istiyor ve belirginlik haritaları gibi araçlar, bir görüntünün tam olarak hangi bölümlerinin en önemli olduğunu görmelerini sağlıyor (Arrieta ve ark., 2020). Bulut tabanlı platformlar, daha az güçlü bilgisayarlara sahip kliniklerin bile teşhis için en son YZ araçlarını kullanabileceği ve daha fazla insana gelişmiş bakım sunabileceği anlamına geliyor (Lahoura ve ark., 2021).

1.5 Araştırma Hedefi

Bu projenin temel amacı, mikroskop görüntülerini kullanarak meme kanseri alt türlerini sınıflandırmada en zor sorunlardan bazılarını ele almaktır. Bu sadece bir model oluşturmakla ilgili değil, dengesiz sınıflar, tümör çeşitliliği ve birbirine benzeyen alt tipleri ayırt etme zorluğu gibi gerçek sorunları çözmekle ilgili. Yüksek kaliteli, açıklamalı veri kümeleri nadirdir ve patoloji görüntülerinin karmaşıklığı görevi daha da zorlaştırır.

Bu zorlukların üstesinden gelmek için, farklı büyütme ölçeklerinde hem benign hem de malignant tümörlerin sekiz farklı alt türünü kapsayan BreakHis veri setini kullandık. ResNet152V2, MobileNetV2 gibi birkaç gelişmiş derin öğrenme modelini ve CBAM ve SE gibi dikkat modüllerine sahip sürümleri karşılaştırdık. Veri artırımı sınıfların eşitlenmesine yardımcı oldu ve transfer öğrenimi mevcut modellerin en iyi şekilde kullanılmasını sağladı.

En yüksek doğruluğun elde edilmesi önemli olsa da, dikkat mekanizmaları ile modelleri güçlendirmenin gerçek dünyadaki kafa karıştırıcı vakaları ayırma becerisini nasıl etkilediğini göstermeye çalıştık. Amaç, patoloğlara hızlı ve doğru kararlar vermelerinde yardımcı olabilecek ve günlük klinik ortamlarda yanlış teşhisleri azaltmasını umduğumuz pratik, güvenilir bir derin öğrenme sistemi oluşturmaktır.

2 LİTERATÜR TARAMASI

2.1 Meme Kanseri Histopatolojisi Görüntü Sınıflandırmasında Geleneksel ve Erken

Otomatik Yaklaşımlar

Onlarca yıl boyunca, meme kanserinin teşhisi ve derecelendirilmesi, büyük ölçüde deneyimli patologlar tarafından mikroskop altında boyanmış doku kesitlerinin öznel değerlendirmesine dayanıyordu. Klinik uzmanlığa dayanan bu manuel süreç, gözlemci değişkenliği, yorgunluk ve meme dokusu morfolojisinin doğasında var olan karmaşıklık gibi sorunlarla sürekli olarak karşı karşıya kalmış ve tanı sonuçlarında gözlemciler arası ve gözlemci içi önemli tutarsızlıklara yol açmıştır (Elmore ve ark., 2015). Dijital patolojinin ortaya çıkışı ve bilgisayar destekli tanı (CAD) sistemlerinin geliştirilmesi, histopatolojik görüntü analizinin otomatikleştirilmesine yönelik ilk adımları atmıştır. En eski otomatik yaklaşımlarda araştırmacılar, hücresel ve doku yapılarının mekansal, dokusal ve kromatik özelliklerini yakalamak için gri seviyeli eş-oluşum matrisleri (GLCM), yerel ikili desenler (LBP) ve renkli histogramlar gibi tanımlayıcılar kullanarak sayısallaştırılmış görüntülerden el yapımı özellikler çıkarmaya odaklandılar (Hamilton ve ark., 2014; Spanhol ve ark., 2016). Bu özellikler daha sonra, iyi huylu ve kötü huylu dokuları ayırt etmeyi veya belirli kanser alt tiplerini tanımlamayı amaçlayan destek vektör makineleri (SVM), k-en yakın komşular (KNN) ve karar ağaçları gibi klasik makine öğrenimi sınıflandırıcılarını eğitmek için kullanıldı. Özellikle (Spanhol ve ark., 2016) GLCM ve renk özelliklerini SVM ile birleştirerek BreakHis veri setine uyguladı ve %80-85'lik bir sınıflandırma doğruluğu elde etti; (Doyle ve ark., 2012) ise doku ve çekirdek tabanlı özelliklerin orta düzeyde performans sağlayabileceğini, doğruluğun ise veri seti özelliklerine bağlı olarak genellikle %90 aralığıyla sınırlı olduğunu bildirdi. Bazı cesaret verici sonuçlara rağmen, bu geleneksel sistemler temelde, önemli alan uzmanlığı gerektiren ve histopatolojik görüntülerin yüksek değişkenliğini ve karmaşıklığını yeterince temsil etmekte başarısız olan manuel özellik mühendisliğine olan bağımlılıklarıyla kısıtlanmıştı. Klasik CAD sistemlerinin doğruluğu ve sağlamlığı, laboratuvarlar arasında boyama protokollerindeki, görüntü edinimindeki ve veri kalitesindeki tutarsızlıklar nedeniyle daha da engellendi ve bu da bulguları genelleştirmeyi veya bu sistemleri rutin klinik iş akışlarında güvenilir bir şekilde uygulamayı zorlaştırdı (Sirinukunwattana ve ark., 2017). Bu nedenle, bu erken otomatik yöntemlerin temel amacı tanılamada tutarlılığı ve verimliliği artırmak olsa da, sınırlı genelleştirilebilirlikleri, orta düzeyde doğrulukları ve gerçek dünya örneklerinin

heterojenliğini tam olarak yakalayamamaları, daha sonra veri odaklı derin öğrenme yaklaşımlarıyla ele alınacak önemli boşluklar bıraktı.

2.2 Derin Öğrenmenin Doğuşu: Meme Kanseri Histopatolojik Görüntü Sınıflandırmasının Dönüşümü

Derin öğrenmenin ortaya çıkışıyla birlikte, özellikle meme kanseri sınıflandırması için histopatolojik görüntü analizi alanında bir paradigma değişimi yaşandı. Elle hazırlanmış özelliklere büyük ölçüde dayanan geleneksel yaklaşımların aksine, derin evrişimli sinir ağları (CNN'ler), ham görüntü verilerinden çok düzeyli ve oldukça soyut temsilleri otomatik olarak çıkarabilen güçlü bir veri odaklı alternatif sundu. Bu yenilik, açık özellik mühendisliğine olan ihtiyacı ortadan kaldırarak modellerin doku mikro ortamına gömülü karmaşık görsel desenlerden doğrudan öğrenmesini sağladı. CNN'lerin meme kanseri histopatolojisine uygulanması, derin sinir ağlarının mitoz tespitinde önceki ölçütleri aşabileceğini ilk kez gösteren gibi öncü çalışmalarla tetiklendi. Bunu takiben, AlexNet, VGGNet, GoogLeNet ve özellikle ResNet gibi giderek daha derin ve daha karmaşık mimariler ortaya çıktıkça araştırma ortamı hızla gelişti. Bu mimarilerin her biri, özellik çıkarımını iyileştirmek, kaybolan gradyan sorununu azaltmak ve genel sınıflandırma doğruluğunu artırmak için yeni tasarım öğeleri sağlıyordu (He ve ark., 2016b; LeCun ve ark., 2015).

Bir dizi etkili çalışma, meme kanseri histopatolojik görüntü sınıflandırmasında CNN tabanlı modellerin geleneksel makine öğrenimine göre üstünlüğünü kısa sürede doğruladı. Örneğin, (Cruz-Roa ve ark., 2014), tüm slayt görüntülerinde invaziv duktal karsinomu otomatik olarak tespit etmek için derin CNN'leri kullanmış ve önceki özellik tabanlı yöntemle göre önemli bir gelişme olan (%71,80, %84,23) doğruluk bildirmiştir. (Araujo ve ark., 2017) tarafından yapılan sonraki bir çalışmada, meme kanseri alt tip sınıflandırması için önceden eğitilmiş VGG ve ResNet mimarileri kullanıldı ve histopatolojik veri kümelerinde %95.6'ya varan bir doğruluk oranına ulaşıldı. Bu gelişmeler yalnızca doğruluktaki iyileştirmelerle sınırlı değildi; CNN'lerin hem yerel hem de küresel uzamsal hiyerarşileri öğrenme konusundaki doğal yeteneği, onları meme dokusu örneklerinin heterojen ve çok ölçekli yapısı için özellikle uygun hale getirdi (Litjens ve ark., 2017).

Dikkat çekici performanslarına rağmen, tıbbi görüntülemeadaki erken derin öğrenme modelleri, öncelikle açıklamalı verilerin sınırlı bulunabilirliğinden ve aşırı uyum riskinden kaynaklanan önemli zorluklarla karşı karşıyaydı. Derin mimarilerin tüm potansiyelini ortaya çıkarmak için gerekli olan büyük, dengeli ve iyi etiketlenmiş veri kümelerine olan gereksinim, manuel açıklamanın zaman alıcı ve pahalı olduğu klinik bağlamda genellikle karşılanmıyordu. Sonuç olarak, birçok çalışma, modelleri halka açık veri kümelerinin nispeten küçük alt kümeleri üzerinde eğitti veya titiz olmayan değerlendirme protokolleri yoluyla sonuçları şişirme riskiyle karşı karşıya kaldı. Örneğin, veri bölme stratejilerindeki farklılıkların (örneğin, görüntü bazında ve hasta bazında) raporlanan performansı önemli ölçüde etkilediği ve bazen genelleştirilebilirlik konusunda aşırı iyimser tahminlere yol açtığı bulunmuştur (Tellez ve ark., 2019).

CNN'leri benimsemenin temel amacı, karmaşık ve ayırt edici özellikleri otomatik olarak öğrenme ve optimize etme becerilerinden yararlanarak manuel mühendisliğin sınırlamalarının üstesinden gelmekti. Bununla birlikte, genelleştirilebilirlik, boyama değişkenliğine karşı dayanıklılık ve yorumlanabilirlik açısından eksiklikler devam etti; bu zorluklar, kısa süre sonra ağ tasarımı, veri artırma ve transfer öğrenmesinde daha fazla ilerlemeye yol açacaktı. CNN tabanlı histopatolojik görüntü sınıflandırmasının vaatleri ve sınırlamaları, yapay zekâ destekli kanser teşhisinde daha da iddialı çabalar için bir temel oluşturdu.

2.3 Derin Öğrenme Tabanlı Histopatolojik Görüntü Analizinde Transfer Öğrenme ve Veri Artırımı

Transfer öğrenme ve veri artırımının devam eden sınırlamalarının (özellikle sınıf dengesizliği, aşırı uyum ve kısıtlı genelleştirilebilirlik ile ilgili olanlar) üstesinden gelmek için, son araştırmalar histopatolojik görüntü sınıflandırması bağlamında topluluk yöntemlerine ve gelişmiş optimizasyon stratejilerine giderek daha fazla yönelmektedir. Tek modelli çerçevelerin aksine, topluluk öğrenmesi birden fazla derin öğrenme modelinin çıktılarını bir araya getirerek daha geniş bir öğrenilmiş özellik çeşitliliğini yakalar ve varyans ile sapmayı etkili bir şekilde azaltır. Meme kanseri çoklu sınıf sınıflandırmasına odaklanan kapsamlı bir çalışmada, denge optimizasyonuna dayalı bir topluluk CNN (Topluluk İçi Sinir Ağı) tanıtılmış ve bu, topluluktaki her bir temel öğrenicinin katkısını bir denge optimizasyon algoritması kullanarak sistematik olarak ayarlamıştır. Bu yaklaşım, model eğitimi öncesinde dengeli veri artırım stratejilerini dahil ederek sınıf dengesizliği sorununu doğrudan ele almış ve BreakHis veri kümesindeki sekiz sınıfın da eşit

şekilde temsil edilmesini sağlamıştır. Sonuç olarak, topluluk modeli BreakHis veri kümesinde %96.71 eğitim doğruluğu ve %94.69 test doğruluğu elde ederek geleneksel tekil CNN'leri ve topluluk temel çizgilerini geride bıraktı. Çalışmada, test kümesindeki makro F1 puanının ulaştığı ve daha önce yeterince temsil edilmeyen tümör alt tipleri de dahil olmak üzere tüm sınıflarda yüksek sağlamlık gösterdiği bildirilmektedir. Denge optimizasyonu ve topluluk birleştirmenin birleşimi, test hatasında belirgin bir azalmaya, aşırı uyumu hafifletmeye (eğitim ve test performansı arasında minimum boşluk bırakarak) ve birden fazla çapraz doğrulama katmanında gelişmiş kararlılığa yol açmıştır. Ayrıca, topluluğun tanı kararları için görsel açıklamalar sağlayan dikkat temelli belirginlik haritalamasının entegre edilmesiyle yorumlanabilirlik kısmen ele alınmıştır (Çetin-Kaya, 2024).

Histopatolojide topluluk optimizasyonunun attığı temel üzerine inşa edilen çalışmalar, tıbbi görüntülemenin diğer alanlarında da ilerlemeler kaydetmiştir. Dikkat çekici bir örnek, otomatik beyin tümörü tespiti için CNN hiperparametrelerine Bayes optimizasyonunun uygulanmasıdır. Sistematik, veri odaklı parametre ayarlaması, standart ızgara veya rastgele aramaya kıyasla daha hızlı model yakınsaması ve gelişmiş tanısal doğruluk sağlamıştır. Optimize edilmiş CNN mimarisi, %98.01'lik bir test doğruluğu ve %99.62'lik bir makro F1 puanı bildirerek, gelişmiş optimizasyonun en son performansa ulaşmadaki değerini doğrulamıştır (Kaya, 2023). Benzer şekilde, nörodejeneratif hastalık değerlendirmesi alanında, yeni optimizasyon rutinlerini içeren derin öğrenme mimarisi, çok sınıflı Alzheimer hastalığı sınıflandırmasında %99.35'lük bir genel test doğruluğu ve %99.63'lük bir makro F1 puanı elde etmiş ve bu tekniklerin hem aktarılabilirliğini hem de tanısal güvenilirlik üzerindeki etkilerini vurgulamıştır (Kaya & Çetin-Kaya, 2024).

Topluluk çerçeveleri ve optimizasyonun getirdiği önemli gelişmelere rağmen, bazı zorluklar hala çözülememiştir. Sınıf dengeleme ve test doğruluğu önemli ölçüde iyileştirilmiş olsa da, bu sistemler genellikle daha fazla hesaplama kaynağı ve daha uzun çıkarım süreleri gerektirir ve bu da klinik iş akışlarında gerçek zamanlı dağıtımın önünde bir engel oluşturabilir. Dahası, belirginlik haritalamasının entegrasyonu ile yorumlanabilirlik kısmen geliştirilmiş olsa da, topluluk modelleri büyük ölçüde kara kutu işlevi görmeye devam etmekte ve bu da düzenleyici onay ve klinik güven için açıklanabilir yapay zeka konusunda daha fazla araştırma yapılmasını gerektirmektedir. Ayrıca, bağımsız veri kümeleri üzerinde harici doğrulama ve daha geniş kapsamlı çok kurumlu çalışmalar,

bu gelişmiş yöntemlerin genelleştirilebilirliğini doğrulamak için kritik gelecekteki adımlar olmaya devam etmektedir.

2.4 Histopatolojik Görüntü Analizi için Derin Öğrenmede Dikkat Mekanizmaları

Dikkat mekanizmalarının derin öğrenme mimarilerine entegrasyonu, model yorumlanabilirliği, özellik seçimi ve ayırt edici güçle ilgili uzun süredir devam eden zorlukları ele alarak histopatolojik görüntü analizinde önemli bir ilerleme sağlamıştır. Sıkıştırma ve uyarma (SE) bloğu ve evrimsel blok dikkat modülü (CBAM) gibi dikkat modülleri, ağların tıbbi görüntülerdeki en bilgilendirici kanallara veya uzamsal bölgelere seçici olarak odaklanmasını sağlamak ve böylece uzman patoloğların tanısal sezgilerini taklit etmek için yaygın olarak kullanılmaktadır. (Hu ve ark., 2018b), kanallar arasındaki karşılıklı bağımlılıkları modelleyerek kanal bazında özellik tepkilerini yeniden kalibre eden ve çeşitli sınıflandırma görevlerinde performansı iyileştiren SE bloklarını ilk olarak sunmuştur. (Woo ve ark., 2018a) tarafından önerilen CBAM modülü, hem kanal hem de uzamsal dikkati birleştirerek bu fikri genişletmekte ve tanısal açıdan ilgili bölgelere dinamik vurgu yapılmasını sağlamaktadır. Bu dikkat modüllerinin standart CNN mimarilerine dahil edilmesi, meme kanseri histopatolojisinde önemli performans kazanımları sağlamıştır.

Son çalışmalar, bu mekanizmaların çok sınıflı meme kanseri sınıflandırması üzerindeki pratik etkisini göstermiştir. (Sengodan, 2024), yakın zamanda histopatoloji için ikili dikkat çerçevesinde CBAM'ı EfficientNetV2 ile birleştirerek BreakHis veri setinde %99,01'lik dikkate değer bir doğruluk ve %98,31'lik bir F1 puanı elde etti.

(Jiang ve ark., 2019) BreakHis veri kümesinde meme kanseri sınıflandırması için hafif ve küçük bir SE-ResNet önerdi ve ikili (iyi huylu - kötü huylu) için %98,87-99,34 ve çoklu sınıf (sekiz alt tip) için %90,66-93,81 doğruluk bildirdi; bu arada parametreleri SE modülü ve basit bir öğrenme oranı zamanlayıcısı aracılığıyla azalttı. (Rakha ve ark., 2024) meme ultrasonu sınıflandırması için CBAM'ı MobileNetV2'ye entegre etti (birleştirilmiş veri kümeleri), %98,6 eğitime kıyasla CBAM olmadan %90,7, %88,2 doğrulamaya kıyasla %82,6 ve %93 test doğruluğu (MobileNetV2 için %82'ye kıyasla) elde etti. CBAM varyantı, aynı test setinde daha derin baz çizgilerini (VGG-16/19, InceptionV3, ResNet-50) de geride bıraktı ve daha net Grad-CAM açıklamaları sağladı. (Aldakhil ve ark., 2024), sekiz sınıflı BreakHis sınıflandırması için ECSAnet'i (EfficientNetV2 + CBAM + FC katmanları) tanıttı ve %94,2 (40×), %92,96 (100×), %88,41 (200×) ve %89,42 (400×) test

doğruluğu bildirdi. Bir ablasyon çalışması, CBAM ve Reinhard lekeli normalizasyonunun faydasını doğruladı ve ECSAnet, eşleşen ayarlar altında en son teknoloji baz çizgilerinin çoğunu geride bıraktı.

CNN'lerin ötesinde, son araştırmalar, Görüntü Dönüştürücüler (ViT) ve hibrit CNN-Dönüştürücü modellerinin, uzun menzilli bağımlılıkları ve küresel bağlamı yakalamak için öz dikkat ve çok başlı dikkati kullandığını vurgulamaktadır. (Atabansi, ve ark., 2023), dönüştürücü mimarilerinin, özellikle büyük veri kümeleri üzerinde önceden eğitildiklerinde ve önemli kıyaslamalarda %98'i aşan doğruluk oranlarına sahip olduklarında (örneğin, CAMELYON16'da PathTR: %98,91) genellikle CNN'lerle eşit veya daha üstün performans elde ettiğini bildirmektedir. Ancak, ViT'ler veri gerektiren ve hesaplama açısından maliyetlidir ve küçük ölçekli veri kümelerinde düşük performans gösterme eğilimindedir; bu da klinik çeviri için zorluklara işaret etmektedir.

Açık performans kazanımlarına rağmen, dikkat mekanizmaları tüm boşlukları tam olarak gidermez. Dikkat haritaları ve belirginlik görselleştirmeleri aracılığıyla daha fazla yorumlanabilirlik sağlasalar da (Arrieta ve ark., 2020), kara kutu yapıları devam eder ve klinik uygulama için model şeffaflığı hala gelişmektedir. Ayrıca, aşırı veya yanlış kalibre edilmiş dikkat, incelikli ancak önemli görüntü özelliklerinin aşırı uyumuna veya ihmal edilmesine yol açabilir. Mevcut araştırmalar, hem doğruluğu hem de açıklanabilirliği en üst düzeye çıkarırken hesaplama yükünü en aza indirmeyi hedefleyerek, kanal, uzamsal ve dönüştürücü tabanlı dikkatin optimum kombinasyonlarını araştırmaya devam etmektedir.

Lawal ve ark. (2025), önerilen hibrit derin öğrenme modeli D-ResNet'in Random Forest sınıflandırıcıyla birleştirilmiş hâlinin, BreakHis 400× veri kümesinde histopatolojik görüntülerin ikili sınıflandırmasında (benign vs. malign) güçlü sonuçlar verdiğini bildirmiştir. Model, %92.34 doğruluk oranına ulaşmış; artık bağlantıların (residual connections) derinliğine ayrılabilir evrişimlerle (depthwise separable convolutions) bütünleştirilmesi ve geleneksel Softmax katmanının Random Forest ile değiştirilmesi sayesinde, standart CNN mimarilerine kıyasla sınıflandırma performansının arttığını göstermiştir (Lawal ve ark., 2025).

Clement ve ark. (2022), BreakHis veri kümesindeki 7.909 histopatolojik meme kanseri görüntüsünü dört büyütmede (40×, 100×, 200×, 400×) ve sekiz alt tipte (dört benign: adenosis, fibroadenoma, phyllodes tumor, tubular adenoma; dört malign: ductal carcinoma, lobular carcinoma, mucinous carcinoma, papillary carcinoma) kullanmıştır. Yazarlar, ResNet50,

ResNet18, DenseNet201 ve EfficientNetB0 ile derin özellikler çıkarıp Softmax yerine bire karşı bir (one-vs-one) SVM ile sınıflandıran çok ölçekli havuzlanmış görüntü özellik temsili (MPIFR) yöntemini önermiştir. Sınıf dengesizliğini gidermek için veri artırma ve aşırı örnekleme uygulanarak veri kümesi 21.701'in üzerine çıkarılmıştır. Sonuçlar, MPIFR-SVM topluluğunun tekil CNN taban çizgilerinden anlamlı biçimde daha iyi olduğunu ve BreakHis üzerinde çok sınıflı sınıflandırma için en yüksek doğruluk olan %97.77'ye ulaştığını göstermektedir (Clement ve ark.,2022).

Zhao ve ark. (2025), BreakHis üzerinde dört büyütme düzeyinde (40×, 100×, 200×, 400×) ikili sınıflandırma (benign vs. malign) için HoRFNet'i değerlendirmiştir; model, çok dallı alıcı alan bloğunu (multi-branch receptive field block) dilate evrişimlerle ve yüksek dereceli küresel etkileşimleri yakalamak üzere ikinci dereceden kovaryans havuzlama (MPN-COV) ile birleştirir. Eğitim/test için %70/%30 rastgele bölme (eğitimin %25'i doğrulama), veri artırma ve SGD (momentum 0.9, başlangıç öğrenme oranı 0.001, ters azalma) kullanılmıştır. En yüksek doğruluk görüntü düzeyinde %99.50 ve hasta düzeyinde %99.23 olup 200×'de elde edilmiştir (Zhao ve ark.,2025).

Maurya ve ark. (2024), BreakHis'i dört büyütmede ikili sınıflandırma için kullanmış ve ResNet-18'in tam evrişimsel kanal-ve-mekânsal dikkat (FCCS-Net) ve artık bağlantılarla güçlendirilmiş bir varyantını önermiştir. Görüntüler 256×256'a yeniden boyutlandırılmış, döndürme/çevirme ile artırılmış ve Adam (öğrenme oranı=0.001, yığın=128) ile eğitilmiştir. Büyütmeye özel bölmeler verilmiştir (ör., 200×: 1409/201/403 eğitim/doğrulama/test). En yüksek doğruluk 200×'de %99.50 olup, 40×'te %99.25, 100×'te %98.32 ve 400×'te %96.98 elde edilmiştir (Maurya ve ark., 2024).

Pacal ve Attallah (2025), hibrit bir CNN-ViT mimarisi olan InceptionNeXt-Transformer'ı tanıtmış ve BreakHis üzerinde hem ikili hem çok sınıflı sınıflandırmayı test etmiştir. Önceki çalışmaların en iyi performansı verdiğini göstermesi nedeniyle yalnızca 40× büyütme kullanılmış; görüntülerin kenarları kaldırılmış, RGB'ye dönüştürülmüş, normalize edilmiş, 224×224'e ölçeklenmiş; %70 eğitim, %10 doğrulama, %20 test bölmesi ile; rastgele çevirme/döndürme, renk titreşimi, Mixup, CutMix ve Gauss gürültüsü dâhil kapsamlı artırma ve ImageNet ağırlıklarından aktarım öğrenmesi uygulanmıştır. İkili sınıflandırmada (benign vs. malign) model %100 doğruluk elde ederek yalnız CNN mimarilerini (maks. %99.75) geride bırakmış ve daha az parametreyle en iyi ViT'lerle aynı düzeye ulaşmıştır. Sekiz alt tipli çok sınıflı sınıflandırmada %98.25 doğrulukla, hem CNN-tabanlı

(yaklaşık maks. %96.75) hem de ViT-tabanlı (yaklaşık maks. %97.00) yöntemleri aşmıştır (Pacal & Attallah 2025).

Aljuaid ve ark. (2022), BreakHis (40×–400×) üzerinde aktarım öğrenimli CNN’ler (ResNet18, Inception-V3, ShuffleNet) kullanmış; medyan/Gauss filtreleme, yeniden boyutlandırma (224×224 veya 299×299) ve eğitim sırasında döndürme/çevirme artırması uygulamış; görüntü temelli %65/%35 eğitim–test bölmesi yapmıştır. Bildirilen ikili doğruluklar: ResNet %99.7, Inception-V3 %97.66, ShuffleNet %96.94; çok sınıflı (8 alt tip) doğruluklar: ResNet %97.81, Inception-V3 %96.07, ShuffleNet %95.79 olup her iki senaryoda da en iyi sonuç ResNet’tedir (Aljuaid ve ark., 2022).

Lamprou ve ark. (2024), tıbbi görüntü veri kümelerinde (BreakHis dâhil) Grad-CAM ile HiResCAM’i karşılaştırmış; ResNet50 ve VGG19’u Conv–Flatten–Class-Scores (Evrişim–Düzleştirme–Sınıf Puanları) kurulumunda 10 katlı çapraz doğrulama ve hafif artırma (çevirme/döndürme) ile ince ayarlamıştır. BreakHis ikili (benign vs. malign) görevinde en iyi test metrikleri ResNet50 ile elde edilmiştir: Dengeli Doğruluk = 0.859, AUC = 0.943; bu değerler VGG19’u (Dengeli Doğruluk = 0.840, AUC = 0.919) aşmaktadır (Lamprou ve ark., 2024).

Chattopadhyay ve ark. (2022), BreakHis histopatolojisi için çok ölçekli iki katmanlı artık yinelemeli CNN olan MTRRE-Net’i sunmuştur. Beş katlı çapraz doğrulama ile değerlendirilen en iyi varyant (MTRRE-Net74), ikili doğruluklarda 40× için %97.12, 100× için %95.22, 200× için %96.85 ve 400× için %97.81 raporlamıştır; çok sınıflı alt tip sonuçları verilmemiştir; çalışmanın en yüksek sonucu 400×’te %97.81’dir (Chattopadhyay ve ark., 2022).

Alirezazadeh ve Dornaika (2023), meme histopatolojisi için Güçlendirilmiş Toplamsal Açısal Marj Kaybı’nı (BAM) önermiş ve bunu BreakHis üzerinde değerlendirilen BreastNet CNN ile eşleştirmiş; ayrıca kayıp fonksiyonunun genelliğini göstermek için hafif omurgaları (MobileNetV3Small, MobileViT) da test etmiştir. İkili benign–malign görevinde BreastNet+BAM, büyötmeye özel en iyi doğrulukları sağlamıştır: %99.79 (40×), %99.86 (100×), %99.96 (200×), %97.65 (400×). Çalışma ayrıca alt sınıf (8 sınıf) sonuçları rapor ederek BAM’in çok sınıflı ayrımı iyileştirdiğini göstermektedir (Alirezazadeh & Dornaika, 2023).

Aldakhil ve ark. (2024), BreakHis üzerinde 8 sınıflı çok sınıflı sınıflandırma için Reinhard leke normalizasyonu ve veri artırma ile eğitilen, CBAM dikkat bloğu ve ek tam bağlantılı katmanlarla

zenginleştirilmiş EfficientNetV2-S tabanlı ECSAnet'i önermiştir. AlexNet, DenseNet121, EfficientNetV2-S (taban), InceptionV3, ResNet50 ve VGG16 ile aynı ayarlar altında bire bir karşılaştırmada ECSAnet'in test doğrulukları 40×'ta %94.2, 100×'te %92.96, 200×'te %88.41, 400×'te %89.42'dir; 200×'te DenseNet121 az farkla daha yüksektir (%88.89) ve 100×'te InceptionV3 ile başa baştır, ancak özellikle 40× ve 400×'te genel lider ECSAnet'tir (Aldakhil ve ark., 2024).

Rafiq ve ark. (2025), BreakHis tüm kesit histopatolojisi üzerinde hem ikili (benign vs. malign) hem de çok sınıflı (8 alt tip) sınıflandırma için DenseNet121 tabanlı derin bir modeli sunmuştur. İkili görevde %98.50 doğruluk ve AUC = 0.98; çok sınıflı görevde %92.50 doğruluk ve AUC = 0.94 rapor etmişlerdir. Bire bir karşılaştırmalarda, önerilen DenseNet121 tabanlı DNN ikili görevde en iyi performansı, çok sınıflı görevde ise rekabetçi sonuçları elde etmiştir (Rafiq ve ark., 2025)

Das ve ark. (2025), BreakHis'i 100×/200×/400× boyunca ikili IDC görevi (benign vs. malign) olarak ele almış; ImageNet ile başlatılan aktarım öğrenimli CNN'ler (ResNet50, VGG16, VGG19, MobileNetV2, Xception) kullanmış; %70/%10/%20 eğitim/doğrulama/test bölmesi ve çevirme, yakınlaştırma, kesme, parlaklık ve döndürme içeren artırma uygulamıştır. En iyi tekil model ResNet50 olup test doğruluğu 100×'te %97.8, 200×'te %97.9, 400×'te %96.4'tür; Top-3 ağırlıklı topluluk (ResNet50+VGG16+VGG19), genel olarak en iyi performansı ortalama %97.27 ile (100×/200×/400× için sırasıyla %97.2/%97.5/%97.1) sağlamıştır (Das ve ark., 2025).

3 EVRİŞİMSEL SINIR AĞI (CNN) YAPISININ ARKA PLANI

3.1 Giriş

Son on yılda bilgisayar görme veya görüntü analizi araştırılmışsa, Convolutional Neural Networks (CNN'ler) görüntülerle çalışmak için, özellikle kanser teşhisi gibi tıbbi alanlarda, birincil araçlar olarak kabul edildiği bilinmektedir. Bu ağların gücü, karmaşık verilerden kalıpların ve özelliklerin otomatik olarak öğrenilebilmesinde yatmaktadır; bu süreçte, neyin tanımlanması gerektiği manuel olarak belirtilmesine gerek kalmaz (LeCun ve ark., 2015; Shen ve ark., 2021). Bu bağlamda, CNN'ler tanımlanmakta, yapıları açıklanmakta ve mikroskobik görüntüler kullanılarak meme kanseri sınıflandırılırken çalışmalarımızda neden tercih edilen yöntem olarak kabul edildikleri özetlenmektedir.

3.2 Evrişimsel Sinir Ağları (CNN'ler)

CNN'ler, görüntüleri işlemek için tasarlanmış “akıllı” derin öğrenme modelleri olarak düşünülebilir. Eski algoritmalarından farklı olarak, önemli özelliklerin tanımlanması için insanlara ihtiyaç duyulurken, CNN'ler ham pikselleri analiz eder ve temel çizgiler ve dokulardan oldukça karmaşık yapılara kadar çeşitli desenleri otomatik olarak öğrenir (Esteva, 2021; Litjens ve ark., 2017). İlk katmanlarda basit kenarlar veya renk değişiklikleri tespit edilebilir, ancak daha derin katmanlara ulaşıldıkça, hücre yapıları veya hatta dokudaki hastalık göstergeleri gibi daha karmaşık şekiller ağ tarafından tanınır.

3.2.1 Evrişimli Katmanlar

Her CNN'in bel kemiği evrişim katmanıdır. Bunu görüntü boyunca hareket eden bir filtre olarak düşünebiliriz, her seferinde küçük parçalara bakan ve yerel desenleri seçen bir filtre olarak hayal edebiliriz. İlk başta sadece çizgileri veya noktaları tespit edebiliriz, ancak her yeni katmanla birlikte

bunları daha anlamlı yapılara dönüştürmeye başlar, tıpkı yüzleri gözlerden, burunlardan ve ağızlardan tanımayı öğrenmemiz gibi (Goodfellow ve ark., 2016; LeCun ve ark., 2015).

3.2.2 Aktivasyon Fonksiyonları

Her konvolüsyondan sonra, ağıın hangi örüntülerin önemli olduğuna karar vermesi için bir yola ihtiyacı vardır. Aktivasyon fonksiyonları, özellikle de pozitif sinyallerin geçmesine izin veren ve geri kalanını engelleyen popüler ReLU burada devreye girer (Nair, ve ark., 2010). Bu hile, modele sadece düz çizgilerle çalışmasına kıyasla çok daha karmaşık ilişkileri anlama esnekliği kazandırır.

3.2.3 Havuzlama Katmanları

Veriler içinde boğulmaktan kaçınmak için CNN'ler bilgileri özetlemek üzere havuzlama katmanları kullanır. Büyük bir resme baktığınızı ve sonra onu küçülttüğünüzü, yalnızca en önemli ayrıntıları tuttuğunuzu düşünün - örneğin maksimum havuzlama, her alandan en güçlü sinyali seçer (Scherer ve ark., 2010). Bu aynı zamanda bir modelin “gürültü” de dahil olmak üzere her küçük ayrıntıyı öğrendiği ve genelleme yapamadığı aşırı uyumu önlemeye yardımcı olur.

3.2.4 Tam Bağlantılı Katmanlar

Ağ, görüntüden tüm temel özellikleri çıkardıktan sonra, bir görüntünün hangi sınıfa ait olduğunu tahmin etmek gibi bir karar vermesi gerekir. Tam bağlı katmanlar burada devreye girer, tüm özellikleri alır ve nihai tahmini yapmak için bunları tartar (Krizhevsky ve ark., 2012).

3.2.5 Ağırlık Paylaşımı ve Yerel Bağlantı

CNN'lerin bu kadar iyi çalışmasının bir nedeni de verimli olmalarıdır. Ağırlık paylaşımı kullanırlar, yani görüntünün her yerine aynı filtre seti uygulanır ve bir seferde yalnızca küçük yerel bölgelere bakarlar. Bu, geleneksel ağlara kıyasla parametre sayısını önemli ölçüde azaltır ve

modelin daha hızlı öğrenmesine ve daha az veriyle bile iyi çalışmasına yardımcı olur (Goodfellow, 2016; LeCun ve ark., 2015).

3.2.6 Eğitim ve Optimizasyon

Bir CNN'i eğitmek, bir çocuğa çok sayıda örnek göstererek ve hataları hakkında geri bildirim vererek öğretmeye benzer. Model, filtrelerini geri yayılım ve SGD veya Adam gibi optimizasyon yöntemleriyle ayarlayarak öğrenir. Yol boyunca, modelin “takılıp kalmasını” veya eğitim verilerini ezberlemesini önlemek için dropout (ağın bazı kısımlarını rastgele kapatan), toplu normalleştirme ve veri artırma gibi hileler kullanılır (Ioffe & Szegedy, 2015; Srivastava ve ark., 2014).

3.2.7 Gelişmeler ve Modern Mimariler

LeNet-5 gibi orijinal CNN'ler küçük başladı, ancak zamanla yeni fikirler AlexNet, VGG, GoogLeNet ve ResNet gibi güçlü modellere yol açtı (He ve ark., 2016a, 2016b; Krizhevsky ve ark., 2012b; Simonyan & Zisserman, 2015; Szegedy ve ark., 2015). Bu ağlar yeni katman türleri ekledi, daha derinleşti ve doğruluğu daha da yükseltmek için her biri bir öncekinin üzerine inşa edilen önemli bilgileri kaybetmeden eğitmenin yollarını buldu.3.3 Transfer Öğrenimi

Derin öğrenmedeki en harika şeylerden biri transfer öğrenmedir. Sıfırdan başlamak yerine, MobileNetV2 Milyonlarca görüntüden öğrendiğimiz bir modeli alıp, kendi özel problemimize uyacak şekilde ayarlıyoruz. Bu, zaman kazandırır, devasa veri kümelerine olan ihtiyacı azaltır ve genellikle daha iyi sonuçlar verir (Pan & Yang, 2009; Raghu, ve ark., 2019). Çalışmamızda, önceden eğitilmiş modelleri BreakHis verilerine uyarlamak için transfer öğrenmeyi kullandık, bu da doğruluğu artırmaya ve eğitimi hızlandırmaya yardımcı oldu.

3.4 Bu Çalışmada Kullanılan CNN Mimarileri

Bu çalışma için hem güçlü hem de pratik modellere ihtiyacımız vardı, bu nedenle bazıları iyi bilinen, bazıları da dikkat mekanizmalarıyla geliştirilmiş en iyi performans gösteren birkaç CNN seçtik. Amacımız, her birinin hız, doğruluk ve meme kanseri dokusu görüntülerindeki ince farklılıkları tespit etme becerisini nasıl dengelediğini görmekti.

3.4.1 ResNet152V2

ResNet152V2, bilginin ağ üzerinden sorunsuzca akmasına yardımcı olan “kısayollar” sayesinde derin ama yine de eğitilebilir olmasıyla ünlüdür. Bu, hem basit hem de karmaşık özellikleri öğrenebileceği anlamına gelir ve bu da onu tıbbi görüntü görevleri için sağlam bir temel haline getirir (He ve ark., 2016b).

3.4.2 SE-ResNet152V2

ResNet152V2'yi temel alan SE-ResNet152V2, Squeeze-and-Excitation bloklarını ekler. Bunlar, ağın her kanala ne kadar önem verdiğini ayarlayarak en önemli özelliklere “daha fazla dikkat etmesini” sağlar, bu da karmaşık verilerdeki ince desenleri yakalamaya yardımcı olur (Hu ve ark., 2018b).

3.4.3 CBAM-ResNet152V2

CBAM-ResNet152V2, yalnızca “ne” olduğuna değil, aynı zamanda önemli özelliklerin görüntüde “nerede” olduğuna odaklanan bir blok ekleyerek daha da ileri gidiyor. CBAM modülü önce hangi kanalların önemli olduğunu vurgular ve ardından en ilgili uzamsal bölgeleri bularak ağın zor durumları ayırt etmede daha da iyi olmasını sağlar (Li ve ark., 2021; Woo ve ark., 2018b).

3.4.4 MobileNetV2

Hızlı ve hafif bir şeye ihtiyacımız olduğunda, MobileNetV2 harika bir seçenektir. Derinlemesine ayrılabilir konvolüsyonlar ve ters çevrilmiş artıklar kullanarak daha azıyla daha fazlasını yapmak için akıllı bir tasarım kullanır, bu nedenle hesaplama gücünün sınırlı olduğu ancak doğruluğun hala önemli olduğu durumlar için mükemmeldir (Sandler ve ark., 2018).

3.4.5 CBAM-MobileNetV2

CBAM-MobileNetV2, MobileNetV2'nin verimliliğini CBAM'in dikkat gücü ile birleştirir. Bu karışım işleri hafif tutar ancak yine de modelin görüntünün en ilgili kısımlarına odaklanmasına izin verir, bu da ince hastalık belirtilerini yakalamaya yardımcı olabilir.

3.4.6 SE-MobileNetV2

SE-MobileNetV2, MobileNetV2'ye SE blokları ekleyerek aynı yönde atılmış bir başka adımdır. Sonuç, verimli kalmaya devam eden ancak tıbbi görüntüler için önemli olan ayrıntılara uyum sağlama konusunda daha iyi bir iş çıkaran bir modeldir (Hu ve ark., 2018c).

3.5 CNN'lerde Dikkat Mekanizmaları

Dikkat modülleri modern CNN'lerde neredeyse standart hale gelmiştir. Ağın, tıpkı bir insan uzmanının yapacağı gibi en fazla bilgiyi taşıyan özellikleri ve alanları “yakınlaştırmaya” yardımcı olurlar. Bu projede iki ana türe odaklandık: Sıkıştırma ve Uyarma (SE) ve Evrimsel Blok Dikkat Modülü (CBAM).

3.5.1 Squeeze-and-Excitation (SE)

SE bloğu, küresel havuzlama (her kanalı özetlemek için) kullanarak ve ardından öğrenilen ağırlıklarla önemli olanları “öne çıkararak” ağın hangi özellik kanallarına dikkat etmeye değer

olduğunu bulmasına yardımcı olur. Bu, nihai özelliklerin eldeki görevin özelliklerine daha uygun olduğu anlamına gelir (Hu ve ark., 2018a) .

3.5.2 Evrişimsel Blok Dikkat Modülü (CBAM)

CBAM, önce hangi kanalların önemli olduğuna karar vererek ve ardından özellik haritasında eylemin nerede gerçekleştiğini bularak işleri daha da ileri götürür. Bu, ağa hem “ne arayacağı” hem de “nereye bakacağı” konusunda bir dizi talimat vermek gibidir ve kararlarını daha keskin ve daha güvenilir hale getirir (Li, ve ark., 2019; Woo ve ark., 2018a).

3.6 CNN'ler Histopatolojik Görüntü Sınıflandırması için Neden Uygun?

CNN'ler bu tür görevler için son derece uygun kabul edilmektedir. Çoklu ölçeklerdeki desenler tespit edilebilir, tıbbi görüntülerde sıklıkla görülen varyasyonlar etkili bir şekilde yönetilebilir ve bir tümör türünü diğerinden ayıran en küçük farklılıklar bile tanımlanabilir. Uygulamada, CNN'ler, çalışmalarımızda el ile oluşturulan özelliklere dayanan eski yöntemlere kıyasla tutarlı bir şekilde daha yüksek doğruluk ve güvenilirlik sağlamaktadır (Deng ve ark., 2020; Litjens ve ark., 2017).

3.7 Seçim Gereççesi

Bu araştırma için modeller ve dikkat modülleri seçilirken, hem teorik hususları hem de pratik uygulamaları ele alacak bir kombinasyon arandı. Gerçek hayatta uygulanabilirlik açısından yeterince verimli kalırken, birden fazla meme kanseri türünü ayırt etme gibi karmaşık bir görevi yönetebilecek bir çözüm gerekiyordu. ResNet152V2 gibi derin ağlar, önemli bilgi kaybı olmadan çok derin öğrenmeyi mümkün kıldıkları için uygun adaylar olarak belirlendi. SE ve CBAM gibi dikkat modülleri ise, modeli bir görüntüdeki en alakalı bölgelere odaklanmaya yönlendirerek performansı artırdığı kanıtlanmıştır (He ve ark., 2016a, 2016b; Hu ve ark., 2018c; Woo ve ark., 2018a).

MobileNetV2 ve geliştirilmiş versiyonları ise, yoğun klinik ortamlar veya sınırlı kaynaklara sahip cihazlar gibi hız ve hesaplama verimliliğinin kritik olduğu senaryolar için ideal olarak kabul edilmektedir (Sandler ve ark., 2018). Standart ve dikkatle geliştirilmiş modelleri değerlendirerek, en önemli performans iyileştirmelerinin nerede gerçekleştiği ve dikkat bloklarının getirdiği ek karmaşıklığın farklı bağlamlarda ve veri kümelerinde haklı olup olmadığı konusunda içgörüler elde edildi. BreakHis veri kümesinde bu yaklaşımların sistematik bir karşılaştırması yapılarak, hesaplama gücü ve pratik kullanılabilirlik arasında optimal bir denge arandı ve derin öğrenmeyi gerçek dünya patoloji görevlerine uygulamak isteyenlere rehberlik sağlanması amaçlandı.

4 MATERYAL VE METOT

4.1 Deneysel Kurulum

Bu çalışma sırasında kullanılan sunucu, 9. Nesil Intel® Core™ i7-9750U işlemciye sahip, 32 GB sistem belleği ve 1 TB HDD ile donatılmış bir MSI dizüstü bilgisayardır. Alt kısmına, Max Q Tasarımlı özel belleğe sahip bir NVIDIA GeForce RTX 2070 takılmıştır. Çalışmak için kullandığımız dil Python ve ortam ise Spyder programına sahip Anaconda Navigator'dır.

4.2 Önerilen Yöntem


Bu çalışmada çok sınıflı meme kanseri sınıflandırması için önerilen yöntem, hem doğruluğu hem de adaleti en üst düzeye çıkarmak için açık ve tekrarlanabilir bir boru hattını takip ederek dikkatlice tasarlanmıştır. Tüm süreç, veri alımından model seçimine kadar sıralı işlemleri özetleyen iş akışı diyagramında (bkz. Şekil 4.1) adım adım özetlenmiştir.

Süreç, sekiz kategoriye ve dört farklı büyütme seviyesine yayılan histopatolojik görüntüler içeren BreakHis veri setinin elde edilmesiyle başlar. Tüm görüntüler, 224×224 piksellik tek tip bir çözünürlüğe yeniden boyutlandırma ve piksel değerlerinin normalleştirilmesi dahil olmak üzere standartlaştırılmış bir ön işleme rutinine tabi tutularak sonraki tüm adımlar için tutarlılık sağlanır. Ön işlemin ardından veri kümesi, sınıf dağılımını korumak için katmanlı bir yaklaşım kullanılarak eğitim ve test kümelerine ayrılır; görüntülerin %80'i eğitime ve %20'si teste ayrılır. Bu bölünme, genelleme kabiliyetinin adil bir şekilde değerlendirilmesini sağlarken sağlam model geliştirmeye olanak tanır.

Veri setindeki doğal sınıf dengesizliğini gidermek için, rastgele döndürmeler, çevirmeler ve ölçeklendirme gibi veri artırma teknikleri yalnızca eğitim setine uygulanır. Paralel olarak iki deneysel strateji izlenir: biri veri artırımı (sınıfları dengelemek için ek örneklerin oluşturulduğu) ve diğeri artırısız, model performansı üzerindeki etkilerinin doğrudan karşılaştırılmasına olanak tanır.

Model seçimi, önerilen işlem hattının son aşamasını oluşturmaktadır. ResNet152V2, SE-ResNet152V2, CBAM-ResNet152V2 ve MobileNetV2 dahil olmak üzere birden fazla derin öğrenme mimarisi araştırılmış, her biri hem artırılmış hem de artırılmamış koşullar altında eğitilmiş ve değerlendirilmiştir. Dikkat mekanizmaları (SE ve CBAM), görüntülerdeki en bilgilendirici özelliklere odaklanma yeteneklerini geliştirmek için belirli modellere dahil edilmiştir.

Şekil 4.1'de görselleştirilen bu sistematik yaklaşım, şeffaflık, tekrarlanabilirlik ve sonraki bölümlerde kapsamlı deneysel analiz için güçlü bir temel sağlar.



Şekil 4.1. Meme kanseri histopatolojik görüntü sınıflandırması için önerilen yöntemi gösteren iş akışı diyagramı

4.3 Veri Seti Açıklaması


Bu tezde, Brezilya'daki Parana Federal Üniversitesi Görme Robotları ve Görüntüleme Laboratuvarı'nın Meme Kanseri Histopatolojik Görüntü Sınıflandırma (BreakHis) Veritabanını

kullandık (Spanhol ve ark., 2016). BreakHis veri kümesi iki ana gruba ayrılmıştır: benign tümörler ve farklı büyütme faktörlerine (40X, 100X, 200X, 400X) sahip malignant tümörler. Veri kümesindeki görüntüler 3 kanallı 700 X 460 piksel çözünürlükte RGB görüntülerdir. 82 hastadan 2.480 benign örnek ve 5.429 malignant örnek bulunmaktadır. Ayrıca, benign görüntüler dört sınıfı temsil etmektedir: Adenosis (A), Fibroadenoma (F), Phyllodes Tumor (PT) ve Tubular Adenoma (TA). Malignant görüntüler dört sınıfı temsil eder: Ductal Carcinoma (DC), Lobular Carcinoma (Nagpal ve ark., 2019), Mucinous Carcinoma (MC) ve Papillary Carcinoma (Alom ve ark., 2019). Aşağıdaki Tablo, BreakHis veri kümesindeki görüntülerin kanser alt türlerine göre bölünmesini açıklamaktadır.


Tablo 4.1. Breakhis veri setindeki görüntülerin meme kanseri kategorilerine göre bölünmesi

Türler	Alt Türler	40X	100X	200X	400X	Toplam
Benign	A	114	113	111	106	444
	F	253	260	264	237	1014
	PT	109	121	108	115	453
	TA	149	150	140	130	569
Malignant	DC	864	903	896	788	3451
	LC	156	170	163	137	626
	MC	205	222	196	169	792
	PC	145	142	135	138	560
Toplam		1995	2081	2013	1820	7909
Train						5,536
Test						2373


Aşağıdaki şekillerde farklı büyütme oranlarında kanser örnekleri gösterilmektedir.




Şekil 4.2. Çoklu büyütme altında adenosis meme tümörü örnekleri




Şekil 4.3. Çoklu büyütme altında tubular adenoma meme tümörü örnekleri




Şekil 4.5. Fibroadenom meme tümörü örnekleri çoklu büyütme altında




Şekil 4.4. Çoklu büyütme altında phyllodes tumor meme tümörü örnekleri




Şekil 4.9. Çoklu büyütme altında mucinous carcinoma meme tümörü örnekleri



Şekil 4.8. Çoklu büyütme altında papillary carcinoma meme tümörü örnekleri



Şekil 4.7. Lobular carcinoma meme tümörü örneklerinin çoklu büyütme altında incelenmesi



Şekil 4.6. Ductal carcinoma meme tümörü örneklerinin çoklu büyütme altında incelenmesi

4.4 Veri Seti Hazırlama

Model eğitiminden önce, optimum performans ve güvenilirlik sağlamak için veri setinin dikkatli bir şekilde hazırlanması gerekliydi. Başlangıçta ‘benign’ ve ‘malignant’ klasörler halinde yapılandırılan ve histopatolojik alt tiplere ayrılan BreakHis veri kümesi, denetimli öğrenme

görevlerini kolaylaştırmak için sistematik yeniden düzenleme gerektirmiştir. Her görüntü, geniş benign veya malignant kategorisi yerine spesifik alt türüne göre yeniden etiketlendi. Bu yaklaşım, modellerin farklı kanser türleri arasındaki daha ince ayrımlara odaklanmasını sağladı.

Tutarlı bir eğitim hattı oluşturmak için tüm görüntüler çıkarılmış ve belirlenen etiketler kullanılarak her bir histolojik sınıfı temsil eden yeni dizinler halinde yeniden düzenlenmiştir: Adenosis (A), Fibroadenoma (F), Phyllodes Tumor (PT), Tubular Adenoma (TA), Ductal Carcinoma (DC), Lobular Carcinoma (Nagpal ve ark., 2019), Mucinous Carcinoma (MC) ve Papillary Carcinoma (Alom ve ark., 2019). Bu, model eğitim sürecinin her bir alt tipi bağımsız bir sınıf olarak ele almasını sağlamıştır.

Veri kümesi daha sonra iki farklı alt kümeye bölünmüştür: eğitim ve test. Görüntülerin yaklaşık %80'i eğitime, kalan %20'si ise teste ayrılmıştır; bu bölme işlemi, alt kümelerdeki veri dengesizliğini önlemek için sınıf dağılımı korunarak gerçekleştirilmiştir. Veri sızıntısını önlemek ve model genellemesinin gerçekçi bir değerlendirmesini sağlamak için aynı hastaya ait görüntülerin birden fazla alt kümede görünmemesine dikkat edilmiştir.

Ayrıca, hazırlık sırasında görüntüler 224X224 piksellik tek tip bir boyuta standartlaştırılarak çoğu evrışimsel sinir ağı için ortak girdi boyutlarıyla uyumlu hale getirilmiştir. Bu yeniden boyutlandırma, önceden eğitilmiş ağ mimarileriyle uyumluluğu sağlamak ve eğitim sürecini hızlandırmak için gerekliydi.

4.5 Veri Ön İşleme

Herhangi bir derin öğrenme modelini eğitmeden önce, tüm görüntülerin sinir ağlarına uygun bir şekilde hazırlandığından emin olmamız gerekiyordu. İlk adımımız, orijinal olarak JPEG olarak saklanan tüm histopatolojik görüntüleri almak ve her birini 224 x 224 piksel olarak yeniden

boyutlandırmaktı. Böylece hangi modeli kullanırsak kullanalım (SE-ResNet152V2, CBAM-ResNet152V2 veya CBAM-MobileNetV2 gibi) tüm girdiler gerekli şekle uyuyordu.

Ardından, piksel değerlerini her birini 255'e bölerek 0 ile 1 arasındaki aralığa dönüştürdük. Bu tür bir normalleştirme oldukça standarttır ve ağın daha sorunsuz bir şekilde eğitilmesine yardımcı olur. Tüm görüntüleri RGB renginde tuttuk, çünkü bu renk ayrıntıları patoloji görüntülerinde doku türlerini ayırt etmek için genellikle çok önemlidir.

Modellerin sadece eğitim verilerinde çok iyi hale gelmesini (aşırı uyum) önlemek için, hem eğitim hem de test seti için veri artırma yöntemine başvurdum. Eğitim sırasında model, hem orijinal hem de değiştirilmiş görüntüleri gördü. Bu değişiklikler arasında görüntüleri yatay olarak çevirme, 0° , 90° , 180° veya 270° döndürme ve -0,2 ile 0,2 aralığında yatay kaydırma uygulamak yer alıyordu. Bazı modellerde ek rastgele parlaklık ($\pm 0,2$) ve kontrast (0,8–1,2) ayarlamaları uygulandı. Dikey çevirme veya yakınlaştırma kullanılmadı. Bu artırımlar, gerçek dünya verilerinde bulunan çeşitliliği taklit etmeye yardımcı oldu ve modelleri daha sağlam hale getirdi.

Etiketleme için, her görüntünün sınıfıyla doğru şekilde ilişkilendirildiğinden emin olduk: iki sınıflı problemler için “benign” veya “malignant” olarak veya çok sınıflı görevler için bir tamsayı etiketi olarak. Eğitim sırasında, öğrenmeyi taze tutmak için veri sırası her dönemin başında karıştırıldı ve görüntüleri verimli bir şekilde yüklemek için TensorFlow'un işlem hattıyla paralel işleme kullandık. Bu şekilde, ağ her zaman kullanıma hazır verilere sahip oldu ve eğitim sorunsuz bir şekilde gerçekleşti.

4.6 Veri Büyütme

Özellikle BreakHis gibi sınırlı bir veri setiyle çalıştığımız için modelin çeşitli görüntüleri işleyebildiğinden emin olmak çok önemliydi. Bu nedenle, temelde küçük değişikliklerle mevcut görüntülerin yeni sürümlerini oluşturarak eğitim setini “büyütmenin” bir yolu olan veri büyütme üzerine çok düşündük.

Bu büyütme eğitimi sırasında anında gerçekleştirilmiş, böylece her parti hem orijinal hem de büyütülmüş örnekler içermiştir, bu da aşırı uyumu önlemeye yardımcı olmuş ve modelin genellemesini geliştirmiştir. Tüm bu yeni görüntüleri önceden oluşturmamak. Bunun yerine, büyütme işlemi anında yapıldı: her eğitim grubu hem orijinal hem de değiştirilmiş görüntüleri içeriyordu. Bu karışım aşırı uyumu önlemeye gerçekten yardımcı oldu ve nispeten az miktarda veriyle bile modellerimizi daha güvenilir hale getirdi. Sonuç olarak, bu teknikler ağlara çok çeşitli görsel senaryolardan öğrenme şansı verdi ve sonuçların iyileştirilmesine yardımcı oldu. Hızlı bir genel bakış için Tablo 4.2, güçlendirme sürecimizin bir parçası olan tüm dönüşümleri listelemektedir.


Tablo 4.2. Veri artırmada kullanılan dönüşümler

Dönüşüm	Parametre/Değer
Resize	224 × 224 pixels
Normalize	[0, 1]
Rotation	0°, 90°, 180°, 270°
Random Horizontal Flip	True
Random Brightness	±0.2
Random Contrast	0.8 – 1.2
Shear (horizontal only)	-0.2 to 0.2

Tablo 4.3. Breakhis veri setindeki görüntülerin büyütme sonrası kanser kategorilerine göre bölünmesi

Types	Sub-Types	Augmented Training Images	Augmented Testing Images	Total After Augmentation
Benign	A	1996	499	2495
	F	1996	499	2495
	PT	1996	499	2495
	TA	1996	499	2495
	DC	1996	499	2495
	LC	1996	499	2495
Malignant	MC	1996	499	2495
	PC	1996	499	2495
Total		15,968	3,992	19,960

Aşağıdaki Şekil 4.10'de 90° ve 180° döndürme ve çevirme yoluyla veri artırma örnekleri gösterilmektedir.



Şekil 4.10: Veri artırımının gösterimi

4.7 Transfer Öğrenimi

Transfer öğrenmesi, derin öğrenmede bir modelin büyük, genel amaçlı bir veri kümesi üzerinde eğitilmesinden elde edilen bilgiden yararlanan ve bunu farklı ancak ilgili bir göreve uygulayan güçlü bir tekniktir. Bu çalışmada, özellikle BreakHis veri setinin sınırlı boyutu ve alana özgü yapısı göz önüne alındığında, meme kanseri sınıflandırma modellerinin performansını ve yakınsama hızını artırmak için transfer öğrenimi kullanılmıştır. Transfer öğrenmenin arkasındaki temel fikir, binlerce kategoride milyonlarca doğal görüntü içeren ImageNet gibi devasa veri kümeleri üzerinde önceden eğitilmiş konvolüsyonel sinir ağı mimarilerini kullanmaktır. Bu ön eğitilmiş modeller, ilk katmanlarında kenarlar, dokular ve şekiller gibi genel özellik temsillerini öğrenir; bunlar genellikle histopatolojik görüntü analizi de dahil olmak üzere çok çeşitli görsel tanıma problemleriyle ilgilidir ve bunlara aktarılabilir.

DeneySEL iş akışında, seçilen tüm mimariler ResNet152V2, SE-ResNet152V2, CBAM-ResNet152V2, MobileNetV2, CBAM-MobileNetV2 ve SE-MobileNetV2, ImageNet veri kümesi üzerinde önceden eğitilmiş ağırlıklarla başlatılmıştır. Her modelin en üst sınıflandırma katmanları, BreakHis'te bulunan sekiz meme kanseri alt türünü ayırt etmek için uygun olan yeni, göreve özgü tam bağlı katmanlarla değiştirildi.

İlk eğitim aşamasında, önceden eğitilmiş her bir konvolüsyonel omurganın ilk katmanları donduruldu, yani ağırlıkları değişmeden kaldı ve yalnızca yeni eklenen üst katmanlar (sınıflandırma görevine özgü) BreakHis veri kümesi üzerinde eğitildi. Bu, modellerin büyük ölçekli ImageNet veri kümesinden elde edilen zengin, düşük seviyeli özellikleri korumasına ve sınıflandırıcıyı belirli histopatolojik kategorilere hızla uyarlamasına olanak sağlamıştır.

Üst katmanların eğitildiği birkaç epoktan sonra, bir ince ayar aşaması başlatılmıştır. Bu aşamada, hem önceden dondurulmuş katmanlar hem de yeni eklenen katmanlar dahil olmak üzere tüm ağı

dondurulmamış ve daha düşük bir öğrenme oranı kullanılarak hedef veri kümesi üzerinde yeniden eğitilmiştir. Bu seçici ince ayar, modelin daha derin özellik temsillerini meme kanseri histopatoloji görüntülerinin benzersiz özelliklerine göre kademeli olarak ayarlamasını ve böylece sınıflandırma doğruluğunu ve model genellemesini en üst düzeye çıkarmasını sağlamıştır.

Bu çalışmada, transfer öğreniminin gerçekten önemli bir fark yarattığı gözlemlendi. Modelleri sıfırdan oluşturmak yerine, büyük görüntü veri kümeleri üzerinde önceden eğitilmiş ağlardan yararlanıldı. Bu yaklaşım, modellerin faydalı kalıpları daha hızlı keşfetmesini sağladı ve genellikle eğitim verilerini “ezberlemek” olarak bilinen ve aşırı öğrenme (overfitting) sorununa yol açan durumun önüne geçilmesine yardımcı oldu.

Ancak, grafikler incelendiğinde, transfer öğrenimi kullanılsa bile modellerin yine de aşırı öğrenme eğilimi gösterdiği görüldü. Yani modeller, bazen eğitim verilerine fazla uyum sağladı ve yeni veriler üzerinde istenilen performansı göstermekte zorlandı.

Bu aşırı öğrenme durumunu azaltmak amacıyla veri artırımı teknikleri uygulandı. Eğitim verilerine çeşitli rastgele dönüşümler (örneğin yatay çevirme, döndürme, parlaklık ve kontrast ayarlamaları) eklenerek modelin yalnızca belirli görüntüleri ezberlemesi yerine daha genelleştirilebilir özellikler öğrenmesi sağlandı. Bu yöntem, aşırı öğrenmenin etkisini önemli ölçüde azalttı ve sonuçların iyileşmesine katkı sağladı.

Bu sayede, modeller başka veri kümelerinde öğrendikleri özellik bilgisini kullanarak, çoğu açık veri kümesine göre daha az görüntü içeren BreakHis veri kümesinde daha iyi performans gösterdi. Sonuç olarak, modellerimiz farklı meme kanseri türlerini sınıflandırmada daha yüksek doğruluk elde etti ve öğrenme süreci çok daha verimli hâle geldi.

4.8 Model Mimarileri

Bu bölümde, birden fazla meme kanseri sınıfını belirlemek için kullandığımız temel derin öğrenme modelleri açıklanmaktadır. Her bir ağı seçtik çünkü güçlü özellik algılama, hafif ve hızlı olma veya yerleşik dikkat mekanizmalarına sahip olma gibi bazı özel avantajları vardı. Aşağıda, her modeli ve dikkatle geliştirilmiş versiyonlarını kısaca açıklıyoruz.

4.8.1 ResNet152V2

ResNet152V2, “kısayol bağlantıları” olarak adlandırılan bağlantılara dayanan derin bir sinir ağıdır. Bu kısayollar, bilginin birçok katman arasında kolayca akmasına yardımcı olarak yol boyunca önemli sinyalleri kaybetmeden derin modelleri eğitmeyi mümkün kılar. Bu mimari, tıbbi görüntüleme de dahil olmak üzere çeşitli görüntü görevlerindeki başarısıyla bilinmektedir (He, 2016). ResNet152V2 mimarisi, önceden eğitilmiş ImageNet ağırlıkları ile Keras derin öğrenme kütüphanesi kullanılarak uygulanmıştır. Model, ResNet152V2 temel ağının üst sınıflandırma katmanı olmadan yüklenmesiyle oluşturulmuştur (`include_top=False`). İlk katmanlar ImageNet'ten öğrenilen genel özellik temsillerini koruması ve aşırı öğrenmenin önlenmesi amacıyla dondurulması için bu katmanların eğitim parametresinin manuel olarak False olarak ayarlanması gerekir. Bu işlem gerçekleştirilirse, kalan katmanlar meme kanseri veri kümesinin özel özelliklerine uyum sağlaması için eğitilebilir olarak bırakılır. Aksi takdirde, modelin tüm katmanları BreakHis veri seti üzerinde yeniden eğitilmiş olur.

Temel modelden sonra, bir Global Ortalama Havuzlama katmanı, aşırı uyumu azaltmak için iki Dropout katmanı, 256 nöronlu dense katman ve ReLU aktivasyonlu yoğun bir katman ve son olarak hedef sınıfların sayısı ile eşleşen bir softmax çıktı katmanından oluşan özel bir sınıflandırma başlığı eklenmiştir. Model, Adam optimizier kullanılarak derlenmiş ve sınıf dengesizliğini gidermek için dengeli bir sınıf ağırlıklandırma şeması ile eğitilmiştir. Model genellemesini ve

sağlamlığını geliştirmek için veri büyütme ve katmanlı veri bölme uygulanmıştır.

4.8.2 SE-ResNet152V2

ResNet152V2'yi bir adım öteye taşımak için, “Sıkıştırma ve Uyarma” (Squeeze-and-Excitation, SE) bloklarını içeren SE-ResNet152V2 modeli kullanıldı. Bu bloklar, ağın en önemli özellik kanallarını adaptif olarak vurgulamasına olanak tanıyarak, patoloji çalışmalarında son derece kritik olan görüntüler arasındaki ince farklılıkları bile algılamasına yardımcı olur (Hu ve ark., 2018b).

SE-ResNet152V2 modeli, Squeeze-and-Excitation (SE) bloklarının ResNet152V2 mimarisine entegre edilmesiyle oluşturulmuştur. Uygulamada, küresel havuzlama ve sınıflandırma katmanlarından önce, ResNet152V2 temel ağının çıktısına özel bir SE bloğu uygulanmıştır. Bu SE bloğu, kanal bazlı bağımlılıkları açıkça modelleyerek özellik haritalarını uyarlamalı şekilde yeniden kalibre eder ve ağın en bilgilendirici özellikleri vurgulamasını sağlar.

Standart modelde olduğu gibi, omurganın ilk 100 katmanı, ImageNet'ten öğrenilen genel özellik temsillerini korumak için dondurulmuştur. Ancak, bu katmanların kodda açıkça dondurulmaması durumunda, tüm ağ tüm katmanlar dahil BreakHis veri seti üzerinde yeniden eğitilir ve bu da fiilen tam bir fine-tuning işlemi anlamına gelir. Bu nedenle, tüm katmanların yeniden eğitilmesi istenmiyorsa, katmanların dondurulması işlemi manuel olarak gerçekleştirilmelidir.

Modelin sonuna, küresel ortalama havuzlama, dropout, yoğun bir katman ve bir softmax çıktısından oluşan özel bir sınıflandırma başlığı eklenmiştir. Bu yaklaşım, histopatolojik görüntülerdeki ince farklılıkları ayırt etmek için kritik olan ilgili görüntü özelliklerine modelin duyarlılığını artırır.

4.8.3 CBAM-ResNet152V2

CBAM-ResNet152V2, CBAM (Evrişimsel Blok Dikkat Modülü) ekleyerek normal ResNet'in ötesine geçer. Bu modül, ağın hem hangi kanalların önemli olduğuna hem de görüntünün neresine

dikkat etmesi gerektiğine odaklanmasına yardımcı olarak anlamlı bölgeleri bulma ve arka plan gürültüsünü göz ardı etme yeteneğini geliştirir (Woo ve ark., 2018b). CBAM-ResNet152V2 modeli, ResNet152V2 omurgasına bir Evrimsel Blok Dikkat Modülü (CBAM) yerleştirilerek uygulanmıştır. Bu uygulamada, özel cbam_block, ResNet152V2 temel modelinin çıktı özellik haritalarına, sınıflandırma kafasından önce uygulanmıştır. CBAM bloğu, kanal ve uzamsal dikkat mekanizmalarını sırayla uygulayarak modelin yalnızca en önemli özellik kanallarına değil, aynı zamanda görüntüler içindeki en ilgili uzamsal bölgelere de odaklanmasını sağlar. Bu, ağırlık alakasız arka plan bilgilerini bastırırken tanısılabilir olarak önemli alanları vurgulama yeteneğini geliştirir. Temel modelin ilk 100 katmanı dondurulmuş ve çıktıyı daha da rafine etmek için sınıflandırma kafasında ek yoğun ve bırakma katmanları kullanılmıştır. Bu yaklaşım, modelin karmaşık histopatolojik görüntülerdeki ince desenleri doğru bir şekilde tespit etme yeteneğini güçlendirmektedir.

4.8.4 MobileNetV2

MobileNetV2 tamamen hafif ve verimli olmakla ilgilidir. Derinlemesine ayrılabilir konvolüsyonlar adı verilen görüntü verilerini işlemenin benzersiz bir yolunu ve ters çevrilmiş artıklar adı verilen bir tasarım kullanır. Bu tercihler, modeli hızlı ve bellek dostu tutarak bilgi işlem gücünün sınırlı olduğu durumlar için uygun hale getirir (Sandler ve ark., 2018). MobileNetV2 modeli, önceden eğitilmiş ImageNet ağırlıkları ile Keras kütüphanesi kullanılarak uygulanmıştır. Omurga ağı, hedef göreve özel uyarlamaya izin vermek için üst sınıflandırma katmanları olmadan yüklenmiştir (include_top=False). Öğrenme, transfer ve esneklik arasında denge kurmak için MobileNetV2 temel seviyesindeki varsayılan katman sayısını kullandık., kalan katmanlar ise alana özgü özelliklere uyum sağlamak için eğitilebilir bırakılmıştır. Temel modelin ardından, Global Ortalama Havuzlama katmanı, düzenlilik için Dropout katmanları, 256 birim ve ReLU

aktivasyonuna sahip yoğun bir katman ve sınıf olasılıklarını tahmin etmek için bir softmax çıkış katmanından oluşan hafif bir sınıflandırma başlığı eklenmiştir. Model Adam ile optimize edilmiş, sınıf dengesizliğini gidermek için sınıf ağırlıkları kullanılarak eğitilmiş ve sağlamlığı sağlamak için tabakalı bölünmelerle değerlendirilmiştir. Bu kurulum, düşük hesaplama maliyetiyle yüksek doğruluk elde etmek için MobileNetV2'nin verimli mimarisinden yararlanır ve bu da onu sınırlı kaynaklara sahip ortamlar için uygun hale getirir.

4.8.5 CBAM-MobileNetV2

MobileNetV2'yi güçlendirmek için CBAM modülünü ekleyerek modelin hem dikkat hem de verimliliğin avantajlarını birleştirmesini sağladık. Bu, çok ağır veya yavaş olmadan önemli özelliklere daha iyi odaklanabileceği anlamına geliyor. CBAM-MobileNetV2 modeli, Evrimsel Blok Dikkat Modülü'nün (CBAM) MobileNetV2 omurgasına entegre edilmesiyle oluşturulmuştur. Bu uygulamada, orijinal MobileNetV2 modeliyle aynı yapı kullanılmış, ancak sınıflandırma kafasından önce MobileNetV2 tarafından çıkarılan özellik haritalarına özel bir CBAM bloğu uygulanmıştır. Bu dikkat modülü, kanal ve uzamsal dikkati sırayla uygulayarak ağın, MobileNetV2'nin hafif ve verimli özelliklerini korurken giriş görüntülerindeki hem en alakalı özelliklere hem de uzamsal konumlara odaklanmasını sağlar. Katman dondurma, düzenleme ve özel yoğun kafa dahil olmak üzere mimarinin geri kalanı standart MobileNetV2 uygulamasıyla aynı kalarak performans ve hesaplama verimliliği arasında bir denge sağlar.

4.8.6 SE-MobileNetV2

SE-MobileNetV2, SE bloklarını MobileNetV2 mimarisine getirir. Bu ekleme, ağın ince desenleri daha iyi algılamasını ve patoloji görüntülerinde tanısal açıdan önemli ayrıntılara odaklanmasını sağlar.

Tüm modeller TensorFlow ve Keras kullanılarak uygulandı ve başlangıç noktası olarak ImageNet'ten önceden eğitilmiş ağırlıklar kullanıldı. Daha önce açıkladığımız süreci izleyerek, son katmanları BreakHis'te bulunan sekiz kategoriye uygun yeni katmanlarla değiştirdik.

SE-MobileNetV2 modeli, Squeeze-and-Excitation (SE) bloklarını MobileNetV2 omurgasına dahil ederek uygulandı. Bu yaklaşımda, SE bloğu, sınıflandırma başlığından önce MobileNetV2 tarafından üretilen özellik haritalarına eklendi. Bu blok, kanal bazında özellik yanıtlarını uyarlanabilir bir şekilde yeniden kalibre ederek ağın patoloji görüntülerinde tanıya ilişkin özellikleri daha iyi vurgulamasına olanak tanır. Diğer modellerde olduğu gibi, Öğrenme, transfer ve esneklik arasında denge kurmak için Se-MobileNetV2 temel seviyesindeki varsayılan katman sayısını kullandık., önceden eğitilmiş ImageNet özelliklerinden yararlanmak için donduruldu ve son sınıflandırma katmanları, sekiz sınıflı BreakHis veri setine uyarlanmış yeni bir başlıkla değiştirildi. Düzenleme ve sınıf dengeleme dahil olmak üzere geri kalan eğitim ve değerlendirme süreci, daha önce açıklanan stratejiyle aynıdır.

4.9 Eğitim Metodolojisi

Tüm bu modelleri eğitme yöntemimiz, hem adil karşılaştırma hem de güçlü sonuçlar elde etmek için tasarlandı. Her mimarinin adil bir şekilde karşılaştırılmasını sağlamak için, hiperparametreleri (öğrenme oranı ve parti boyutu gibi) tutarlı tuttuk. Bu seçimler, doğrulama seti geri bildirimlerine göre ayarlandı.

Optimizasyon için, öğrenme oranını otomatik olarak uyarladığı ve seyrek gradyanlarla iyi çalıştığı için Adam algoritmasını kullandık. İlk öğrenme oranı 0,0001 olarak ayarlandı, bu da hızlı öğrenme ve eğitim istikrarı arasında iyi bir denge sağladı.

Takılmayı veya duraklamayı önlemek için ReduceLROnPlateau adlı bir öğrenme oranı planlayıcısı kullandık. Bu araç, doğrulama kaybı iyileşmeyi durdurduğunda öğrenme oranını düşürerek modele ağırlıklarının ince ayar yapma şansı verir. Bu tür uyarlanabilir öğrenme oranı yöntemleri, daha iyi model performansı elde etmek için yaygın olarak kullanılır.

Her model, bir seferde 32 görüntüden oluşan mini gruplar kullanılarak 50 tur boyunca eğitildi. Bu grup boyutu, donanımım ve veri kümesi boyutlarımızla iyi uyum sağladı ve belleği aşırı yüklemekten istikrarlı güncellemeler sağladı. Erken durdurma da uygulandı: Doğrulama kaybı birkaç tur boyunca iyileşmezse, aşırı uyumlanmayı önlemek için eğitim erken durduruldu.

Öğrenmeyi daha sağlam hale getirmek için, her turun başında görüntü verilerini karıştırdık ve TensorFlow'un boru hattıyla paralel veri yükleme kullandık. Bu şekilde, GPU her zaman verilere hazır ve yavaşlamalar önlendi.

Model kontrol noktaları, en iyi doğrulama doğruluğuna sahip sürümü otomatik olarak kaydetmek üzere ayarlandı. Tüm eğitim tamamlandıktan sonra, her modeli ayrılmış test setinde çalıştırdık ve doğruluk, hassasiyet, geri çağırma, F1 puanı ve karışıklık matrisleri gibi metrikleri hesapladık. Bu yaklaşım, her ağın performansını net ve eksiksiz bir şekilde görmemi sağladı.

Dinamik öğrenme oranları, düzenleme ve verimli veri boru hatları kullanılarak eğitim hem hızlı hem de güvenilir oldu. Ayrıca, farklı mimarileri mümkün olduğunca adil bir şekilde karşılaştırmamızı sağladı.

Tablo 4.4. Eğitim metodolojisinin özellikleri

Mülk	Değer
Initial learning rate	1e-4 (0.0001)
Learn Rate Schedule	ReduceLROnPlateau (dynamic adjustment)
Optimizer	adam
Epoch	50
Mini Batch Size	32

4.10 Değerlendirme Metrikleri

Karışıklık matrisi, çoklu sınıflandırıcının performansını ölçmek için mükemmel bir araçtır. Aşağıdaki Tablo 4.5, çoklu sınıflandırma için karışıklık matrislerini ve deneyde kullanılan değerlendirme matrislerini göstermektedir.

- True Positive (TP): Gözlem pozitif ve pozitif olacağı tahmin edilmektedir.
- False Negative (FN): Gözlem olumlu ancak tahmin edilen olumsuz.
- True Negative (TN): Gözlem negatiftir ve negatif olacağı tahmin edilmektedir.
- False Positive (FP): Gözlem negatif ancak tahmin pozitif.

Tablo 4.5. Değerlendirme matrisleri

Değerlendirme ölçütleri	Formül
	$TP + TN$
Accuracy	$\frac{TP + TN}{TP + FP + TN + FN}$
Precision	$\frac{TP}{TP + FP}$
Positive Predictive Value	$\frac{TP}{TP + FP}$
Sensitivity (Recall) True Positive Rate	$\frac{TP}{TP + FN}$
Specificity	$\frac{TN}{FP + TN}$
True Negative Rate	$\frac{TN}{FP + TN}$
F1 Score	$2 * Sensitivity * Precision$
	$\frac{Sensitivity + Precision}{2}$

5 DENEY VE SONUÇLAR

5.1 Deneysel

Bu tezin deneysel kısmı, histopatolojik görüntülerden çok sınıflı meme kanseri tahmini için derin öğrenme mimarileri oluşturmak, dağıtmak ve değerlendirmek için uygulanan sistematik yöntemi açıklamaya ve gerekçelendirmeye adanmıştır. Bu bölümde, uygulanan metodolojiler, kullanılan setler, kullanılan ön işleme prosedürleri, uygulanan model yapıları, modellerin eğitilme prosedürleri ve araştırma sürecinde kullanılan değerlendirme şemaları ayrıntılı olarak açıklanmaktadır.

İlk deneysel yöntem, veri setinin hazırlanması ve seçilmesini içeriyordu. BreakHis veri setinden alınan meme dokusunun yüksek çözünürlüklü histopatolojik görüntüleri, yüksek değişkenlik ve bilimsel güvenilirlik sergiledikleri için kullanılmıştır. Görüntüler, patolojik alt tiplerine göre sınıflandırılmış ve modeli eğitmek ve test etmek için sağlam ve karakteristik bir örneklem elde etmek amacıyla çoklu büyütme seviyeleri (40X, 100X, 200X ve 400X) kullanılmıştır.

Giriş görüntülerinin kalitesini ve tutarlılığını sağlamak için veri hazırlama ve ön işleme çok önemliydi. Her görüntü standartlaştırıldı, uygun boyutlara yeniden boyutlandırıldı ve konvolüsyonel sinir ağı modellerinin giriş gereksinimlerini karşılamak için normalleştirildi. Eğitim verilerinin değişkenliğini artırmak, aşırı uyumu önlemek ve modellerin genelleme gücünü artırmak için veri artırma işlemleri de gerçekleştirildi. Bu işlemler, modellerin performansı üzerindeki gerçek etkiyi doğru bir şekilde ölçmek için artırma deneyleri ile ve artırma deneyleri olmadan rastgele döndürme ve çevirme işlemlerini içeriyordu.

Bu araştırma çalışmasında, ResNet152V2, SE-ResNet152V2, CBAM-ResNet152V2, MobileNetV2, CBAM-MobileNetV2 ve SE-MobileNetV2 gibi birkaç son teknoloji derin öğrenme

yapısı denendi. Her ağ, performanslarını etkili bir şekilde değerlendirmek için dikkat ve veri artırma ile ve bunlar olmadan denendi. Yakınsama sürecini hızlandırmak ve sınıflandırıcının doğruluğunu artırmak için, önceden eğitilmiş ağırlıklarla modeller başlatıldı ve ardından meme kanseri veritabanında ince ayarları yapıldı. Veriler, tüm alt kümelerde sınıf dağılımını korumak için tabakalı bölünme ile doğrulama ve eğitim amaçları için ayrı doğrulama ve eğitim kümelerine ayrıldı. Model, öğrenme hızı, parti boyutu ve düzenleme tekniğinin hiperparametre ayarlaması ile eğitildi. Erken durdurma, öğrenme hızı azaltma ve model kontrol noktalarının kaydedilmesi ile geri aramalar, maksimum performans elde etmek ve aşırı uyumu önlemek amacıyla uygulandı.

Modellerin performansı, doğruluk, kesinlik, geri çağırma, F1 puanı ve karışıklık matrisleri gibi çeşitli ölçütler kullanılarak kapsamlı bir şekilde değerlendirildi. Modellerin farklı ölçütleri, çeşitli histopatolojik alt tipleri ayırt etmede modellerin benzersiz güçlü ve zayıf yönlerini ortaya çıkardı. Sınıflandırma çıktıları için artırma ve dikkat mekanizmalarının etkilerini göstermek amacıyla karşılaştırma deneyleri gerçekleştirildi.

5.2 ResNet152V2

ResNet152V2 modelinin gücünü ve genelleme potansiyelini de geliştirmek için, eğitim sırasında en son teknolojiye sahip veri artırma stratejileri kullanıldı. Genişletmenin iki amacı vardı: ilk olarak, rastgele geometrik ve fotometrik dönüşümler uygulayarak eğitim örneklerinin çeşitliliğini artırdı; ikinci ve en önemlisi, veri setinin dengelenmesine önemli ölçüde yardımcı oldu. Özellikle, sınıf dengesizliğini etkili bir şekilde aşmak ve öğrenme sürecinde olası önyargıları önlemek için her sınıfta aynı sayıda görüntü olması gerekliliğini karşılamak üzere veri genişletme uygulandı.

Daha az temsil edilen sınıflar için sentetik olarak yeni örnekler oluşturularak, ağa daha eksiksiz ve dengeli bir özellik dağılımı sağlandı. Bu yaklaşım, belirli alt tiplerinin veri setinde daha az sıklıkla

görüldüğü meme kanseri histopatolojisi durumunda özellikle yararlı oldu. Dengeleme, her sınıfın tüm eğitim setine eşit katkı sağlamasını garanti etti ve buna bağlı olarak daha adil bir öğrenme ve daha adil bir değerlendirme sağladı.

Veri artırımı ile ResNet152V2'nin performansı Tablo 5.1'de verilmiştir. Ağ, eğitim ve doğrulama süreçlerinde sırasıyla %97.79 ve %95.74 gibi yüksek bir doğruluk oranına ulaşarak, ayırt edici bilgileri öğrenme ve görülmemiş örnekleri iyi bir şekilde genelleme konusunda güçlü kapasitesini göstermiştir. Bu değerler, güçlü ResNet152V2 mimarisinin ve dengeli artırmanın akıllı uygulamasının katkısını göstermektedir.

Öğrenme süreci, Şekil 5.1'de sonraki dönemlere ait kayıp ve doğruluk eğrileri olarak grafiksel olarak gösterilmiştir. Eğitim ve doğrulama miktarlarının düzgün, giderek istikrarlı seyri, düzenli öğrenmeyi ve önemli bir aşırı uyumun olmadığını göstermektedir. Yakınsama modeli de, modelin genişletilmiş, dengeli veri setinden faydalandığını ve bunun sonucunda çeşitli meme kanseri türleri için optimize edilmiş performans elde ettiğini kanıtlamaktadır. Sınıf tahmin sonuçlarının daha ayrıntılı analizi, Şekil 5.1'de test örneği için sunulan karışıklık figüründe verilmiştir. Şekil, veri artırımı ile ResNet152V2'nin aslında sınıfların çoğunda güçlü geri çağırma ve hassasiyet elde ettiğini ortaya koymaktadır. Küçük hatalar genellikle sadece morfolojik özellikleri son derece benzer sınıflar arasında gözlemlenirken, şekil genel olarak modelin güvenilirliğini ve ayrımcılığını doğrulamaktadır.


Son olarak, özellikle veri setini dengeleme görevi için veri artırma uygulaması, ResNet152V2 modelinin performansını önemli ölçüde artırmıştır. Tablo 5.1'de sunulan ve Şekil 5.1 ve 5.2'de gösterilen sonuçlar, meme kanseri sınıflandırmasının alt tipleri için sağlam, doğru ve tarafsız otomatik sistemlerin geliştirilmesinde bu yaklaşımın etkinliğini doğrulamaktadır.

ResNet152V2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi kullanılarak analiz edilmiştir (sırasıyla Şekil 5.1 ve 5.2). Doğruluk eğrisi (Şekil 5.1), hem eğitim hem de doğrulama doğruluğunda istikrarlı bir iyileşme göstermektedir. Model, %97,79 genel doğruluk ve %95,74 genel test doğruluğu elde etmiştir. Eğitim ve doğrulama eğrileri arasındaki küçük fark, görülmemiş verilere iyi bir genelleme yapıldığını göstermektedir. Karışıklık matrisi (Şekil 5.2), en yüksek sınıflandırma performansının Müsinöz Karsinom ve Filodom Tümör sınıfları için elde edildiğini, Duktus Karsinom ve Tübüler Adenom sınıflarının ise en düşük performansı kaydettiğini göstermektedir. Bu sonuçlar, ResNet152V2'nin histopatolojik görüntülerden ayırt edici özellikleri çıkarma konusundaki güçlü yeteneğini göstermekte ve model sağlamlığını ve genel sınıflandırma doğruluğunu iyileştirmede veri artırmanın rolünü vurgulamaktadır.


Tablo 5.1. ResNet152V2 için performans istatistikleri

Eğitilmiş ResNet152V2'nin performansının karşılaştırılması

Overall Test Accuracy	95.74%
------------------------------	--------



Şekil 5.1. ResNet152V2 için doğruluk ve kayıp grafikleri



Şekil 5.2. ResNet152V2 için karışıklık matrisleri

5.3 ResNet152V2, artırma olmadan

ResNet152V2 mimarisinin dışsal iyileştirmeler olmadan içsel yeteneğini değerlendirmek için, orijinal, artırılmamış veri kümesi kullanılarak bir dizi deney gerçekleştirildi. Bu ortamda, model, yapay dengeleme veya veri genişletme yapılmaksızın, meme kanseri histopatolojik görüntülerinin doğal olarak dengesiz dağılımı üzerinde eğitildi. Bu yaklaşım, modelin temel performansının net bir şekilde değerlendirilmesini sağlar ve veri artırmanın faydalarının ölçülebileceği bir referans noktası sunar.

Eğitim sırasında, görüntüler 224×224 piksel çözünürlüğe standartlaştırıldı ve modelin giriş gereksinimleriyle uyumluluğu sağlamak için normalleştirildi. Eğitim protokolü, Adam optimizör, 1e-4 öğrenme oranı ve 32'lik parti boyutu kullanılarak, artırılmış deneylerin protokolünü yansıtıyordu. Sınıf temsiliyi korumak için tabakalı bölme uygulandı ve kararlılığı artırmak ve aşırı

uyumu önlemek için erken durdurma, öğrenme oranı azaltma ve kontrol noktası geri aramaları dahil edildi.

Artırma yapılmayan ResNet152V2'nin sonuçları Tablo 5.2'de özetlenmiştir. Model, %98.97'lik bir eğitim doğruluğu ve %86.35'lik bir test doğruluğu elde etti. Bu sonuçlar saygıdeğer olmakla birlikte, dengeli artırma ile elde edilen sonuçlardan belirgin şekilde daha düşüktür. Veri artırmanın olmaması, sınıf içi değişkenliğe maruz kalmanın sınırlı olmasına ve sınıf dengesizliğinin daha belirgin bir etkiye sahip olmasına neden oldu, bu da modelin azınlık alt türlerine genelleme yapmasını zorlaştırdı.

Şekil 5.3, modelin öğrenme sürecine ilişkin grafiksel bir genel bakış sunmaktadır. Doğruluk ve kayıp eğrileri, artırılmış senaryoya kıyasla daha büyük dalgalanmalar ve daha yavaş bir yakınsama göstermektedir. Doğrulama performansı daha erken ve daha düşük bir değerde sabitlenmiştir, bu da modelin sınırlı ve dengesiz verilerden yeterince çeşitli özellikler çıkarmakta zorlandığını göstermektedir.

Şekil 5.4, artırılmamış bağlamda test kümesi için karışıklık matrisini göstermektedir. ResNet152V2, ana sınıfları ayırt etme konusunda makul bir yetenek sergilemiş olsa da, matris, özellikle yetersiz temsil edilen veya morfolojik olarak benzer alt tipler arasında yanlış sınıflandırma oranlarının arttığını göstermektedir. Bu gözlem, dengesiz veri kümesinin getirdiği sınırlamaları vurgulamakta ve sınıflandırma adaleti ve sağlamlığını iyileştirmede artırmanın önemini altını çizmektedir.

Veri artırımı yapılmayan ResNet152V2 ile yapılan deneyler, modelin sağlam temel yeteneklerini gösterirken, veri dengeleme ve artırımı yoluyla elde edilebilecek önemli iyileştirmeleri de ortaya koymaktadır. Tablo 5.2, Şekil 5.3 ve Şekil 5.4'te gösterilen karşılaştırmalı sonuçlar, karmaşık tıbbi


görüntü sınıflandırma görevlerinde optimum performans için gelişmiş ön işleme stratejilerinin gerekliliğini vurgulamaktadır.

Veri artırma yapılmadan ResNet152V2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi kullanılarak analiz edilmiştir (sırasıyla Şekil 5.3 ve 5.4). Doğruluk eğrisi (Şekil 5.3), eğitim doğruluğunun hızla yüksek bir seviyeye ulaştığını ve %98,97'lik bir genel doğruluk elde ettiğini gösterirken, doğrulama doğruluğu daha düşük bir değerde sabit kalarak %86,35'lik bir genel test doğruluğu ile sonuçlanmıştır. Bu fark, modelin eğitim setinde üstün performans gösterdiği ancak görülmemiş verilerde daha az etkili olduğu bir dereceye kadar aşırı uyumlanma olduğunu göstermektedir. Karışıklık matrisi (Şekil 5.4), en yüksek sınıflandırma performansının Adenoz ve Tübüler Adenom sınıfları için elde edildiğini, Lobüler Karsinom ve Filodom Tümör sınıflarının ise en düşük performansı kaydettiğini ortaya koymaktadır. Bu sonuçlar, ResNet152V2'nin güçlü özellik çıkarma yeteneklerine sahip olmasına rağmen, veri artırmanın olmaması, histopatolojik görüntülerde bulunan değişkenlik ve karmaşıklığı işleme yeteneğini sınırladığını göstermektedir.


Tablo 5.2. ResNet152V2 için büyütme olmadan performans istatistikleri

ResNet152V2'nin Güçlendirme Olmadan Eğitilmiş Performansının Karşılaştırılması

Overall Test Accuracy	86.35%
------------------------------	--------



Şekil 5.3. Güçlendirme olmadan ResNet152V2 için doğruluk ve kayıp grafikleri



Şekil 5.4. Güçlendirme olmadan ResNet152V2 için karışıklık matrisleri

5.4 CBAM-ResNet152V2

Meme kanseri sınıflandırması için derin konvolüsyonel sinir ağlarının temsil kapasitesini artırmak amacıyla, Convolutional Block Attention Module (CBAM) ResNet152V2 mimarisine entegre edildi. CBAM, hem kanal hem de uzamsal dikkat mekanizmaları sunarak ağın histopatolojik görüntülerdeki belirgin özelliklere ve bölgelere daha seçici bir şekilde odaklanmasını sağlar. Bu değişiklik, benzer doku türleri arasında genellikle ince, ayırt edici desenlerin fark yarattığı tıbbi görüntüleme bağlamında özellikle değerlidir.

CBAM-ResNet152V2 için deneysel kurulum, temel ResNet152V2'nin kurulumunu yansıtmaktadır. Her iki model de ImageNet ile önceden eğitilmiş ağırlıklar kullanılarak başlatılmış ve gelişmiş veri artırma yoluyla oluşturulan dengeli veri kümeleri üzerinde eğitilmiştir. İki modeli

karşılaştırarak, CBAM modülünün genel sınıflandırma performansına katkısını doğrudan değerlendirmek mümkündür.

CBAM-ResNet152V2 ile elde edilen sonuçlar Tablo 5.3'te ayrıntılı olarak verilmiştir. Model, %93.36'lık bir eğitim doğruluğu ve %90.38'lik bir test doğruluğu elde ederek, hem eğitim kararlılığı hem de test verilerine genelleme açısından temel modele göre belirgin iyileşmeler göstermiştir. CBAM'ın dahil edilmesi, modelin daha ilgili bağlamsal bilgileri yakalamasını sağlamış ve bu da çeşitli meme kanseri alt tipleri için daha yüksek tanıma oranlarına yol açmıştır.

Şekil 5.5, eğitim ve test sırasında doğruluk ve kayıp eğrilerini göstermektedir. Çizilen yörüngeler, doğrulama doğruluğunun tüm dönemler boyunca eğitim performansını yakından takip ettiği, düzgün ve istikrarlı bir yakınsama olduğunu ortaya koymaktadır. Bu davranış, modelin dikkat mekanizmaları ve dengeli verilerin birleşik etkilerinden yararlandığını ve bunun sonucunda sağlam bir öğrenme ve minimum aşırı uyum sağlandığını göstermektedir.

Modelin tahmin davranışının kapsamlı bir değerlendirmesi, Şekil 5.6'da gösterilen karışıklık matrisi ile sağlanmaktadır. CBAM-ResNet152V2, çoğu kategoride üstün sınıflandırma performansı göstermiş ve neredeyse tüm alt tipler için yüksek hassasiyet ve geri çağırma oranları elde etmiştir. Yanlış sınıflandırmalar, özellikle ince farklılıklar gösteren alt tiplerde, temel modele kıyasla azalmıştır. Bu durum, dikkat modüllerinin modelin odağını her görüntünün içindeki kritik bölgelere yönlendirmedeki değerini doğrulamaktadır.


Genel olarak, CBAM modülünün ResNet152V2 omurgasına entegrasyonu, çok sınıflı sınıflandırma performansında dikkate değer bir iyileşme sağlamıştır. Tablo 5.3, Şekil 5.5 ve Şekil 5.6'da özetlendiği gibi, CBAM-ResNet152V2 modeli daha dikkatli ve ayırt edici bir yaklaşım

sunarak, otomatik meme kanseri tanı sistemlerinde gerçek dünya uygulamaları için güçlü bir aday olmaktadır.


CBAM-ResNet152V2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi (sırasıyla Şekil 5.5 ve 5.6) kullanılarak analiz edilmiştir. Doğruluk eğrisi (Şekil 5.5), eğitim süreci boyunca hem eğitim hem de doğrulama doğruluğunda istikrarlı bir iyileşme gösterir. Model, %93,36 genel doğruluk ve %90,38 genel test doğruluğu elde eder. Eğitim ve doğrulama eğrileri arasında bazı farklar olsa da, model makul bir genelleme yeteneği sergiler. Karışıklık matrisi (Şekil 5.6), en yüksek sınıflandırma performansının Müsinöz Karsinom ve Lobüler Karsinom sınıfları için elde edildiğini, Fibroadenom ve Duktus Karsinom sınıflarının ise en düşük performansı kaydettiğini göstermektedir. Bu sonuçlar, CBAM mekanizmasının modelin ilgili uzamsal ve kanal özelliklerine odaklanma yeteneğini artırmasına rağmen, sınıflandırma doğruluğunun belirli histopatolojik alt tipler arasındaki içsel karmaşıklık ve benzerlikten hala etkilenebileceğini göstermektedir.

Tablo 5.3. CBAM-ResNet152V2 için performans istatistikleri

CBAM-ResNet152V2'nin performans karşılaştırması	
Overall Test Accuracy	90.38%



Şekil 5.5. CBAM-ResNet152V2 için doğruluk ve kayıp grafikleri



Şekil 5.6. CBAM-ResNet152V2 için karışıklık matrisleri

5.5 CBAM-ResNet152V2 Augmentasyon Olmadan

Dikkat mekanizmasının tek başına doğrudan etkisini daha ayrıntılı olarak incelemek için, veri artırma yapılmadan CBAM-ResNet152V2 mimarisi kullanılarak ek deneyler gerçekleştirildi. Bu

senaryoda, model yalnızca orijinal, doğal olarak dengesiz histopatolojik görüntü seti üzerinde eğitildi. Bu yapılandırma, veriler değiştirilmeden ve dengesiz kaldığında CBAM modülünün modelin performansına nasıl katkıda bulunduğunu daha net bir şekilde anlamayı sağlar.

Eğitim süreci, önceki deneylerle tutarlı olarak, Adam optimizyer, $1e-4$ başlangıç öğrenme oranı ve 32'lik parti boyutu kullanılarak gerçekleştirildi. Giriş görüntüleri normalleştirildi ve 224×224 piksele yeniden boyutlandırıldı. Hem eğitim hem de doğrulama kümelerinde tüm sınıfların temsili dağılımlarını korumak için yine tabakalı bölme kullanıldı. Erken durdurma, öğrenme oranı azaltma ve kontrol noktası belirleme gibi önemli geri aramalar da eğitim sürecini optimize etmek için uygulandı.

Artırma yapılmayan CBAM-ResNet152V2'nin performans istatistikleri Tablo 5.7'de verilmiştir. Model, %98.92 eğitim doğruluğu ve %87.32 test doğruluğu elde etmiştir. CBAM modülünün varlığı, önemli özelliklere odaklanma yeteneğini iyileştirerek hala belirgin faydalar sağlasa da, artırılmış ve dengeli verilerin eksikliği nedeniyle genel performans sınırlı kalmıştır. Model, azınlık ve morfolojik olarak benzer sınıfları ayırt etmede daha büyük zorluklarla karşılaştı; bu eğilim, temel ResNet152V2'de de gözlemlendi.

Eğitim sırasında modelin doğruluğu ve kaybının ilerleyişi Şekil 5.7'de gösterilmektedir. Veri artırımı ile elde edilen sonuçlarla karşılaştırıldığında, buradaki öğrenme eğrileri daha fazla dalgalanma ve biraz daha yavaş bir yakınsama göstermektedir. Bu davranış, modelin dengesiz bir veri kümesinden çeşitli ve temsil edici özellikleri çıkarmakta zorlandığını yansıtıyor ve tamamlayıcı bir strateji olarak veri artırmanın değerini vurguluyor.

Şekil 5.8, bu artırılmamış senaryoda CBAM-ResNet152V2 modelinin karışıklık matrisini göstermektedir. Dikkat mekanizması bazı yanlış sınıflandırmaları azaltmaya yardımcı oldu ve sınıf

bazında makul bir performans sağladı, ancak matris, özellikle verilerde yeterince temsil edilmeyen belirli alt türleri ayırt etmede devam eden zorlukları ortaya koymaktadır. Genel sınıflandırma sonuçları, artırma yapılmayan temel senaryoya göre iyileşmiş olsa da, veri dengeleme uygulandığında elde edilen seviyelere ulaşamamıştır.


Artırma yapılmayan CBAM-ResNet152V2 mimarisi, dikkat mekanizmalarının özellik ayrımını geliştirebileceğini, ancak tam potansiyellerinin veri artırma ve dengeleme teknikleriyle birleştirildiğinde en iyi şekilde gerçekleştirildiğini göstermektedir. Tablo 5.4, Şekil 5.7 ve Şekil 5.8, karmaşık tıbbi görüntü sınıflandırma görevlerinde veri çeşitliliği ve dengesinin önemini vurgulamaktadır.

Veri artırma yapılmayan CBAM-ResNet152V2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi (sırasıyla Şekil 5.7 ve 5.8) kullanılarak analiz edilmiştir. Doğruluk eğrisi (Şekil 5.7), eğitim doğruluğunun hızla yüksek bir seviyeye ulaştığını ve %98,92'lik bir genel doğruluk elde ettiğini gösterirken, doğrulama doğruluğu daha düşük bir değerde sabitlenerek %87,32'lik bir genel test doğruluğu ile sonuçlanmıştır. Eğitim ve doğrulama doğruluğu arasındaki bu fark, modelin eğitim verilerinde çok iyi performans gösterdiği ancak görülmemiş örneklerde daha az etkili olduğu bir aşırı uyum derecesine işaret etmektedir. Karışıklık matrisi (Şekil 5.8), en yüksek sınıflandırma performansının Adenozis ve Tübüler Adenom sınıfları için elde edildiğini, Phyllodes Tümörü ve Lobüler Karsinom sınıflarının ise en düşük performansı kaydettiğini göstermektedir. Bu sonuçlar, CBAM dikkat mekanizmasının özellik odaklanmasını artırırken, artırmanın olmaması modelin çeşitli histopatolojik görüntülere etkili bir şekilde genelleme yapma yeteneğini sınırladığını göstermektedir.


Tablo 5.4. CBAM-ResNet152V2 için artırma olmadan performans istatistikleri

CBAM-ResNet152V2'nin performans karşılaştırması

Overall Test Accuracy 87.32%



Şekil 5.7. CBAM-ResNet152V2 için artırma olmadan doğruluk ve kayıp grafikleri



Şekil 5.8. CBAM-ResNet152V2 için büyütme olmadan karışıklık matrisleri

5.6 SE-ResNet152V2

Squeeze-and-Excitation (SE) bloğu, derin öğrenmede güçlü bir dikkat mekanizması olarak ortaya çıkmış ve sinir ağlarının kanal bazında özellik tepkilerini dinamik olarak yeniden kalibre etmesini sağlamıştır. Bu çalışmada, SE bloğu ResNet152V2 omurgasına entegre edilerek meme kanseri histopatolojik görüntülerinin sınıflandırılması üzerindeki etkisi araştırılmıştır. SE-ResNet152V2 modeli, ağır görüntülerdeki önemli özelliklere daha etkili bir şekilde odaklanmasına yardımcı olurken, daha az yararlı ayrıntılara olan dikkati en aza indirmek için tasarlanmıştır. Bu ayarlama, modelin farklı sınıfları daha iyi ayırt etmesini sağlar.

Eğitim süreci için, SE-ResNet152V2'ye çeşitli artırılmış örnekler içeren dengeli bir veri kümesi sağlandı. Diğer modellerle karşılaştırmaların geçerli olmasını sağlamak için, görüntülerin ön işleme şekli, kullanılan optimizasyon ve öğrenme oranı ve parti boyutu seçimi dahil olmak üzere

tüm deneysel ayarları aynı tuttuk. SE bloğunun entegrasyonunun, modele histopatolojik görüntülerin karmaşık yapısı içinde sınıfına özgü ince özellikleri öğrenmede daha fazla uyarlanabilirlik sağlaması bekleniyordu.

SE-ResNet152V2'nin performans sonuçları Tablo 5.5'te verilmiştir. Model, %98.52'lik bir eğitim doğruluğu ve %97.04'lik bir test doğruluğu elde ederek, bu çalışmadaki hem temel hem de CBAM ile artırılmış varyantları geride bırakmıştır. Doğruluktaki bu önemli artış, SE bloğu tarafından sağlanan kanal bazlı yeniden kalibrasyonun gücünü göstermektedir ve modelin ayırt edici özellikleri daha etkili bir şekilde kullanmasına ve gürültüyü veya alakasız kalıpları azaltmasına olanak tanır.

Eğitim ve doğrulama doğruluğu ve kayıp eğrileri Şekil 5.9'da gösterilmektedir. Bu grafikler, eğitim dönemleri boyunca istikrarlı ve hızlı bir yakınsamayı yansıtmaktadır; her iki metrik de düzgün bir seyir ve minimum aşırı uyum sergilemektedir. Modelin, eğitim doğruluğu ile doğrulama doğruluğunu yakından takip etme yeteneği, sağlamlığını ve genelleme gücünü vurgulamaktadır; bu da SE dikkatinin ve dengeli artırmanın sinerjik etkilerine atfedilebilir.

Modelin tahminlerinin ayrıntılı bir analizi, Şekil 5.10'daki karışıklık matrisinde görselleştirilmiştir. SE-ResNet152V2, morfolojik olarak benzer kategoriler arasında bile alt tiplerin çoğunun doğru sınıflandırılması ve çok az sayıda yanlış sınıflandırma ile sınıf bazında olağanüstü bir performans sergilemiştir. Matris, özellikle meme kanseri alt tipi tanımlama gibi karmaşık çok sınıflı görevlerde SE ile artırılmış ağırların üstün ayırt edici kapasitesini daha da desteklemektedir.

Sonuç olarak, SE-ResNet152V2 bu araştırmada yeni bir performans ölçütü belirlemiş ve en yüksek genel doğruluk ve en sağlam sınıflandırma davranışını sergilemiştir. Tablo 5.5, Şekil 5.9 ve Şekil


5.10'da özetlenen sonuçlar, zorlu tıbbi görüntü analizi uygulamaları için derin konvolüsyonel omurgalara SE dikkat mekanizmalarının entegre edilmesinin avantajını açıkça göstermektedir.

SE-ResNet152V2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi (sırasıyla Şekil 5.9 ve 5.10) kullanılarak analiz edilmiştir. Doğruluk eğrisi (Şekil 5.9), hem eğitim hem de doğrulama doğruluğunda tutarlı ve istikrarlı bir artış gösterir. Model, %98,52 genel doğruluk ve %97,04 genel test doğruluğu elde etmiştir. Eğitim ve doğrulama eğrilerinin birbirine yakın olması, modelin görülmemiş verilere iyi bir şekilde genelleştirildiğini ve önemli ölçüde aşırı uyumlamadan kaçındığını göstermektedir. Karışıklık matrisi (Şekil 5.10), tüm sınıflarda güçlü bir sınıflandırma performansı sergilemektedir. En yüksek doğruluk Müsinöz Karsinomda gözlemlenirken, Duktus Karsinom en düşük göreceli performansı kaydetmiştir. Bu bulgular, ResNet152V2'nin derin mimarisini Squeeze-and-Excitation (SE) dikkat mekanizmasıyla birleştirmenin etkinliğini doğrulamaktadır. Bu, modelin histopatolojik görüntülerdeki en ilgili özelliklere odaklanmasını ve yüksek sınıflandırma doğruluğu elde etmesini sağlamaktadır.


Tablo 5.5. SE-ResNet152V2 için performans istatistikleri

SE-ResNet152V2'nin performans karşılaştırması

Overall Test Accuracy	97.04%
------------------------------	--------



Şekil 5.9. SE-ResNet152V2 için doğruluk ve kayıp grafikleri



Şekil 5.10. SE-ResNet152V2 için karışıklık matrisleri

5.7 SE-ResNet152V2 Augmentasyon Olmadan

Yapay veri genişletme olmadan SE-ResNet152V2 modelinin performansını değerlendirmek için, orijinal, genişletilmemiş veri kümesi kullanılarak ek deneyler gerçekleştirildi. Bu yaklaşım,

modelin doğal olarak dengesiz ve sınırlı eğitim verilerinden öğrenme konusundaki içsel yeteneğini doğrudan değerlendirir ve genişletilmiş senaryo ile adil bir karşılaştırma yapılmasını sağlar.

Eğitim protokolü, önceki deneylerdekiyle aynıydı ve tüm görüntüler 224×224 piksele yeniden boyutlandırıldı ve normalleştirildi. Model mimarisi, ResNet152V2 omurgasına SE bloğunu dahil etti ve özellik seçimi ve temsili geliştirmek için kanal bazlı dikkati kullandı. Adam optimizier, $1e-4$ öğrenme oranı, 32 parti boyutu ve tabakalı veri bölme, model performansını en üst düzeye çıkarmak için erken durdurma, öğrenme oranı planlama ve kontrol noktası ile birlikte tutarlı bir şekilde uygulandı.

Tablo 5.6, artırma yapılmadan SE-ResNet152V2 için temel performans ölçütlerini göstermektedir. Model, %98.72 eğitim doğruluğu ve %84.66 test doğruluğu elde etti. Bu sonuçlar sağlam olmakla birlikte SE bloğunun yararlı etkisini doğrulamasına rağmen, artırılmış ortamda elde edilen sonuçlardan daha düşük kalmaktadır. Performans düşüşü, öncelikle dengesiz verilerin doğasında var olan sınırlamalara atfedilebilir; bu sınırlamalar, özellikle azınlık sınıfları için eğitim örneklerinin çeşitliliğini ve temsil gücünü azaltmaktadır.

Şekil 5.11, öğrenme süreci boyunca hem eğitim hem de doğrulama kümeleri için doğruluk ve kayıp eğrilerini göstermektedir. Artırılmış senaryodan farklı olarak, buradaki eğriler daha belirgin dalgalanmalar ve daha yavaş bir yakınsama sergilemektedir, bu da sınıf dengesizliği ve sınırlı örnek değişkenliğinin yarattığı artan zorluğu yansıtmaktadır. Bu zorluklara rağmen, model nispeten istikrarlı bir öğrenme dinamiği sürdürmüştür, bu da SE bloğunun dengeleyici etkisinin bir kanıtıdır.

Şekil 5.12'de gösterilen karışıklık matrisi, modelin sınıf bazında tahmin performansına ilişkin daha fazla bilgi sağlar. SE-ResNet152V2, ana sınıflar için yüksek sınıflandırma doğruluğunu

koruyabilmiş olsa da, matris, yeterince temsil edilmeyen veya yakından ilişkili alt türler arasında daha yüksek yanlış sınıflandırma oranları olduğunu ortaya koymaktadır. Bu, adaleti artırmak ve tüm kategorilerde sağlam performans sağlamak için veri artırmanın önemini vurgulamaktadır.

Veri artırımı yapılmayan SE-ResNet152V2, kanal bazlı dikkat mekanizmasının da yardımıyla sağlam bir temel performans sergilemiştir, ancak veri çeşitliliğinin eksikliği nedeniyle tam potansiyelini ortaya koyamamıştır. Tablo 5.6, Şekil 5.11 ve Şekil 5.12'de ayrıntılı olarak gösterilen sonuçlar, dikkat mekanizmalarının entegrasyonunun tek başına karmaşık tıbbi görüntü sınıflandırma görevlerinde dengesiz veri kümelerinin yarattığı zorlukların üstesinden gelmek için yeterli olmadığını vurgulamaktadır.

Veri artırma yapılmayan SE-ResNet152V2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi kullanılarak analiz edilmiştir (sırasıyla Şekil 5.11 ve 5.12). Doğruluk eğrisi (Şekil 5.11), eğitim doğruluğunda hızlı bir artış olduğunu ve genel doğruluğun %98,72'ye ulaştığını gösterirken, doğrulama doğruluğu daha düşük bir seviyede sabitlenerek genel test doğruluğunun %84,66 olmasına neden olmuştur. Eğitim ve doğrulama doğruluğu arasındaki fark, modelin eğitim verilerinde çok iyi performans gösterdiği ancak görülmemiş verilerde genelleme yeteneğinin azaldığı için orta düzeyde bir aşırı uyum olduğunu göstermektedir. Karışıklık matrisi (Şekil 5.12), en yüksek sınıflandırma performansının Adenozis ve Tübüler Adenom sınıfları için elde edildiğini, Lobüler Karsinom ve Filodom Tümör sınıflarının ise en düşük performansı kaydettiğini ortaya koymaktadır. Bu bulgular, SE-ResNet152V2'nin güçlü özellik çıkarma ve dikkat mekanizmasından yararlanmasına rağmen, artırmanın olmaması nedeniyle karmaşık histopatolojik görüntü sınıflandırmasındaki değişkenliği ele alma yeteneğinin sınırlı olduğunu göstermektedir.


Tablo 5.6. SE-ResNet152V2 için güçlendirme olmadan performans istatistikleri

SE-ResNet152V2'nin performansının karşılaştırılması (artırma olmadan)

Overall Test Accuracy 84.66%



Şekil 5.11. SE-ResNet152V2 için büyütme olmadan doğruluk ve kayıp grafikleri



Şekil 5.12. SE-ResNet152V2 için karışıklık matrisleri güçlendirme olmadan

5.8 MobileNetV2

MobileNetV2, kaynak kısıtlı ortamlar ve hızlı çıkarım için tasarlanmış hafif ve verimli bir evrişimli sinir ağı mimarisidir, bu da onu büyük ölçekli biyomedikal görüntü analizi için güçlü bir aday haline getirir. Bu çalışmada, MobileNetV2 meme kanseri histopatolojik görüntülerinin çok sınıflı sınıflandırılması için kullanıldı, bu da daha derin ve daha karmaşık modellere göre etkinliğinin değerlendirilmesine olanak sağladı.

MobileNetV2 için deneysel kurulum, ResNet tabanlı mimarilere uygulananlarla aynı titiz protokolleri izlemiştir. Ağ, ImageNet ile önceden eğitilmiş ağırlıklarla başlatılmış ve BreakHis veri setinde bulunan sekiz meme kanseri alt tipine göre uyarlanmış tam bağlantılı katmanlarla değiştirilmiştir. Giriş görüntüleri, eğitimden önce 224×224 piksele yeniden boyutlandırılmış ve

normalleştirilmiştir. Veri seti, sınıf dengesizliğini gidermek ve model genellemesini geliştirmek için genişletilmiş ve dengelenmiştir.

MobileNetV2'nin performans istatistikleri Tablo 5.7'de özetlenmiştir. Model, %97.19 eğitim doğruluğu ve %96.79 test doğruluğu elde etmiştir. Model genel olarak iyi performans göstermiş olsa da, test doğruluğu daha derin ResNet152V2 varyantlarından biraz daha düşüktü, bu da model karmaşıklığı ve temsil kapasitesi arasındaki dengeleri yansıtıyordu. Bununla birlikte, MobileNetV2'nin verimliliği, hesaplama kaynakları veya çıkarım hızının sınırlayıcı faktörler olduğu senaryolar için onu çekici bir seçenek haline getirdi.

Eğitim ve doğrulama aşamaları için doğruluk ve kayıp eğrileri Şekil 5.13'te sunulmuştur. Eğriler, aşırı uyumun minimum belirtileriyle pürüzsüz, istikrarlı bir öğrenme dinamiği gösterir ve bu da etkili yakınsama ve model sağlamlığını gösterir. Bu sonuçlar, ağıın nispeten sığ derinliğine rağmen dengeli, genişletilmiş verilerden ayırt edici özellikleri öğrenme yeteneğini güçlendirir.

Modelin tahmin gücünün daha yakından incelenmesi, MobileNetV2 için karışıklık matrisini gösteren Şekil 5.14'te gösterilmektedir. Matris, bazı yanlış sınıflandırmaların devam etmesine rağmen, özellikle morfolojik olarak benzer alt tipler arasında, çoğu sınıfta güçlü performansı vurgulamaktadır. Genel olarak, sonuçlar MobileNetV2'nin verimli kaynak kullanımıyla sağlam sınıflandırma performansı elde edebildiğini doğrulamaktadır.


MobileNetV2, özellikle veri artırımı ile geliştirildiğinde, otomatik meme kanseri alt tipi sınıflandırması için hızlı ve etkili bir omurga olarak güçlü bir potansiyel sergilemiştir. Tablo 5.7, Şekil 5.13 ve Şekil 5.14'te gösterildiği gibi, model doğruluk ve hesaplama verimliliği arasında pratik bir denge sunarak, hız ve ölçeklenebilirliğin önemli olduğu gerçek dünya klinik uygulamaları için uygun hale gelmektedir.

MobileNetV2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi kullanılarak analiz edilmiştir (sırasıyla Şekil 5.13 ve 5.14). Doğruluk eğrisi (Şekil 5.13), hem eğitim hem de doğrulama doğruluğunda istikrarlı ve tutarlı bir artış olduğunu göstermektedir. Model, %98.52 genel doğruluk ve %97,62 genel test doğruluğu elde etmiştir. Eğitim ve doğrulama eğrilerinin birbirine yakın olması, güçlü bir genelleme ve önemli bir aşırı uyumun olmadığını gösterir. Karışıklık matrisi (Şekil 5.14), çoğu sınıfta yüksek sınıflandırma performansı gösterir; en iyi sonuçlar Tübüler Adenom ve Adenozis için gözlemlenirken, Duktus Karsinomu en düşük göreceli performansı gösterir. Bu sonuçlar, MobileNetV2'nin, artırma yoluyla yeterli veri çeşitliliği ile desteklendiğinde, çok sınıflı histopatolojik sınıflandırmada etkinliğini vurgular.


Tablo 5.7. MobileNetV2 için performans istatistikleri

Eğitilmiş MobileNetV2'nin performans karşılaştırması

Overall Test Accuracy	97.62%
------------------------------	--------



Şekil 5.13. MobileNetV2 için doğruluk ve kayıp grafikleri



Şekil 5.14. MobileNetV2 için karışıklık matrisleri

5.9 Mobilenetv2 Artırma Olmadan

Yapay veri genişletmenin etkisi olmadan MobileNetV2'nin temel yeteneklerini değerlendirmek için, orijinal, genişletilmemiş veri seti üzerinde ek deneyler gerçekleştirildi. Bu yapılandırma, doğal olarak dengesiz ve sınırlı bir histopatolojik görüntü seti üzerinde eğitildiğinde modelin performansına ilişkin içgörü sağlar ve genişletilmiş senaryo ile karşılaştırma noktası oluşturur.

Eğitim ve değerlendirme protokolleri önceki modellerle tutarlı tutulmuştur. Tüm görüntüler, ağa beslenmeden önce 224×224 piksele yeniden boyutlandırılmış ve normalleştirilmiştir. MobileNetV2, ImageNet ile önceden eğitilmiş ağırlıklarla başlatılmış ve sekiz meme kanseri alt tipi için yeni sınıflandırma katmanlarıyla uyarlanmıştır. Katmanlı veri bölme, Adam optimizier, öğrenme oranı planlama ve erken durdurma gibi standart uygulamalar, sağlam ve tekrarlanabilir sonuçlar elde etmek için kullanılmıştır.

Geniřletme yapılmayan MobileNetV2'nin performans istatistikleri Tablo 5.8'de sunulmuřtur. Model, %97.33'lik bir eęitim doęruluęu ve %72.73'lik bir test doęruluęu elde etmiřtir. Bu deęerler, veri geniřletme ile elde edilen deęerlerden belirgin řekilde daha dūřuktur ve sınıf dengesizlięi ve azalmıř veri eřitlilięinin getirdięi sınırlamaları vurgulamaktadır. Geniřletme yapılmadan, model sınıf ii deęiřkenlięin tūm aralıęını yakalamakta zorlanmıř ve zellikle yetersiz temsil edilen alt tipler iin daha dūřuk genelleme yeteneęi sergilemiřtir.

řekil 5.15, eęitim sūresince hem eęitim hem de doęrulama kūmeleri iin doęruluk ve kayıp eęrilerini gstermektedir. Bu grafikler, artırılmıř deneylere kıyasla daha fazla kararsızlık ve daha yavař yakınsama olduęunu ortaya koymaktadır. Doęrulama metrikleri daha dūřuk seviyelerde sabit kalmıřtır, bu da yetersiz ve dengesiz verilerin yarattıęı zorlukları daha da aık bir řekilde gstermektedir.


řekil 5.16'da gsterilen karıřıklık matrisi, modelin sınıf bazında performansının ayrıntılı bir dkūmūnū sunar. MobileNetV2, ana sınıflar iin makul bir doęruluk oranını korurken, matris, daha az eęitim rneęi veya ok benzer zelliklere sahip alt tipler arasında yanlıř sınıflandırma oranlarının arttıęını gstermektedir. Bu sonu, saęlam ve adil sınıflandırma sonuları elde etmek iin veri artırma ve dengeleme stratejilerinin nemini vurgulamaktadır.

Veri artırımı yapılmadan MobileNetV2 ile yapılan deneyler, modelin saęlam bir temel performansı koruduęunu, ancak tam potansiyelinin eęitim verilerinin eřitlilięindeki sınırlamalar nedeniyle kısıtlandıęını doęrulamıřtır. Tablo 5.8, řekil 5.15 ve řekil 5.16'da zetlenen karıřılařtırma analiz, karmařık ok sınıflı tıbbi grūntū sınıflandırmasında optimum performans iin veri artırmanın temel rolūnū pekiřtirmektedir.


Veri artırma yapılmayan MobileNetV2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi kullanılarak analiz edilmiştir (sırasıyla Şekil 5.15 ve 5.16). Doğruluk eğrisi (Şekil 5.15), eğitim doğruluğunda hızlı bir artış olduğunu ve genel doğruluğun %97,33'e ulaştığını gösterirken, doğrulama doğruluğu genel test doğruluğu %72,73 ile sabitlenmiştir. Eğitim ve doğrulama doğruluğu arasındaki belirgin fark, modelin eğitim setine iyi uyum sağladığı ancak görülmemiş verilere etkili bir şekilde genelleme yapmada zorlandığı için aşırı uyumlanma olduğunu gösterir. Karışıklık matrisi (Şekil 5.16), en yüksek sınıflandırma performansının Adenozis ve Duktus Karsinomu sınıfları için elde edildiğini, Phyllodes Tümörü ve Lobüler Karsinomu sınıflarının ise en düşük performansı gösterdiğini ortaya koymaktadır. Bu bulgular, artırma yapılmadan modelin belirli histopatolojik alt tipleri etkili bir şekilde ayırt etmek için eğitim verilerinde gerekli çeşitliliğe sahip olmadığını göstermekte ve sınıflandırma sağlamlığını iyileştirmede veri artırmanın önemini vurgulamaktadır.

Tablo 5.8. MobileNetV2 için büyütme olmadan performans istatistikleri

Eğitilmiş MobileNetV2 performansının karşılaştırılması (büyütme olmadan)	
Overall Test Accuracy	72.73%



Şekil 5.15. MobileNetV2 için artırım olmadan doğruluk ve kayıp grafikleri



Şekil 5.16. MobileNetV2 için büyütme olmadan karışıklık matrisleri

5.10 CBAM-MobileNetV2

Convolutional Block Attention Module (CBAM) modülünün MobileNetV2 mimarisine entegrasyonu, modelin histopatolojik görüntülerdeki en bilgilendirici özelliklere odaklanma

yeteneğini geliştirmek amacıyla yapılan stratejik bir iyileştirmedir. CBAM, hem kanal hem de uzamsal dikkat mekanizmalarını kullanarak ağırlıklı kalıpları uyarlanabilir bir şekilde vurgulamasına ve daha az önemli bilgileri bastırmasına olanak tanır. Bu özellik, ince morfolojik farklılıkların doğru sınıflandırma için kritik öneme sahip olabileceği tıbbi görüntü analizinde özellikle faydalıdır.

Bu çalışmada, CBAM-MobileNetV2, daha önce açıklanan aynı titiz ön işleme ve eğitim protokollerini izleyerek dengeli ve genişletilmiş bir veri seti üzerinde eğitilmiştir. Ağ, önceden eğitilmiş ImageNet ağırlıkları ile başlatılmış ve sekiz meme kanseri alt tipini ayırt etmek için özelleştirilmiş sınıflandırma katmanları eklenmiştir. Veri genişletmenin kullanılması, tüm sınıfların eşit temsil edilmesini sağlamış ve modelin çeşitli görüntü örnekleri arasında genelleme yeteneğini geliştirmiştir.

Tablo 5.9, CBAM-MobileNetV2 için temel performans ölçütlerini göstermektedir. Model, %98.04'lük bir eğitim doğruluğu ve %97.34'lük bir test doğruluğu elde ederek, temel MobileNetV2'ye göre önemli bir gelişme kaydetmiştir. CBAM modülünün eklenmesi, modelin daha ayırt edici ve bağlamsal olarak daha alakalı özellikleri öğrenmesini sağlayarak hem eğitim hem de test performansını artırmıştır.

CBAM-MobileNetV2'nin öğrenme dinamikleri, hem eğitim hem de doğrulama kümeleri için doğruluk ve kayıp eğrilerini gösteren Şekil 5.17'de gösterilmektedir. Grafikler, hızlı ve istikrarlı bir yakınsamayı yansıtmaktadır ve doğrulama doğruluğu, dönemler boyunca eğitim yörüngesini yakından yansıtmaktadır. Bu model, artırılmış verilerin etkili bir şekilde kullanıldığını göstermekte ve dikkat mekanizmasının dengeleyici etkisini vurgulamaktadır.

Şekil 5.18, CBAM-MobileNetV2 için karışıklık matrisini göstermektedir. Matris, çoğu sınıf için yüksek hassasiyet ve geri çağırma oranları sergilemekte olup, ayırt edilmesi genellikle zor olan alt tipler arasında hatalı sınıflandırmaların sayısında belirgin bir azalma görülmektedir. Sonuçlar, MobileNetV2'nin verimliliği ve CBAM'ın dikkat odaklamasının birleşik etkileri sayesinde modelin doku morfolojisindeki ince farklılıkları yakalama yeteneğinin geliştiğini vurgulamaktadır.


CBAM-MobileNetV2, çok sınıflı meme kanseri sınıflandırmasında sağlam ve güvenilir bir performans sergilemiş, dikkat mekanizması olmayan muadillerinden daha iyi performans göstermiş ve doğruluk ile hesaplama verimliliği arasında etkileyici bir denge sunmuştur. Tablo 5.9, Şekil 5.17 ve Şekil 5.18'de ayrıntılı olarak gösterildiği gibi, model, zorlu biyomedikal görüntüleme görevleri için hafif sinir ağı mimarileri içinde dikkat modüllerini entegre etmenin yararını doğrulamaktadır.

CBAM-MobileNetV2 modelinin sonuçları, doğruluk eğrileri (Doğruluk) ve karışıklık matrisi (Karışıklık Matrisi) değerlendirilerek analiz edilir (sırasıyla Şekil 5.17 ve 5.18). Doğruluk eğrisi (Şekil 5.17), 50 eğitim dönemi boyunca hem eğitim doğruluğunda hem de doğrulama doğruluğunda istikrarlı ve kademeli bir artış olduğunu göstermektedir. Eğitim doğruluğu yaklaşık %98,04'e ulaşırken, model %97,34'lük bir doğrulama doğruluğu elde etmiştir. Eğitim ve doğrulama doğruluğu arasındaki yakın uyum, istikrarlı bir performans ve aşırı uyumun önlendiğini göstermektedir. Karışıklık matrisi (Şekil 5.18) ile ilgili olarak, model çoğu sınıflandırmada yüksek doğruluk göstermiştir ve değerler ana diyagonal boyunca yoğunlaşmıştır, bu da farklı sınıfları doğru bir şekilde ayırt etme konusundaki güçlü yeteneğini yansıtmaktadır. Papiller Karsinom sınıfı en yüksek doğruluğu elde etmiş, onu Adenoz ve Tübüler Adenom izlemiştir, ancak Duktus Karsinom sınıfı en düşük göreceli doğruluğu kaydetmiştir, bu da modelin onu diğer bazı sınıflardan ayırt etmekte bazı zorluklar yaşadığını göstermektedir. Bu güçlü performans, öncelikle Convolutional Block Attention Module (CBAM) entegrasyonuna atfedilebilir. Bu modül, modelin histopatolojik görüntülerde tanısal açıdan ilgili özelliklere odaklanma yeteneğini geliştirerek bu güvenilir sonuçlara katkıda bulunmuştur.


Tablo 5.9. CBAM-MobileNetV2 için performans istatistikleri

CBAM-MobileNetV2'nin performans karşılaştırması

Overall Test Accuracy 97.34%



Şekil 5.17. CBAM-MobileNetV2 için doğruluk ve kayıp grafikleri



Şekil 5.18. CBAM-MobileNetV2 için karışıklık matrisleri

5.11 CBAM-MobileNetV2 Artırma Olmadan

Hafif mimarilerde dikkat mekanizmalarının bağımsız etkisini daha da açıklığa kavuşturmak için, orijinal, artırılmamış veri seti üzerinde CBAM-MobileNetV2 modeli kullanılarak ek deneyler gerçekleştirildi. Bu yapılandırmada, model doğrudan doğal olarak dengesiz ve sınırlı veriler üzerinde eğitildi, böylece CBAM'nin veri artırımı olmadan performansı nasıl etkilendiğine odaklanan bir değerlendirme yapılabilir.

Tüm deneysel parametreler önceki protokollerle tutarlı tutuldu: giriş görüntüleri yeniden boyutlandırıldı ve 224×224 piksele normalleştirildi, MobileNetV2 ImageNet ağırlıkları ile başlatıldı ve CBAM kanal ve uzamsal dikkat sağlamak için dahil edildi. Veri kümesi tabakalı bir yaklaşım kullanılarak bölündü ve güvenilir eğitimi desteklemek için Adam optimizör, erken durdurma ve öğrenme oranı planlaması dahil olmak üzere standart optimizasyon stratejileri uygulandı.

Artırma yapılmayan CBAM-MobileNetV2 için performans ölçütleri Tablo 5.10'da sunulmuştur. Model, %99.96 eğitim doğruluğu ve %83.94 test doğruluğu elde etmiştir. Bu sonuçlar, artırma yapılmayan temel MobileNetV2'ye göre belirgin bir iyileşme olduğunu göstermekte ve CBAM'ın özellik seçiciliğini artırmada ve veri çeşitliliğinin eksikliğini bir dereceye kadar telafi etmede etkinliğini doğrulamaktadır. Ancak, genel performans hala dengeli, artırılmış veri kümeleriyle elde edilen sonuçların gerisinde kalmaktadır, bu da sınıf dengesizliği ve sınırlı sınıf içi değişkenliğin yarattığı kalıcı zorlukları yansıtmaktadır.

Şekil 5.19, hem eğitim hem de doğrulama kümeleri için doğruluk ve kayıp eğrilerini göstermektedir. Öğrenme süreci, artırılmış senaryoya kıyasla biraz daha büyük dalgalanmalar ve daha yavaş bir yakınsama oranı ile karakterize edildi. Bu, dikkat mekanizmalarının öğrenme

istikrarını ve genellemeyi iyileştirmesine rağmen, veri artırmanın en yüksek performansa ulaşmak için hala çok önemli bir faktör olduğunu göstermektedir.


Şekil 5.20'de gösterilen karışıklık matrisi, sınıf bazında tahminlerin ayrıntılı bir dökümünü sunmaktadır. CBAM-MobileNetV2, çoğu sınıfta güçlü performansı korumayı başarmıştır, ancak matris, özellikle daha az eğitim örneği veya örtüşen özelliklere sahip alt türler için yanlış sınıflandırmanın devam ettiği alanları da ortaya koymaktadır. Bu gözlemler, dengesiz verilerle çalışırken yalnızca dikkat mekanizmalarına güvenmenin sınırlarını daha da vurgulamaktadır.

Veri artırımı yapılmayan CBAM-MobileNetV2, temel seviyeye göre kayda değer iyileşmeler göstermiş, ancak sonuçta orijinal veri kümesinin doğasında var olan eksiklikler nedeniyle sınırlı kalmıştır. Tablo 5.10, Şekil 5.19 ve Şekil 5.20'de özetlenen bulgular, tıbbi görüntülemede optimal sınıflandırma sonuçları elde etmek için dikkat modüllerini sağlam veri artırımı stratejileriyle birleştirmenin sinerjik değerini vurgulamaktadır.


Veri artırma yapılmayan CBAM-MobileNetV2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi (sırasıyla Şekil 5.19 ve 5.20) değerlendirilerek analiz edilmiştir. Doğruluk eğrisi (Şekil 5.19), eğitim doğruluğunun hızla artarak neredeyse %100'e (%99.96) ulaştığını, doğrulama doğruluğunun ise daha düşük bir seviyede sabitlendiğini ve nihai genel test doğruluğunun %83,94 olduğunu göstermektedir. Eğitim ve doğrulama doğruluğu arasındaki belirgin fark, veri artırma olmadığında modelin eğitim verilerine aşırı uyum sağlama eğiliminde olduğunu ve görünmeyen verilere etkili bir şekilde genelleştirilemeyen belirli kalıpları öğrendiğini göstermektedir. Karışıklık matrisi (Şekil 5.20), tahminlerin çoğunun ana diyagonal boyunca yoğunlaştığını ve genel olarak doğru sınıflandırmalar olduğunu göstermektedir. En yüksek sınıflandırma doğruluğu Adenozis ve Duktus Karsinomu sınıflarında gözlemlenirken, Lobüler Karsinomu ve Filodom Tümörü sınıfları nispeten daha düşük doğruluklar göstermiştir, bu da artırma ile sağlanan ek

değişkenlik olmadan bu alt tipleri ayırt etmenin zor olduğunu göstermektedir. Genel olarak, veri artırmanın olmaması, CBAM dikkat mekanizmasının özellik odaklanmasını iyileştirmesine rağmen, modelin genelleme yeteneğini sınırladı. Bu, karmaşık histopatolojik sınıflandırma görevleri için dikkat modüllerinin dengeli ve çeşitli eğitim verileriyle birleştirildiğinde en etkili olduğunu vurgulamaktadır.

Tablo 5.10. CBAM-MobileNetV2 için büyütme olmadan performans istatistikleri



Şekil 5.19. CBAM-MobileNetV2 için artırım olmadan doğruluk ve kayıp grafikleri



Şekil 5.20. CBAM-MobileNetV2 için büyütme olmadan karışıklık matrisleri

5.12 SE-MobileNetV2

Sıkıştırma ve Uyarma (SE) mekanizması, dinamik, kanal bazlı özellik yeniden kalibrasyonu getirerek sinir ağlarının temsil kapasitesini artırmak için basit ama güçlü bir yaklaşım sunar. Bu çalışmada, SE blokları MobileNetV2 mimarisine entegre edilerek SE-MobileNetV2 modeli oluşturuldu. Bu modelin amacı, histopatolojik görüntüler kullanılarak çok sınıflı meme kanseri sınıflandırmasında etkinliğini artırmaktır.

SE-MobileNetV2 için eğitim protokolü, deney bölümünde uygulanan aynı titiz standartları izlemiştir. Model, ImageNet ile önceden eğitilmiş ağırlıklarla başlatılmış ve BreakHis veri集中的eki sekiz meme kanseri alt tipine uyacak şekilde özel sınıflandırma katmanlarıyla uyarlanmıştır. Giriş görüntüleri 224×224 piksele yeniden boyutlandırılmış ve normalleştirilmiş, veri seti ise tüm sınıflar arasında eşit temsil sağlamak için veri artırma yoluyla dengelenmiştir.

Tablo 5.11, SE-MobileNetV2 için temel performans istatistiklerini göstermektedir. Model, %98.73 eğitim doğruluğu ve %97.75 test doğruluğu elde etmiştir. Bu sonuçlar, SE mekanizmasının MobileNetV2'nin temel performansını iyileştirirken, genel doğruluğun CBAM-MobileNetV2 ve daha derin ResNet tabanlı modellere kıyasla biraz daha düşük olduğunu göstermektedir. Bununla birlikte, SE-MobileNetV2 yine de gelişmiş verimlilikle rekabetçi sonuçlar sağlamıştır.

Şekil 5.21, hem eğitim hem de doğrulama kümeleri için doğruluk ve kayıp eğrilerini göstermektedir. Grafikler, minimum aşırı uyum ve düzgün bir yakınsama modeli ile tutarlı öğrenme davranışı göstermektedir. Bu, modelin dengeli, artırılmış veri kümesinden genelleme yapma kapasitesini yansıtmaktadır. Sabit yörüngeler, SE bloklarının dengeleyici etkisini ve benimsenen eğitim stratejisinin etkinliğini vurgulamaktadır.

Şekil 5.22, SE-MobileNetV2 için karışıklık matrisini göstermektedir. Matris, özellikle benzer morfolojik özelliklere sahip alt tipler arasında birkaç yanlış sınıflandırma devam etmesine rağmen, sınıfların çoğunda yüksek tahmin doğruluğu olduğunu ortaya koymaktadır. Sonuçlar, SE bloğunun ağın en bilgilendirici kanallara odaklanmasına yardımcı olduğunu ve böylece hafif bir omurgada bile sınıf bazında ayrımı iyileştirdiğini göstermektedir.

SE-MobileNetV2, dikkat mekanizmalarının avantajları ile hesaplama verimliliğini dengeleyerek, çok sınıflı meme kanseri sınıflandırmasında sağlam bir performans sergilemiştir. Tablo 5.11, Şekil 5.21 ve Şekil 5.22'deki sonuçların da gösterdiği gibi, model hızlı, kaynak verimli ve doğru tıbbi görüntü analizi gerektiren gerçek dünya uygulamaları için pratik bir çözüm sunmaktadır.


SE-MobileNetV2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi (sırasıyla Şekil 5.21 ve 5.22) değerlendirilerek analiz edilmiştir. Doğruluk eğrisi (Şekil 5.21), 50 epok boyunca hem eğitim doğruluğunda hem de doğrulama doğruluğunda istikrarlı ve paralel bir artış gösterir. Eğitim

doğruluğu yaklaşık %98.73'e ulaşırken, doğrulama doğruluğu %97.75 gibi yüksek bir genel test doğruluğu elde eder. Eğitim ve doğrulama eğrilerinin birbirine yakın olması, mükemmel genelleme ve aşırı uyumun olmadığını gösterir. Karışıklık matrisi (Şekil 5.22), tüm sınıflarda tutarlı bir şekilde yüksek sınıflandırma performansı ortaya koyar ve değerler ağırlıklı olarak ana köşegen boyunca yoğunlaşır. En yüksek doğruluklar Tubüler Adenom (100%), Papiller Karsinom (99,6%) ve Phyllodes Tümörü (99,8%) için kaydedilirken, Duktus Karsinomu sınıfı en düşük göreceli doğruluğu (84,2%) göstermiştir, bu da sınıflandırılması en zor alt tip olmaya devam ettiğini göstermektedir. Genel olarak, Squeeze-and-Excitation (SE) mekanizmasının entegrasyonu, modelin histopatolojik görüntülerdeki en ayırt edici özelliklere odaklanma yeteneğini önemli ölçüde artırmış, bu da tüm alt tiplerde üstün sınıflandırma performansı ve güçlü sağlamlık ile sonuçlanmıştır.


Tablo 5.11. SE-MobileNetV2 için performans istatistikleri

Se-MobileNetV2'nin performans karşılaştırması

Overall Test Accuracy 97.75%



Şekil 5.21. SE-MobileNetV2 için doğruluk ve kayıp grafikleri



Şekil 5.22. Se-MobileNetV2 için karışıklık matrisleri

5.13 SE-MobileNetV2 Artırma Olmadan

SE-MobileNetV2 mimarisinin sağlamlığını ve içsel yeteneğini kapsamlı bir şekilde değerlendirmek için, orijinal, artırılmamış veri seti kullanılarak ek deneyler gerçekleştirildi. Bu yapılandırmada, model doğal olarak dengesiz veriler üzerinde eğitildi ve yapay veri genişletmenin yararı olmadan özellik seçimi ve temsilini geliştirmede SE bloğunun etkinliği hakkında fikir verdi.

Deney protokolü önceki ayarlarla tutarlıydı: tüm görüntüler yeniden boyutlandırıldı ve 224×224 piksele normalleştirildi, MobileNetV2 ImageNet ile önceden eğitilmiş ağırlıklarla başlatıldı ve dinamik kanal bazlı dikkatin etkinleştirilmesi için SE bloğu dahil edildi. Veriler tabakalı bir şekilde bölündü ve güvenilirliği korumak ve aşırı uyumu önlemek için Adam optimizyer, erken durdurma ve öğrenme oranı planlaması gibi yaygın optimizasyon stratejileri uygulandı.

Genişletme yapılmayan SE-MobileNetV2'nin performans istatistikleri Tablo 5.12'de özetlenmiştir. Model, %97.33 eğitim doğruluğu ve %71.72 test doğruluğu elde etmiştir. Bu sonuçlar, dengeli, artırılmış verilerle elde edilen sonuçlardan daha düşüktür ve sınıf dengesizliği ve sınırlı veri çeşitliliğinin getirdiği sınırlamaları vurgulamaktadır. SE bloğu, kanal seçiciliğini iyileştirerek bu zorlukların bazılarını hafifletmeye yardımcı olsa da, artırmanın olmaması modelin tam potansiyelini hala kısıtlamaktadır.

Şekil 5.23, hem eğitim hem de doğrulama kümeleri için doğruluk ve kayıp eğrilerini göstermektedir. Öğrenme eğrileri, artırılmış senaryoya kıyasla daha fazla dalgalanma ve daha yavaş bir yakınsama göstermektedir, bu da sınırlı ve dengesiz örneklerden istikrarlı bir genelleme elde etmenin zorluğunu yansıtmaktadır. Bu zorluklara rağmen, SE-MobileNetV2, SE mekanizması tarafından sağlanan kanal bazlı yeniden kalibrasyon sayesinde nispeten sağlam bir öğrenme davranışı sergilemiştir.

Modelin tahminlerinin ayrıntılı bir analizi, Şekil 5.24'te sunulmaktadır. Bu şekil, artırma yapılmayan SE-MobileNetV2 için karışıklık matrisini göstermektedir. Matris, ana alt tipler için sınıf bazında makul bir doğruluk oranını vurgulamaktadır, ancak azınlık veya yakından ilişkili sınıflar arasında artan yanlış sınıflandırma oranları gözlemlenmiştir. Bu sonuçlar, karmaşık tıbbi görüntüleme görevlerinde adil ve doğru sınıflandırma elde etmek için veri artırmanın önemini vurgulamaktadır.

Veri artırımı yapılmayan SE-MobileNetV2, temel yetkinliği göstermiş ancak sonuçta veri kümesinin doğasında var olan eksiklikler nedeniyle sınırlı kalmıştır. Tablo 5.12, Şekil 5.23 ve Şekil 5.24'te gösterildiği gibi, SE dikkat mekanizmalarının entegrasyonu tek başına dengesiz ve sınırlı eğitim verilerini tam olarak telafi edememektedir, bu da zorlu biyomedikal sınıflandırma senaryolarında kapsamlı veri artırımı gerekliliğini yeniden teyit etmektedir.


Veri artırma yapılmayan SE-MobileNetV2 modelinin sonuçları, doğruluk eğrileri ve karışıklık matrisi (sırasıyla Şekil 5.23 ve 5.24) kullanılarak analiz edilmiştir. Doğruluk eğrisi (Şekil 5.23), eğitim doğruluğunda hızlı bir artış olduğunu göstermektedir. Eğitim doğruluğu yaklaşık %97,33'e ulaşırken, doğrulama doğruluğu çok daha düşük bir değerde sabit kalmış ve genel test doğruluğu %71,72 olarak gerçekleşmiştir. Eğitim ve doğrulama doğruluğu arasındaki büyük fark, modelin eğitim seti kalıplarını çok iyi öğrenmesine rağmen, görülmemiş verilere etkili bir şekilde genelleme yapamadığı için önemli bir aşırı uyum olduğunu göstermektedir. Karışıklık matrisi (Şekil 5.24), çoğu sınıfta sınıflandırma performansında önemli bir düşüş olduğunu ortaya koymaktadır. En yüksek doğruluk, Ductal Karsinom sınıfında (%78,5) ve en düşük doğruluk ise Lobüler Karsinom sınıfında (%58,2) kaydedilmiştir. Fibroadenom, Phyllodes Tümörü ve Papiller Karsinom gibi birkaç sınıf da nispeten düşük doğruluk oranları göstermiştir, bu da artırma ile getirilen ek değişkenlik ve denge olmadan sınıflandırmanın zorluğunu yansıtmaktadır. Bu

sonuçlar, SE mekanizmasının kanal bazında özellik dikkatini iyileştirmesine rağmen, küçük ve dengesiz bir veri kümesinin sınırlamalarını tam olarak telafi edemediğini vurgulamaktadır. Bu da, karmaşık histopatolojik görüntü sınıflandırma görevlerinde sağlam performans elde etmek için veri artırmanın çok önemli bir bileşen olduğunu göstermektedir.


Tablo 5.12. SE-MobileNetV2 için büyütme olmadan performans istatistikleri

Se-MobileNetV2'nin performansının karşılaştırılması (artırma olmadan)

Overall Test Accuracy	71.72 %
------------------------------	---------



Şekil 5.23. SE-MobileNetV2 için artırım olmadan doğruluk ve kayıp grafikleri



Şekil 5.24. SE-MobileNetV2 için büyütme olmadan karışıklık matrisleri

5.14 İkili Sınıflandırma Sonuçları

Histopatolojik meme kanseri görüntülerinin ikili sınıflandırmasında, Se-ResNet152V2, CBAM-ResNet152V2 ve CBAM-MobileNetV2 olmak üzere üç yüksek performanslı model üzerinde kapsamlı bir değerlendirme gerçekleştirildi. Her model, çoklu büyütme seviyelerinde (40X, 100X, 200X ve 400X) bağımsız olarak titizlikle eğitildi ve doğrulandı, böylece ikili tıbbi görüntü analizinde sağlamlık, ölçeklenebilirlik ve ayırt edici verimliliği değerlendirmek için kapsamlı bir karşılaştırma ölçütü sağlandı.

Se-ResNet152V2 modeli, 40X'te %97,83, 100X'te %98,40, 200X'te %96,36 ve 400X'te %92,67 gibi olağanüstü doğruluk oranları elde ederek tutarlı bir şekilde üstün genelleme yetenekleri sergilemiştir. Bu sonuçlar, Squeeze-and-Excitation entegre kalıntı ağlarının, değişen görüntü çözünürlüklerinde ince ancak kritik histolojik kalıpları yakalamadaki mimari gücünü teyit etmektedir. Se-ResNet152V2, büyütme oranları arasında olağanüstü bir kararlılık sergilemiş ve klinik tanı görevlerinde hayati bir gereklilik olan ölçekten bağımsız özellik çıkarma yeteneğini vurgulamıştır.


Buna karşılık, Convolutional Block Attention Mechanisms'ı kullanan CBAM-ResNet152V2 modeli, 40X'te %97,83, 100X'te %96,32, 200X'te %96,19 ve 400X'te %95,05 doğruluk oranları ile oldukça rekabetçi sonuçlar elde etti. Belirli büyütme oranlarında Se-ResNet152V2'nin biraz gerisinde kalsa da, CBAM-ResNet152V2 tutarlı bir şekilde yüksek tahmin performansı sergiledi ve ikili ayırım görevlerinde özellik önemini iyileştirme ve sınıflandırma güvenilirliğini artırmada dikkat modüllerinin önemini vurguladı.

CBAM-MobileNetV2 modeli, hesaplama verimliliği için optimize edilmiş hafif bir mimariye sahip olmakla birlikte, 40X'te %96,33, 100X'te %87,68, 200X'te %94,70 ve 400X'te %94,87 gibi saygıdeğer doğruluk oranları elde etti. 100X'te belirgin bir düşüşe rağmen, daha yüksek büyütme oranlarında sağlam bir şekilde toparlanması, dikkat mekanizmalarıyla güçlendirilmiş hafif modellerin, kaynakların sınırlı olduğu ortamlarda bile etkili performans sunma potansiyelini vurgulamaktadır.

Toplamda, ampirik sonuçlar Se-ResNet152V2 ve CBAM-ResNet152V2 gibi daha derin mimarilerin, özellikle değişen büyütme koşullarında histopatolojik görüntülerin ikili sınıflandırılmasında önemli bir avantaj sağladığını doğrulamaktadır. Öte yandan, CBAM-MobileNetV2, hesaplama kaynaklarının sınırlı olduğu mobil veya gerçek zamanlı klinik uygulamalarda kullanılmak üzere umut verici bir alternatif sunmaktadır. Bu sonuçlar, hesaplamalı patoloji alanında en son teknolojiye sahip benchmarkları elde etmek ve hatta aşmak için dikkat mekanizmaları ve derinlik açısından özellik yeniden kalibrasyon stratejilerinin dahil edilmesinin önemli rolünü daha da vurgulamaktadır.

Tablo 5.13. 40X Görüntüler üzerinde eğitilmiş CNN'lerin performans istatistikleri


40X Görüntüler üzerinde eğitilmiş CNN'lerin performansının karşılaştırılması			
Evaluation Metrics	CBAM-ResNet152V2	SE-ResNet152V2	CBAM-MobileNetV2
Test Accuracy	97.83%	97.83%	96.33%
Precision	97.06 %	97.00%	96.40%
Recall	97.99%	98.00%	94.97%
F1 Score	97.51%	97.00%	95.65%



Şekil 5.25. 40X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri

Tablo 5.14. 100X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri


100X Görüntülerle eğitilmiş CNN'lerin performans karşılaştırması			
Evaluation Metrics	CBAM-ResNet152V2	SE-ResNet152V2	CBAM-MobileNetV2
Test Accuracy	96.32%	98.40%	87.68%
Precision	95.40 %	97.00%	91.07 %
Recall	96.52%	98.00%	81.63 %
F1 Score	95.92 %	98.00%	84.42%



Şekil 5.26. 100X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri

Tablo 5.15. 200X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri


200X Görüntülerle eğitilmiş CNN'lerin performans karşılaştırması			
Evaluation Metrics	CBAM-ResNet1152V2	SE-ResNet152V2	CBAM-MobileNetV2
Test Accuracy	96.19%	96.36%	94.70%
Precision	95.28%	94.00%	93.79%
Recall	95.92%	96.00%	93.17 %
F1 Score	95.59%	95.00%	93.47%



Şekil 5.27. 200X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri


Tablo 5.16. 400G Görüntülerle eğitilmiş CNN'lerin performans istatistikleri

400X Görüntülerle eğitilmiş CNN'lerin performans karşılaştırması			
Evaluation Metrics	CBAM-ResNet1152V2	SE-ResNet152V2	CBAM-MobileNetV2
Test Accuracy	95.05%	92.67%	94.87%
Precision	93.52%	89.00%	94.46%
Recall	96.04%	93.00%	93.61 %
F1 Score	94.56%	91.00%	94.02%




Şekil 5.28. 400X Görüntülerle eğitilmiş CNN'lerin performans istatistikleri


Şekiller, 40x, 100x, 200x ve 400x farklı büyütme faktörlerine sahip SE-ResNet152V2, CBAM-ResNet152V2 ve CBAM-MobileNetV2 CNN'lerin karışıklık matrislerini göstermektedir.



Şekil 5.29. Farklı büyütme oranları için SE-ResNet152V2'nin karışıklık matrisleri



Şekil 5.30. Farklı büyütme oranları için CBAM-ResNet152V2'nin karışıklık matrisleri



Şekil 5.31. Farklı büyütme oranları için CBAM-MobileNetV2'nin karışıklık matrisleri

5.15 Zoom ile Çok Sınıflı Sınıflandırma Sonuçları

Histopatolojik meme kanseri görüntülerinin sekiz farklı kategoriye çok sınıflı sınıflandırılmasında, üç gelişmiş derin öğrenme mimarisi (SE-ResNet152V2, CBAM-ResNet152V2 ve CBAM-MobileNetV2) farklı büyütme seviyelerinde (40X, 100X, 200X ve 400X) kapsamlı bir şekilde değerlendirildi. Modeller, yalnızca genel sınıflandırma doğruluğu açısından değil, aynı zamanda hesaplamalı patolojide kritik bir faktör olan çeşitli çözünürlüklerde ayırt edici hassasiyeti koruma yetenekleri açısından da analiz edildi.

SE-ResNet152V2 modeli, tüm büyütme oranlarında güçlü ve tutarlı bir performans sergiledi ve 40X'te %89,65, 100X'te %84,44, 200X'te %82,78 ve 400X'te %87,00 sınıflandırma doğruluğu elde etti. Farklı yakınlaştırma düzeylerinde gösterdiği istikrar, modelin karmaşık histopatolojik yapılardan sağlam ve genelleştirilebilir özellikler çıkarabilme yeteneğini yansıtıyor ve değişen ölçeklere ve morfolojik varyanslara maruz kaldığında üstün uyarlanabilirlik sergiliyor. Öte


yandan, CBAM-ResNet152V2 modeli belirli yakınlaştırma ayarlarında diğerlerini geride bırakarak, özellikle 40X'te %94,16 ile kaydedilen en yüksek doğruluğu elde etti. Ancak, performansı daha yüksek büyütme oranlarında hafif bir düşüş gösterdi ve 100X'te %85,92, 200X'te %84,77 ve 400X'te %84,62 doğruluk oranları kaydetti. Convolutional Block Attention Module (CBAM) entegrasyonu, modelin düşük büyütme oranlarında özellik seçme yeteneklerini açıkça geliştirdi ve sekiz kanser alt tipi arasında daha iyi ayırım yapılmasını sağladı, ancak çözünürlük değişikliklerine karşı hafif bir duyarlılık gözlemlendi.

Hesaplama verimliliği sağlamak üzere tasarlanan CBAM-MobileNetV2 modeli, nispeten mütevazı ancak umut verici sonuçlar sunarak 40X'te %79,47, 100X'te %83,20, 200X'te %84,44 ve 400X'te %85,71 oranlarında performans gösterdi. Hafif yapısına rağmen, model, görüntü büyütme oranının artmasıyla performansı kademeli olarak iyileştirme yeteneği gösterdi, bu da daha yüksek çözünürlüklü histolojik detayların daha belirgin hale geldiği senaryolarda gücünü ortaya koydu.

Genel olarak, karşılaştırmalı değerlendirme, SE-ResNet152V2'nin belirli koşullar altında (özellikle 40X büyütmede) üstün doğruluk sağladığını, CBAM-ResNet152V2'nin ise tüm büyütme oranlarında dengeli ve güvenilir performansı ile öne çıktığını vurgulamaktadır. Buna karşılık, CBAM-MobileNetV2, doğruluktan önemli ölçüde ödün vermeden, model boyutu ve hesaplama verimliliğinin öncelikli olduğu ortamlar için cazip bir seçenek sunar. Bu bulgular, histopatolojik görüntü analizinde çok sınıflı sınıflandırma görevlerinin başarısı üzerinde model mimarisi derinliği, dikkat mekanizmaları ve büyütme seviyesi duyarlılığının kritik etkisini vurgulamaktadır.

Tablo 5.17. Çok sınıflı sınıflandırma için genel test doğruluğu

Çok Sınıflı Sınıflandırma için Genel Test Doğruluğu				
Neural Networks	40X	100X	200X	400X
CBAM-MobileNetV2	79.47%	83.20%	84.44%	85.71%
CBAM-ResNet152V2	94.16%	85.92%	84.77%	84.62%
SE-ResNet152V2	89.65%	84.44%	82.78%	87.00%




Şekil 5.32. Çoklu sınıf için tüm modellerde test doğruluğunu karşılaştıran grafik

5.15.1 CBAM-MobileNetV2

Tablo 5.18. 40X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performans istatistikleri


40X görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	93.18%	82.00%	93.18%	87.23%
Ductal Carcinoma	66.28%	99.43%	66.28%	79.54%
Fibroadenoma	91.04%	89.71%	91.04%	90.37%
Lobular Carcinoma	91.67%	72.13%	91.67%	80.73%
Mucinous Carcinoma	92.54%	53.91%	92.54%	68.13%
Papillary Carcinoma	65.12%	100%	65.12%	78.87%
Phyllodes Tumor	96.77%	75.00%	96.77%	84.51%
Tubular Adenoma	97.37%	58.73%	97.37%	73.27%
Overall Test Accuracy	79.47%			



Şekil 5.33. 40X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performansının karşılaştırılması

Tablo 5.19. 100X Görüntülerde eğitilen CBAM-MobileNetV2 için performans istatistikleri


100X Görüntülerde eğitilen CBAM-MobileNetV2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	97.06%	60.00%	97.06%	74.16%
Ductal Carcinoma	80.83%	95.98%	80.83%	87.76%
Fibroadenoma	77.22%	91.04%	77.22%	83.56%
Lobular Carcinoma	95.65%	57.14%	95.65%	71.54%
Mucinous Carcinoma	84.81%	79.76%	84.81%	82.21%
Papillary Carcinoma	80.00%	68.09%	80.00%	73.56%
Phyllodes Tumor	66.67%	91.67%	66.67%	77.19%
Tubular Adenoma	95.83%	97.87%	95.83%	96.84 %
Overall Test Accuracy	83.20%			



Şekil 5.34. 100X Görüntülerde eğitilen CBAM-MobileNetV2'nin performansının karşılaştırılması

Tablo 5.20:200X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performans istatistikleri


200X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	100%	66.67%	100 %	80.00%
Ductal Carcinoma	87.59%	91.82%	87.59%	89.66%
Fibroadenoma	87.50%	88.73%	87.50%	88.11%
Lobular Carcinoma	61.54%	62.75%	61.54%	62.14 %
Mucinous Carcinoma	92.73%	68.92%	92.73%	79.07%
Papillary Carcinoma	79.07%	91.89%	79.07%	85.00%
Phyllodes Tumor	71.88%	88.46%	71.88%	79.31%
Tubular Adenoma	78.95%	96.77%	78.95%	86.96%
Overall Test Accuracy	84.44%			



Şekil 5.35. 200X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performansının karşılaştırılması

Tablo 5.21. 400X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performans istatistikleri

400X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	87.18%	85.00%	87.18%	86.08%
Ductal Carcinoma	86.00%	89.21%	86.00%	87.58%
Fibroadenoma	91.30%	69.77%	91.30%	92.65%
Lobular Carcinoma	73.17%	70.91%	73.17%	71.43%
Mucinous Carcinoma	88.64%	68.92%	88.64%	78.79%
Papillary Carcinoma	74.36%	85.29%	74.36%	79.45%
Phyllodes Tumor	85.19%	88.46%	85.19%	86.79%
Tubular Adenoma	94.59%	87.50%	94.59%	90.91%
Overall Test Accuracy	85.71%			




Şekil 5.36. 400X Görüntüler üzerinde eğitilmiş CBAM-MobileNetV2'nin performansının karşılaştırılması

5.15.2 CBAM-ResNet152V2

Tablo 5.22. 40X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri


40X görüntüler üzerinde eğitilmiş CBAM-CBAM-ResNet152V2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	100%	100 %	100 %	100%
Ductal Carcinoma	90.46%	96.89%	90.46%	93.56%
Fibroadenoma	95.00%	100%	95.00%	97.44%
Lobular Carcinoma	93.48%	70.49%	93.48%	80.37%
Mucinous Carcinoma	97.06%	98.51%	97.06%	97.78%
Papillary Carcinoma	96.30%	94.55%	96.30%	95.41%
Phyllodes Tumor	100%	85.71%	100%	92.31%
Tubular Adenoma	97.78%	97.78%	97.78%	97.78%
Overall Test Accuracy	94.16%			



Şekil 5.37. 40X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performansının karşılaştırılması

Tablo 5.23. 100X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri


100X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	97.22%	92.11%	97.22%	94.59%
Ductal Carcinoma	84.62%	93.22%	84.62%	88.71%
Fibroadenoma	83.91%	94.81%	83.91%	89.02%
Lobular Carcinoma	91.53%	60.00%	91.53%	72.48%
Mucinous Carcinoma	84.62%	69.84%	84.62%	76.52%
Papillary Carcinoma	77.36%	97.62%	77.36%	86.32%
Phyllodes Tumor	80.65%	86.21%	80.65%	83.33%
Tubular Adenoma	95.74%	90.00%	95.74%	92.78%
Overall Test Accuracy	85.92%			



Şekil 5.38. 100X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri

Tablo 5.24. 200X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri


200X Görüntüler üzerinde eğitilmiş CBAM-CBAM-ResNet152V2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	94.74%	87.80%	94.74%	91.14%
Ductal Carcinoma	82.16%	93.64%	82.16%	87.52%
Fibroadenoma	90.00%	82.89%	90.00%	86.30%
Lobular Carcinoma	78.72%	54.41%	78.72%	64.35%
Mucinous Carcinoma	88.33%	76.81%	88.33%	82.17%
Papillary Carcinoma	89.19%	82.50%	89.19%	85.71%
Phyllodes Tumor	80.65%	89.29%	80.65%	84.75%
Tubular Adenoma	84.62%	95.65%	84.62%	89.80%
Overall Test Accuracy	84.77%			



Şekil 5.39. 200X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performansının karşılaştırılması

Tablo 5.25. 400X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performans istatistikleri

400X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	97.37%	72.55%	97.37%	83.15%
Ductal Carcinoma	87.56%	93.36%	87.56%	90.37%
Fibroadenoma	73.81%	88.57%	73.81%	80.52%
Lobular Carcinoma	76.32%	65.91%	76.32%	70.73%
Mucinous Carcinoma	82.61%	84.44%	82.61%	83.52%
Papillary Carcinoma	80.49%	82.50%	80.49%	81.48%
Phyllodes Tumor	84.85%	71.79%	84.85%	77.78%
Tubular Adenoma	92.68%	82.61%	92.68%	87.36%
Overall Test Accuracy	84.62%			




Şekil 5.40. 400X Görüntüler üzerinde eğitilmiş CBAM-ResNet152V2'nin performansının karşılaştırılması

5.15.3 SE-ResNet152V2

Tablo 5.26. 40X Görüntüler üzerinde eğitilmiş S-ResNet152V2'nin performans istatistikleri


40X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	83%	100%	83%	91%
Ductal Carcinoma	86%	96%	86%	91%
Fibroadenoma	100%	89%	100%	94%
Lobular Carcinoma	80%	74%	80%	77%
Mucinous Carcinoma	91%	88%	91%	89%
Papillary Carcinoma	98%	68%	98%	80%
Phyllodes Tumor	89%	97%	89%	93%
Tubular Adenoma	93%	96%	93%	95%
Overall Test Accuracy	89.65%			



Şekil 5.41. 40X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması

Tablo 5.27. 100X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performans istatistikleri

100X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	94%	94%	94%	94%
Ductal Carcinoma	83%	93%	83%	88%
Fibroadenoma	98%	79%	98%	88%
Lobular Carcinoma	67%	72%	67%	69%
Mucinous Carcinoma	78%	85%	78%	81%
Papillary Carcinoma	93%	63%	93%	75%
Phyllodes Tumor	70%	90%	70%	79%
Tubular Adenoma	95%	83%	95%	89%
Overall Test Accuracy	84.44%			



Şekil 5.42. 100X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması

Tablo 5.28. 200X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performans istatistikleri


200X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	94%	83%	94%	88%
Ductal Carcinoma	82%	95%	82%	88%
Fibroadenoma	90%	81%	90%	69%
Lobular Carcinoma	91%	55%	91%	77%
Mucinous Carcinoma	68%	88%	68%	71%
Papillary Carcinoma	88%	60%	88%	71%
Phyllodes Tumor	66%	77%	66%	71%
Tubular Adenoma	87%	98%	87%	92%
Overall Test Accuracy	82.78%			




Şekil 5.43. 200X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması

Tablo 5.29. 400X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performans istatistikleri



400X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması				
Class Name	Accuracy	Precision	Recall	F1 Score
Adenosis	92%	92%	92%	92%
Ductal Carcinoma	87%	92%	87%	90%
Fibroadenoma	93%	92%	93%	93%
Lobular Carcinoma	71%	76%	71%	73%
Mucinous Carcinoma	81%	89%	81%	85%
Papillary Carcinoma	92%	60%	92%	72%
Phyllodes Tumor	88%	94%	88%	91%
Tubular Adenoma	95%	90%	95%	92%
Overall Test Accuracy	87.00%			




Şekil 5.44. 400X Görüntüler üzerinde eğitilmiş SE-ResNet152V2'nin performansının karşılaştırılması




Şekil 5.45: Tüm yakınlaştırma oranları için SE-RESNET152V2'nin karışıklık



Şekil 5.46. Tüm yakınlaştırma düzeyleri için CBAM-MobileNetV2'nin karışıklık matrisleri



Şekil 5.47. Tüm yakınlaştırma düzeyleri için CBAM-ResNet152V2'nin karışıklık matrisleri



Şekil 5.47. (Devam) Tüm yakınlaştırma düzeyleri için CBAM-ResNet152V2'nin karışıklık matrisleri


Yukarıdaki sonuçları özetlemek gerekirse, SE-ResNet152V2 modeli 40X'te %97,61, 100X'te %84,44, 200X'te %82,78 ve 400X'te %87,00 doğruluk oranları elde ederek tüm büyütme oranlarında tutarlı bir performans sergilemiştir. CBAM-ResNet152V2 modeli, 40X'te %94,16 ile en yüksek tek doğruluk oranını elde etti, bunu 100X'te %85,92, 200X'te %84,77 ve 400X'te %84,62 izledi. CBAM-MobileNetV2 modeli, büyütme seviyeleriyle birlikte kademeli bir iyileşme göstererek 40X'te %79,47, 100X'te %83,20, 200X'te %84,44 ve 400X'te %85,71 doğruluk elde etti.


4.16 Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM)

Gradyan Ağırlıklı Sınıf Aktivasyon Haritalaması (Grad-CAM), evrişimsel sinir ağlarının (CNN) verdiği kararları yorumlamak ve anlamak için kullanılan bir görselleştirme tekniğidir. Tahmin yaparken modelin odaklandığı girdi görüntüsündeki önemli bölgeleri vurgular. Bu, tahmin edilen sınıf puanının son evrişim katmanının özellik haritalarına göre gradyanlarının (türevlerinin) hesaplanmasıyla sağlanır. Elde edilen bu gradyanlar, özellik haritalarını ağırlıklandırmak için kullanılır ve özgün görüntü üzerine bindirilen bir ısı haritası üretilir.

Bu çalışmada, modelin kararını etkileyen bölgeleri görselleştirmek amacıyla sekiz farklı meme kanseri alt tipine ait örnek histopatolojik görüntülere Grad-CAM uygulanmıştır. Gösterildiği üzere,

her satır bir alt tipi temsil ederken, her sütun sırasıyla özgün görüntüyü, karşılık gelen Grad-CAM ısı haritasını ve ikisinin bindirmesini sunmaktadır. Bu yaklaşım, modelin tanısal açıdan ilgili bölgelere odaklandığını doğrulamakla kalmaz; aynı zamanda tıbbi alanda derin öğrenme modelinin tahminlerine yönelik açıklanabilirliği ve güveni de artırır.





Şekil 5.48. Meme kanseri histopatolojik görüntülerinin Grade-Cam'i

5.17 Tartışma

Bu deneysel çalışmada farklı derin öğrenme modellerinin karşılaştırmalı analizi, çok sınıflı meme kanseri histopatoloji sınıflandırmasında karşılaşılan zorluklar ve çözümler hakkında birkaç önemli içgörü ortaya koymaktadır. Araştırma boyunca, sınıf dengesizliği, sınırlı veri çeşitliliği ve sağlam, genelleştirilebilir özellik çıkarma ihtiyacı gibi temel sorunların ele alınmasına önemli ölçüde çaba harcanmıştır. Sonuçlar, gelişmiş model mimarileri, veri artırma ve dikkat mekanizmalarının stratejik birleşiminin sınıflandırma performansını önemli ölçüde artırabileceğini göstermektedir.

Test edilen tüm modeller arasında, veri artırmanın entegrasyonu, sınıflandırma sonuçlarının hem istikrarını hem de doğruluğunu artırmada önemli bir faktör olarak ortaya çıkmıştır. Artırma, sınıf dengesizliği sorununu çözmede özellikle etkili olmuş ve her alt türün öğrenme sürecine eşit katkıda bulunmasını sağlamıştır. Bu dengeleme, çoğunluk sınıflarına yönelik önyargıyı azaltmakla kalmamış, aynı zamanda modellerin tüm kategorilerde ince, ayırt edici özellikleri yakalamasını da sağlamış ve test doğruluğunda belirgin bir artışa yol açmıştır. Dengeli ve artırılmış veri kümeleriyle eğitilen modeller, daha yüksek doğruluk oranları, daha düzgün öğrenme eğrileri ve daha güvenilir karışıklık matrisleri ile kanıtlandığı üzere, artırılmamış modellerden tutarlı bir şekilde daha iyi performans gösterdi.


Dikkat mekanizmalarının, özellikle CBAM ve SE modüllerinin eklenmesi, modellerin karmaşık histopatolojik görüntülerdeki en alakalı özelliklere odaklanma kapasitesini daha da geliştirdi. Örneğin, CBAM-MobileNetV2 modeli, değerlendirilen tüm ağlar arasında en yüksek test doğruluğunu elde etti ve bu, ayırt edici gücü artırmada kanal bazında yeniden kalibrasyonun önemli faydasını yansıtmaktadır. Benzer şekilde, SE ile geliştirilmiş mimariler, önemli uzamsal ve kanala özgü bilgileri uyarlanabilir bir şekilde vurgulayarak üstün performans gösterdi. Bu bulgular,

dikkat mekanizmalarının, özellikle tıbbi görüntü analizi görevlerinde, öğrenilen temsillerin derinliğini ve alaka düzeyini artırmak için paha biçilmez araçlar olduğunu doğrulamaktadır.

Veri dengesizliği ve yetersiz özellik odaklanma gibi ikili zorlukları ele alan deneysel süreç, sağlam ve tekrarlanabilir sınıflandırma sonuçları elde etmeyi başardı. Dengeli veri artırma, transfer öğrenimi ve dikkat modüllerinin birleşik uygulaması, en iyi performans gösteren yapılandırmalarda %97'ü aşan test doğruluklarının elde edilmesini sağladı. Bu doğruluk seviyesi, otomatik meme kanseri teşhisi bağlamında önemlidir, çünkü klinik kullanım için adil, güvenilir ve ölçeklenebilir teşhis araçlarının geliştirilmesini destekler.

Tablo 5.30. Tüm Modeller için Performans İstatistikleri

En İyi Modellerin Performanslarının Karşılaştırılması				
Model Adı	Data Augmentation	Attention Mechanism	Training Accuracy	Test Accuracy
ResNet152V2	Yes	No	97.79%	95.74%
ResNet152V2	No	No	98.97%	86.35%
CBAM-ResNet152V2	Yes	CBAM	93.36%	90.38%
CBAM-ResNet152V2	No	CBAM	98.92%	87.32%
SE-ResNet152V2	Yes	SE	98.52%	97.04%
SE-ResNet152V2	No	SE	98.72%	84.66%
MobileNetV2	Yes	No	98.52%	97.62%
MobileNetV2	No	No	99.96%	83.94%
CBAM-MobileNetV2	Yes	CBAM	98.82%	98.35%
CBAM-MobileNetV2	No	CBAM	99.96%	83.94%
SE-MobileNetV2	Yes	SE	98.73%	97.75%
SE-MobileNetV2	No	SE	97.33%	71.72 %



Şekil 5.49. Eğitim ve Test doğruluk karşılaştırması

Tablo 5.31. Meme kanseri histopatolojik görüntü sınıflandırması için derin öğrenme modellerinin önceki çalışmalar ve önerilen çalışma ile karşılaştırmalı performansı

References	Model	Task	Attention Mechanism	Test Accuracy
Çetin-Kaya, 2024	ResNet152V2	MultiClass	No	91.15%
Zhang ve ark., 2023	CBAM-ResNet	MultiClass	CBAM	86.7%
Alqahtani, ve ark., 2022	SE-ResNet18	MultiClass	SE	83.56%
S. Sumaiyya ve ark., 2024	MobileNetV2	MultiClass	NO	85-87%
Rakha, M.ve ark., 2024	CBAM-MobileNetV2	MultiClass	CBAM	93%
Lawal ve ark., 2025	D-ResNet + Random Forest (replaces Softmax)	Binary	NO	400X = 92.34%
Aldakhil ve ark., 2024	ECSAnet (EfficientNetV2-S + CBAM)	MultiClass	CBAM	40X= 94.2% @ 100X= 92.96% 200X= 88.41% 400X= 89.42%
Proposed Study	SE-ResNet152V2	Binary	SE	100X= 98.72%
Proposed Study	CBAM-ResNet152V2	MultiClass	CBAM	40X=94.16%
Proposed Study	CBAM-MobileNetV2	MultiClass	CBAM	98.35%

6 SONUÇ VE GELECEK ÇALIŞMALAR

6.1 Sonuçlar

Bu tez, meme kanseri histopatolojik görüntülerinin çok sınıflı sınıflandırılması için gelişmiş derin öğrenme modellerinin uygulanmasına ilişkin kapsamlı bir araştırma sunmuştur. Sistematiik ve titiz bir deneysel çerçeve aracılığıyla, ResNet152V2, CBAM-ResNet152V2, SE-ResNet152V2, MobileNetV2, CBAM-MobileNetV2 ve SE-MobileNetV2 dahil olmak üzere çok sayıda mimari, dikkat mekanizmaları ve veri artırma ile ve bunlar olmadan çeşitli yapılandırmalar altında değerlendirilmiştir.

Bu araştırmanın en önemli bulgularından biri, dengeli veri artırımı ile en son teknoloji dikkat modüllerinin birleştirilmesinin dönüştürücü etkisidir. Veri artırımı ile CBAM-MobileNetV2 modeli, %97.34 ile en yüksek test doğruluğunu elde ederek, otomatik meme kanseri alt tipi sınıflandırması için yeni bir referans noktası oluşturmuştur. Bu sonuçlar, kanal ve uzamsal dikkat mekanizmaları gibi mimari yeniliklerin, sağlam, çeşitli ve dengeli eğitim verileri ile birleştirildiğinde en etkili olduğunu vurgulamaktadır.

Çalışma ayrıca, dikkatli veri hazırlamanın ağ tasarımı kadar önemli olduğunu ortaya koymuştur. Artırma, veri kümesinin çeşitliliğini artırmakla kalmamış, sınıf dengesizliğini de gidererek daha eşit ve adil bir model eğitimi sağlamıştır. Dikkat mekanizmaları, modellerin sınıfları tanımlayan ince özelliklere odaklanma yeteneğini daha da geliştirmiştir. Bu, sınıflar arası farkların minimum düzeyde olabileceği tıbbi görüntü analizinde özellikle önemlidir.

Deneyler, MobileNetV2 gibi hafif modellerin, özellikle dikkat modülleriyle geliştirildiğinde ve dengeli veri kümeleri üzerinde eğitildiğinde, gerçek zamanlı veya kaynak kısıtlı klinik uygulamalar için yol açan, saygın bir doğruluk elde edebileceğini doğruladı. Bununla birlikte, SE-

ResNet152V2 gibi daha derin mimariler, mutlak doğruluk ve sağlamlık açısından üstün olmaya devam ediyor ve bu da onları hassasiyetin çok önemli olduğu teşhis görevleri için ideal hale getiriyor.

6.2 Zorluklar ve Sınırlamalar

Elde edilen başarılarla rağmen, bu araştırma sırasında birkaç zorluk ve sınırlama ile karşılaşıldı. Başlıca zorluk, orijinal BreakHis veri setindeki doğal sınıf dengesizliğiydi. Bu sorun çözülmezse, modeller çoğunluk sınıflarına yönelmiş ve genelleme yetenekleri ciddi şekilde sınırlanmış olacaktı. Veri artırma uygulaması bu sorunu hafifletmede etkili oldu.

Diğer bir sınırlama, derin dikkat tabanlı modellerin eğitimi ile ilgili hesaplama gereksinimleriydi. SE-ResNet152V2 ve CBAM-ResNet152V2 gibi modeller, özellikle artırılmış, yüksek çözünürlüklü veri kümeleri üzerinde eğitildiğinde, önemli miktarda işlem gücü ve bellek gerektiriyordu. Bu durum bazen deneylerin ölçeğini kısıtladı, parti boyutlarını sınırladı ve eğitim sürelerini uzattı.

Araştırma, sabit sayıda görüntü büyütme seviyesi ve daha büyük, daha çeşitli histopatolojik veri kümelerine erişim eksikliği nedeniyle de kısıtlandı. Artırma, görünür veri kümesi boyutunu genişletti, ancak temel veriler değişkenlik ve kaynak çeşitliliği açısından sınırlı kaldı, bu da modellerin farklı kurumlardan veya popülasyonlardan elde edilen görüntülere genellenebilirliğini etkileyebilir.

Ek olarak, dikkat mekanizmaları özellik seçimini kanıtlanabilir şekilde iyileştirirken, tam yorumlanabilirlikleri hala bir zorluktur. Hangi görüntü bölgelerinin belirli tahminlere katkıda bulunduğunu ve bunların klinik patolojiyle nasıl ilişkili olduğunu tam olarak anlamak, muhtemelen açıklanabilir AI teknikleri aracılığıyla daha fazla araştırma gerektirir.

Çok modlu verilerin (ör. klinik ve genomik bilgiler) entegrasyonu, yarı denetimli veya kendi kendine denetimli öğrenmenin kullanılması veya slayt düzeyinde tanı için uçtan uca sistemlerin geliştirilmesi gibi bazı umut verici araştırma yönleri, zaman ve kaynak sınırlamaları nedeniyle bu tezin kapsamı dışındaydı.

6.3 Gelecekteki Çalışmalar

Bu araştırmanın bulgularına ve derslerine dayanarak, gelecekteki çalışmalar için birkaç yol önerilmektedir. İlk olarak, veri setinin birden fazla kurumdan ve görüntüleme cihazından daha geniş bir histopatolojik görüntü yelpazesini içerecek şekilde genişletilmesi, modellerin genelleştirilebilirliğini ve klinik uygunluğunu artıracaktır. Uzmanlarca açıklanmış veri kümeleri elde etmek ve model tahminlerini gerçek klinik iş akışlarında doğrulamak için tıp uzmanlarıyla iş birliği yapılması da önerilmektedir.

Transformatör tabanlı modeller veya karma ağlar gibi daha gelişmiş dikkat mekanizmalarının veya hibrit mimarilerin dahil edilmesi, özellik çıkarma ve sınıflandırma doğruluğunu daha da artırabilir. Açıklanabilir YZ yöntemlerinin araştırılması da daha fazla şeffaflık sağlayarak patologlar ve klinisyenler arasında otomatik sistemlere güven oluşturmaya yardımcı olacaktır.

Umut vaat eden bir başka yön de, hasta klinik kayıtları, radyoloji ve genetik bilgiler dahil olmak üzere çok modlu verilerin sınıflandırma hattına entegre edilmesidir. Bu, daha bütünsel, hastaya özgü tahminler yapılmasını sağlayabilir ve hassas tıp yaklaşımlarını destekleyebilir.

Son olarak, bu modellerin gerçek zamanlı klinik ortamlarda, kullanıcı dostu arayüzler ve sağlam son işlemlerle kullanılması, pratikte benimsenmesi için önemli bir adım olacaktır. Son kullanıcılardan gelen sürekli geri bildirimler ve gerçek dünya performansına dayalı yinelemeli iyileştirme, güvenli, etkili ve eşitlikçi tanı araçları sağlamak için çok önemli olacaktır.

7 KAYNAKLAR

- Aldakhil, L. A., Alhasson, H. F., & Alharbi, S. S. (2024). Attention-based deep learning approach for breast cancer histopathological image multi-classification. *Diagnostics*, 14(13), 1402. <https://doi.org/10.3390/diagnostics14131402>
- Alirezazadeh, P., & Dornaika, F. (2023). Boosted Additive Angular Margin Loss for breast cancer diagnosis from histopathological images. *Computers in Biology and Medicine*.
- Aljuaid, H., Alturki, N., Alsubaie, N., Cavallaro, L., & Liotta, A. (2022). Computer-aided diagnosis for breast cancer classification using deep neural networks and transfer learning. *Computer Methods and Programs in Biomedicine*, 223, 106951.
- Alom, M. Z., Yakopcic, C., Nasrin, M. S., & Taha, T. M., & Asari, V. K. . (2019). Breast Cancer Classification from Histopathological Images with Inception Recurrent Residual Convolutional Neural Network. *Journal of Digital Imaging*, 32(4), 605–617.
- Alqahtani, Y., Mandawkar, U., Sharma, A., Hasan, M. N. S., Kulkarni, M. H., & Sugumar, R. (2022). Breast cancer pathological image classification based on the multiscale CNN squeeze model. *Computational Intelligence and Neuroscience*, 2022(1), 7075408.
- Araujo, T., Aresta, G., Castro, E., Rouco, J., Aguiar, P., Eloy, C., & Campilho, A. (2017). Classification of breast cancer histology images using Convolutional Neural Networks. *PLoS ONE*, 12(6), e0177544. <https://doi.org/10.1371/journal.pone.0177544>
- Arrieta, A. B., Diaz-Rodriguez, N., Del Ser, J., Bennetot, A., Tabik, S., Barbado, A., & Herrera, F. (2020). Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Information Fusion*, 58, 82–115. <https://doi.org/10.1016/j.inffus.2019.12.012>
- Atabansi, C. C., Nie, J., Liu, H. (2023). A survey of Transformer applications for histopathological image analysis: New developments and future directions. *BioMed Eng OnLine*, 22, 96. <https://doi.org/10.1186/s12938-023-01157-0>
- Carels, N., Spinassé, L. B., Tilli, & T. M., T., J. A. (2016). Toward precision medicine of breast cancer. *Theoretical Biology and Medical Modelling*, 13(1), 7.
- Çetin-Kaya, Y. (2024). Equilibrium Optimization-Based Ensemble CNN Framework for Breast Cancer Multiclass Classification Using Histopathological Image. *Diagnostics*, 14(9), 2253.
- Chattopadhyay, S., Dey, A., Singh, P. K., Oliva, D., Cuevas, E., & Sarkar, R. (2022). MTRRE-Net: A deep learning model for detection of breast cancer from histopathological images. *Computers in Biology and Medicine*, 150, 106155.
- Cheng, J. Z., Ni, D., Chou, Y. H., Qin, J., & Tiu, C. M., Chang, Y. C., ... & Chen, C. M. (2021). Computer-aided diagnosis with deep learning architecture: Applications to breast lesions in US images and pulmonary nodules in CT scans. *Scientific Reports*, 6(1), 24454. <https://doi.org/10.1038/srep24454>
- Cireşan, D. C., Giusti, A., & Gambardella, L. M., & Schmidhuber, J. (2013). Mitosis detection in breast cancer histology images with deep neural networks. *Medical Image Computing and Computer-Assisted Intervention*, 16(pt 2), 411–418. https://doi.org/10.1007/978-3-642-40763-5_51

- Cömert, D., van Gils, C. H., Veldhuis, W. B., & Mann, R. M. (2023). Challenges and changes of the breast cancer screening paradigm. *Journal of Magnetic Resonance Imaging*, 57(3), 706–726. <https://doi.org/10.1002/jmri.28495>
- Cruz-Roa, A., Basavanthally, A., Gonzalez, F., Gilmore, H., & Feldman, M., Ganesan, S., ... & Madabhushi, A. (2014). Automatic detection of invasive ductal carcinoma in whole slide images with convolutional neural networks. *Medical Imaging 2014: Digital Pathology*, 9041, 904103. <https://doi.org/10.1117/12.2043872>
- Das, H. S., Borah, K., & Bora, K. (2025). Ensemble Learning Approach for Detecting Breast Invasive Ductal Carcinoma from Histopathological Images. *Pathology-Research and Practice*, 156041.
- Deng, S., Zhang, X., Yan, W., Chang, E. I., Fan, Y., Lai, M., & Xu, Y. (2020). Deep learning in digital pathology image analysis: a survey. *Frontiers in Medicine*, 14(4), 470–487. <https://doi.org/10.1007/s11684-020-0782-9>
- Doyle, S., Feldman, M. D., Shih, N., & Tomaszewski, J., & Madabhushi, A. (2012). Cascaded discrimination of normal, abnormal, and confounder classes in histopathology: Gleason grading of prostate cancer. *BMC bioinformatics*, 13(1), 282. <https://doi.org/10.1186/1471-2105-13-282>
- Elmore, J. G., Longton, G. M., Carney, P. A., & Geller, B. M., Onega, T., Tosteson, A. N., ... & Weaver, D. L. (2015). Diagnostic concordance among pathologists interpreting breast biopsy specimens. *JAMA*, 313(11), 1122–1132. <https://doi.org/10.1001/jama.2015.1405>
- Esteva, A., Chou, K., Yeung, S., Naik, N., Madani, A., Mottaghi, A., ... & Socher, R. (2021). Deep learning-enabled medical computer vision. *NPJ Digital Medicine*, 4, 1. <https://doi.org/10.1038/s41746-020-00376-2>
- Frid-Adar, M., Klang, E., Amitai, M., Goldberger, J., & Greenspan, H. (2018). Synthetic data augmentation using GAN for improved liver lesion classification. In *2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018)* 289. <https://doi.org/10.1109/ISBI.2018.8363576>
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep Learning* (Vol. 1). Cambridge: MIT Press.
- Hamilton, P. W., Bankhead, P., Wang, Y., & Hutchinson, R., Kieran, D., McArt, D. G., ... & Salto-Tellez, M. . (2014). Digital pathology and image analysis in tissue biomarker research. *Methods*, 70(1), 59–73. <https://doi.org/10.1016/j.ymeth.2014.06.015>.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition*
- Hossain, M. I., Zamzmi, G., Mouton, P. R., & Salekin, M. S., Sun, Y., & Goldgof, D. (2025). Explainable AI for medical data: Current methods, limitations, and future directions. *ACM Computing Surveys*, 57(6), 1–46. <https://doi.org/10.1145/363748>
- Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-excitation networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition*,
- Ioffe, S., & Szegedy, C. (2015, June). Batch normalization: Accelerating deep network training by reducing internal covariate shift. In *International conference on machine learning*.
- Jiang, Y., Chen, L., Zhang, H., & Xiao, X. (2019). Breast cancer histopathological image classification using convolutional neural networks with small SE-ResNet module. *PLOS ONE*, 14(3), e0214587. <https://doi.org/10.1371/journal.pone.0214587>

- Jiang, B., Bao, L., & He, S. (2024). Deep learning applications in breast cancer histopathological imaging: diagnosis, treatment, and prognosis. *Breast Cancer Res* 26, 137. <https://doi.org/10.1186/s13058-024-01895-6>
- Johnson, J. A., Moore, B. J., Syrnioti, G., Eden, C. M., Wright, D., & Newman, L. A. (2023). Landmark series: the cancer genome atlas and the study of breast cancer disparities. *Annals of Surgical Oncology*, 30(11), 6427-6440.
- Kaplan, E., Güler, S., & Temurtas, F. (2020). Brain MRI Image Classification Using Local Binary Patterns and Machine Learning Methods. *Engineering Science and Technology*, 23(5), 1226–1233.
- Kaya, M. (2023). Bayesian Optimization-based CNN Framework for Automated Detection of Brain Tumors. *Balkan Journal of Electrical and Computer Engineering*, 11(4), 395–404.
- Kaya, M., & Çetin-Kaya, Y. (2024). A novel deep learning architecture optimization for multiclass classification of Alzheimer's disease level. *IEEE Access*, 12, 46562–46581.
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. (2012). ImageNet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems (NeurIPS)* (pp. 1097–1105).
- Lahoura, V., Singh, H., Aggarwal, A., Sharma, B., & Mohammed, M. A., Damaševičius, R., Kadry, S., & Cengiz, K. (2021). Cloud Computing-Based Framework for Breast Cancer Diagnosis Using Extreme Learning Machine. *Diagnostics (Basel, Switzerland)*, 11(2), 241. <https://doi.org/10.3390/diagnostics11020241>
- Lamprou, V., Kallipolitis, A., & Maglogiannis, I. (2024). On the evaluation of deep learning interpretability methods for medical images under the scope of faithfulness. *Computer Methods and Programs in Biomedicine*, 253, 108238.
- Lawal, M. K. B., Almousa, M., Ibrahim, A. U., Pwavodi, P. C., Usman, A. G., & Aloraini, B. (2025). Artificial intelligent-powered detection of breast cancer. *Journal of Radiation Research and Applied Sciences*, 18(2), 101422 <https://doi.org/10.1016/j.jrras.2025.101422>
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Li, X., Li, M., Yan, P., Li, G., Jiang, Y., Luo, H., & Yin, S. . (2023). Deep Learning Attention Mechanism in Medical Image Analysis: Basics and Beyonds. *International Journal of Network Dynamics and Intelligence*, 2(1), 93–116. <https://doi.org/10.53941/ijndi0201006>
- Li, X., Wang, W., Hu, X., & Yang, J. (2019). Selective Kernel Networks.
- Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., & Ghafoorian, M., ... & van der Laak, J. A. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, 42, 60–88. <https://doi.org/10.1016/j.media.2017.07.005>
- Maurya, R., Pandey, N. N., Dutta, M. K., & Karnati, M. (2024). FCCS-Net: Breast cancer classification using Multi-Level fully Convolutional-Channel and spatial attention-based transfer learning approach. *Biomedical Signal Processing and Control*, 94, 106258.
- Nagpal, K., Foote, D., Liu, Y., Chen, P. H. C., Wulczyn, E., Tan, F., & Stumpe, M. C. (2019). Development and validation of a deep learning algorithm for improving Gleason scoring of prostate cancer. *NPJ Digital Medicine*, 2(1), 48. <https://doi.org/10.1038/s41746-019-0112-2>
- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted boltzmann machines. In *Proceedings of the 27th international conference on machine learning (ICML-10)*

- Pacal, I., & Attallah, O. (2025). InceptionNeXt-Transformer: A novel multi-scale deep feature learning architecture for multimodal breast cancer diagnosis. *Biomedical Signal Processing and Control*, 110, 108116.
- Pan, S. J., & Yang, Q. (2009). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>
- Patel, R., Klein, P., Tiersten, A., & Sparano, J. A. (2023). An emerging generation of endocrine therapies in breast cancer: a clinical perspective. *NPJ Breast Cancer*, 9(1), 20.
- Perry, N., Broeders, M., Wolf, C., Törnberg, S., & Holland, R. v. K., L. (2008). European guidelines for quality assurance in breast cancer screening and diagnosis. Fourth edition--summary document. *Annals of oncology : official journal of the European Society for Medical Oncology*, 19(4), 614–622. <https://doi.org/10.1093/annonc/mdm481>
- Rafiq, A., Jaffar, A., Latif, G., Masood, S., & Abdelhamid, S. E. (2025). Enhanced Multi-Class Breast Cancer Classification from Whole-Slide Histopathology Images Using a Proposed Deep Learning Model. *Diagnostics*, 15(5), 582.
- Ragab, D. A., Attallah, O., Sharkas, M., & Ren, J., & Marshall, S. (2021). A framework for breast cancer classification using multi-DCNNs. *Computers in Biology and Medicine*, 131, 104245. <https://doi.org/10.1016/j.compbiomed.2021.104245>
- Raghu, M., Zhang, C., Kleinberg, J., & Bengio, S. (2019). Transfusion: Understanding transfer learning for medical imaging. *Advances in neural information processing systems NeurIPS*, 32.
- Rakha, M., Sulistiyo, M. D., Nasien, D., & Ridha, M. (2024). A Combined MobileNetV2 and CBAM Model to Improve Classifying the Breast Cancer Ultrasound Images. *Journal of Applied Engineering and Technological Science (JAETS)*, 6(1), 561–578. <https://doi.org/10.37385/jaets.v6i1.4836>.
- Ross, J. S., Ali, S. M., Wang, K., Khaira, D., Palma, N. A., & Chmielecki, J., Palmer, G. A., Morosini, D., Elvin, J. A., Fernandez, S. V., Miller, V. A., Stephens, P. J., & Cristofanilli, M. (2015). Comprehensive genomic profiling of inflammatory breast cancer cases reveals a high frequency of clinically relevant genomic alterations. *Breast cancer research and treatment*, 154(1), 155–162. <https://doi.org/10.1007/s10549-015-3592-z>
- S. Sumaiyya, S. G, N.R, L., & B, P. G. (2024). Breast Cancer Detection with MobileNetV2 and Explainable AI. 4th International Conference on Sustainable Expert Systems (ICSSES), Kaski, Nepal.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks.
- Scherer, D., Müller, A., & Behnke, S. (2010). Evaluation of pooling operations in convolutional architectures for object recognition. In *ICANN*.
- Sengodan, N. (2024). Breast Cancer Histopathology Classification using CBAM-EfficientNetV2 with Transfer Learning. *arXiv preprint arXiv:2410.22392*.
- Shams Rana, A., Rafique, J., & Riffat, H. (2024). Advances in Breast Ultrasound Imaging: Enhancing Diagnostic Precision and Clinical Utility. *IntechOpen*. <https://doi.org/10.5772/intechopen.1005373>
- Shen, D., Wu, G., & Suk, H. I. (2021). Deep learning in medical image analysis. *Annual Review of Biomedical Engineering*, 19, 221–248.

- Shen, L., Margolies, L. R., Rothstein, J. H., Fluder, E., McBride, R., & Sieh, W. (2019). Deep learning to improve breast cancer detection on screening mammography. *Scientific Reports*, 9(1), 12495. <https://doi.org/10.1038/s41598-019-48995-4>
- Simonyan, K., & Zisserman, A. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition.
- Sirinukunwattana, K., Raza, S. E. A., Tsang, Y. W., & Snead, D. R. J., Cree, I. A., & Rajpoot, N. M. (2017). Locality sensitive deep learning for detection and classification of nuclei in routine colon cancer histology images. *IEEE Transactions on Medical Imaging*, 35(5), 1196–1206. <https://doi.org/10.1109/TMI.2016.2525803>
- Smith, R. A., Duffy, S. W., Gabe, R., Tabár, L., & Yen, A. M. F. (2004). The randomized trials of breast cancer screening: What have we learned? *Radiologic Clinics of North America*, 42(5), 793–806. <https://doi.org/10.1016/j.rcl.2004.06.014>
- Spanhol, F. A., Oliveira, L. S., Petitjean, C., & Heutte, L. (2016). A Dataset for Breast Cancer Histopathological Image Classification. *IEEE Transactions on Biomedical Engineering*, 63(7), 1455–1462. <https://doi.org/10.1109/TBME.2015.2496264>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *Journal of Machine Learning Research*, 15, 1929–1958.
- Sung, H., Ferlay, J., Siegel, R. L., Laversanne, M., Soerjomataram, I., Jemal, A., & Bray, F. (2021). Global cancer statistics 2020: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*, 71(3), 209–249. <https://doi.org/10.3322/caac.21660>
- Szegedy, C., Liu, W., & Jia, Y. (2015, 2015). Going deeper with convolutions.
- Tellez, D., Litjens, G., Bándi, P., Bulten, W., & Bokhorst, J. M., Ciompi, F., & van der Laak, J. (2019). Quantifying the effects of data augmentation and stain color normalization in convolutional neural networks for computational pathology. *Medical Image Analysis*, 58, 101544. <https://doi.org/10.1016/j.media.2019.101544>
- Terry, S. F., & McLeod, H. L. (2019). The impact of precision medicine on breast cancer therapy. *Pharmacogenomics and Personalized Medicine*, 12, 113–123. <https://doi.org/10.2147/PGPM.S206043>
- Tian, Y., Xu, Z., Ma, Y., Ding, W., Wang, R., & Gao, Z., ... & Zhao, X. . (2023). Survey on deep learning in multimodal medical imaging for cancer detection. *Neural Computing and Applications*, 1–16. <https://doi.org/10.1007/s00521-023-09214-4>
- Weinstein, Susan. (2009). Evolving Role of MRI in Breast Cancer Imaging. *PET clinics*, 4(3), 241–253. <https://doi.org/10.1016/j.cpet.2009.09.003>
- WHO, W. H. (2023). Breast cancer. In.
- Woo, S., Park, J., Lee, J. Y., & Kweon, I. S. (2018). CBAM: Convolutional block attention module. In Proceedings of the European conference on computer vision (ECCV),
- World Cancer Research Fund International, W. C. R. F. I. (2022). Breast cancer statistics. In.
- Zhang, Y., Feng, W., Wu, Z., Li, W., Tao, L., Liu, X., ... & Guo, X. (2023). Deep-learning model of ResNet combined with CBAM for malignant–benign pulmonary nodules classification on computed tomography images. *Medicina*, 59(6), 1088.
- Lawal, M. K. B., Almousa, M., Ibrahim, A. U., Pwavodi, P. C., Usman, A. G., & Aloraini, B. (2025). Artificial intelligent-powered detection of breast cancer. *Journal of Radiation Research and Applied Sciences*, 18(2), 101422.

<https://doi.org/10.1016/j.jrras.2025.101422>

- Clement, D., Agu, E., Suleiman, M. A., Obayemi, J., Adeshina, S., & Soboyejo, W. (2022). Multi-class breast cancer histopathological image classification using multi-scale pooled image feature representation (mpifr) and one-versus-one support vector machines. *Applied Sciences*, 13(1), 156.
- Zhao, M., Hou, C., Cao, L., & Zhang, J. (2025). Breast Cancer Histopathological Image Classification Based on High-Order Modeling and Multi-Branch Receptive Fields. *Applied Sciences*, 15(11), 6085s.



ÖZGEÇMİŞ

