T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

CİLT KANSERİ SINIFLANDIRMASI İÇİN HİBRİT DERİN ÖĞRENME MODELLERİNİN GELİŞTİRİLMESİ

Hazırlayan
İbrahim ARUK

Danışman
Dr. Öğr. Üyesi Ahmet Nusret TOPRAK

Doktora Tezi

Kasım 2024
KAYSERİ

T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

CİLT KANSERİ SINIFLANDIRMASI İÇİN HİBRİT DERİN ÖĞRENME MODELLERİNİN GELİŞTİRİLMESİ

(Doktora Tezi)

Hazırlayan
İbrahim ARUK

Danışman
Dr. Öğr. Üyesi Ahmet Nusret TOPRAK

Kasım 2024
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

İbrahim ARUK

“Cilt Kanseri Sınıflandırması için Hibrit Derin Öğrenme Modellerinin Geliştirilmesi” adlı Doktora tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ne uygun olarak hazırlanmıştır.

Hazırlayan
İbrahim ARUK

Danışman
Dr. Öğr. Üyesi Ahmet Nusret TOPRAK

Bilgisayar Mühendisliği ABD Başkanı
Prof. Dr. Veysel ASLANTAŞ

TEŞEKKÜR

Doktora çalışmamın başarı ile tamamlanması, birçok kişinin desteği ve emeği ile mümkün olmuştur. En başta danışmanım Dr. Öğr. Üyesi Ahmet Nusret TOPRAK'a çok değerli bilgi ve birikimleri ile bana sağladığı katkılardan dolayı teşekkür ediyorum. Tez izleme kurulu üyeleri Prof. Dr. Celal ÖZTÜRK ve Doç. Dr. Selçuk ASLAN'a çalışmalarımın bu aşamaya gelmesinde sağladıkları katkılarından dolayı şükranlarımı sunuyorum. Doktora eğitimim boyunca hiçbir zaman bilgi ve katkılarını esirgemeyen Dr. Öğr. Üyesi Turab SELÇUK ve Dr. Öğr. Üyesi İshak PAÇAL'a desteklerinden dolayı teşekkür ediyorum. Ayrıca tüm bu süreç boyunca moral ve motivasyon ile bana destek olan ailem ve dostlarıma şükranlarımı sunuyorum.

Son olarak üzerimde büyük emeği olan anneme, doktora sürecimin başından sonuna kadar, sevgi, sabır ve desteklerini esirgemeyen sevgili eşim Emine ARUK'a, oğullarım Hasan Emre ve Hüseyin Bera ile canım kızım Ahsen Neva'ya en kalbi teşekkürlerimi sunarım.

İbrahim ARUK

Kasım 2024, KAYSERİ

CİLT KANSERİ SINIFLANDIRMASI İÇİN HİBRİT DERİN ÖĞRENME MODELLERİNİN GELİŞTİRİLMESİ

İbrahim ARUK

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Doktora Tezi, Kasım 2024
Danışman : Dr. Öğr. Üyesi Ahmet Nusret TOPRAK

ÖZET

Kanser, dünya çapında milyonlarca insanın yaşamını tehdit eden ve çeşitli organları etkileyen ölümcül bir hastalıktır. En sık rastlanan kanser türlerinden biri olan cilt kanseri, erken evrede teşhis edilmediğinde ciddi sağlık sorunlarına ve ölüm riskine yol açabilmektedir. Cilt kanseri oluşumunda güneş ışığındaki ultraviyole radyasyon, sigara ve alkol kullanımı, genetik yatkınlık, belirli hastalıklar ve çevresel faktörler önemli rol oynamaktadır. Bu etmenler cilt hücrelerinin DNA'sına zarar vererek kanser riskini artırabilmektedir. Bu nedenle, cilt kanserinin erken evrede teşhisi, hastalığın kontrol altına alınması ve tedavi süreçlerinde kritik bir öneme sahiptir.

Bu tez çalışmasında, cilt kanseri sınıflandırması problemine yönelik üç yeni hibrit derin öğrenme modeli önerilmektedir. İlk modelde, dermoskopik görüntülerden farklı Evrişimsel Sinir Ağı (CNN) modelleri aracılığıyla derin öznitelikler çıkarılmakta ve öznitelik seçimi algoritmaları ile en anlamlı öznitelikler belirlenerek sınıflandırma yapılmaktadır. İkinci olarak, ConvNeXt blokları ile güçlendirilmiş MetaFormer tabanlı hibrit CAFormer modeli geliştirilmiştir. Bu model, CNN ve Görü Dönüştürücü (ViT) tabanlı mimarilerin güçlü yönlerini bir araya getirerek cilt kanseri sınıflandırmasını gerçekleştirmektedir. Son olarak, CNN ve ViT modelleri ile topluluk öğrenme tabanlı hibrit bir model önerilmiştir. Bu model dermoskopik görüntü sınıflandırmasını etkin bir şekilde sağlamaktadır. Önerilen modeller, literatürdeki güncel yaklaşımlar ile karşılaştırıldığında cilt kanseri sınıflandırmasında daha başarılı sonuçlar sergilemiştir.

Anahtar Kelimeler: Cilt kanseri sınıflandırma, evrişimsel sinir ağları, görü dönüştürücü, topluluk öğrenme

DEVELOPMENT OF HYBRID DEEP LEARNING MODELS FOR SKIN CANCER CLASSIFICATION

İbrahim ARUK

Erciyes University, Graduate School of Natural and Applied Sciences
Ph.D. Thesis, November 2024
Supervisor: Asst. Prof. Dr. Ahmet Nusret TOPRAK

ABSTRACT

Cancer is a fatal disease that threatens the lives of millions worldwide and affects various organs. Among the most common cancer types, skin cancer can lead to severe health complications and an increased risk of mortality if not diagnosed at an early stage. Ultraviolet radiation from sunlight, smoking, alcohol consumption, genetic predisposition, certain diseases, and environmental factors play significant roles in the development of skin cancer. These factors can damage the DNA of skin cells, increasing the risk of cancer. Therefore, early diagnosis of skin cancer is crucial for controlling the disease and improving treatment outcomes.

In this thesis, three novel hybrid deep learning models are proposed for addressing the skin cancer classification problem. In the first model, deep features are extracted from dermoscopic images using various Convolutional Neural Network (CNN) models, and classification is performed by selecting the most significant features through feature selection algorithms. Secondly, a hybrid CAFormer model based on a MetaFormer architecture enhanced with ConvNeXt blocks has been developed. This model integrates the advantages of CNN and Vision Transformer (ViT)-based architectures to perform skin cancer classification. Lastly, a hybrid ensemble learning-based model combining CNN and ViT architectures is proposed, offering an effective approach to dermoscopic image classification. The proposed models have demonstrated superior performance in skin cancer classification compared to state-of-the-art approaches in the literature.

Keywords: Skin cancer classification, convolutional neural networks, vision transformer, ensemble learning

İÇİNDEKİLER

CİLT KANSERİ SINIFLANDIRMASI İÇİN HİBRİT DERİN ÖĞRENME MODELLERİNİN GELİŞTİRİLMESİ

BİLİMSEL ETİĞE UYGUNLUK ii
YÖNERGEYE UYGUNLUK iii
KABUL VE ONAY iv
TEŞEKKÜR v
ÖZET vi
ABSTRACT vii
İÇİNDEKİLER viii
KISALTMALAR xiii
TABLOLAR LİSTESİ xv
ŞEKİLLER LİSTESİ xviii
GİRİŞ 1

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. Cilt Kanseri 7
1.1.1. Bazal Hücreli Karsinom (BCC) 8
1.1.2. Skuamöz Hücreli Karsinom (SCC) 10
1.1.3. Melanom (MEL) 11
1.2. Derin Öğrenme (DL) Mimarileri 14
1.2.1. Evrişimsel Sinir Ağları (CNN) 15
1.2.1.1. Evrişim Katmanı 16
1.2.1.2. Ortaklama Katmanı 17
1.2.1.3. Aktivasyon Katmanı 17
1.2.1.4. Tam Bağlı Katman 18
1.2.2. CNN Tabanlı Mimariler 19

1.2.2.1. MobileNetv2 Mimarisi **19**

1.2.2.2. EfficientNetB0 Mimarisi **20**

1.2.2.3. DenseNet201 Mimarisi **20**

1.2.2.4. DarkNet53 Mimarisi **21**

1.2.2.5. InceptionResNetv2 Mimarisi **21**

1.2.2.6. NasNetLarge Mimarisi **22**

1.2.2.7. ResNet18 Mimarisi **22**

1.2.2.8. ResNet50 Mimarisi **22**

1.2.2.9. ConvNeXt Mimarisi **23**

1.2.3. Görü Dönüştürücü (ViT) **26**

1.2.3.1. Öz-dikkat Mekanizması **28**

1.2.3.2. Çok Başlı Dikkat (MHA) Mekanizması **29**

1.2.4. MetaFormer Temel Modelleri **31**

1.2.5. Topluluk Öğrenme Mimarileri **31**

1.2.5.1. Esnek Oylama Yöntemi **32**

1.2.5.2. Katı Oylama Yöntemi **33**

1.3. Transfer Öğrenme **34**

1.4. Görüntü Bölütleme **35**

1.4.1. DeepLabv3+ Mimarisi **36**

1.5. Öznitelik Seçim Algoritmaları **37**

1.5.1. ReliefF Algoritması **38**

1.5.2. Minimum Fazlalık Maksimum İlgililik Algoritması (mRMR) **39**

1.5.3. Chi-square Testi Kullanarak Öznitelik Sıralama Algoritması (Fscchi2) **40**

1.6. Sınıflandırma Algoritmaları **40**

1.6.1. Destek Vektör Makinesi (SVM) Algoritması **41**

1.6.2. Naive Bayes (NB) Algoritması **41**

1.6.3. Doğrusal Ayrım Analizi (LDA) Algoritması **42**

1.6.4. Karar Ağacı (DT) Algoritması **42**

1.6.5. k-En Yakın Komşu (kNN) Algoritması **42**

1.7. Literatür Özeti **43**

1.7.1. CNN Tabanlı Çalışmalar **43**

1.7.2. ViT Tabanlı Çalışmalar **45**

1.7.3. CNN Tabanlı Hibrit Çalışmalar **46**

1.7.4. CNN ve ViT Tabanlı Hibrit Çalışmalar **50**

1.7.5. DL Tabanlı Topluluk Öğrenme Çalışmaları **53**

1.8. Cilt Kanseri Veri Setleri **56**

1.8.1. ISIC 2018 Veri Seti **56**

1.8.2. HAM10000 Veri Seti **57**

1.8.3. ISIC 2019 Veri Seti **59**

1.9. Değerlendirme Metrikleri **60**

1.10.Cilt Kanseri Sınıflandırmasında Mevcut Problemler **64**

2. BÖLÜM

CİLT KANSERİ SINIFLANDIRMASI İÇİN YENİ BİR HİBRİT EVRİŞİMSEL SİNİR AĞI MODELİ

2.1. Çok Sınıflı Cilt Kanseri Sınıflandırması için Geliştirilen Hibrit Model ... **66**

2.2. Veri Ön İşleme ve Veri Artırma **69**

2.3. Önerilen Yöntemdeki Temel Bileşenlerin Belirlenmesi ve Uygulama Ortamı **70**

2.4. Görüntü Bölütleme İşlemi ve Sonuçları **71**

2.5. Çok Sınıflı Cilt Kanseri Sınıflandırması için Hibrit Model Deney Sonuçları **73**

2.5.1. HAM10000 Veri Seti için Deney Sonuçları **73**

2.5.2. ISIC 2019 Veri Seti için Deney Sonuçları **85**

2.6. Görüntü Bölütlemesinin Performans Üzerindeki Etkisi **96**

2.7. Önerilen Hibrit Modelin Güncel Yöntemlerle Karşılaştırılması **98**

2.8. Değerlendirme **104**

3. BÖLÜM

CİLT KANSERİNİN TANIMLANMASI İÇİN CONVNEXT BLOKLARI ENTEGRE EDİLMİŞ METAFORMER TABANLI CAFORMER MODELİ

3.1. Önerilen ConvNeXt Blokları ile Güçlendirilmiş MetaFormer Tabanlı CAFormer Modeli 106

3.2. Veri Ön İşleme ve Veri Artırma 110

3.3. Oluşturulan Hibrit Modelin Eğitimi 111

3.4. Yöntemin Parametrelerinin Belirlenmesi için Gerçekleştirilen Çalışmalar 112

3.5. ConvNeXt Blokları ile Güçlendirilmiş MetaFormer Tabanlı CAFormer Modeli Deney Sonuçları 116

3.5.1. HAM10000 Veri Seti için Deney Sonuçları 117

3.5.2. ISIC 2019 Veri Seti için Deney Sonuçları 122

3.6. Önerilen Modelin Güncel Hibrit Yöntemlerle Karşılaştırılması 127

3.7. Değerlendirme 130

4. BÖLÜM

CİLT KANSERİNİN SINIFLANDIRILMASI İÇİN YENİ BİR HİBRİT TOPLULUK ÖĞRENME MODELİ

4.1. Geliştirilen CNN ve ViT Tabanlı Hibrit Topluluk Öğrenme Modeli 131

4.2. Veri Ön İşleme ve Veri Artırma 133

4.3. Oluşturulan Hibrit Modelin Eğitimi 135

4.4. Geliştirilen Topluluk Öğrenmesi Tabanlı Hibrit Model Deney Sonuçları . 136

4.4.1. Önerilen Topluluk Öğrenmesi Tabanlı Modelin HAM10000 Veri Seti için Deney Sonuçları 136

4.4.2. Önerilen Topluluk Öğrenmesi Tabanlı Modelin ISIC 2019 Veri Seti için Deney Sonuçları 141

4.5. Önerilen Hibrit Topluluk Modelin Güncel Yöntemlerle Karşılaştırılması 147

4.6. Değerlendirme 150

5. BÖLÜM

TARTIŞMA, SONUÇ ve ÖNERİLER

5.1. Tartışma ve Sonuç **151**

5.2. Öneriler **155**

KAYNAKÇA **157**

EKLER **178**

ÖZGEÇMİŞ **179**

KISALTMALAR

ABCDE	:	Asimetri, Kenar, Renk, Çap, Gelişim
ABD	:	Amerika Birleşik Devletleri
AK	:	Aktinik Keratozis
ASPP	:	Atrous Uzamsal Piramit Ortaklama
BCC	:	Bazal Hücreli Karsinom
BKL	:	İyi Huylu Keratoz
BN	:	Toplu Normalleştirme
CAD	:	Bilgisayar Destekli Tanı
CNN	:	Evrişimsel Sinir Ağları
CRF	:	Koşullu Rastgele Alan
DF	:	Dermatofibroma
DL	:	Derin Öğrenme
DNA	:	Deoksiribo Nükleik Asit
DT	:	Karar Ağacı
FFN	:	İleri Besleme Ağı
FL	:	Odak Kaybı
FN	:	Yanlış Negatif
FP	:	Yanlış Pozitif
FPN	:	Özellik Piramidi Ağı
GELU	:	Gauss Hatası Doğrusal Birimler
HAM10000	:	10000 Eğitim Görüntüsü ile İnsan Makineye Karşı
ISIC	:	Uluslararası Cilt Görüntüleme İşbirliği
kNN	:	k-En Yakın Komşu
LDA	:	Doğrusal Ayrım Analizi
LN	:	Katman Normalleştirme
MEL	:	Melanom
MHA	:	Çok Başlıklı Dikkat
ML	:	Makine Öğrenimi
MLP	:	Çok Katmanlı Algılayıcı
mRMR	:	Minimum Fazlalık Maksimum İlgililik Algoritması
NB	:	Naive Bayes
NV	:	Melanositik Nevüs
OCC	:	Bir Tek Sınıflı Sınıflandırma

PH^2	:	Pedro Hispano Hastanesi Dermatoloji Servisi
RAM	:	Rastgele Erişimli Bellek
ReLU	:	Doğrultulmuş Doğrusal Birim
RGB	:	Kırmızı-Yeşil-Mavi
SCC	:	Skuamöz Hücreli Karsinom
SGD	:	Stokastik Gradyan İnişi
SVM	:	Destek Vektör Makinesi
TN	:	Gerçek Negatif
TP	:	Gerçek Pozitif
UV	:	Ultraviyole
VASC	:	Vasküler Lezyon
ViT	:	Görü Dönüştürücü

TABLOLAR LİSTESİ

Tablo 1.1. Amerikan Kanser Derneği tarafından tanımlanan MEL evreleri ve açıklamaları [30]. 14

Tablo 1.2. HAM10000 veri setindeki sınıflara göre görüntü sayıları. 58

Tablo 1.3. ISIC 2019 veri setindeki sınıflara göre görüntü sayıları. 60

Tablo 2.1. HAM10000 veri setindeki sınıflara göre veri artırma ile elde edilen görüntü sayıları. 71

Tablo 2.2. ISIC 2019 veri setindeki sınıflara göre veri artırma ile elde edilen görüntü sayıları. 71

Tablo 2.3. DeepLabv3+ modelinin farklı omurga ağları ile bölütleme doğrulukları. 73

Tablo 2.4. Farklı öznitelik sınıflandırıcılar açısından karşılaştırılan CNN modellerinin HAM10000 veri seti üzerindeki performansları. 74

Tablo 2.5. Önerilen yaklaşımın HAM10000 veri seti üzerinde kNN algoritması ile öznitelik seçim algoritmaları sınıflandırma sonuçları. 78

Tablo 2.6. Önerilen yaklaşımın HAM10000 veri setinde tekil DarkNet53, InceptionResNetv2 ve NasNetLarge modelleriyle karşılaştırılması. 81

Tablo 2.7. Farklı öznitelik sınıflandırıcılar açısından karşılaştırılan CNN modellerinin ISIC 2019 veri seti üzerindeki doğruluk oranları. 87

Tablo 2.8. Önerilen yaklaşımın ISIC 2019 veri seti üzerinde kNN algoritması ile öznitelik seçim algoritmaları sınıflandırma sonuçları. 89

Tablo 2.9. Önerilen yaklaşımın ISIC 2019 veri setinde tekil MobileNetv2, EfficientNetb0 ve DenseNet201 modelleriyle karşılaştırılması. 91

Tablo 2.10. Önerilen yaklaşımın HAM10000 veri seti üzerindeki görüntü bölütlemeli/bölütlemesiz sınıflandırma sonuçları. 97

Tablo 2.11. Önerilen yaklaşımın ISIC 2019 veri seti üzerindeki görüntü bölütlemeli/bölütlemesiz sınıflandırma sonuçları. 99

Tablo 2.12. HAM10000 veri seti kullanılarak önerilen yaklaşımın literatürdeki en son çalışmalarla karşılaştırmalı analizi. 101

Tablo 2.13. ISIC 2019 veri seti kullanılarak önerilen yaklaşımın literatürdeki en son çalışmalarla karşılaştırmalı analizi. 103

Tablo 3.1. HAM10000 veri setinin eğitim, doğrulama, test ve toplam dağılımı. ... 111

Tablo 3.2. ISIC 2019 veri setinin eğitim, doğrulama, test ve toplam dağılımı. 111

Tablo 3.3. Modellerin eğitim hiper parametreleri. 112

Tablo 3.4. Önerilen modelin ve MetaFormer varyantlarının HAM10000 veri seti üzerindeki verimliliği. 113

Tablo 3.5. Önerilen modelin ve MetaFormer varyantlarının ISIC 2019 veri seti üzerindeki verimliliği. 115

Tablo 3.6. Tüm DL modellerinin HAM10000 veri seti üzerindeki sonuçları. 118

Tablo 3.7. Önerilen modelin HAM10000 veri setindeki sınıf bazında performans metrikleri sonuçları 122

Tablo 3.8. Tüm DL modellerinin ISIC 2019 veri seti üzerindeki sonuçları. 123

Tablo 3.9. Önerilen modelin ISIC 2019 veri setindeki sınıf bazında performans metrikleri sonuçları. 127

Tablo 3.10. HAM10000 veri seti üzerinde CNN ve ViT tabanlı hibrit yöntemlerin karşılaştırılması. 128

Tablo 3.11. ISIC 2019 veri seti üzerinde CNN ve ViT tabanlı hibrit yöntemlerin karşılaştırılması. 129

Tablo 4.1. HAM10000 veri setinin eğitim, doğrulama, test ve toplam dağılımı. ... 135

Tablo 4.2. ISIC 2019 veri setinin eğitim, doğrulama, test ve toplam dağılımı. 135

Tablo 4.3. CNN ve ViT tabanlı modellerin HAM10000 veri seti üzerindeki sonuçları. 137

Tablo 4.4. HAM10000 veri seti üzerindeki topluluk öğrenme sonuçları. 139

Tablo 4.5. Önerilen modelin HAM10000 veri setindeki sınıf bazında performans metrikleri sonuçları 141

Tablo 4.6. CNN ve ViT tabanlı modellerin ISIC 2019 veri seti üzerindeki sonuçları. 142

Tablo 4.7. ISIC 2019 veri seti üzerindeki topluluk öğrenme sonuçları. 144

Tablo 4.8. Önerilen modelin ISIC 2019 veri setindeki sınıf bazında performans metrikleri sonuçları..... 146

Tablo 4.9. HAM10000 veri seti üzerinde topluluk öğrenme yöntemlerin karşılaştırılması. 147

Tablo 4.10. ISIC 2019 veri seti üzerinde topluluk öğrenme yöntemlerin karşılaştırılması. 149

Tablo 5.1. Tez çalışmamızda önerilen modellerin HAM10000 veri seti üzerindeki sonuçlarının birbirleri ile karşılaştırılması. 152

Tablo 5.2. Tez çalışmamızda önerilen modellerin ISIC 2019 veri seti üzerindeki sonuçlarının birbirleri ile karşılaştırılması..... 152

ŞEKİLLER LİSTESİ

Şekil G.1. BCC, SCC ve MEL'in grafiksel gösterimi [2]. 2

Şekil 1.1. İnsan cildinin anatomisi [19]..... 8

Şekil 1.2. BCC, SCC ve MEL'in diyagram gösterimi [20]. 9

Şekil 1.3. BCC'nin dermoskopik görüntüsü..... 9

Şekil 1.4. SCC'nin dermoskopik görüntüsü. 10

Şekil 1.5. MEL'in dermoskopik görüntüsü. 11

Şekil 1.6. MEL'in ABCDE kuralına göre belirtileri [28]. 12

Şekil 1.7. MEL'in gelişim evreleri [20]..... 13

Şekil 1.8. CNN mimarisinin çalışma prensibi [47]..... 16

Şekil 1.9. (a) MobileNetv1 ve (b) MobileNetv2 mimarileri arasındaki farkların mimari gösterimi [53]. 19

Şekil 1.10. EfficientNetb0 modelinin genel mimarisi [55]. 20

Şekil 1.11. DenseNet201 modelinin ağ mimarisi [56]. 21

Şekil 1.12. ResNet18 modelinin ağ mimarisi [62]..... 23

Şekil 1.13. ResNet50 modelinin ağ mimarisi [64]..... 24

Şekil 1.14. ConvNeXt temel mimarisi [67]. 24

Şekil 1.15. ConvNeXt mimarisinde bulunan blok tasarımları (a) Stem bloğu iç yapısı, (b) Aşağı örnekleme bloğu iç yapısı, (c) ConvNeXt bloğu iç yapısı [67]..... 25

Şekil 1.16. Genel ViT mimarisi [74]. 28

Şekil 1.17. Öz-dikkat bloğu [70]. 29

Şekil 1.18. Çok başlı dikkat mimarisi [70]..... 30

Şekil 1.19. Esnek oylama çalışma prensibi örneği. 33

Şekil 1.20. Katı oylama çalışma prensibi örneği. 34

Şekil 1.21. DeepLabv3+ mimarisi [92]. 37

Şekil 1.22. (a) ISIC 2018 veri setinden örnek dermoskopik lezyon görüntüleri, (b) lezyon görüntülerine ait ikili maske görüntüleri [153]..... 57

Şekil 1.23. HAM10000 veri setindeki yedi sınıfa ait örnek dermoskopik görüntüler [153]. 58

Şekil 1.24. HAM10000 veri kümesindeki her bir sınıfa ait görüntü sayıları. 59

Şekil 1.25. ISIC 2019 veri setindeki sekiz sınıfa ait örnek dermoskopik görüntüler [153]. 60

Şekil 1.26. ISIC 2019 veri setindeki her bir sınıfa ait görüntü sayıları. 61

Şekil 2.1. HAM10000 veri seti için geliştirilen modelin şematik diyagramı. 67

Şekil 2.2. ISIC 2019 veri seti için geliştirilen modelin şematik diyagramı. 67

Şekil 2.3. Veri artırımı işlemi: (a) orijinal görüntü, (b), döndürülmüş görüntü, (c) yakınlaştırılmış görüntü. 70

Şekil 2.4. Görüntü bölütleme işlemi: (a) orijinal RGB dermoskopik görüntüler (b) DeepLabv3+ tarafından elde edilen maskeler, (c) bölütlenmiş lezyonlar. 75

Şekil 2.5. DarkNet53, InceptionResNetv2, NasNetLarge ve önerilen yöntemin karışıklık matrisleri. 83

Şekil 2.6. HAM10000 veri seti için önerilen modelin tüm sınıflarının ROC eğrileri..... 85

Şekil 2.7. MobileNetv2, EfficientNetb0, DenseNet201 ve önerilen hibrit yaklaşımın karışıklık matrisleri. 93

Şekil 2.8. ISIC 2019 veri seti için önerilen modelin tüm sınıflarının ROC eğrileri. 95

Şekil 3.1. Önerilen ConvNeXt blokları ile güçlendirilmiş MetaFormer tabanlı CAFormer modeli. 107

Şekil 3.2. Önerilen modelin HAM10000 veri seti üzerinde CNN tabanlı ve ViT tabanlı modellerle doğruluk değerlerinin karşılaştırması. 119

Şekil 3.3. Önerilen modelin HAM10000 veri seti üzerinde CNN tabanlı ve ViT tabanlı modellerle F1-skor değerlerinin karşılaştırması. 120

Şekil 3.4. HAM10000 veri seti üzerinde önerilen model için karışıklık matrisi. ... 121

Şekil 3.5. Önerilen modelin ISIC 2019 veri seti üzerinde CNN tabanlı ve ViT tabanlı modellerle doğruluk değerlerinin karşılaştırması. 125

Şekil 3.6. Önerilen modelin ISIC 2019 veri seti üzerinde CNN tabanlı ve ViT tabanlı modellerle F1-skor değerlerinin karşılaştırması. 125

Şekil 3.7. ISIC 2019 veri seti üzerinde önerilen model için karışıklık matrisi. 126

Şekil 4.1. Önerilen CNN ve ViT tabanlı hibrit esnek oylama topluluk öğrenme mimarisi. 133

Şekil 4.2. Önerilen CNN ve ViT tabanlı hibrit katı oylama topluluk öğrenme mimarisi. 134

Şekil 4.3. HAM10000 veri seti üzerinde önerilen CNN ve ViT tabanlı topluluk öğrenme modelinin karışıklık matrisi. 140

Şekil 4.4. ISIC 2019 veri seti üzerinde önerilen CNN ve ViT tabanlı topluluk öğrenme modelinin karışıklık matrisi. 145

Şekil 5.1. Önerilen hibrit yöntemlerin HAM10000 veri seti üzerindeki performanslarının karşılaştırma grafiği. 153

Şekil 5.2. Önerilen hibrit yöntemlerin ISIC 2019 veri seti üzerindeki performanslarının karşılaştırma grafiği. 154

GİRİŞ

Kanser, hücrelerin kontrolsüz bir şekilde çoğalması sonucu oluşan ve çevre dokulara yayılabilen, vücudun işleyişini bozarak yaşamı tehdit eden ciddi bir hastalıktır. Dünya genelinde en sık görülen kanser türlerinden biri olan cilt kanseri, toplum sağlığı açısından önemli bir risk oluşturmaktadır. İstatistikler, Amerikan toplumunun %20'sinin yetmiş yaşına kadar cilt kanserine yakalanma olasılığı taşıdığını göstermektedir. Ayrıca, Amerika Birleşik Devletlerinde (ABD) her saat iki kişi cilt kanseri nedeniyle hayatını kaybetmektedir. Beş veya daha fazla güneş yanığına maruz kalmak, melanom (Melanoma, MEL) riskini iki katına çıkarırken, bu kanser türü erken evrede tespit edildiğinde beş yıllık hayatta kalma oranı %99 gibi yüksek bir değere ulaşmaktadır. Bu veriler, cilt kanseriyle mücadelede erken tanı ve koruyucu önlemlerin önemini bir kez daha ortaya koymaktadır [1].

Cilt kanseri, mutasyonları tetikleyen onarılmamış DNA hasarının neden olduğu en dış deri tabakası olan epidermiste anormal hücrelerin kontrol dışı büyümesi ile ortaya çıkmaktadır. Bu mutasyonlar cilt hücrelerinin hızla çoğalmasına ve kötü huylu tümörlerin oluşmasına yol açmaktadır. Şekil G.1'de [2] başlıca cilt kanseri türleri olan bazal hücreli karsinom (Basal Cell Carcinoma, BCC), skuamöz hücreli karsinom (Squamous Cell Carcinoma, SCC) ve MEL'in grafiksel gösterimi verilmiştir [3].

Cilt kanserinin büyük bir kısmı güneş ışınlarının cilde verdiği hasarlardan kaynaklanmaktadır ve cildin epidermis tabakasındaki hücreler güneşten en fazla zarar gören hücrelerdir. Epidermiste yaygın olarak bulunan keratinositlerin alt tabakasında yer alan bazal hücreler, BCC'nin geliştiği bölgelerdir. BCC, genellikle baş, yüz, kulaklar ve boyun gibi güneş ışığına yoğun şekilde maruz kalan bölgelerde sıkça ortaya çıkmaktadır. Cildin üst iki tabakası, keratinle dolu ölü hücrelerden oluşmakta olup, bu yapı cilde hem dayanıklılık kazandırmakta hem de koruma sağlamaktadır. SCC, epidermisteki bazal tabakanın üstünde gelişmektedir. MEL ise, epidermisin derin katmanlarında bulunan

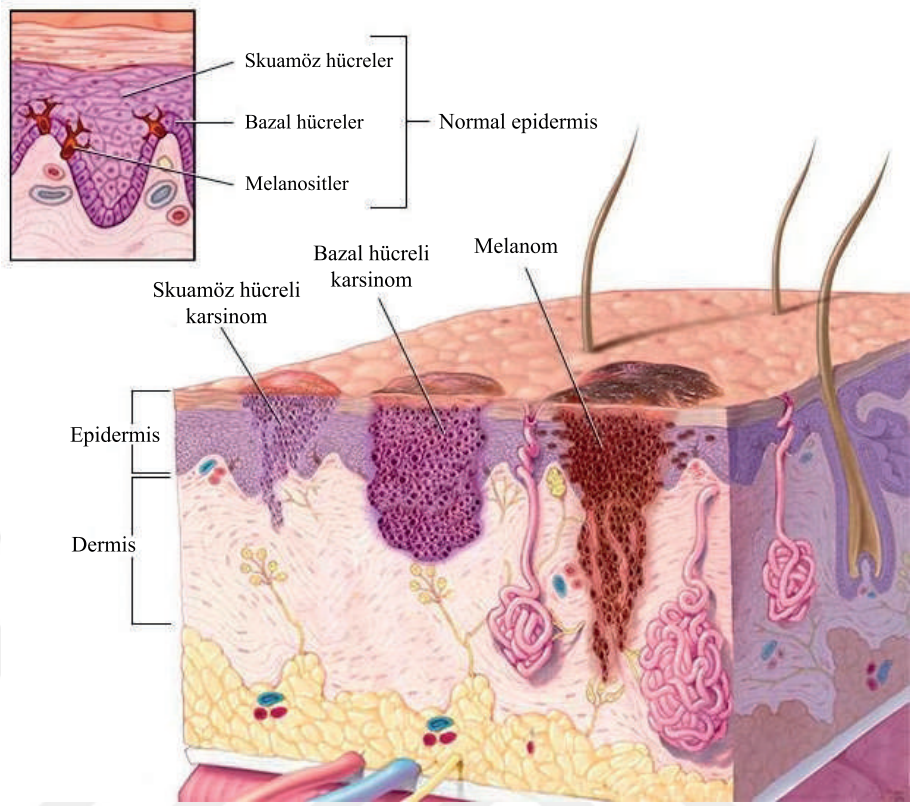

Şekil G.1. BCC, SCC ve MEL'in grafiksel gösterimi [2].

ve güneşe maruz kalınca melanin üreten melanositlerde başlamaktadır. Bu hücresel farklılıklar, çeşitli cilt kanseri türlerinde güneş hasarının etkisini göstermektedir [4].

Cilt kanseri teşhisinde sıklıkla kullanılan dermoskopi ve biyopsi yöntemleri, erken tanı ve doğru tedavi için birçok avantaj sağlamaktadır [5]. Dermoskopi, lezyonları ayrıntılı bir şekilde inceleme imkanı sunmaktadır. Kısa sürede uygulanabilmekte ve kanser türlerine özgü görsel ipuçlarını ortaya çıkarabilmektedir. Bu nedenle, deneyimli uzmanlar için hızlı ve etkili bir değerlendirme aracı olarak öne çıkmaktadır. Biyopsi ise cilt dokusundan alınan örneğin laboratuvarda analiz edilmesiyle kesin tanı sağlamada son derece güvenilir bir yöntemdir. Biyopsinin doğruluğu, özellikle MEL gibi yüksek riskli kanser türlerinde son derece değer kazanmakta ve teşhis sürecinde vazgeçilmez bir rol oynamaktadır.

Ancak, dermoskopik muayene ve biyopsi yöntemlerinin bazı sınırlamaları mevcuttur. Haenssle ve ark. tarafında yapılan kapsamlı bir çalışmada, uzman dermatologların bile dermoskopik görüntülerden en fazla %86.60 oranında bir duyarlılıkla tanı koyabildiğini göstermiştir [6]. Teşhisin doğruluğu, dermatoloğun deneyimine ve bu yöntem hakkındaki bilgisine bağlı olarak değişebilmektedir. Aynı dermatoloğun farklı zamanlarda yaptığı

değerlendirmeler arasında bile farklılık gösterebilmektedir. Ayrıca, dermoskopi her zaman kesin tanı sağlamamakta ve yalnızca ön tanı aracı olarak kullanılmaktadır. Biyopsi ise cerrahi bir işlem olduğundan, hasta için, enfeksiyon riski ve işlem sonrası rahatsızlık gibi olumsuz etkiler doğurabilmektedir. Ayrıca, maliyetli ve sonuçların elde edilmesi zaman almaktadır. Bu da teşhis sürecinin yavaşlamasına yol açabilmektedir.

Cilt kanseri teşhisindeki bu zorlukları aşmak için günümüzde Bilgisayar Destekli Tanı (Computer Aided Diagnosis, CAD) sistemleri geliştirilmektedir. CAD sistemleri, dermoskopik görüntüleri otomatik olarak analiz ederek hızlı, tutarlı ve objektif sonuçlar sunmaktadır [7]. Bu sistemler, uzman teşhisinin güvenilirliğini artırmakta ve özellikle büyük hasta gruplarında hızlı tarama yapılmasını mümkün kılmaktadır [8]. Üstelik, yüksek doğruluk oranlarına ulaşabilen CAD sistemleri, tanı süreçlerini daha verimli hale getirerek hem uzman sağlık personeline destek sağlamakta hem de hastalara zaman kazandırmaktadır.

Cilt kanseri sınıflandırmasında Derin Öğrenme (Deep Learning, DL) algoritmaları ham verilerden karmaşık görüntü özniteliklerini otomatik olarak öğrenmektedir. Bu modeller, çeşitli hasta popülasyonları ve görüntüleme tipleri arasında sağlam genelleme yapabilmektedirler. Sürekli öğrenme ve gelişen tıbbi uygulamalara uyum sağlama, tanı doğruluğunu ve güvenilirliğini artırmaktadır. Bu avantajlar, DL tabanlı sistemlerin doğru tanılar elde etmesine ve güvenilir sonuçlar sağlamasına olanak tanımaktadır [8, 9].

Evrişimsel Sinir Ağları (Convolutional Neural Network, CNN) ve Görü Dönüştürücüler (Vision Transformer, ViT), tıbbi görüntü analizinde kullanılan iki ana DL mimarisidir. CNN mimarileri, görüntülerdeki mekansal hiyerarşileri öğrenmekte ve evrişimsel katmanlar aracılığıyla otomatik derin öznitelik çıkarımı gerçekleştirerek büyük veri setlerinde yüksek doğruluk elde etmektedirler. Öte yandan, ViT tabanlı mimariler görüntüleri daha küçük parçalara ayırmakta ve her bir parçayı bir dizilim olarak ele almaktadır. Ardından, bu dizileri dikkat blokları kullanarak analiz etmektedir. Dikkat blokları, modelin görüntü üzerindeki farklı bölgeleri arasındaki ilişkileri öğrenme yeteneğini artırarak daha etkili ve esnek bir yaklaşım sağlamaktadır. Her iki mimari de tıbbi görüntü analizinde etkili, güvenilir ve yüksek doğrulukta tanı sonuçları elde etmek amacıyla yaygın olarak kullanılmaktadır.

DL teknikleri, geniş bir sağlık sistemi yelpazesinde birçok başarılı uygulamada kullanılmaktadır [10]. Ayrıca, DL tabanlı yöntemler kullanarak cilt kanseri sınıflandırması üzerine literatürde birçok çalışma gerçekleştirilmiştir [11–14]. Bu araştırmalar, geliştirilen yöntemlerin klinik alanda uygulanabilirliğini ortaya koymaktadır.

Bununla birlikte, cilt kanseri sınıflandırması işleminde, etkili tanı ve tedavi sürecini sekteye uğratan çeşitli zorluklar ve boşluklar bulunmaktadır. Bu zorlukların başında, cilt kanseri türlerinin yapısal çeşitliliği gelmektedir. Bu heterojen yapı, doğru sınıflandırmayı karmaşık hale getiren farklı tanısal kriterlerin kullanılmasını gerektirmektedir. Ayrıca, kötü ve iyi huylu lezyonlar arasındaki görsel ve histolojik benzerlikler, teşhisi daha da güçleştirmektedir. Dermoskopik görüntüleme ile tanı doğruluğu artmış olsa da, görüntü kalitesindeki değişkenlik, bu verilerin ileri düzey DL algoritmalarına entegrasyonunda boşluklar oluşturmaktadır. Bu durum, tutarlı ve güvenilir sınıflandırma sonuçları elde etmek açısından bir engel teşkil etmektedir.

Tezin Motivasyonu

Cilt kanseri, Dünya Sağlık Örgütü'nün raporlarına göre, görülme sıklığı giderek artan ve ölüm oranları açısından önemli bir sağlık sorunu olarak öne çıkmaktadır. Bu durum, erken teşhis ve etkili tedavi yöntemlerinin geliştirilmesini zorunlu hale getirmiştir. Ancak mevcut tanı süreçleri, hem klinik uygulamalarda hem de hastaların yaşam kalitesinde çeşitli sıkıntılar oluşturmaktadır.

Dermoskopik görüntülerin değerlendirilmesi, dermatologların bilgi ve deneyim seviyesine bağlı olarak değişkenlik göstermekte, bu da değerlendirme sürecinin zaman alıcı ve subjektif olmasına yol açmaktadır. Bu durum, doğru ve hızlı teşhis oranlarının artırılmasında önemli bir engel oluşturmaktadır. Ayrıca, biyopsi gibi invaziv yöntemler, hasta konforunu düşürmekte ve enfeksiyon gibi komplikasyon risklerini beraberinde getirmektedir.

Cilt kanserinin teşhisinde karşılaşılan bir diğer zorluk, çok sayıda kanser türünün bir arada değerlendirilmesinin gerekmesi ve bu durumun sınıflandırma süreçlerini daha karmaşık hale getirmesidir. Bu karmaşıklık, yanlış tanı olasılığını artırarak tedavi süreçlerini olumsuz yönde etkilemektedir. Erken tanıdaki eksiklikler ise hayati öneme sahip

müdahalelerin zamanında yapılmasını engelleyerek hasta sağlığı üzerinde ciddi sonuçlar doğurmaktadır. Bu sebeple, cilt kanseri teşhisine yönelik daha objektif, hızlı, güvenilir ve hasta konforunu ön planda tutan yeni teknolojilerin geliştirilmesi gerekmektedir.

Araştırmanın Önemi

Cilt kanseri teşhisinde mevcut yöntemlerin yetersizliği, tanı süreçlerini geliştirecek yeni yaklaşımları gerekli kılmaktadır. Hibrit modellerin farklı mimarilerin güçlü yönlerini birleştirme potansiyeli, bu alanda önemli bir avantaj sunmaktadır.

Araştırma, hibrit modellerin tanı doğruluğunu artırma ve mevcut sınırlamaları azaltma konusundaki katkılarını ortaya koymayı amaçlamaktadır. Bu modellerin uygulanabilirliğini değerlendirmek, cilt kanseri teşhisinde daha etkili çözümler geliştirilmesine önemli bir temel oluşturmaktadır.

Tezin Amacı ve Katkılar

Bu tez çalışması, literatürde bulunan mevcut yöntemlerden daha başarılı bir şekilde dermoskopik görüntülerden cilt kanserinin erken teşhisinde yüksek doğruluk oranları sağlayacak, hibrit DL modelleri geliştirmeyi amaçlamaktadır. Geliştirilen modeller, dermoskopik görüntülerden etkili bir şekilde cilt lezyonlarını sınıflandırarak, dermatologların tanı süreçlerini hızlandırmayı ve doğruluk oranlarını artırmayı hedeflemektedir. Tez çalışması sonucunda sağlanması hedeflenen katkılar şu şekilde sıralanabilir:

- Dermoskopik görüntülerden derin öznitelikler çıkararak tekil CNN modellerin güçlü yönlerini birleştiren yeni hibrit modellerin önerilmesi.
- Cilt kanseri sınıflandırmasını gerçekleştirmek için ConvNeXt blokları ile MetaFormer tabanlı CAFormer mimarisi ile yenilikçi bir hibrit model sunulması.
- Cilt kanseri sınıflandırma problemine yönelik CNN ve ViT tabanlı yeni bir hibrit topluluk öğrenme modelinin geliştirilmesi.
- Farklı CNN ve ViT yöntemlerinin avantaj ve dezavantajlarının kapsamlı bir incelemesini sunarak gelecekteki araştırmalara rehberlik edecek yeni bakış açılarının sağlanması.

Tezin Organizasyonu

Cilt kanseri görüntülerinin sınıflandırılması için hibrit modeller önerilen bu tezin organizasyonu şu şekildedir:

Birinci bölümde, cilt kanseri ve DL hakkında genel bilgiler verilerek, literatürdeki cilt kanseri sınıflandırılması için geliştirilmiş yöntemler kategorize edilerek sunulmaktadır. Ayrıca geliştirilen hibrit modellerin eğitim ve testlerinde kullanılan veri setleri ile başarımlarının değerlendirilmesi için kullanılan metriklerden bahsedilmektedir.

İkinci bölümde, görüntü bölütleme ve öznitelik çıkarımı ile birlikte CNN modellerle oluşturulan hibrit bir yöntem sunulmaktadır. Farklı sınıflandırma metotları ile başarımları karşılaştırılan modellerin performansları değerlendirilmektedir.

Üçüncü bölümde, cilt kanseri sınıflandırma amacı ile geliştirilen ConvNeXt blokları ile güçlendirilmiş MetaFormer tabanlı CAFormer modeli sunulmaktadır. Bu hibrit yöntem CNN ve ViT tabanlı yöntemlerin üstün yönlerini birleştirmektedir.

Dördüncü bölümde, cilt kanseri görüntülerinin sınıflandırılması için CNN ve ViT tabanlı yeni bir hibrit topluluk öğrenme modeli önerilmektedir. Tekil modellerin üstün yönleri kullanılarak yüksek başarımlı sonuçlar elde edilmektedir.

Beşinci bölümde, tez çalışması çerçevesinde elde edilen bulguların analizi yapılmakta ve gelecekteki araştırmalara yönelik öneriler sunulmaktadır.

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. Cilt Kanseri

Kanser, dünya genelinde milyonlarca insanın yaşamını derinden etkileyen ve insan sağlığı için ciddi tehditler oluşturan bir hastalıktır. Cilt kanseri, kanser türleri arasında en yaygın olanlarından biridir. Erken teşhis edilip tedavi edilmediğinde ölümcül sonuçlara yol açabilmektedir [15]. İnsan cildi, patojenler ve çevresel etmenlere karşı vücudu koruyan en dış katman olarak görev yapmaktadır. Bu dış faktörlere maruz kalmak, cilt hastalıkları riskini önemli ölçüde artırmaktadır [16]. Güneş ışığından gelen ultraviyole (Ultraviolet, UV) radyasyon, cilt hücrelerinin DNA'sına zarar vererek cilt kanserine sebep olabilmektedir. Ayrıca sigara kullanımı, alkol tüketimi, alerjiler, bazı hastalıklar, virüsler ve çeşitli çevresel değişiklikler de cilt kanserine neden olabilmektedir [17]. Cilt kanseri insidansı, dünya çapında ülkeler ve bölgeler arasında önemli farklılıklar göstermektedir. 2024 yılında ABD'de 100.640 yeni cilt kanseri vakasının teşhis edilmesi beklenmekte, ayrıca toplamda 8.290 ölüm öngörülmektedir. Cilt kanseri görülme sıklığı, bölgesel faktörler, güneşe maruz kalma, cilt pigmentasyonu ve genetik farklılıklar gibi unsurlarla ilişkilendirilmektedir [18].

İnsan cildinin anatomisi Şekil 1.1'de görülmektedir [19]. Cilt kanseri, epidermis olarak bilinen en dıştaki cilt katmanında anormal hücrelerin kontrolsüz büyümesiyle oluşmakta olup, onarılmamış DNA hasarlarının tetiklediği mutasyonlardan kaynaklanmaktadır [19]. Bu mutasyonlar, cilt hücrelerinin hızla çoğalmasına ve kötü huylu tümörlerin gelişmesine neden olmaktadır. Şekil 1.2'de [20] görüldüğü gibi cilt kanserinin başlıca türleri arasında BCC, SCC ve MEL yer almaktadır [21].

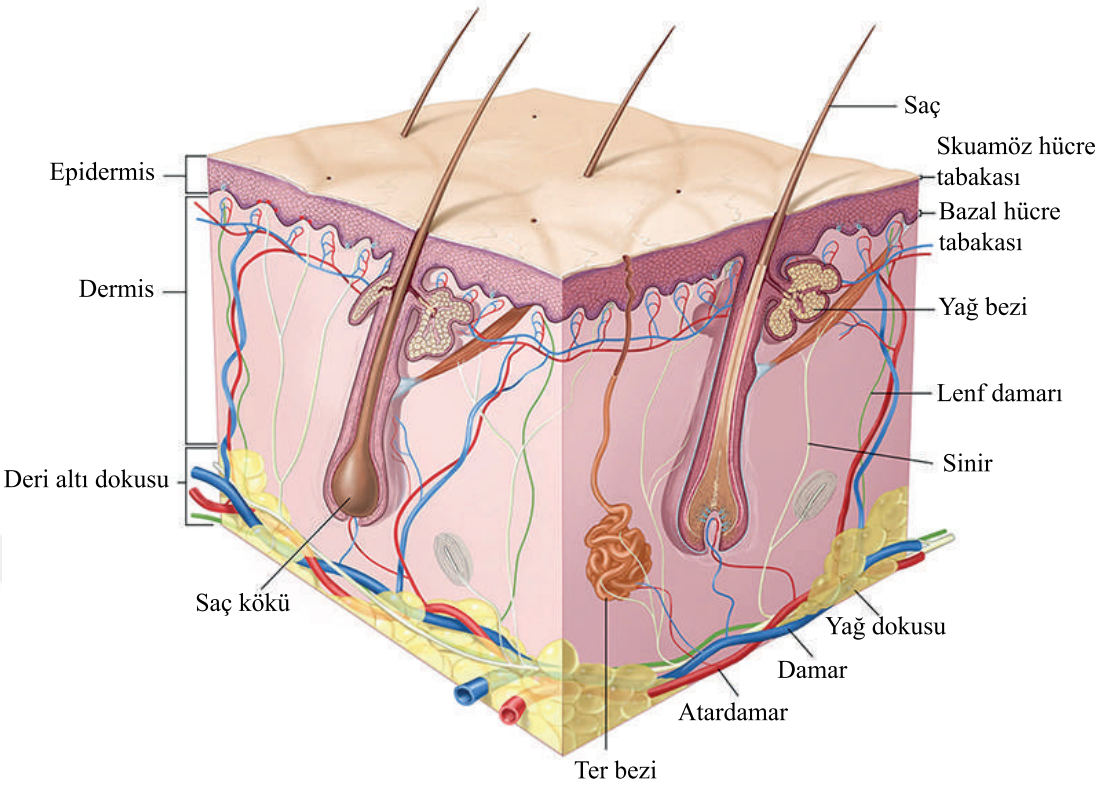

Şekil 1.1. İnsan cildinin anatomisi [19].

Cilt kanseri, derinin yüzeyinde veya daha derin katmanlarında gelişebilmektedir. Başlıca üç türe ayrılmasına rağmen genellikle MEL ve MEL dışı olarak değerlendirilmektedir [22]. MEL dışı cilt kanserleri yüzeysel deri katmanlarında oluşmakta olup, daha az ölümcül özellik göstermektedir [23].

1.1.1. Bazal Hücreli Karsinom (BCC)

Şekil 1.3'te dermoskopik görüntüsü sunulan BCC, dünya genelinde en yaygın cilt kanseri türüdür. Bu kanser türü, cildin dış tabakasının en alt kısmında bulunan bazal hücrelerde gelişmektedir. BCC, tüm MEL dışı cilt kanserlerinin yaklaşık %75'ini kapsamaktadır [24]. Yeni cilt hücreleri üretme görevini üstlenen bu hücrelerde, genellikle güneşe uzun süre maruz kalınması sonucunda DNA hasarı oluşmaktadır. Bu durum hücrelerin kontrolsüz çoğalmasına ve kanserli bir lezyonun oluşumuna yol açmaktadır. Çoğunlukla güneşe maruz kalan baş, boyun ve yüz gibi bölgelerde gelişen BCC, beyaz ciltte ten rengi veya pembe, esmer ciltte ise kahverengi ya da parlak siyah bir yumru olarak ortaya çıkmaktadır. Belirtileri arasında iyileşmeyen yaralar, ciltte büyüyen lezyonlar ve kabarık kenarlı düz yamalar bulunmaktadır [25–27].

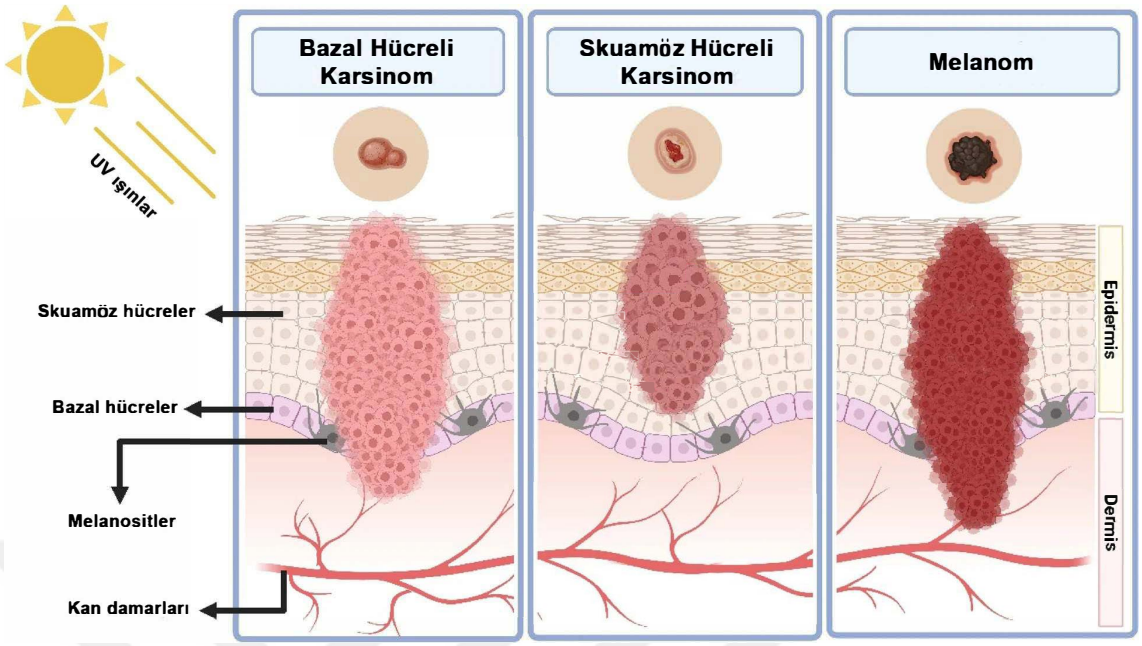

Şekil 1.2. BCC, SCC ve MEL'in diyagram gösterimi [20].

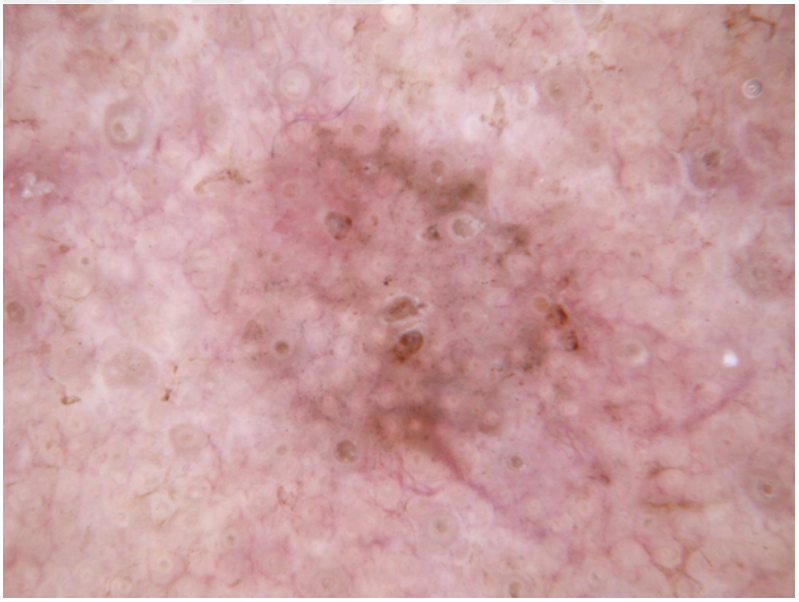

Şekil 1.3. BCC'nin dermoskopik görüntüsü.

BCC'nin başlıca nedeni UV radyasyona maruz kalmaktır. Ancak güneşe doğrudan maruz kalınmayan bölgelerde de gelişebilmektedir. Bu nedenle, güneşten korunma önlemlerinin yanı sıra ciltteki değişimlerin düzenli kontrol edilmesi önerilmektedir. Risk faktörleri arasında uzun süreli güneş ışığına veya solaryum cihazlarına maruz kalma, açık ten rengi, ileri yaş, bağışıklık sistemini baskılayıcı ilaç kullanımı, arsenik maruziyeti ve bazı genetik sendromlar yer almaktadır [25, 26].

1.1.2. Skuamöz Hücreli Karsinom (SCC)

SCC, cildin orta ve dış katmanlarında bulunan skuamöz hücrelerde DNA değişiklikleri sonucu gelişen yaygın bir cilt kanseri türüdür. SCC'nin dermoskopik görüntüsü Şekil 1.4'te gösterilmektedir. Bu kanser türü çoğu zaman yaşamı tehdit etmese de, tedavi edilmediğinde büyüyerek diğer bölgelere yayılabilmekte ve ciddi komplikasyonlara yol açabilmektedir. BCC'den daha hızlı büyüme eğiliminde olan SCC, tüm cilt kanserlerinin yaklaşık %23'lük bir kısmını oluşturmaktadır [24].

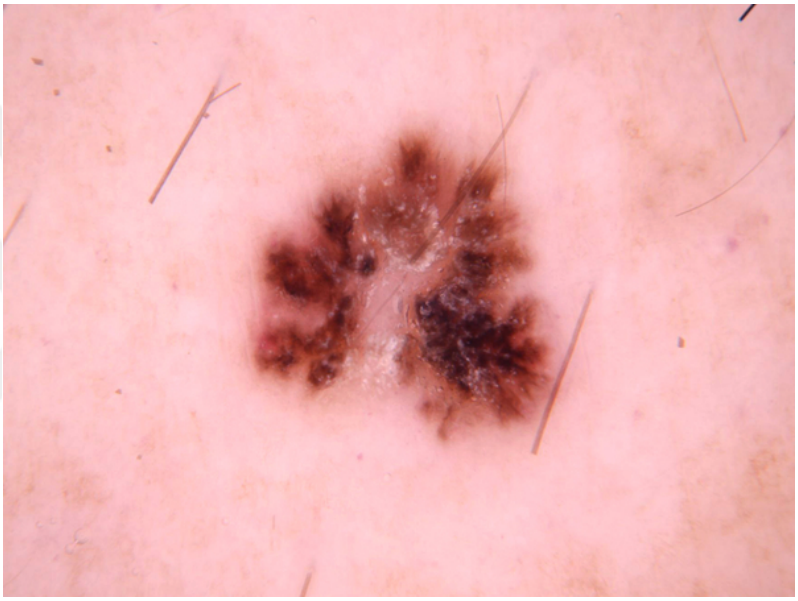

Şekil 1.4. SCC'nin dermoskopik görüntüsü.

SCC genellikle vücudun en çok güneşe maruz kalan bölgelerinde gelişmektedir. Baş, boyun, ellerin ve kolların arka kısımları gibi alanlarda sıkça görülmekle birlikte, yanıklar veya uzun süre iyileşmeyen yaralarda da ortaya çıkabilmektedir. Siyah veya koyu renkli tene sahip kişilerde ise bu kanser tipi, genellikle genital bölge gibi güneş görmeyen alanlarda ortaya çıkmaktadır. Çoğu SCC vakası yalnızca ciltte sınırlı kalmaktadır. Nadiren, yakındaki lenf düğümlerine veya vücudun diğer bölgelerine yayılabilmektedir [27].

SCC kanser tipinin belirtileri arasında, cilt renginden farklı veya aynı renkte olabilen sert bir yumru yer almaktadır. Ayrıca pullu kabuklanmış yaralar, eski yara üzerinde yeni çıkıntılar veya dudaklarda pürüzlü lezyonlar şeklinde de gözlemlenebilmektedir.

1.1.3. Melanom (MEL)

Cilt kanserinin en tehlikeli türü olan MEL, deriye rengini veren ve melanin pigmenti üreten melanosit hücrelerinde başlamaktadır. MEL, çok hızlı büyüme ve vücudun diğer bölgelerine yayılma eğilimine sahiptir. Erken teşhis ve tedavi edilmediğinde, yüksek ölüm oranlarına yol açabilmektedir. Bu cilt kanseri türü, tüm cilt kanseri vakalarının sadece %3'ünü oluşturmasına rağmen, cilt kanserine bağlı ölümlerin yaklaşık %80'inden sorumludur [18]. Dolayısıyla, erken teşhis ve tedavi, hayatta kalma oranlarını iyileştirmek için kritik bir rol oynamaktadır [23].

Şekil 1.5'te dermoskopik görüntüsü görülen MEL, genellikle vücudun güneşe sıkça maruz kalan sırt, yüz, kollar ve bacaklar gibi bölgelerinde gelişmektedir. Ancak nadir de olsa göz, burun ve boğaz gibi vücudun iç kısımlarında da ortaya çıkabilmektedir.

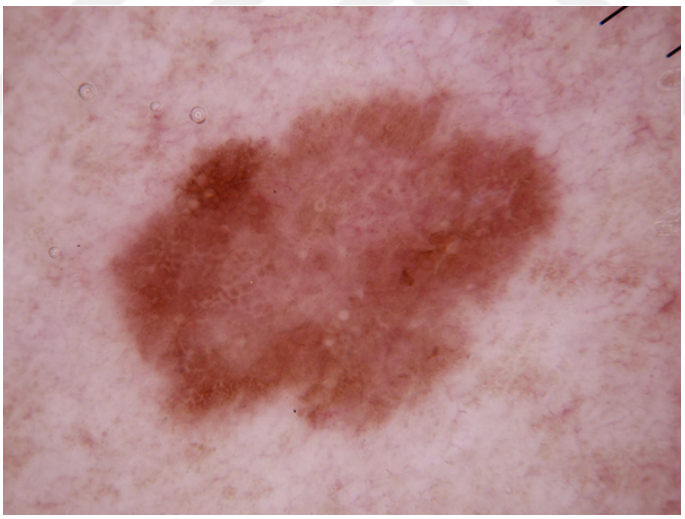

Şekil 1.5. MEL'in dermoskopik görüntüsü.

MEL'in ortaya çıkışının kesin nedenleri tam olarak bilinmemekle birlikte, çoğu vaka UV ışığa maruz kalmakla ilişkilendirilmektedir. Ayrıca, güneş ışığı veya bronzlaşma yataklarından gelen UV ışınlarına uzun süre maruz kalınması, MEL riskini artırmaktadır. Bu risk özellikle kırk yaş altı bireylerde daha yüksek seviyelere çıkmaktadır. MEL erken teşhis edilirse, başarılı bir şekilde tedavi edilen hasta, sağlığına kavuşabilmektedir.

MEL belirtileri, ciltteki mevcut bir benin yapısındaki değişiklikler veya ciltte yeni ve alışılmadık bir lezyon oluşumu ile kendini gösterebilmektedir. MEL her zaman normal

bir ben olarak başlamamakta, bazen sağlıklı cilt üzerinde de gelişebilmektedir. Tipik benler belirgin sınırları bulunan, genellikle tek renkli olup pembe, kahverengi veya siyah gibi tonlardadır. Ancak bazı benler Şekil 1.6'da görüldüğü gibi ABCDE kuralına göre belirtiler gösterebilmektedir [28]. MEL belirtileri, asimetrik (A-Asymmetry) şekil, sınır (B-Border) düzensizliği, renk (C-Color) değişiklikleri, boyut (D-Diameter) artışı ve gelişim (E-Evolving) gibi özellikler taşımaktadır. Bu tür değişiklikler içeren benlerin düzenli olarak kontrol edilmesi önerilmektedir. Özellikle koyu tenli bireylerde, güneş görmeyen ayak tabanları, avuç içleri, tırnak yatakları, saçlı deri ve genital bölgelerde de MEL görülebilmektedir. Bu tür gizli MEL genellikle daha geç fark edilmektedir. Bu nedenle bu bölgelerin düzenli kontrol edilmesi çok önemlidir.

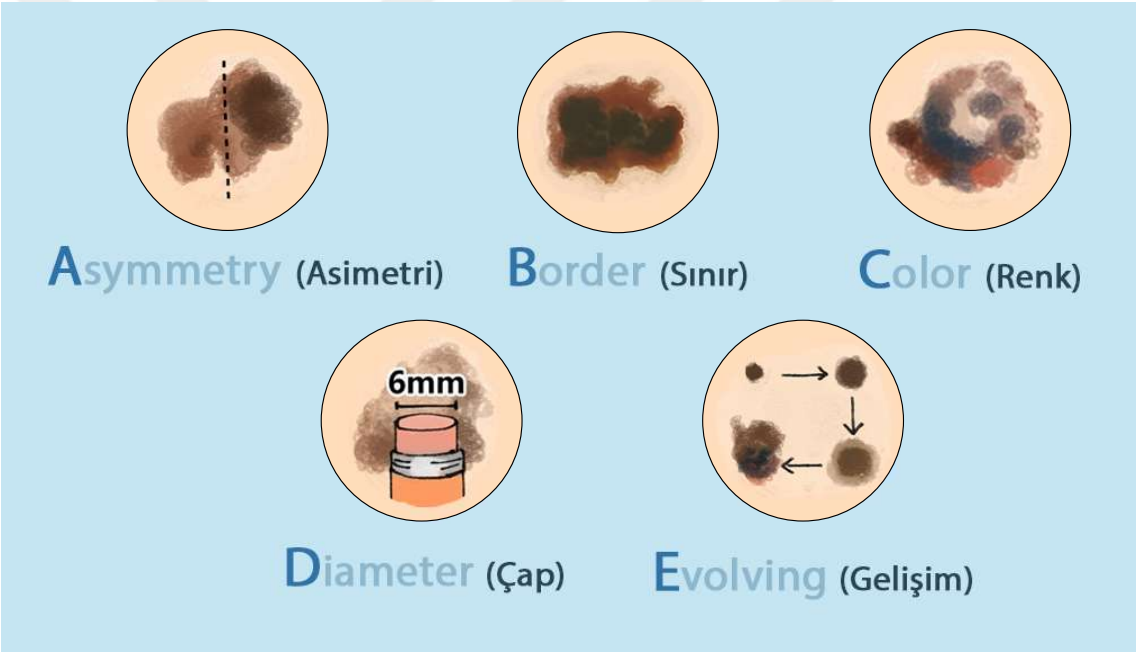

Şekil 1.6. MEL'in ABCDE kuralına göre belirtileri [28].

MEL riskini artıran faktörler arasında ailede MEL öyküsü, şiddetli güneş yanıkları, UV ışığına maruz kalma, çok sayıda veya atipik ben bulunması, ekvatora yakın veya yüksek rakımlarda yaşamak, açık tenli cilt yapısına sahip olmak ve bağışıklık sisteminin zayıflığı yer almaktadır [29].

Tablo 1.1'de Amerikan Kanser Derneği'ne göre MEL'in tüm evreleri sunulmaktadır [30]. Ayrıca, grafiksel olarak MEL'in gelişim evreleri Şekil 1.7'de gösterilmektedir [20]. MEL lezyonu, başlangıç evresinde pigment içeren, belirsiz şekilli ve yalnızca epidermis tabakasıyla sınırlı olan bir yapı sergilemektedir. İleri evrelerde tümör, dikey olarak

büyüyerek dermis tabakasındaki kolajen liflerine kadar inmektedir. Son aşamada ise tümör, en alt tabakalara sızarak organlara yayılmaktadır.

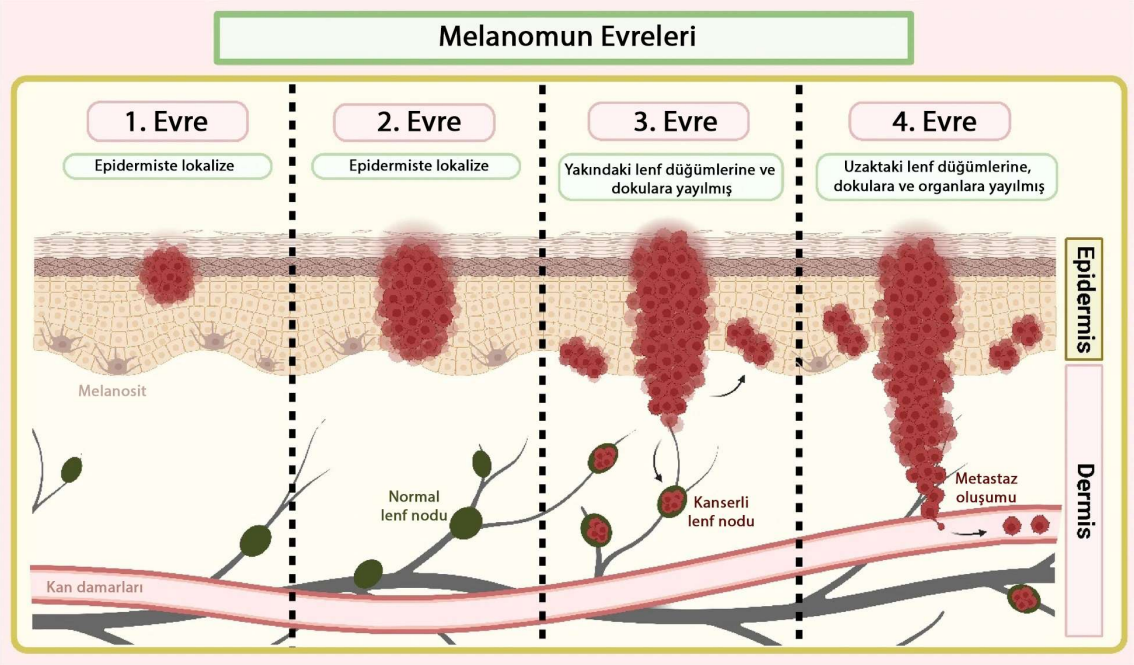

Şekil 1.7. MEL'in gelişim evreleri [20].

Dermatologlar için özellikle erken evrelerinde MEL lezyonlarını MEL dışı lezyonlardan doğru bir şekilde ayırt etmek büyük bir zorluk oluşturmaktadır [31]. Cilt lezyonlarını değerlendirmek için dermatologlar, genellikle dermoskopik incelemeler ve biyopsi uygulamaktadır. Biyopsi, şüpheli bir lezyondan doku örneği alarak mikroskop altında incelenmesi işlemidir. Ancak, bu yöntem hem hasta hem de uzman hekimler için zorlayıcı ve zaman alıcı bir süreç olabilmektedir [32]. Ayrıca, yüksek maliyetler ve ciltte iz bırakma riski nedeniyle biyopsi sıkça tercih edilmemektedir. Bunun yerine, dermatologlar çoğunlukla dermoskopik incelemeleri kullanmaktadır. Dermoskopi, cilt lezyonlarının yapısal, renk ve boyut özelliklerini detaylı bir şekilde incelemeye olanak tanıyan bir dermoskop yardımıyla yapılan muayene yöntemidir. Bu teknik, dermatologların cilt lezyonlarını daha kapsamlı bir şekilde değerlendirmelerine ve erken teşhis ile etkili tedavi planları geliştirmelerine olanak tanımaktadır [33]. Aynı şekilde, cilt lezyonlarının görsel incelemesi ve değerlendirilmesi, dermatologlar için zaman alıcı bir süreç olup büyük bir uzmanlık ve dikkat gerektirmektedir [31].

Tablo 1.1. Amerikan Kanser Derneği tarafından tanımlanan MEL evreleri ve açıklamaları [30].

MEL Evresi	Açıklama
0	Tümör, yavaş bir hızla cilt yüzeyine yerleşmektedir. Bu aşamada tümör, yakın lenf bezlerine veya uzak dokulara/organlara yayılmamıştır.
I	Tümör, cilt yüzeyinde yatay bir genişleme göstermektedir. Kalınlığı 2 mm'yi geçmemektedir. Ülserli veya ülsersiz olabilir. Bu aşamada da tümör yakın lenf bezlerine veya uzak dokulara/organlara yayılmamıştır.
II	Tümör, dikey olarak genişleyebilmektedir. Kalınlığı en az 1 mm'den 4 mm'ye kadar değişebilir. Ülserli veya ülsersiz olabilir. Bu evrede de tümör, yakın lenf bezlerine veya uzak dokulara/organlara yayılmamıştır.
III A	Kalınlığı 2 mm'yi geçmeyen tümör, Ülserli veya ülsersiz olabilir. Kanser, 1 ila 3 yakın lenf noduna yayılmıştır. Bu yayılım yalnızca mikroskop altında görülebilmektedir. Uzak dokulara/organlara yayılmamıştır.
III B	Kalınlığı 4 mm'yi geçmeyen tümör, ülserli veya ülsersiz olabilir. Bu evrede kanser, yakın bir lenf noduna ve cildin yakın küçük alanlarına yayılmıştır. Uzak dokulara/organlara yayılmamıştır.
III C	Kalınlığı 4 mm'yi geçmeyen tümör, ülserli veya ülsersiz olabilir. Bu durumda kanser, cildin yakın küçük alanlarına ve dört veya daha fazla yakın lenf noduna yayılmıştır. Uzak dokulara/organlara yayılmamıştır.
III D	Kalınlığı 4 mm'den fazla ve ülserli olan tümör, yakın cildin küçük alanlarına ve dört veya daha fazla yakın lenf noduna yayılmıştır. Uzak dokulara/organlara yayılmamıştır.
IV	Son olarak, tümör herhangi bir kalınlıkta olabilir. Bu durumda kanser, yakın lenf nodlarına ve beyin, karaciğer, akciğerler, kemik veya böbrek gibi uzak organlara yayılmıştır.

1.2. Derin Öğrenme (DL) Mimarileri

Makine öğreniminin (Machine Learning, ML) bir alt dalı olan DL, yapay zeka alanında önemli ilerlemeler sağlamaktadır. Geleneksel ML yaklaşımları, önceden tanımlanmış ve iyi belirlenmiş özniteliklere dayanırken, DL algoritmaları verilerin hiyerarşik temsillerini otomatik olarak öğrenebilme yeteneğine sahiptir. Bu yetenek, karmaşık örüntülerin ve yapılandırılmamış verilerin olduğu görevlerde, özellikle görüntü ve konuşma tanıma gibi alanlarda etkili bir çözüm sunmaktadır. DL modelleri, insan beyninin yapısına dayalı olarak tasarlanmakta ve birbirine bağlı çok sayıda katmandan oluşmaktadır. Bu mimari, modellerin ham verilerden soyut öznitelikler çıkarmasını mümkün kılmaktadır [34].

DL modellerinin en önemli avantajlarından biri, büyük veri setleri ile birlikte kullanıldığında, yüksek doğruluk oranları elde edebilmesidir. Örneğin, görüntü sınıflandırma görevlerinde DL modelleri, geniş etiketlenmiş veri kümeleriyle eğitilerek

nesne tanıma ve bölütleme gibi karmaşık işlemlerde insan performansının üzerine çıkabilmektedir. Bu süreçte, DL algoritmaları, katmanlar arasında öğrenme sürecini optimize etmek için geri yayılım algoritmasını kullanarak, modelin çıktısını iyileştirmek için ağırlıkları güncellemektedir [35, 36].

Ayrıca DL, transfer öğrenme gibi tekniklerle desteklenerek, önceden eğitilmiş modellerin başka benzer görevlerde hızlı ve etkili bir şekilde kullanılmasını sağlamaktadır. Bu sayede, özellikle sınırlı veri setlerine sahip alanlarda büyük bir avantaj sunmakta ve araştırmacıların daha az veri ile başarılı sonuçlar elde etmelerine yardımcı olmaktadır. DL çeşitli alanlarda kayda değer başarılar elde etmiştir [37]. Görüntü işleme [11], nesneleri tanıma [38], tıbbi görüntüleme [39], savunma sektörü [40], finans [41], otonom arabalar [42], tarım [43], uzaktan algılama [44] ve tıp [45] gibi birçok sektördeki uygulamaları, bu teknolojinin potansiyelini ve gelecekteki önemini daha da pekiştirmektedir.

Özellikle cilt kanseri gibi tıbbi görüntüleme alanında, DL yöntemleri, dermoskopik görüntülerden öznitelik çıkarımı yaparak, erken teşhis ve tedavi süreçlerine katkıda bulunmakta, böylece tıbbi karar destek sistemlerinde kritik bir rol oynamaktadır [10].

1.2.1. Evrişimsel Sinir Ağları (CNN)

CNN, 2010 yıllarının başında DL alanında görüntü işleme ve analizinde devrim yapan güçlü bir mimaridir. Özellikle görsel verilerin işlenmesinde kullanılan bu ağlar, katmanlı yapılarına ve yerel bağlantı özelliklerine sahip olmaları sayesinde, yüksek düzeyde öznitelik çıkarımı gerçekleştirme yeteneğine sahiptir. CNN mimarileri, geleneksel yapay sinir ağlarından farklı olarak, görüntüdeki pikseller arasındaki uzamsal ilişkileri koruyarak, evrişimsel filtreler aracılığıyla özniteliklerin hiyerarşik bir şekilde öğrenilmesine olanak tanımaktadır [46]. Bu öznitelikleri, görüntülerdeki nesneleri tanıma, sınıflandırma ve bölütleme gibi görevlerde daha iyi sonuçlar elde etmeyi sağlamaktadır. CNN mimarilerinin, özellikle cilt kanseri sınıflandırması gibi tıbbi görüntüleme uygulamalarında kullanılması, erken teşhis ve tedavi süreçlerinde önemli bir rol oynamaktadır. Son yıllarda, çeşitli CNN mimarilerinin, veri artırma teknikleriyle birleştirilmesi, model performansını artırmakta ve tıbbi görüntülerden anlamlı öznitelikler elde edilmesine katkıda bulunmaktadır. Bu nedenle, CNN mimarilerinin cilt kanseri

gibi kritik sağlık alanlarındaki uygulamaları, DL algoritmalarının potansiyelini ve bu teknolojinin gelecekteki gelişmelerinin önemini vurgulamaktadır.

Tipik bir CNN mimarisi, sırayla yer alan evrişim ve ortaklama katmanlarıyla karakterize edilmektedir. Şekil 1.8'de gösterilen temel CNN yapıları [47], giriş ve çıkış katmanı hariç dört ana bileşenden oluşmaktadır. Bu bileşenler, evrişim katmanı, ortaklama katmanı, aktivasyon katmanı ve tam bağlı katmandır. CNN mimarileri, sinir ağı topolojilerinin oluşturulmasında kritik bir rol oynamaktadır. İyi tasarlanmış bir ağ mimarisi, katmanlar arasındaki uyum etkisini artırmakta ve ağ içindeki gereksiz hesaplamaları azaltarak performansın iyileştirilmesine katkıda bulunmaktadır [48].

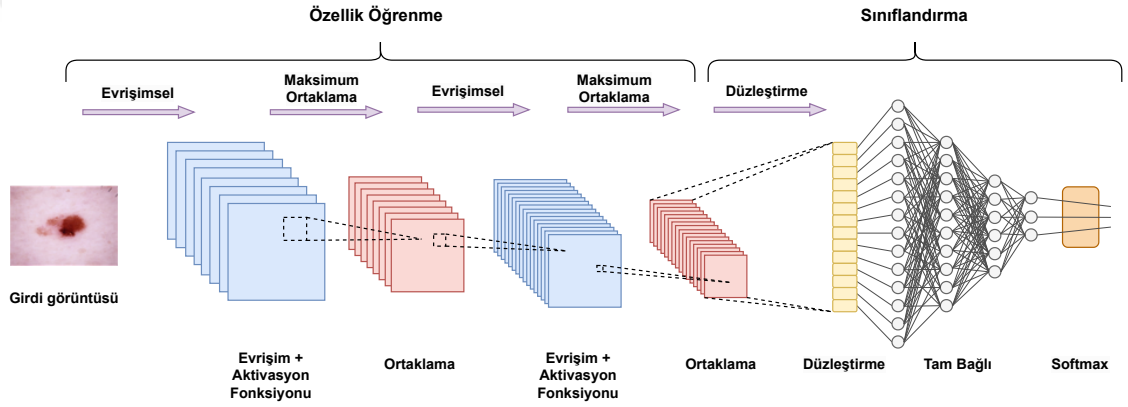

Şekil 1.8. CNN mimarisinin çalışma prensibi [47].

1.2.1.1. Evrişim Katmanı

Evrişim katmanı, DL modellerinde özellikle görüntü işleme alanında kritik bir rol oynamaktadır. Bu katman, giriş verisi üzerinde evrişim işlemi uygulayarak, özniteliklerin otomatik olarak çıkarılmasını sağlamaktadır. Genellikle, bir dizi evrişim filtresi veya çekirdek ile çalışmaktadır. Bu filtreler, görüntüdeki kenarlar, dokular ve şekiller gibi farklı öznitelikleri tanımlamak için tasarlanmıştır. Evrişim işlemi, filtrelerin giriş görüntüsü üzerinde kaydırılarak uygulanmasıyla gerçekleştirilir. Bu işlem, her bir filtrenin belirli bir özniteliği vurgulamasını sağlayarak çıktı olarak öznitelik haritalarını oluşturur. Bu katmanın en önemli avantajlarından biri, parametre paylaşımıdır. Bu özellik, aynı filtrelerin farklı konumlarda uygulanması ile modelin hesaplama verimliliğini artırmaktadır. Ayrıca, evrişim katmanı, modelin uzamsal hiyerarşisini koruyarak, yüksek düzeyde soyutlamaların elde edilmesine katkıda bulunmaktadır. Öznitelik çıkarma

görevini üstlenen evrişim katmanının $k.$ çıktı öznitelik haritasının hesaplanması aşağıdaki denklemdeki gibidir:

$$Y_k = f(W_k \times \ x) \tag{1.1}$$

burada, x giriş görüntüsünü temsil etmektedir. W_k, $k.$ öznitelik haritası ile ilişkili olan evrişim filtresini ifade etmektedir. Denklemin içinde, f, doğrusal olmayan aktivasyon fonksiyonunu göstermektedir. Y_k, bir sonraki katmanın $k.$ girdisini belirtmektedir [49].

1.2.1.2. Ortaklama Katmanı

Bu katman, evrişim katmanından elde edilen en önemli öznitelikleri depolamakta ve aşağı örnekleme yoluyla öznitelik haritalarının uzamsal doğruluğunu azaltmaktadır. Ortaklama katmanları, maksimum ortaklama ve ortalama ortaklama olmak üzere iki farklı kategoriye ayrılmaktadır. Maksimum ortaklama işlemi, öznitelik haritasındaki her bir yama içerisinden en yüksek değeri seçerken, ortalama ortaklama katmanı, her yamanın ortalama değerini hesaplamaktadır [50] ve şu denklemle ifade edilmektedir:

$$z = \frac{1}{N} + \sum_{(i,j)\in S}^{\infty} x_{ij}, i, j = 1, \ 2, ..., p \tag{1.2}$$

burada, S, boyutu $p \times p$ olan bir pencereyi temsil etmektedir. Ortalama ortaklamada, x_{ij}, (i, j) konumundaki aktivasyon değerini ifade eder ve N, S penceresindeki toplam eleman sayısını göstermektedir.

1.2.1.3. Aktivasyon Katmanı

CNN mimarisinde ağın doğrusal olmayan öğrenme kapasitesini artıran ve karar sınırlarının belirlenmesini sağlayan temel bileşenlerden birisi aktivasyon katmanıdır. Bu katman, nöronların girdilerini alarak belirli bir kurala göre dönüştüren aktivasyon fonksiyonları kullanmaktadır. Aktivasyon fonksiyonları, modelin karmaşık verileri daha iyi anlamasını sağlarken, doğrusal olmayan ilişkileri öğrenmesine de olanak tanımaktadır. Doğrusal modeller karmaşık verileri yeterince iyi temsil edemezken, doğrusal olmayan aktivasyonlar bu sorunu aşmaktadır. Doğrultulmuş Doğrusal Birim

(Rectified Linear Unit, ReLU), genellikle DL uygulamalarında en yaygın kullanılan aktivasyon fonksiyonudur ve pozitif girdiler için aynı değeri korurken, negatif girdiler için sıfır çıkışı üretmektedir. Diğer yaygın aktivasyon fonksiyonları arasında sigmoid ve softmax yer almaktadır. Sigmoid, çıktıyı sıfır ile bir arasında sıkıştırırken, softmax çok sınıflı sınıflandırma problemlerinde olasılık dağılımı oluşturmaktadır [51].

Aktivasyon katmanı, modelin öğrenme yeteneğini artırarak daha karmaşık fonksiyonları öğrenebilmesine yardımcı olmakta ve özellikle sınıflandırma problemlerinde modelin hangi sınıfa ait olduğunu belirlemesine katkı sağlamaktadır.

1.2.1.4. Tam Bağlı Katman

DL modellerinin önemli bir bileşeni olan tam bağlı katman, sinir ağlarının son aşamalarında yer almaktadır. Bu katman, önceki katmanlardan elde edilen özniteliklerin birleştirilerek daha yüksek düzeyde soyutlamaların sağlanmasına olanak tanımaktadır. Her bir nöron, kendisinden önceki katmandaki tüm nöronlarla bağlantılıdır ve bu bağlantılar aracılığıyla bilgiyi işlemektedir. Tam bağlı katmanlar, aktivasyon fonksiyonları kullanarak doğrusal olmayan bir özellik eklemektedir. Bu da modelin daha karmaşık ilişkileri öğrenmesini mümkün kılmaktadır. Ayrıca, çıkış katmanı olarak kullanıldığında, modelin belirli sınıflara ait olma olasılıklarını tahmin etmesine olanak tanımaktadır. Bu katmanın eğitim sürecinde, ağırlıklar ve yanlılık terimleri, geri yayılım algoritması ile optimize edilerek, modelin genel performansını artırmak amacıyla güncellenmektedir. Tam bağlı katman takip eden denklem ile ifade edilmektedir:

$$y = f\left(Wz + b\right) \tag{1.3}$$

burada, y çıkış vektörünü, z giriş vektörünü temsil etmektedir. f, aktivasyon fonksiyonunu gösterirken, W tam bağlı katmanın ağırlığını ve b yanlılık terimini ifade etmektedir.

1.2.2. CNN Tabanlı Mimariler

Bu bölümde tez çalışmamızda kullanılan bazı CNN mimarileri hakkında kısa bilgiler sunulmaktadır.

1.2.2.1. MobileNetv2 Mimarisi

MobileNetv2 mimarisi, MobileNetv1 mimarisi üzerine tersine çevrilebilir dar boğaz modülleri ekleyerek geliştirilmiştir. Bu model mimarisi, $224 \times 224 \times 3$ piksel boyutundaki giriş görüntülerini alarak, otuz iki adet filtre içeren bir evrişim katmanı ile başlamaktadır. Bu mimari, $7 \times 7 \times 1280$ piksel boyutunda bir çıktı üreten nokta evrişimi ile sonuçlanan, tersine çevrilmiş artık dar boğazdan oluşan on dokuz katman içermektedir. Artık blok, ağın daha derin katmanlarına bilginin iletilmesine olanak tanıyan bir bağlantıyla birleştirilmiştir [52]. Şekil 1.9'da, MobileNetv1 ve MobileNetv2 mimarileri arasındaki farkların görsel temsili sunulmaktadır [53].

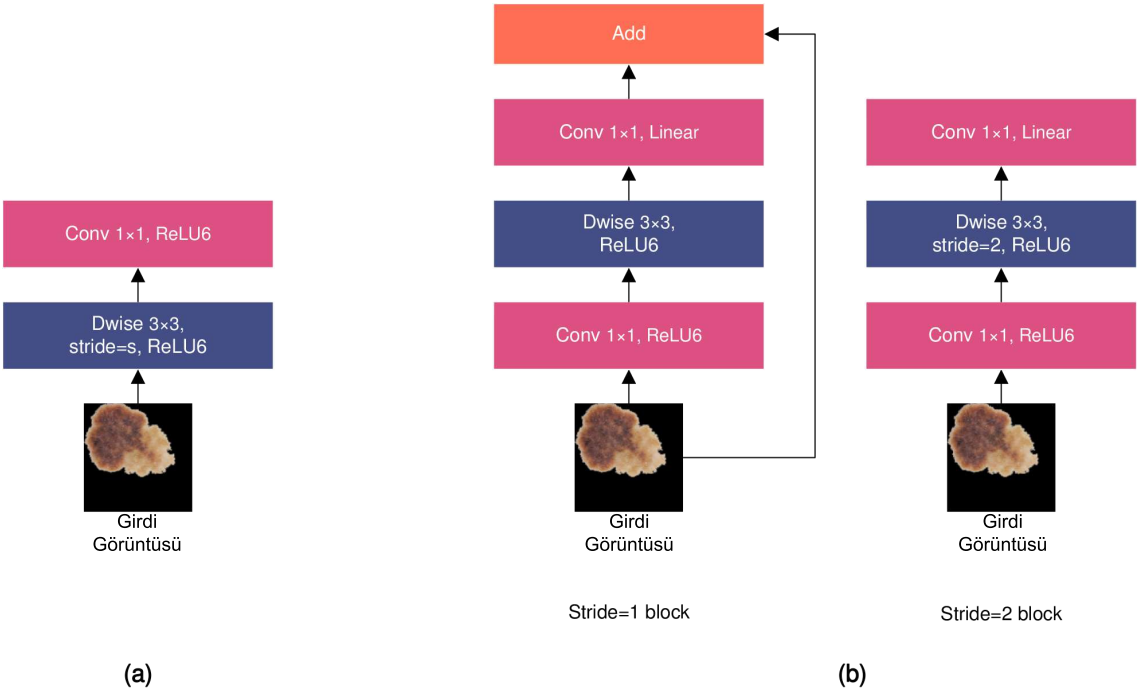

Şekil 1.9. (a) MobileNetv1 ve (b) MobileNetv2 mimarileri arasındaki farkların mimari gösterimi [53].

1.2.2.2. EfficientNetB0 Mimarisi

EfficientNet mimarisi, ImageNet veri seti üzerinde eğitilmiş B0'dan B7'ye kadar sekiz modelden oluşmaktadır. Bu modeller, hesaplama açısından verimlilikleriyle tanınmakta olup, bileşik ölçekleme yöntemi sayesinde yüksek doğruluk artışları göstermektedir. Bileşik ölçekleme yöntemi, ağın derinlik, genişlik ve çözünürlük boyunca eşit şekilde ölçeklendirilmesini içermektedir. Bu sayede temel evrişimsel ağ modelinin hedef model boyutuna genişletilmesine olanak tanımaktadır [54].

Şekil 1.10'da genel mimarisi gösterilen EfficientNetb0 modeli [55], 3×3 boyutunda bir evrişim işlemi ile başlamaktadır. Ardından, görüntü özniteliklerini çıkarmak amacıyla on altı adet ters dar boğaz evrişim modülü kullanılmıştır. Sınıflandırma sonuçları, 1×1 evrişim ve global ortalama ortaklamanın ardından tam bağlı katman aracılığıyla üretilmektedir. Ayrıca, ağdaki her evrişim işleminden sonra toplu normalleştirme (Batch Normalization, BN) işlemi uygulanmaktadır [54].

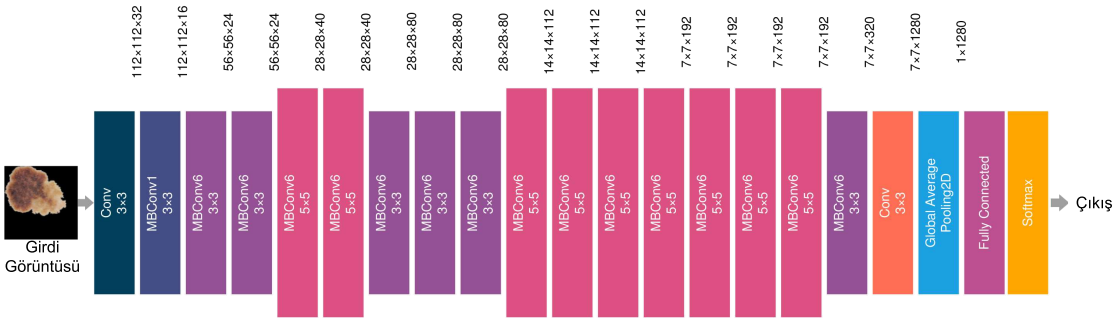

Şekil 1.10. EfficientNetb0 modelinin genel mimarisi [55].

1.2.2.3. DenseNet201 Mimarisi

Şekil 1.11'de mimarisi görülen DenseNet201 modeli [56], iki yüz bir katmandan oluşan bir CNN mimarisidir. Ağın en üst katmanı, görüntü sınıflandırmasına uygun hale getirilmek amacıyla softmax sınıflandırıcı ve global ortalama ortaklama ile değiştirilmiştir. DenseNet201 mimarisinin bileşik fonksiyonu, BN, ReLU ve 3×3 evrişim katmanını içermektedir. Öznitelik haritalarının boyutunu azaltmak amacıyla, BN ile başlayan, ardından 1×1 evrişim ve son olarak 2×2 ortalama ortaklama katmanından

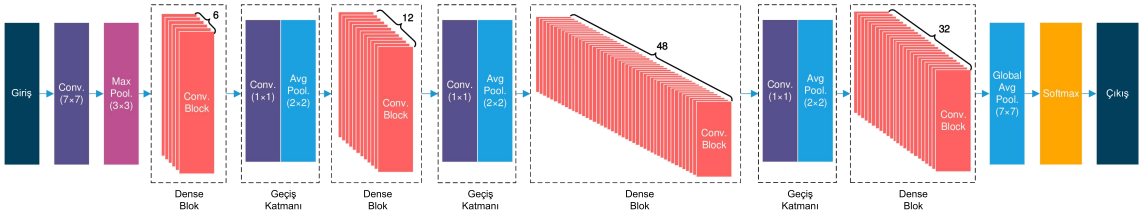

Şekil 1.11. DenseNet201 modelinin ağ mimarisi [56].

oluşan geçiş katmanları bulunmaktadır. Ayrıca, modelin hesaplama verimliliğini artırmak amacıyla, her 3×3 evrişim katmanının ardından 1×1 evrişim katmanı içeren bir dar boğaz katmanı eklenmiştir [57].

1.2.2.4. DarkNet53 Mimarisi

DarkNet53 mimarisi, YOLOv3 modelinin temelini oluşturan ve özellikle nesne tespiti için tasarlanmış elli üç katmanlı bir CNN modelidir. Bu model ile YOLOv3 mimarisinin nesne tespiti performansı optimize edilmektedir. DarkNet53 modeli, DarkNet19 mimarisi ve residual bağlantıların kombinasyonu sonucu oluşturulmuştur. Bu sayede derin ağların eğitiminde kaybolan gradyan problemini azaltmaktadır. Modelinin mimarisinde 1×1 ve 3×3 boyutlarında çekirdekler, BN ve LeakyReLU katmanları bulunmaktadır. DarkNet53, dar ve geniş katmanlar arasında denge kurarak yüksek doğruluk ve verimlilik sağlamaktadır. Büyük veri setleri üzerinde etkili bir performans sergilemektedir. Ayrıca, çoklu evrişim çekirdekleri kullanarak öznitelik vektör analizi yapmakta ve çıktıyı normalleştirmektedir [58, 59].

1.2.2.5. InceptionResNetv2 Mimarisi

InceptionResNetv2 mimarisi, Inception mimarisi ile residual ağların avantajlarını birleştiren bir modelidir. Google tarafından geliştirilen model toplamda yüz altmış dört derin artık katmanı içermektedir. Bu mimari, residual bağlantılar sayesinde daha derin katmanlardan öğrenmeyi kolaylaştırarak, kaybolan gradyan sorununu azaltmayı hedeflemektedir. $299 \times 299 \times 3$ boyutlarındaki RGB görüntüleri girdi olarak almaktadır. Inception modüllerinde, farklı boyutlardaki evrişim çekirdekleri ile çoklu ölçeklerde öznitelik çıkarımı yapılmaktadır [60].

1.2.2.6. NasNetLarge Mimarisi

NasNetLarge, Zoph ve ark. tarafından, sinirsel mimari arama teknikleri kullanılarak, görüntü tanıma uygulamaları için tasarlanmış bir derin sinir ağıdır. Bu mimari, hücre tabanlı bir arama alanı üzerine inşa edilmiştir. Büyük veri setlerinde yüksek doğruluk ve verimlilik sağlamayı hedeflemektedir. Yapısında evrişim katmanları, ortaklama katmanları, BN ve ReLU işlemleri bulunmaktadır. 5.3 milyon parametre ve seksen sekiz evrişimsel katman içeren NasNetLarge, hem yerel hem de küresel öznitelikleri öğrenmek için normal ve azaltma hücreleri kullanmaktadır. Azaltma hücreleri, öznitelik haritalarını küçültüp küresel ögeleri toplarken, normal hücreler yerel öznitelikleri çıkarmaktadır [61].

1.2.2.7. ResNet18 Mimarisi

Şekil 1.12'de mimarisi gösterilen ResNet18 mimarisi [62], DL alanında önemli bir mimari olan ResNet ailesinin en küçük varyantlarından biridir. ResNet mimarilerinin katman sayısı ile ifade edilen birçok versiyonu bulunmaktadır. ResNet18 mimarisi, on sekiz katman ve $3 \times 224 \times 224$ görüntü giriş boyutuna sahiptir. ResNet18, derin ağların eğitilmesinde karşılaşılan zorlukları aşmayı amaçlayan bağlantılar kullanmaktadır. Bu bağlantılar, ağın katmanlar arasında bilgi aktarımını sağlayarak gradyan kaybı problemini minimize etmekte ve daha derin ağların eğitimini mümkün kılmaktadır. ResNet18 mimarisinin başarısı, katmanlar arasındaki bilgi kaybını engelleyerek daha hızlı ve verimli bir öğrenme süreci sağlamasında yatmaktadır. Ayrıca, bu yapı, yüz tanıma, nesne sınıflandırma ve tıbbi görüntü analizi gibi çeşitli görsel tanıma görevlerinde etkili bir şekilde kullanılmaktadır. ResNet18, genellikle daha derin ağlarla karşılaştırıldığında daha düşük hesaplama maliyetlerine sahiptir. Bu nedenle pratik uygulamalarda tercih edilen bir modeldir [62, 63].

1.2.2.8. ResNet50 Mimarisi

ResNet50 mimarisi, evrişim, maksimum ortaklama, ortalama ortaklama, tam bağlı ve softmax katmanlarından oluşan elli artık bloğa sahiptir. ResNet50 mimarisinin çalışma prensibi, katman derinleştikçe önceki katmandaki bozulmanın performansa olumsuz etki etmemesini amaçlayan atlamalı bağlantıdır. Şekil 1.13'te gösterilen ResNet50

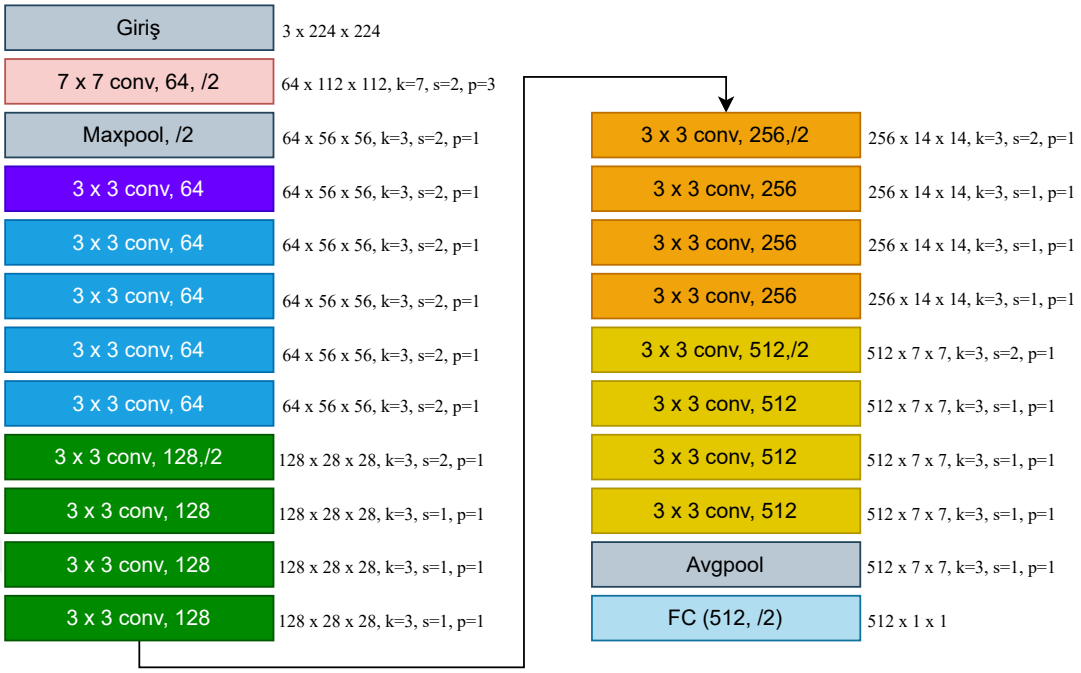

Şekil 1.12. ResNet18 modelinin ağ mimarisi [62].

mimarisinde [64], farklı renklerde özdeş katmanlar vardır ve her katman, bir önceki katmandaki bozulmayı bir sonraki katmana aktarmaktadır [64].

1.2.2.9. ConvNeXt Mimarisi

Liu ve ark. [65] tarafından sunulan ConvNeXt mimarisi, ResNet-50 ağını temel alan ve ConvNet modüllerini kullanan bir CNN modelidir. Bu yapı, swin dönüştürücünün tasarımına dayalı olarak geliştirilmiş, doğruluk ve ölçeklenebilirlik açısından başarılı performans göstermektedir. Ayrıca, ConvNeXt, standart ConvNet modüllerinin sadeliği ile işlem verimliliğini koruma yeteneğini sürdürmektedir [66, 67].

Şekil 1.14'te, ConvNeXt mimarisinin genel yapısı, Şekil 1.15'te ise her bir ConvNeXt bloğunun detaylı iç yapısı gösterilmektedir [67]. ConvNeXt mimarisi, giriş birimi ile başlayarak, özniteliklerin çıkarılması ve işlenmesini sağlayan dört ConvNeXt blok aşaması ile devam etmektedir. Ardından verilerin boyutunu düşürerek özet bilgiler sağlayan bir Global Ortalama Ortaklama (GAP) katmanı içermektedir. Bu süreç, verilerin normalleştirilmesi için bir Katman Normalleştirme (Layer Normalization, LN) katmanıyla devam etmektedir. Son aşamada sınıflandırma veya regresyon gibi görevler için bir doğrusal katman bulunmaktadır.

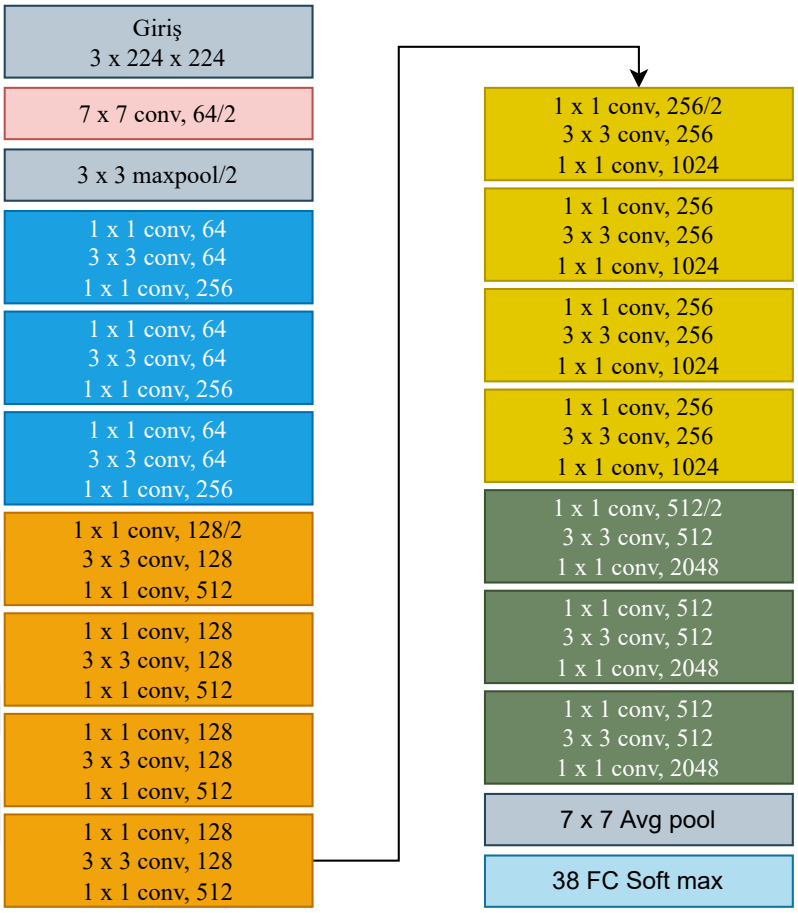

Şekil 1.13. ResNet50 modelinin ağ mimarisi [64].

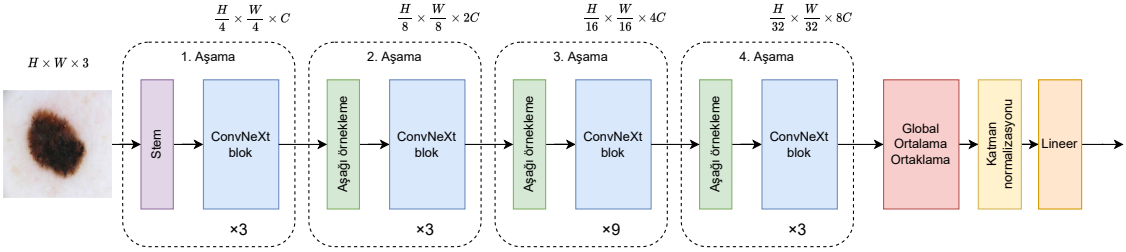

Şekil 1.14. ConvNeXt temel mimarisi [67].

Şekil 1.14'te stem bloğu, Şekil 1.15'te ayrıntılı görülebileceği gibi, giriş görüntülerini bir evrişim katmanı ve bir LN'dan oluşan yapı aracılığıyla işlemektedir. Böylece, H ve W sırasıyla görüntünün yüksekliği ve genişliği olmak üzere, H × W × 3 olan bir giriş görüntüsü için, evrişim katmanı 4 × 4 (k = 4) ve 4 (s = 4) adımlı C çekirdekleri aracılığıyla aşağı örnekleme yaparak C kanalları ile giriş boyutunun dörtte biri kadar özellik üretmektedir. Son olarak, oluşturulan özniteliklere bir LN uygulanmaktadır.

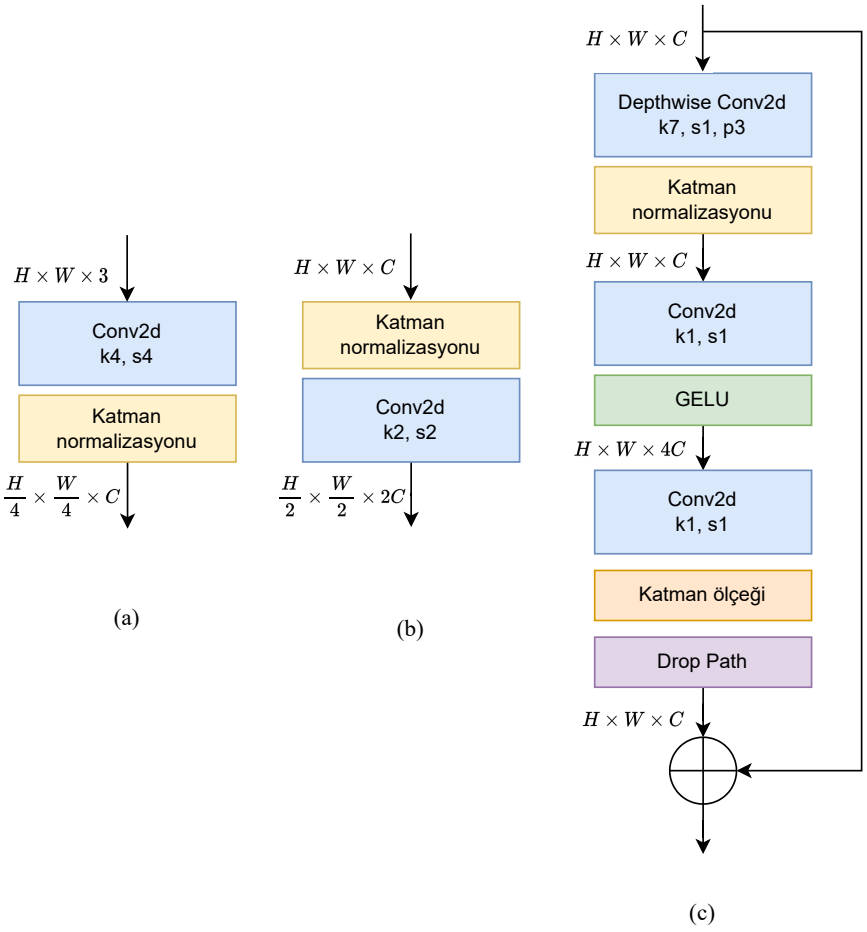

Şekil 1.15. ConvNeXt mimarisinde bulunan blok tasarımları (a) Stem bloğu iç yapısı, (b) Aşağı örnekleme bloğu iç yapısı, (c) ConvNeXt bloğu iç yapısı [67].

ConvNeXt, eğitim kararlılığını ve performansını artırmak amacıyla BN yerine LN [68] kullanmaktadır. Bu güncelleme, ConvNeXt mimarisinin BN tarafından sağlanan karmaşıklık olmadan daha iyi sonuçlar elde etmesine yardımcı olmaktadır. ConvNeXt bloğunda LN, girişleri öznitelikler ile eşitlemek için kullanılmaktadır ve aşağıdaki denklem ile ifade edilmektedir:

$$LN\left(x\right) = \frac{x - \mu}{\sqrt{\sigma^2 + \epsilon}}.\gamma + \beta \tag{1.4}$$

burada, μ ve σ giriş x'in ortalama ve standart sapmasını, γ ve β ise model tarafından öğrenilen ölçekleme ve kaydırma parametrelerini temsil etmektedir. ϵ ise sayısal kararlılık için küçük bir sabittir. LN genellikle derinlikten ayrılmış evrişim katmanından sonra ve aktivasyon fonksiyonundan önce yerleştirilir. Temel amacı, evrişim katmanının çıktısını normalize ederek eğitim kararlılığını ve genel model performansını artırmaktır [65].

Ayrıca, Şekil 1.14'te ConvNeXt mimarisinin dört aşamasının her biri bir aşağı örnekleme bloğu ve ConvNeXt bloklarından oluşmaktadır. ConvNeXt bloklarının her biri, bloğun altında belirtildiği gibi farklı sayıda döngü yapmaktadır.

Şekil 1.15 (b)'de aşağı örnekleme bloğu 2 × 2 (k = 2) çekirdekli ve 2 adımlı (s = 2) evrişim gerçekleştirerek çoklu ölçekte hiyerarşik özellikler üretmektedir. Bu da giriş öznitelik haritalarının çözünürlüğünü azaltmakta ve kanal sayısını iki katına çıkarmaktadır. Şekil 1.15 (c)'de ConvNeXt bloğu üç evrişim katmanı, bir depthwise evrişim (k = 7, s = 1), iki 1 × 1 evrişim katmanı (k = 1, s = 1) ve bunların arasında aktivasyon fonksiyonu olarak bir Gauss Hatası Doğrusal Birimler (Gaussian Error Linear Unit, GELU) içermektedir. İkinci evrişim katmanının çıkışında bir katman ölçeği ve bir drop path uygulanır. Son olarak, bir artık bağlantı kullanılır.

Aktivasyon fonksiyonu, doğrusal bir sinir ağının çıktısına doğrusal olmayanlık eklemek için GELU [69] kullanmaktadır. GELU şu denklem ile ifade edilmektedir:

$$GELU\left(x\right) = x\Phi\left(x\right) \tag{1.5}$$

burada, x modele verilen girdiyi, $\Phi\left(x\right)$ standart normal dağılımın kümülatif dağılım fonksiyonunu temsil etmektedir. Bu aynı zamanda şu şekilde de ifade edilebilmektedir:

$$GELU\left(x\right) = x\frac{1}{2}\left[1 + erf\left(\frac{x}{\sqrt{2}}\right)\right] \tag{1.6}$$

burada, $erf(x)$ hata fonksiyonunu temsil etmektedir. GELU denkleminde $erf(x)$ fonksiyonu yerine konulduğunda yaklaşık denklem aşağıdaki şekilde olmaktadır [69]:

$$GELU\left(x\right) = 0.5x\left(1 + tanh\left[\sqrt{2/\pi}\left(x + 0,044715x^3\right)\right]\right) \tag{1.7}$$

1.2.3. Görü Dönüştürücü (ViT)

Görü dönüştürücüler [70], metinsel doğal dil işleme alanındaki dönüştürücü model mimarileri temel alınarak geliştirilmiştir. Dönüştürücü tabanlı ağlar, küresel öz-dikkat süreçlerine sahip oldukları için her veri ögesini birbiriyle ilişkilendirebilmektedir. Bu nedenle, CNN mimarilerinin yerel evrişimsel yapısından farklı olarak, uzun vadeli

ilişkileri doğal olarak yakalama yeteneğine sahiptirler. Bilgisayarla görme görevleri de küresel ilişkileri içerdiğinden, dönüştürücü yapıları son yıllarda bilgisayarla görme alanında büyük ilgi görmektedir.

ViT, görüntü tanıma gibi görevleri yerine getiren ileri düzey bir DL modelidir. ViT mimarisi, giriş görüntüsünü önceden belirlenmiş boyutlardaki daha küçük bölütlere ayırmakta ve her bir bölüt belirtgeç olarak adlandırılmaktadır. Bireysel bileşenler, bir diziye sıkıştırılmakta ve ardından doğrusal bir katman aracılığıyla daha büyük boyutlara aktarılmaktadır [70, 71].

Bölümlerin konum bilgisi, pozisyonel kodlama aracılığıyla entegre edilmektedir. Bu aşamaların tamamlanmasının ardından, belirteçler Çok Başlı Dikkat (Multi-Head Attention, MHA) mekanizması ve ileri besleme ağları içeren dönüştürücü blokları aracılığıyla işlenmektedir. Dönüştürücü bloklarının amacı, her bir bileşen ile diğer bileşenler arasındaki etkileşimler hakkında bilgi edinerek tüm bağlamı tanımlamaktır. Tüm belirteçlerden gelen girdi bilgileri bir araya getirilerek nihai sınıflandırma kararını doğrusal katman aracılığıyla belirleyen ayrı bir sınıflandırma belirtecine eklenmektedir. ViT, geniş veri setleri üzerinde eğitildiğinde güçlü bir performans sergilemekte ve CNN mimarilerine kıyasla daha az parametre ile benzer doğruluk oranlarına ulaşabilmektedir. ViT algoritmalarının örüntü tanıma, nesne tespiti ve bölütleme gibi bilgisayarlı görme görevlerinde çeşitli uygulama alanları bulunmaktadır [72, 73].

Şekil 1.16'da gösterilen genel ViT mimarisinde [74], öncelikle orijinal görüntü $x \in \mathbb{R}^{H \times W \times C}$ 16×16 boyutunda örtüşmeyen parçalara ayrılmaktadır. Bu parçalar daha sonra $1 \times n$ matrisine düzleştirilir. 2D görüntü $x \in \mathbb{R}^{H \times W \times C}$ düzleştirilmiş 2D parçaların bir dizisi olarak $x \in \mathbb{R}^{N \times (P^2.C)}$ biçiminde yeniden şekillendirilir. Burada (H, W) orijinal görüntünün çözünürlüğünü, C kanal sayısını belirtmektedir. (P, P) her bir görüntü parçasının çözünürlüğünü ifade ederken, $N = \frac{HW}{P^2}$ elde edilen parça sayısını göstermektedir. Düzleştirilmiş parçalar, öğrenilebilir bir doğrusal katman aracılığıyla boyutu D olacak şekilde ayarlanır ve matris biçiminde $x \in \mathbb{R}^{N \times D}$ olarak temsil edilmektedir [75]. ViT mimarilerinin başlıca avantajlarından biri, çeşitli boyutlardaki görüntüleri ve verileri verimli bir şekilde işleyebilme kapasitesidir. Ancak, önemli miktarda bellek ve hesaplama gücü gerektirdiği için hesaplama açısından maliyetlidir.

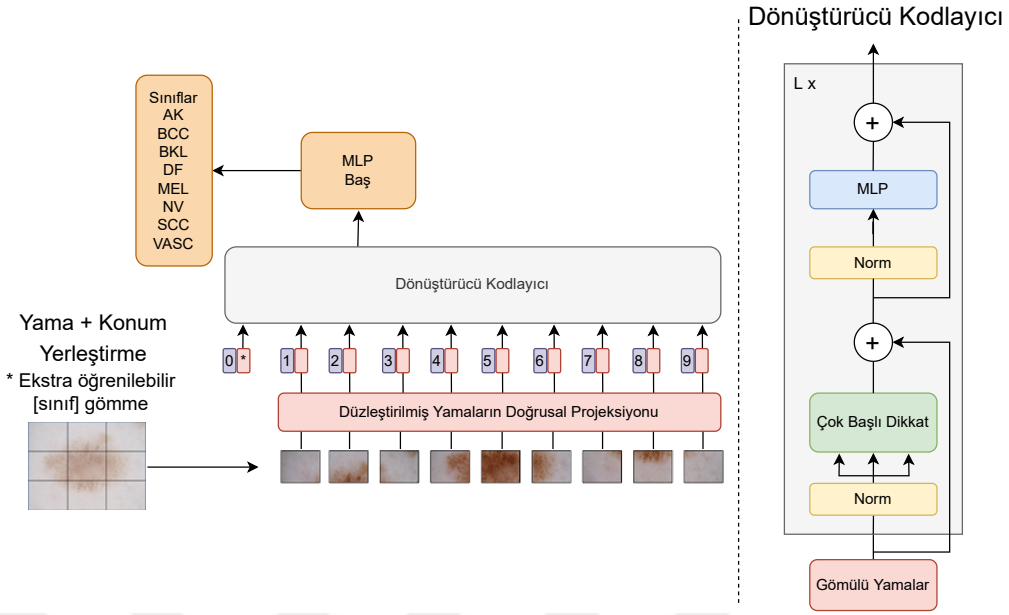

Şekil 1.16. Genel ViT mimarisi [74].

1.2.3.1. Öz-dikkat Mekanizması

Bir dizinin farklı ögelerine ağırlık atayan ve modelin en alakalı bilgilere odaklanmasını sağlayan bir tekniktir. Dönüştürücü modelleri bağlamında, bir öz-dikkat mekanizması, bir sorguyu ve bir dizi anahtar-değer çiftini bir çıktıya eşlemektedir. Spesifik olarak, sorgu, modelin odak bilgilerini temsil eden bir vektörden oluşmaktadır. Anahtar ise girdi verisinin bir ögesini temsil eden vektördür. Değer, anahtarla ilişkili ilgili bilgiyi belirten bir vektördür. Son olarak, çıktı, sorgu ile karşılık gelen anahtarlar arasındaki benzerlik temelinde belirlenen ağırlıklarla değerlerin ağırlıklı toplamı alınarak hesaplanmaktadır [70, 71, 76].

Şekil 1.17'de blok diyagramını gösterilen öz-dikkat mekanizması [70], dönüştürücü modellerinin önemli bir bileşenidir. Bu mekanizma, uzun menzilli bağımlılıkların yakalanmasına ve girdi dizisinin ilgili kısımlarına odaklanılmasına olanak tanımaktadır. Öz-dikkat mekanizmasının ana avantajlarından biri, bir dizideki uzun menzilli bağımlılıkları yakalamadaki verimliliğidir. Bu, modellerin tahmin yaparken girdinin uzak kısımlarından gelen bilgileri dikkate almasını sağlamaktadır.

Öz-dikkat mekanizması, sorgu (Q), anahtarlar (K) ve değerler (V) matrislerini kullanarak çalışmaktadır. Bir dikkat fonksiyonu aşağıdaki denklemle ifade edilmektedir:

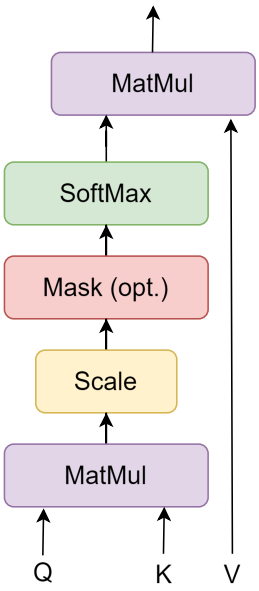

Şekil 1.17. Öz-dikkat bloğu [70].

$$Dikkat\left(Q,K,V\right)=softmax\left(\frac{QK^{T}}{\sqrt{d_{k}}}\right)V \tag{1.8}$$

burada, Q sorgu matrisini, K anahtar matrisini, V değerler matrisini, T transpozisyonu ve d_k anahtarların boyutunu temsil etmektedir [70].

1.2.3.2. Çok Başlı Dikkat (MHA) Mekanizması

Tek başlı dikkat mekanizmasının zayıf modelleme yeteneği nedeniyle MHA önerilmiştir. Şekil 1.18'de mimarisi gösterilen MHA [70], her dikkat katmanının modelleme yeteneğini artırırken, parametre sayısını artırmamaktadır. Tek başlı dikkat mekanizmasından farklı olarak, MHA, Q, K ve V matrislerini paralel olarak işlemek için farklı, daha düşük boyutlu alt alanlara (d_q, d_k ve d_v) doğrusal olarak haritalamaktadır. Bu yaklaşım, benzerlik ve dikkat hesaplamalarının paralel yapılmasını sağlayarak modelin daha fazla bilgi yakalamasına olanak tanımaktadır. Elde edilen vektörler daha sonra birleştirilmekte ve nihai çıktıyı elde etmek için yeniden haritalandırılmaktadır. MHA mekanizması aşağıdaki denklem ile ifade edilmektedir:

$$MHA\left(Q,K,V\right)=Concat\left(head_{1},\ldots,head_{h}\right)W^{O} \tag{1.9}$$

burada her bir başlık ($head_i$) aşağıdaki denklem kullanılarak hesaplanmaktadır:

$$head_i = Dikkat\left(QW_i^Q, KW_i^K, VW_i^V\right) \tag{1.10}$$

burada, $W_i^Q \in \mathbb{R}^{d_{model} \times d_k}$, $W_i^K \in \mathbb{R}^{d_{model} \times d_k}$, $W_i^V \in \mathbb{R}^{d_{model} \times d_v}$, $W^O \in \mathbb{R}^{hd_v \times \mathrm{d}_{model}}$ parametre matrisini temsil etmektedir [70].

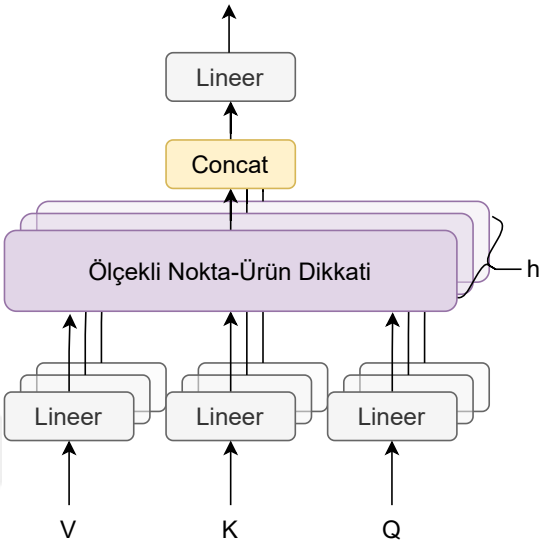

Şekil 1.18. Çok başlı dikkat mimarisi [70].

MHA, her baş için dikkat hesaplaması sırasında her bir vektörün boyut sayısını azaltarak aşırı uyumu kısmen azaltmaktadır. Farklı alt alanlardaki dikkatlerin değişken dağılımları nedeniyle, bu modül vektör birleştirilmesi sırasında farklı dizilim boyutları arasındaki özellik etkileşimlerini entegre etmektedir [77].

Her bir kodlayıcı ve kod çözücü katmanı, her noktaya ayrı ayrı ve tutarlı bir şekilde uygulanan tam bağlı bir ağ içermektedir. Bu katman, arasında bir ReLU aktivasyonu bulunan iki doğrusal dönüşümden oluşmaktadır. İleri Besleme Ağı (Feedforward Neural Network, FFN) takip eden denklem ile ifade edilmektedir:

$$FFN\left(x\right) = max\left(0, xW_1 + b_1\right)W_2 + b_2 \tag{1.11}$$

burada, x giriş vektörü, W_1 ve W_2 ağırlık matrisleri, b_1 ve b_2 ise yanlılık terimleridir. Bu dönüşümler her pozisyonda aynı şekilde uygulanmakta, ancak her katmanda farklı parametreler kullanılmaktadır [70].

1.2.4. MetaFormer Temel Modelleri

MetaFormer, dönüştürücü temeline dayalı ve belirli bir modelden bağımsız genelleştirilmiş bir çerçevedir. Belirteç karıştırıcı mekanizmalarının verimliliğini ve etkinliğini artırmak amacıyla tasarlanmıştır. Dönüştürücülerden, belirteç karıştırıcıyı tanımlamama özelliği ile ayrılan bu mimari, girdileri belirteçler halinde işler ve özelleştirilebilir bilgi işleme yöntemlerini destekler [78]. Verilen belirteç dizisi aşağıdaki denklem ile ifade edilmektedir:

$$X = GirdiYerleştirme\,(I) \tag{1.12}$$

burada, I giriş görüntüsünü temsil etmektedir [78]. Belirteç dizisi $X \in \mathbb{R}^{N\times C}$ uzunluğu N ve kanal boyutu C ile tekrar eden MetaFormer bloklarına geçirilir ve bu bloklar aşağıdaki şekillerde ifade edilir:

$$X' = X + BelirteçKarıştırıcı(Norm_B(X)) \tag{1.13}$$

$$X'' = X' + f\left(Norm_L\left(X'\right)W_1\right)W_2 \tag{1.14}$$

burada, X' ve X'' güncellenmiş giriş temsillerini ifade etmektedir. $Norm_B(.)$ BN'yi ve $Norm_L(.)$ LN'yi temsil etmektedir. $BelirteçKarıştırıcı(.)$ temelde, belirteçler arasında bilgi yaymak için kullanılan bir belirteç karıştırıcısını ifade etmektedir. $f(.)$ aktivasyon fonksiyonunu belirtir. W_1 ve W_2 kanal MLP'sindeki öğrenilebilir parametrelerdir. Belirteç karıştırıcılarının somut modüller olarak belirlenmesi sayesinde, MetaFormer çeşitli özel modeller oluşturacak şekilde uyarlanabilir. Her model kendine özgü özelliklere ve performansa sahip olabilmektedir [78].

1.2.5. Topluluk Öğrenme Mimarileri

Topluluk öğrenme, çeşitli öğrenme algoritmalarını kullanarak bir sınıflandırıcının doğruluğunu artırmak için kullanılabilecek bir stratejidir. Bu yaklaşım, tekil modellere kıyasla daha etkili sonuçlar verebilmektedir. Zayıf öğrenicileri güçlü olanlarla

birleştirerek genel performansı artıran etkili bir meta-sınıflandırma tekniğidir [79]. Topluluk öğrenme teknikleri, tek bir sınıflandırıcıya kıyasla daha doğru tahminler elde etmek için birden fazla ML algoritmasını birleştirmektedir. Topluluk modellerinin kullanımındaki amaç, genelleme hatasını minimize etmektir. Bu yaklaşım, çeşitli ve bağımsız modelleri kullanarak tahmin hatalarını etkili bir şekilde azaltmaktadır [80]. Topluluk yaklaşımı, tekil modellerin toplu çıktısını kullanarak tahminlerde bulunmaktadır. Birden fazla temel modelden oluşmasına rağmen, topluluk modeli tek bir model gibi işlev görmekte ve davranmaktadır [79]. Topluluk öğrenme torbalama, güçlendirme, istifleme ve oylama olmak üzere dört ana algoritmaya ayrılmaktadır [81].

Oylama, topluluk öğrenme algoritmaları içinde yer alan bir yöntem olup, tekil modellerin sonuçlarına dayanarak nihai çıktıyı belirlemek için kullanılan bir tekniktir [82]. Tek bir modelin sonuçlarına dayanmak yerine, farklı modellerden gelen görüşleri toplayarak daha doğru tahminler yapmak için "kalabalığın bilgeliği" kavramını kullanmaktadır. Sınıflandırıcılarda iki tür oylama yöntemi bulunmaktadır. Bunlar, esnek oylama ve katı oylamadır [80].

1.2.5.1. Esnek Oylama Yöntemi

Bu oylama yöntemi, topluluk öğrenme modelleri içinde kullanılan bir tahmin birleştirme tekniğidir. Bu yöntemde, her bir modelin tahminleri, belirli bir olasılık dağılımı kullanılarak birleştirilmektedir. Her modelin tahminine bir ağırlık verilmekte ve bu ağırlıklar, tahminlerin toplamı üzerinden hesaplanmaktadır. Esnek oylama, özellikle sınıflandırma problemlerinde kullanılmakta ve her modelin tahmininin yanı sıra, modelin güvenilirliğini de dikkate almaktadır [83]. Şekil 1.19'da esnek oylama yöntemi örneklendirilerek anlatılmaktadır. Burada üç farklı model için eğitilen veri setinden üç farklı tahmin sonucu elde edilmektedir. Giriş görüntüsü, birinci modelde %60 oranla "Sınıf 1"e, %40 oranla "Sınıf 2"ye ait olarak sınıflandırılmaktadır. İkinci modelde bu oranlar %70 "Sınıf 1" ve %30 "Sınıf 2" olarak belirlenmiştir. Üçüncü modelde ise %40 "Sınıf 1" ve %60 "Sınıf 2" oranlarıyla sınıflandırma yapılmaktadır. "Sınıf 1" için üç farklı modelin ortalama tahmin oranı %56,66, "Sınıf 2" için ortalama tahmin oranı %43,33 olarak hesaplanmıştır. Bu durumda esnek oylama algoritmasına göre nihai tahmin sonucu görüntünün "Sınıf 1"'e ait olduğu şeklinde karar verilmektedir.

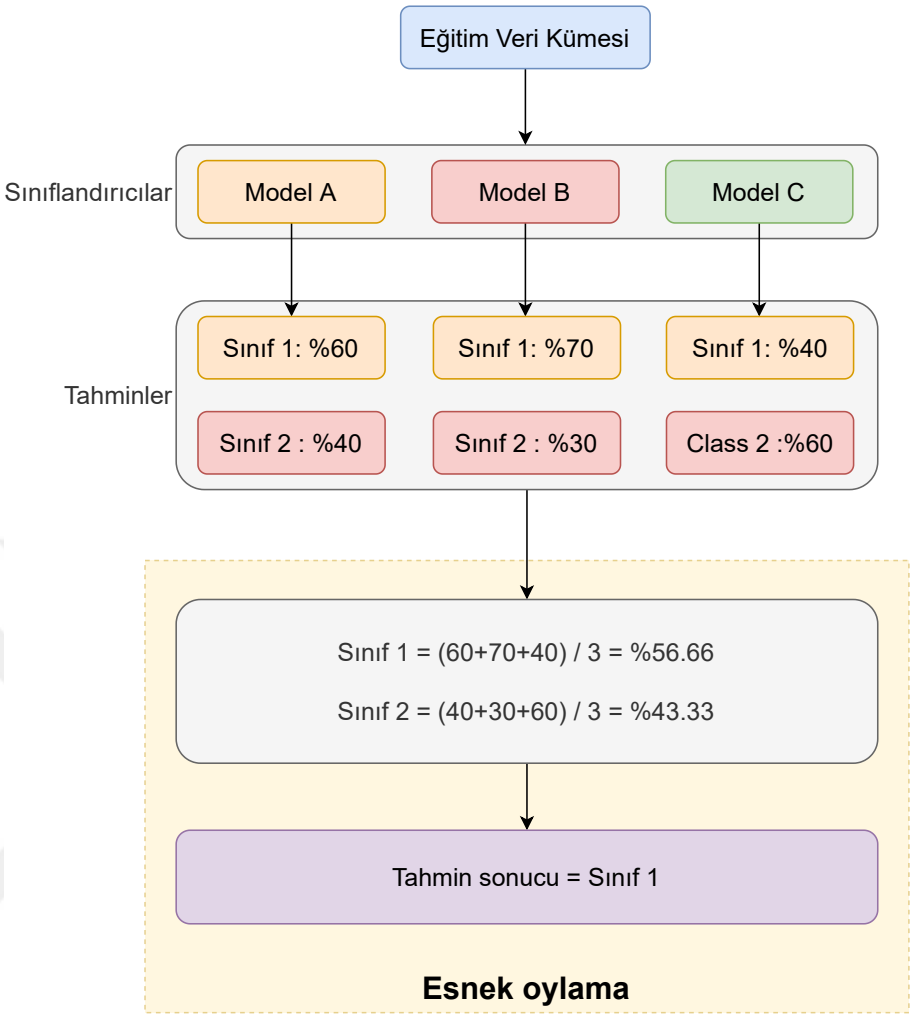

Şekil 1.19. Esnek oylama çalışma prensibi örneği.

1.2.5.2. Katı Oylama Yöntemi

Literatürde çoğunluk oylaması olarak da anılan katı oylama yöntemi, sınıflandırma probleminde kullanılan her bir modelin tahminlerinin birleştirildiği bir yöntemdir [84]. Bu yöntemle, en fazla oyu alan sınıflandırma etiketi nihai karar olarak seçilmektedir. Şekil 1.20'de gösterilen örnekte, A modeli, B modeli ve C modeli olmak üzere üç farklı sınıflandırıcının tahmin sonuçlarının sırasıyla "Sınıf 2", "Sınıf 2" ve "Sınıf 1" olduğu görülmektedir. Bu durumda, iki oy ile "Sınıf 2" çoğunluk oyunu aldığından, nihai sınıflandırma "Sınıf 2" olarak belirlenmektedir.

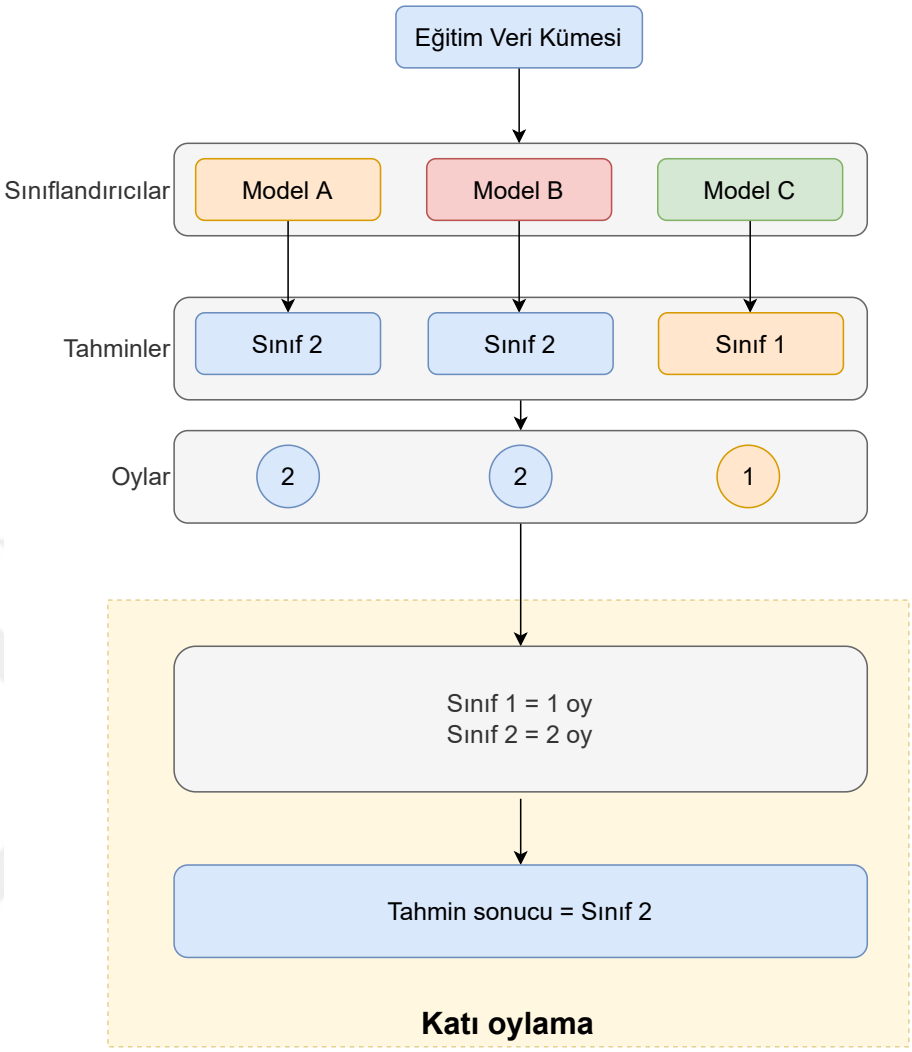

Şekil 1.20. Katı oylama çalışma prensibi örneği.

1.3. Transfer Öğrenme

ML algoritmalarında, transfer öğrenme bir görevde elde edilen bilgilerin başka bir görevin performansını artırmak için kullanma sürecini ifade etmektedir. Bu yöntem genellikle bilgisayarla görü, doğal dil işleme ve konuşma tanıma gibi disiplinlerde tercih edilmektedir. Transfer öğrenme, özellikle hedef görev için sınırlı etiketli veri olduğunda faydalı olmaktadır. Bu tür durumlarda, model daha fazla etiketli veri içeren ilişkili bir görevden elde edilen bilgileri dahil ederek aşırı uyum sorununu giderebilmekte ve performansı artırabilmektedir [85].

Transfer öğrenme kavramı genel olarak kaynak ve hedef alanları olmak üzere iki ana

bileşeni içermektedir. Kaynak alan, modelin ilk olarak eğitildiği görev veya veri setini temsil ederken, hedef alan modelin uygulanacağı yeni görev veya veri setini ifade etmektedir. Model transferi sırasında, daha önce eğitilmiş modelin ağırlıkları ve öznitelikleri yeni iş için tekrar kullanılabilmektedir. DL ile birlikte, transfer öğrenme daha soyut ve yüksek seviyeli bilgilerin öğrenilmesini sağlamaktadır. Bu nitelikler, farklı veri dağılımları, veri türleri, model yapıları veya model türleri arasında aktarılabilmektedir [86].

Son yıllarda, CNN mimarileri, cilt kanseri sınıflandırması da dahil olmak üzere çeşitli bilgisayarla görme görevlerinde yaygın olarak kullanılmaktadır. Bunun başlıca nedeni, CNN mimarilerinin büyük hacimli verileri, verimli bir şekilde işleyip analiz etme yeteneğine sahip olmasıdır. Bununla birlikte, çoğu CNN mimarisi önemli sayıda parametre gerektirmekte ve etkili eğitim için büyük ölçekli veri setlerine ihtiyaç duymaktadır. Cilt kanseri sınıflandırmasında, mevcut veri setlerinin boyutlarının sınırlı olması, yüksek parametre sayısına sahip CNN modellerinin eğitilmesinde ciddi zorluklara ve aşırı öğrenme riskine yol açmaktadır. Bu sorunları aşmak için, CNN tabanlı yaklaşımlarda transfer öğrenme tekniği yaygın bir şekilde kullanılmaktadır [87].

1.4. Görüntü Bölütleme

Görüntü bölütleme, bir görüntüyü belirli özelliklere göre ayrıştırarak, ilgilenilen nesne ya da bölgeyi diğer alanlardan ayırma işlemidir [88]. Bu işlemde, görüntüdeki nesneler pikseller aracılığıyla analiz edilmekte ve her bir pikselin belirli bir sınıfa atanması sağlanmaktadır. Görüntü bölütleme işlemi, nesne tespiti, sınıflandırma ve analiz süreçlerin temel bir adımıdır. Özellikle tıbbi görüntüleme alanında, lezyonların diğer dokulardan ayrılarak ayrıntılı analizlere olanak tanımaktadır. Bu ayrıştırma, görüntüden elde edilen bilgi miktarını artırırken analiz doğruluğunu ve verimliliğini yükseltmektedir.

Görüntü bölütlemesi, dermoskopik görüntülerde cilt kanseri gibi hastalıkların tanı ve tedavisinde büyük öneme sahiptir. Bu süreç, görüntüdeki lezyonun arka plandan ayrılması ve diğer sağlıklı doku ile sınırlarının net bir şekilde belirlenmesi amacıyla gerçekleştirilmektedir [89]. Manuel olarak yapılan lezyon bölütlemesi uzman yorumu gerektirirken, otomatik bölütleme yöntemleri zamandan tasarruf sağlamakta ve hata

oranını azaltmaktadır. Görüntü bölütleme işlemi, DL ve yapay zeka tabanlı algoritmaların kullanımıyla daha hassas ve doğru sonuçlar vermektedir. Özellikle CNN gibi modern yöntemler, bu alanda yaygın olarak kullanılmakta ve çeşitli veri setlerinde başarılı performans göstermektedir. Bu bağlamda, doğru bir görüntü bölütleme, tanı sürecindeki doğruluğu artırarak klinik uygulamalara katkı sağlamaktadır.

1.4.1. DeepLabv3+ Mimarisi

Semantik bölütleme, bir görüntüdeki her pikselin ilgili sınıfla etiketlenerek nesnelerin ve alanların tanımlanması sürecidir ve bilgisayarla görmenin temel bir unsurudur. Semantik bölütleme için literatüre en iyi bilinen modellerden olan ve dört farklı sürümü (v1, v2, v3 ve v3+) yayımlanmış olan DeepLab serisidir. DeepLabv3+ mimarisi, DeepLabv3 mimarisinin bir uzantısı olan DL tabanlı bir görüntü bölütleme modelidir. Oldukça başarılı sonuçlar veren bu model, otonom sürüş, tıbbi görüntü işleme ve video analizi gibi çeşitli uygulamalarda kullanılmaktadır [90].

DeepLab serisi, semantik görüntü bölütlemesi için tasarlanmış, son teknoloji bir derin sinir ağı mimarisidir. Modelin ilk sürümünde, görüntülerdeki çözünürlüğü düşürmeden daha geniş bir bağlam elde edilmesini sağlayan atrous evrişimler tanıtılmıştır. Bir sonraki sürüm olan DeepLabv2 mimarisinde, nesnelerin farklı ölçeklerde işlenmesini önemli ölçüde geliştiren Atrous Uzamsal Piramit Ortaklama (Atrous Spatial Pyramid Pooling, ASPP) yöntemi tanıtılmış ve modelin çok daha esnek ve etkili hale gelmesi sağlanmıştır. DeepLabv3, ASPP konseptini daha derin ve güçlü bir derin ağ ile geliştirerek bu yaklaşımı entegre etmiştir. İlk DeepLab modellerinin diğer önemli bir özelliği ise tam bağlantılı Koşullu Rastgele Alan (Conditional Random Field, CRF) yapısıdır. CRF, model tarafından üretilen ham çıktıyı, konumsal bilgilerin yanı sıra her konumun ve komşu konumların etiketlerini kullanarak, ayrıntılı hale getirmek amacıyla tasarlanmıştır [91].

DeepLab ailesinin en son ve en gelişmiş sürümü olan DeepLabv3+ mimarisi, Şekil 1.21'de gösterilmektedir [92]. Bu mimari, CRF mekanizmasını ortadan kaldırarak, görüntü bölütlemesini iyileştirmek için kodlayı ve kod çözücü mimarisi kullanarak önceki modellerden ayrılmaktadır. DeepLabv3+ mimarisindeki kodlayıcının temel işlevi, görüntülerden semantik bilgi çıkarmaktır. Bu işlev, değiştirilmiş bir Xception modeli

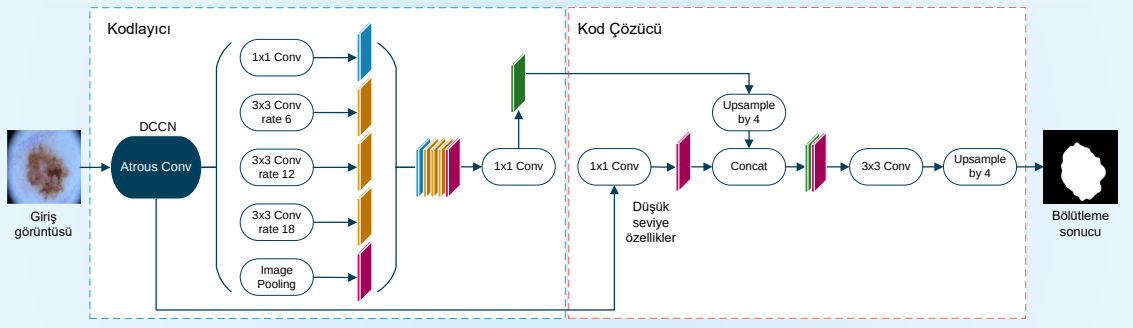

Şekil 1.21. DeepLabv3+ mimarisi [92].

kullanılarak gerçekleştirilmektedir. Kod çözücü ise özellikle nesne sınırlarında bölütleme sonuçlarını iyileştirmeye odaklanmaktadır. Kodlayıcıdan elde edilen ham semantik özellikler ile ağın erken evrelerindeki düşük seviyeli özellikleri birleştirerek, kod çözücü bölütleme sonuçlarını kademeli olarak geliştirmekte ve nesne kenarlarının daha iyi konumlandırılmasını sağlamaktadır. Bu özelliklerin birleştirilmesi ile, çeşitli görsel tanıma uygulamalarında sağlam ve doğru bölütleme sonuçları elde edilebilmektedir [92].

1.5. Öznitelik Seçim Algoritmaları

Doğru derin özniteliklerin seçilmesi, görüntü sınıflandırma ve tanıma performansı üzerinde önemli bir etkiye sahip kritik bir görevdir. Öznitelik seçiminin amacı, ilgili özniteliklerin bir alt kümesini belirleyip seçmek ve alakasız olan öznitelikleri elemekten oluşmaktadır. Bu işlem, kullanılan veri setinden en az sayıda öznitelik ile en faydalı bilgi çıkarılarak başarılı sonuçların elde edilmesine yardımcı olmaktadır. Seçim sürecinde, az veya hiç öngörücü bilgi içermeyen öznitelikler elenmektedir. Sınıflandırma için kullanılan bu seçilmiş öznitelikler, öğrenme süresinin kısaltılması ve doğruluğun artırılması gibi avantajlar sağlamaktadır [93].

Sınıflandırma problemlerinde, denetimli öznitelik seçimi algoritmaları, doğru tahmin için en uygun öznitelikleri bulmak amacıyla yaygın olarak kullanılmaktadır. Bu algoritmalar, öznitelikler ile etiketler arasındaki ilişkiyi kullanarak, belirli bir veri seti için en iyi sınıflandırma performansını sağlayan öznitelik vektörünün bir alt kümesini belirlemektedir. Bu bölümde, literatürde üç tanınmış öznitelik seçimi algoritması olan ReliefF, mRMR ve Fscchi2 hakkında detaylı bilgi sunulmaktadır.

1.5.1. ReliefF Algoritması

ReliefF algoritması, gözetimli öğrenmede kullanılan en başarılı öznitelik seçimi yöntemlerinden biridir. İlk olarak 1992 yılında Kira ve Rendell tarafından önerilen [94] Relief algoritmasının geliştirilmiş bir versiyonudur. Özellikle büyük boyutlu veri setlerinde önemli özniteliklerin belirlenmesine yardımcı olmaktadır. Daha sonra çok sınıflı problemler için uyarlanmış [95] ve başarılı öznitelik seçimi sağlanmıştır. ReliefF algoritması oldukça verimli sonuçlar üretmekte ve çeşitli veri türlerini işleyebilmektedir. Farklı kategorilerdeki tüm örneklerden en yakın komşu örneklerini seçerek çok sınıflı problemleri çözebilmektedir.

ReliefF algoritması işlem adımları, eğitim setinden rastgele bir örnek (R_i) seçerek başlamaktadır. Ardından, aynı kategoriye ait k yakın örnek bulmakta ve bunlar $H_j(j = 1, 2, ..., K)$ ile ifade edilmektedir. Benzer şekilde, R_i'ye ait farklı kategorilerden k yakın örnek bulunur ve bunları $M_j(c) : (j = 1, 2, ..., K)$ ile ifade edilmektedir. ReliefF algoritması, her öznitelik boyutu için aynı işlemleri izlemektedir. $W(F)$, F özniteliğin kalite tahminini temsil etmekte ve $C = \{c_1, c_2, ..., c_l\}$ l kategorili sınıf etiketlerini göstermektedir. Bu durumda, F özelliğinin kalitesi aşağıdaki şekilde hesaplanmaktadır [96]:

$$\begin{array}{c} W(F) = W(F) - \sum_{j=1}^{k} diff(F, R_i, H_j) / (m * k) \\ \sum_{c \notin class(R_i)} \left[\frac{p(c)}{1 - p(class(R_i))} \sum_{j=1}^{k} diff(F, R_i, M_j(c)) \right] / (m * k) \end{array} \tag{1.15}$$

burada, m, yineleme sayısını ifade ederken, $p(c)$, sınıf c'nin olasılığını temsil etmektedir ve $diff(F, R_1, R_2)$, F özelliği için R_1 ve R_2 örnekleri arasındaki farkı ifade etmektedir. Bu fark şu şekilde ifade edilmektedir:

$$diff(F, R_1, R_2) = \begin{cases} \frac{R_1[F] - R_2[F]}{\max(F) - \min(F)}, & \text{eğer } F \text{ sürekliliğe sahipse} \\ 0, & \text{eğer } F \text{ ayrık ise} \\ & ve\ R_1[F] = R_2[F] \\ 1, & \text{eğer } F \text{ ayrık ise} \\ & ve\ R_1[F] \neq R_2[F] \end{cases} \tag{1.16}$$

1.5.2. Minimum Fazlalık Maksimum İlgililik Algoritması (mRMR)

mRMR algoritması, öznitelik seçimi problemleri için kullanılan etkili bir yöntemdir. Bu algoritmanın temel amacı, sınıflar arasındaki ayrım gücünü en fazla artıran ve birbirleriyle en az bağımlı olan öznitelikleri seçmektir. mRMR algoritması, iki temel ilkeye dayanmaktadır. Bunlar, maksimum alaka ve minimum tekrarlamadır. Maksimum alaka, seçilen özniteliklerin sınıflandırma problemiyle güçlü bir ilişkisinin olmasını ifade etmektedir. Her öznitelik ile sınıf etiketi arasındaki bilgi kazancı veya karşılıklı bilgi maksimum düzeyde olmalıdır. Bu ilgi düzeyi, özniteliklerin hedef değişkenle ilişkili olmasını sağlamaktadır. Minimum tekrarda ise, seçilen öznitelikler arasında minimum düzeyde bağımlılık olmalıdır. Öznitelikler arasında çok fazla korelasyon veya bilgi tekrarı varsa, modelin öğrenme kapasitesi boşa harcanmış olmaktadır. Bu nedenle, mRMR algoritması, öznitelikler arasında olabildiğince düşük bağımlılık sağlayarak, birbirinden bağımsız özniteliklerin seçilmesini amaçlamaktadır.

Öznitelikler ile sınıf değişkenleri arasındaki yüksek korelasyon, modelin sorunları etkili bir şekilde çözebileceğini göstermektedir. Maksimum ilgiliyi hesaplamak için korelasyonu ölçen aşağıdaki denklem kullanılmaktadır [97]:

$$\max D(S,c), \quad D = \frac{1}{|S|} \sum_{F_i \in S} I(F_i, c) \tag{1.17}$$

burada, S özniteliklerin alt kümesini, $c = \{c_1, c_2, ..., c_L\}$ sınıf değişkenlerini ve F_i $i.$ özelliği temsil etmektedir. Bu korelasyonu maksimize etmek, model geliştirme süreci için kritik öneme sahiptir. Bu sayede modelin doğru tahminler sağlayabilmesini garanti etmektedir.

Öznitelikler arasındaki korelasyon ne kadar yüksekse, o kadar fazla tekrar içermektedir. Bu ilke, özniteliklerin benzersiz olmasını sağlayarak tekrarları minimize etmeyi amaçlamaktadır. Öznitelik F_i ve F_j arasındaki ortak bilgiyi $I(F_i, F_j)$ olarak tanımlandığında, minimum tekrar aşağıdaki denklem ile hesaplanmaktadır [97]:

$$\min R(S), \quad R = \frac{1}{|S|^2} \sum_{F_i, F_j \in S} I(F_i, F_j) \tag{1.18}$$

mRMR algoritması, özellikle yüksek boyutlu veri setleriyle çalışırken tercih edilmektedir.

Genetik veri analizi, biyomedikal veri işleme ve metin madenciliği gibi büyük boyutlu ve karmaşık veri setlerinde öznitelik seçimi için yaygın olarak kullanılmaktadır.

1.5.3. Chi-square Testi Kullanarak Öznitelik Sıralama Algoritması (Fscchi2)

Fscchi2 algoritması, kategorik özniteliklerle ilgili olarak tahmin ve gerçek sonuçlar arasındaki benzerliği belirleyen matematiksel bir model hesaplayarak, sınıflandırmada tek değişkenli öznitelik sıralaması için kullanılmaktadır. Bu algoritma, her öznitelik vektöründen en yüksek puanı olan özniteliği seçmektedir. Fscchi2 algoritmasının temel amacı, sınıf etiketleri ile öznitelikler arasındaki bağımlılığı analiz etmek ve özniteliklerin hedef değişken üzerindeki etkilerini sıralayarak en anlamlı olanları seçmektir. Özellikle kategorik veriler için etkili bir öznitelik seçme yöntemidir ve yüksek boyutlu veri setlerinde kullanılabilmektedir. Denklem (1.19)'daki Fscchi2 algoritmasının matematiksel ifadesi şu şekilde verilmektedir:

$$W^2 = \sum_{S}^{i=1} \frac{(F_i - e_i)^2}{F_i} \tag{1.19}$$

burada, S veri setindeki özniteliklerin sayısını, F_i ve e_i ise sırasıyla i. özniteliğin gözlemlenen ve beklenen frekanslarını temsil etmektedir [98].

1.6. Sınıflandırma Algoritmaları

Sınıflandırma, veri setindeki örnekleri belirli sınıflara ayırarak, yeni gelen verilerin hangi sınıfa ait olduğunun tahmin edilmesi sürecidir. Bu işlem, etiketlenmiş veriyle eğitilen bir modelin, öğrendiği sınıflandırma kurallarını yeni veri örneklerine uygulamasıyla gerçekleşmektedir. Veri sınıflandırmasında farklı teknikler kullanılmaktadır. Araştırmalar, hiçbir sınıflandırma tekniğinin tek başına tüm problem türleri için en yüksek doğruluğu sağlayamadığını göstermektedir [99]. Bu bölümde, Destek Vektör Makinesi (Support Vector Machine, SVM), Naive Bayes (NB), Doğrusal Ayrım Analizi (Linear Discriminant Analysis, LDA), Karar Ağacı (Decision Tree, DT) ve k-en yakın komşu (K-Nearest Neighbor, kNN) algoritmaları hakkında detaylı bilgi sunulmaktadır.

1.6.1. Destek Vektör Makinesi (SVM) Algoritması

SVM, yüksek tahmin doğruluğu sağlamak amacıyla güçlü bir sınıflandırma tekniği sunmakta ve modelin eğitim verilerine aşırı uyum sağlama riskini minimize etmektedir. Cortes ve ark. tarafından geliştirilen SVM, özellikle birçok tahmin değişkeni içeren veri setlerini analiz etmek için kullanılmaktadır [100]. SVM, veriler doğrusal olarak ayrılamadığı durumlarda bile veri noktalarını doğru bir şekilde sınıflandırabilmektedir. Bunu, verileri daha yüksek boyutlu bir öznitelik uzayına haritalayarak, kategoriler arasında net bir ayırıcı belirleyerek başarmaktadır. Bu ayırıcı, yeni verilerin ait olduğu sınıfı tahmin etmek için kullanılabilecek bir hiper düzleme dönüştürülmektedir. SVM ile, yeni verilerin öznitelikleri etkili bir şekilde kullanılarak doğru tahminler yapılabilmektedir. Bir hiper düzlem takip eden denklem ile temsil edilmektedir:

$$u = wx - b \tag{1.20}$$

burada w hiper düzlemin normal vektörünü, x giriş vektörünü ve b yanlılık terimini temsil etmektedir.

1.6.2. Naive Bayes (NB) Algoritması

NB, kategorik öznitelikler kullanılarak ikili ve çok sınıflı sınıflandırma yapabilen denetimli bir olasılık algoritmasıdır. Bayes teoremine dayanan NB, bir veri noktasının belirli bir sınıfa ait olma olasılığını hesaplamaktadır. Birden fazla sınıfı işleyebilme yeteneği ve basit uygulama yöntemi sayesinde, NB sınıflandırıcısı birçok uygulamada tercih edilen bir yöntem olarak kullanılmaktadır [101].

Verilen n sayıda özniteliğe sahip $x = \{x_1, x_2, ..., x_n\}$ öznitelik vektörüne göre, NB, x için sınıf C'yi aşağıdaki denklemde hesaplanan olasılığa dayanarak tahmin etmektedir:

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)} \tag{1.21}$$

burada $P(c)$ sınıf öncelikli olasılıkları, $P(c|x)$, x'e bağlı olarak sınıf olasılığını, $P(c)$ sınıfın öncül olasılığını, $P(x|c)$ ise tahmin edicinin olasılığını ifade etmektedir.

1.6.3. Doğrusal Ayrım Analizi (LDA) Algoritması

Basit ama sağlam bir sınıflandırma yöntemi olan LDA, yüksek tahmin doğruluğuna sahip sonuçlar üretmektedir. LDA, birden fazla sınıfı, birden fazla öznitelik temelinde ayırmak için kullanılabilmekte ve bunu verinin boyutunu azaltarak gerçekleştirmektedir [102]. LDA'nın lojistik regresyona göre kayda değer avantajlarından biri, sınıfların iyi bir şekilde ayrıldığı durumlarda daha stabil performans sergilemesidir. Buna karşın, lojistik regresyon bu gibi durumlarda kararsızlık gösterebilmektedir. Bunun nedeni, LDA'nın her bir sınıfın dağılımını tahmin eden ve yeni örnekleri sınıflandırmak için Bayes kuralını kullanan bir üretici model olmasıdır. LDA aşırı öğrenmeye daha az eğilimli olup, iyi ayrılmış sınıfları daha sağlam bir şekilde ele alabilmektedir. LDA'da tahmin edilen değerler (L), $L = \beta X + k$ (burada k sabittir) gibi bir doğrusal denklem aracılığıyla bir dizi etki faktörüyle birleştirilerek belirlenmektedir. Bu, sınıflar arasındaki farkı ayırt etmek için en iyi ayrımı sağlayan katsayıların (β) bulunmasına yardımcı olmaktadır [102].

1.6.4. Karar Ağacı (DT) Algoritması

DT, hem regresyon hem de sınıflandırma görevlerini başarıyla gerçekleştirebilen güçlü bir algoritmadır. Ağaç yapısına dayalı bir dizi test yöntemiyle çalışan bu algoritma, eğitim verilerinden basit karar kurallarını öğrenerek hedef değişkenin doğru sınıflandırılmasını sağlayan bir model oluşturmayı amaçlamaktadır [101]. DT algoritması, veri alanını ve sınıflandırma sınırlarını sezgisel ve anlaşılır bir yapıda temsil etmektedir. Parametrik olmayan bu yöntem, özellikle yüksek boyutlu veri setleriyle etkin biçimde başa çıkabilmekte ve hem kategorik hem de sayısal verileri işleyebilmektedir.

1.6.5. k-En Yakın Komşu (kNN) Algoritması

Sınıflandırma ve regresyon görevleri için kullanılan k-en yakın komşu (kNN) algoritması, güçlü bir ML aracıdır. Parametrik olmayan ve denetimli bir öğrenme algoritması olarak, bir veri noktasının eğitim setindeki k-en yakın komşusuna olan yakınlığını hesaplamaktadır [103]. Benzer veri noktalarının birbirine yakın olduğunu varsayarak, algoritma yeni veri noktalarını doğru bir şekilde tahmin edebilmekte ve sınıflandırabilmektedir. Bu özellik, kNN algoritmasını özellikle sınıflandırma

görevlerinde değerli kılmaktadır. kNN algoritması, yeni veri noktalarına etiketler atarken, eğitim setindeki etiketli veri noktalarına olan yakınlıklarını göz önünde bulundurmaktadır.

1.7. Literatür Özeti

Cilt kanseri sınıflandırması alanında yapılan araştırmalar, son yıllarda DL yöntemlerinin ve özellikle CNN ile ViT mimarilerinin etkileyici performansını ortaya koymaktadır. Bu alanlarda gerçekleştirilen çalışmalar, cilt lezyonlarının otomatik olarak sınıflandırılmasında önemli ilerlemeler kaydetmiş ve bu sayede erken teşhis doğrulukları artırmıştır. Bunun yanı sıra, topluluk öğrenme yöntemleri de, cilt kanseri sınıflandırması için potansiyel çözümler sunarak araştırmacılar tarafından incelenmiştir. Hibrit modellerin geliştirilmesi, farklı DL yaklaşımlarının birleşimini sağlayarak sınıflandırma performansını artırmakta ve mevcut yöntemlerin sınırlamalarını aşmayı amaçlamaktadır. Bu bölümde sunulan literatür özeti, cilt kanseri sınıflandırma alanındaki beş alt başlık altında yapılan çalışmaları incelemekte ve mevcut araştırmaların sunduğu katkıları detaylandırmaktadır.

1.7.1. CNN Tabanlı Çalışmalar

Cilt kanseri sınıflandırmasında CNN mimarileri, güçlü öznitelik çıkarma yetenekleri ve görüntüleri başarılı bir şekilde yorumlama kapasiteleri ile öne çıkan bir yaklaşım olarak kabul edilmektedir. Literatürdeki birçok araştırma, sınıflandırma doğruluğunu ve genel performansı artırmak amacıyla farklı CNN mimarilerini ve bu mimariler üzerinde yapılabilecek iyileştirmeleri incelemiştir. Bu bölümde cilt kanseri teşhisi için CNN mimarilerini kullanan güncel çalışmalara yer verilmektedir.

Azeem ve ark., cilt lezyonlarını sınıflandırmak amacıyla SkinLesNet adlı çok katmanlı bir CNN modeli geliştirmişlerdir. Bu model, seboreik keratoz, NV ve MEL sınıflarını içeren modifiye edilmiş PAD-UFES-20 veri setinde eğitilmiştir. SkinLesNet, ResNet50 ve VGG16 modellerine karşı test edilmiş ve modifiye edilmiş PAD-UFES-20 veri setinde %96,00, HAM10000 veri setinde %90,00 ve ISIC 2017 veri setinde %92,00 doğruluk oranıyla performans göstermiştir [104]. Gopikha ve Balamurugan, katman bazlı ağırlık kısıtlamaları ile etkili öznitelik öğrenimi sağlayan derin bir CNN mimarisi olan

CLCM-net modelini sunmuşlardır. Bu model, ISIC 2019 veri setinde %91,73 doğruluk oranına ulaşmıştır [105].

Gilani ve ark., cilt lezyonu görüntülerinden kanser tanımlaması için bir model sunmuştur. Dermoskopik görüntüleri sınıflandırmak için vekil gradyan iniş yöntemi ile derin bir sinir ağı kullanılmıştır. Model, ISIC 2019 veri kümesi üzerinde %89,57 doğruluk elde etmiştir [106]. Jui ve ark., transfer öğrenme yardımıyla cilt kanserini sınıflandırmak için bir model geliştirmiştir. Modellerinde Xception ağını kullanmışlar ve ISIC 2019 veri kümesi üzerinde test etmişlerdir. Değerlendirme, sınıflandırma sonucunun %88,00 doğruluğa sahip olduğunu göstermiştir [107].

Suleman ve ark., erken cilt kanseri tespitinde yaşanan zorlukları çözmek amacıyla MobileNet tabanlı hafif bir model olan Smart MobiNet'i geliştirmişlerdir. ISIC 2019 veri seti ve yaygın veri artırma teknikleriyle eğitilen Smart MobiNet modeli, %89,00 doğruluk, %90,00 hassasiyet, %90,00 duyarlılık ve %90,00 F1-skor değeri elde etmiştir [108]. Tuncer ve ark., cilt lezyonlarını kategorize etmek için TurkerNet adını verdikleri yeni bir CNN modeli önermiştir. Bu model, giriş, artık şişe boynu, verimli ve çıktı blokları olmak üzere dört temel bileşenden oluşmaktadır. TurkerNet, 3.297 görüntü içeren açık erişimli bir veri setinde %92,12 test doğruluğuna ulaşmıştır [109].

Yukarıda sunulan CNN tabanlı çalışmalar, cilt kanseri sınıflandırmasında önemli bir yere sahiptir ve bu alandaki yenilikçi yaklaşımlar, model performansını artırma çabalarını yansıtmaktadır. Geliştirilen çeşitli CNN mimarileri, güçlü öznitelik çıkarma yetenekleri sayesinde, görüntü verilerinin daha etkili bir şekilde yorumlanmasını sağlamaktadır. Özellikle, farklı veri setleri üzerinde yapılan testler, CNN mimarilerinin cilt lezyonlarının tanısında yüksek doğruluk oranları elde etmesine olanak tanımaktadır. Bu çalışmalar, cilt kanseri teşhisinde kullanılan mevcut yöntemlerin sınırlamalarını aşma hedefini taşımakta ve bu sayede klinik uygulamalarda daha güvenilir ve hızlı sonuçlar elde edilmesine katkıda bulunmaktadır.

1.7.2. ViT Tabanlı Çalışmalar

ViT mimarileri, cilt kanseri sınıflandırmasında, görüntülerdeki uzun menzilli bağımlılıkları ve küresel bağlamı etkili bir şekilde yakalama kabiliyetleri sayesinde dikkat çekmeye başlamıştır. Bu özellikleriyle ViT mimarileri, karmaşık mekansal ilişkileri modelleyebilmekte ve cilt kanseri teşhisi ile sınıflandırmasında başarılı sonuçlar sunmaktadır. Bu bağlamda ViT modellerini içeren bazı önemli çalışmalar şunlardır:

Desale ve Patil, cilt tümörü sınıflandırması için verimli bir ViT modeli önererek kapsamlı ön işleme teknikleri, kendiliğinden seyrekleşen su havzası bölütlemesi ve Walsh-Hadamard ile Karhunen–Loeve dönüşümleriyle öznitelik çıkarım süreçlerini bir araya getiren bir model sunmuştur. Geliştirdikleri model, ISIC 2019 veri seti üzerinde test edilmiş ve cilt kanseri sınıflandırmasında yüksek bir başarı elde etmiştir [110]. Dagnaw ve ark. ise, cilt lezyonu görüntülerini sınıflandırmada çeşitli DL mimarilerini karşılaştırarak ViT modellerinin etkili olduğunu göstermişlerdir. Çalışmalarında ViT modelleri, swin dönüştürücüler ve CNN mimarileri ile karşılaştırılmıştır. Sonuç olarak ViT mimarileri, uzun mesafeli bağımlılıkları yakalama yetenekleriyle %88,60 doğruluk oranına ulaşan bir performans sergilemiştir [111].

Salvia ve ark., taşınabilir cihaz geliştirme bağlamında bir ViT modelinin işleme süreleri, enerji tüketimi ve iletişim gecikmesi gibi anahtar faktörlerini incelemiştir. Bulgular, bulut tabanlı çözümlerin işlem sürelerini azalttığını ve kötü huylu melanosit kategorisinde %91,00 başarı oranı elde ettiğini göstermiştir [112]. Ghosh ve ark., CNN, Caps-Net ve ViT çerçevelerini kullanarak yeni bir model geliştirmişlerdir. Bu model, HAM10000 veri seti üzerindeki değerlendirmelerde %91,60 doğruluk oranı elde etmiştir [113]. Flosdorf ve ark., kullandığı ViT modeli, cilt lezyonlarını öz dikkat mekanizmasını kullanarak sınıflandıran bir yöntem sunmuştur. HAM10000 veri seti ile yapılan deneysel sonuçlar, ViT-L32 modelinin %91,57 doğruluk ve %58,54 duyarlılık oranı elde ettiğini göstermiştir [114].

Reis ve Türk, cilt görüntüleri sınıflandırmak için ViT modelleri ile yeni bir çerçeve geliştirmiştir. ISIC 2020 veri setinde kullandıkları ViT modeli %76,50 doğruluk elde

etmiştir [115]. Shobhit ve Kumar, ViT modelleri kullanarak MEL sınıflandırmasının iyileştirilmesi potansiyelini araştırmıştır. Çalışma, tıbbi görüntülerin analizi için çeşitli metodolojileri incelemiştir. Geliştirdikleri model, %91,00 test doğruluğu elde etmiştir [116].

Kusumastuti ve Sunyoto çalışmalarında, cilt lezyonlarını sınıflandırmak ve olası kötü huylu cilt kanseri vakalarını tanımlamak için kendi metodolojilerini kullanmaktadır. Yöntem için kullanılan ViT-b16 modelleri, kullandıkları veri setinde %87,12 doğruluk elde etmiştir [117]. Nikitin ve Danilov, cilt kanseri sınıflandırmasında ViT mimarisi için fraktal boyut metriklerinin entegrasyonunu incelemiştir. AttentionFDViT modeli, kullanılan modeller arasında en yüksek performansı sergileyerek %79,04 doğruluk elde etmiştir [118]. Vachmanus ve ark. çalışmalarında, farklı bilgiler ile birlikte görüntüleri kullanarak cilt kanserini tanımlamak için tasarlanmış bir DL sistemi olan DeepMetaForge'u tanıtmaktadır. Görüntü kodlama altyapısı olarak, maske görüntü modelleme görevi için özel olarak tasarlanmış BEiT adlı önceden eğitilmiş bir görüntü transformatörü kullanmaktadır. Dört açık erişimli veri setinden elde edilen deneysel sonuçları, önerilen çerçevenin optimal yapılandırmasının ortalama makro F1-skorunun %87,10 olduğunu göstermiştir [119].

Bu bölümde sunulan ViT tabanlı çalışmalar, cilt kanseri sınıflandırmasında önemli bir ilerleme kaydetmiştir. Yukarıda özetlenen araştırmalar, ViT modellerinin karmaşık görüntü verilerini etkili bir şekilde analiz etme yeteneğini ve uzun menzilli bağımlılıkları yakalama becerisini vurgulamaktadır. Genel olarak, ViT mimarileri, cilt kanseri tanısında yenilikçi çözümler sunarak, gelecekteki araştırmalar için sağlam bir temel oluşturmaktadır. Bu çalışmalar, hem teorik hem de uygulamalı düzeyde, cilt kanseri sınıflandırmasının geliştirilmesine katkıda bulunmayı sürdürmektedir.

1.7.3. CNN Tabanlı Hibrit Çalışmalar

Cilt kanseri sınıflandırmasında hibrit CNN mimarileri, güçlü öznitelik çıkarma yetenekleri ve görüntü verilerini başarılı bir şekilde yorumlama kapasiteleri ile öne çıkan bir yaklaşım olarak kabul edilmektedir. Birçok araştırma, sınıflandırma doğruluğunu ve genel performansı artırmak amacıyla farklı hibrit CNN topolojilerini ve iyileştirmelerini

incelemiştir. Cilt kanseri teşhisi için hibrit CNN modelleri kullanan önemli çalışmalardan bazıları şunlardır:

Ramamurthy ve ark., cilt lezyonlarının sınıflandırma performansını artırmak amacıyla yerel, küresel ve hiyerarşik öznitelikleri bir araya getiren iki aşamalı DL modeli geliştirmiştir. Bu hibrit modelin birinci aşamasında, koordinat dikkat modülü eklenmiş modifiye edilmiş bir DenseNet169 mimarisini kullanarak yerel öznitelikleri yakalamaktadır. İkinci aşama, çok ölçekli öznitelikleri ve küresel bağlamsal bilgileri yakalamak için bir öznitelik piramidi ağı ve küresel bağlam ağı içeren özel bir CNN yapısından oluşmaktadır. Elde edilen yerel ve küresel öznitelikler birlikte kullanılmıştır. DenseNet çerçevesine eklenen bu mimari model HAM10000 veri setinde %93,20 sınıflandırma doğruluğu elde etmiştir [120].

Kumar ve ark., çalışmalarında, görüntü, spektrogram ve cepstrum alanı özniteliklerini bir araya getiren yenilikçi el yapımı öznitelikler geliştirilmiştir. Bu öznitelikler, hem mekansal hem de spektral bilgiyi kullanarak, yeni geliştirilen CNN modeline cilt lezyonlarının sınıflandırılması için girdi olarak verilmiştir. HAM10000 ve Dermnet veri setlerinde yapılan deneysel analiz sonucunda, önerilen ağın HAM10000 veri setinde %89,71 ve Dermnet veri setinde %88,57 doğruluk elde ettiği gösterilmiştir [121].

Subhashini ve Chandrasekar, cilt kanseri teşhisi ve tedavi planlaması için DL tabanlı bir yaklaşım sunmaktadır. Önerilen sistem, bir dizi yenilikçi algoritma kullanmaktadır. ISIC 2019 veri setlerinde değerlendirilen model, %94,23 doğruluk oranları elde etmiştir [122]. De ve ark., dermoskopik görüntülerden cilt hastalıklarının sınıflandırılması ve tahmini için bir derin sinir ağı modeli sunmuştur. Model, geleneksel bir CNN mimarisi ile önceden eğitilmiş DenseNet modelini birleştirerek HAM10000 veri setinde yüksek bir performans elde etmiştir. Metodoloji, veri temizleme, keşifsel veri analizi, veri bölme, normalizasyon ve etiket kodlama gibi veri ön işleme adımlarını içermektedir. Model mimarisi ve veri uyumu optimizasyonu için model hibritizasyonu, BN, maksimum ortaklama ve veri önişleme gibi teknikler kullanılmıştır. Performansı artırmak için model DenseNet mimarisi ile hibrit hale getirilmiş ve hiper parametre ayarlamaları yapılmıştır. Deneysel sonuçlarda, model HAM10000 veri setinde %89,00 doğruluk göstermiştir [123].

Gajera ve ark., önceden eğitilmiş derin bir CNN modelinden dermoskopi görüntülerinin görsel özniteliklerini çıkarmıştır. Ardından MEL tespiti için bir dizi sınıflayıcı kullanarak değerlendirmeler yapmıştır. Çalışmada, sekiz güncel CNN modelinden çıkarılan derin özniteliklerin etkinliği araştırılmıştır. Ayrıca, sınır lokalizasyonu ve normalizasyon tekniklerinin MEL tespiti üzerindeki etkisini incelenmiştir. Önerilen yaklaşım, PH^2, ISIC 2016, ISIC 2017 ve HAM10000 olmak üzere dört açık erişimli veri seti ile değerlendirilmiştir. Deneysel sonuçlar, MLP ile birlikte kullanılan DenseNet121 mimarisinin, PH^2, ISIC 2016, ISIC 2017 ve HAM10000 veri setlerinde sırasıyla %98,33, %80,47, %81,16 ve %81,00 doğruluk elde ettiğini göstermektedir [87].

Yu ve ark., küçük ve dengesiz veri kümeleri için Tek Sınıflı Sınıflandırmaya (One-Class Classification, OCC) dayalı yeni bir cilt lezyonları sınıflandırma stratejisi önermiştir. OCC, pozitif gerçek verilerden bir tanımlayıcı paradigma öğrenmeyi amaçlamakta ve çıkarım sırasında bu paradigmaya uymayan sahte verileri reddetmektedir. MEL sınıflandırması için veri dengesizliğini göz önünde bulundurarak, geliştirilmiş bir OCC ağı tasarlanmıştır. Bu ağ, artık bir sinir ağı mimarisine dayalı olarak değişken kendini kodlayıcı ve karşıt eğitim fikirlerini birleştirmekte, ikili çapraz-entropy kaybını kullanmakta ve kanal dikkat mekanizmasını tanıtmaktadır. Model HAM10000 veri setinde %89,27 doğruluk ve ISIC 2019 veri setinde %87,48 doğruluk değeri elde etmiştir [124].

Seeja ve Geetha, cilt lezyonlarının kesin sınıflandırılması için daha güçlü öznitelikler elde etmek amacıyla hibrit bir yöntem sunmuştur. Önerilen yöntemde, ilk olarak cilt lezyon bölgesini bölütlemek için U-Net algoritması kullanılmıştır. Ardından, sağlam doku öznitelikleri çıkarılmıştır. Öznitelik çıkarımından sonra, cilt lezyonu görüntüsü farklı sınıflandırma algoritmaları ile sınıflandırılmıştır. ISIC 2016, ISIC 2017 ve ISIC 2019 veri setleri üzerinde yapılan değerlendirmelerde, VGG16 ağı ile sırasıyla %94,87, %86,88 ve %93,65 sınıflandırma doğruluğu elde edilmiştir [125].

Abdelhafeez ve ark., cilt lezyonlarını sınıflandırmak için yenilikçi bir CNN tabanlı hibrit yöntem önermektedir. Önerilen yöntem iki aşamadan oluşmaktadır. İlk aşamada, her bir eğitilmiş ağın sınıflandırma doğruluğu artırılmış ve öznitelik birleştirme metodolojisi ile çıkarılan özniteliklerin açıklayıcı gücü zenginleştirilerek modelin doğruluk oranları

sırasıyla %79,20 ve %84,50'ye yükseltilmiştir. İkinci aşamada, bu ağların daha fazla iyileştirme için nasıl birleştirileceği araştırılmıştır. DarkNet ve GoogleNet öznitelik haritalarının kaynaştırılmasıyla, doğru ve yanlış SVM sınıflandırıcıları oluşturmak için hata düzeltici çıkış kodları paradigması kullanılmıştır. Sonuç olarak, sınıflandırma doğruluğu %85,74'e yükselmiştir [126].

Li ve ark., çalışmalarında, geleneksel nöronlar yerine ikinci dereceden nöronlar kullanan yeni bir yarı denetimli öğrenme modeli önermektedir. Bu model, öznitelik çıkarım yeteneğini artırmak amacıyla geleneksel evrişim katmanı yerine ikinci dereceden evrişimi kullanmaktadır. Ayrıca, ağın doğrusal olmayan uyum yeteneğini artırmak için modelin sonuna yeni katmanlar eklenmiştir. ISIC 2019 veri setinde yapılan deneyler, önerilen yöntemle modelin %87,07 doğruluk oranına ulaştığını göstermektedir [127].

Pandey ve ark., giriş verisinin kalitesini artıran, anlamlı ve ayırt edici öznitelikler çıkaran ve modelin genel performansını iyileştiren çok aşamalı bir yaklaşım sunmaktadır. Bu hibrit yaklaşım, gürültüye dayanıklılık, öznitelik çıkarma ve sınıflandırma doğruluğu gibi zorlukları ele alarak karmaşık görüntü analiz görevlerinde özellikle etkili hale getirilmektedir. Yüksek çözünürlüklü görüntüler içeren veri setleri kullanılarak gerçekleştirilen tüm testlerin ardından, HAM10000 veri seti için %85,61 ve ISIC 2019 veri seti için %81,23 sınıflandırma doğruluk oranı elde edilmiştir [128].

İncelenen hibrit CNN tabanlı çalışmalar, cilt kanseri sınıflandırmasında önemli bir yere sahiptir. Bu alandaki yenilikçi yaklaşımlar, model performansını artırma çabalarını yansıtmaktadır. Geliştirilen çeşitli hibrit CNN mimarileri, güçlü öznitelik çıkarma yetenekleri sayesinde, görüntü verilerinin daha etkili bir şekilde yorumlanmasını sağlamaktadır. Özellikle, farklı veri setleri üzerinde yapılan testler, CNN mimarilerinin cilt lezyonlarının tanısında yüksek doğruluk oranları elde etmesine olanak tanımaktadır. Bu çalışmalar, cilt kanseri teşhisinde kullanılan mevcut yöntemlerin sınırlamalarını aşma hedefini taşımakta ve bu sayede klinik uygulamalarda daha güvenilir ve hızlı sonuçlar elde edilmesine katkıda bulunmaktadır.

1.7.4. CNN ve ViT Tabanlı Hibrit Çalışmalar

Literatürde CNN ve ViT mimarilerinden oluşan hibrit modeller, cilt lezyonlarının sınıflandırılmasında etkili bir şekilde kullanılmaktadır. Hibrit model yaklaşımları, bu iki mimarinin avantajlarını bir araya getirerek, hem yerel hem de genel özniteliklerin daha iyi yakalanmasını sağlamakta ve sınıflandırma performansını artırmaktadır. Bu bölümde, son dönemde geliştirilen CNN ve ViT tabanlı hibrit yöntemler incelemekte ve bu yaklaşımların cilt kanseri teşhisindeki başarıları değerlendirilmektedir.

Khan ve ark., araştırmalarında, MEL ve MEL olmayan dermoskopik görüntüleri ayırt etmek için hibrit bir CNN ve ViT tabanlı yöntem önermiştir. Önerilen SkinCaNet yöntemi, sınıflandırma doğruluğunu artırmak amacıyla yerel ve küresel öznitelikleri etkili bir şekilde yakalamak için FFN blokları, MHA blokları ve MLP içermektedir. SkinCaNet modeli, HAM10000 veri setinde eğitilmiş ve %92,38 doğruluk ile %95,62 kesinlik değerleri elde etmiştir [129].

Sajol ve ark., cilt kanserinin otomatik tespiti için yeni bir yöntem geliştirmiştir. Bu yöntem, DL tekniklerini kullanarak, CNN mimarileri, ViT mimarileri ve bu iki mimarinin hibrit modelleri arasında karşılaştırma yapmaktadır. Çalışmada, HAM10000 veri seti kullanılarak, cilt lezyonlarını tanımlamak için en iyi modeli belirlemek amacıyla doğruluk ve F1-skoru gibi metriklerden faydalanılmıştır. Uygulanan modeller arasında MobileViTv2 hibrit yöntem en yüksek %90,75 doğruluk ve %72,00 F1-skor değeri elde etmiştir [130].

Tada ve Han, ViT ve CNN tabanlı hibrit model ile cilt lezyonlarının tanınmasına yönelik bir yaklaşım önermiştir. Çalışmada, ilk önce bir CNN omurgası kullanılarak yüksek seviyeli öznitelik haritaları çıkarılmakta, ardından bu haritalarda küresel bağımlılıkları modellemek için bir dönüştürücü bloğu uygulanmaktadır. Daha sonra, öznitelik ileri besleme modülünde derinliksel evrişim bloğu ile mekansal ilişki modellemesi yapılmaktadır. Önerilen yöntem, HAM10000 veri setinde %91,10 doğruluk ve ISIC 2019 veri setinde %87,20 test doğruluğu göstermiştir [131].

Guchhait ve ark., tarafından önerilen modelde, özel bir Masksemble bloğu kullanılarak ayırt edici görüntü öznitelikleri oluşturulmaktadır. Bu blok, bir dermoskopi görüntüsünün belirsizliğini tahmin ederek kanser teşhisinde kritik bir rol oynamaktadır. Model, cilt kanserini tespit etmekte HAM10000 veri seti üzerinde çok sınıflı sınıflandırma için de test edililmiştir. Test sonucunda model %86,68 doğruluk ve %83,00 F1-skor değeri elde etmiştir [132].

Gairola ve ark., çok modelli öznitelik birleşim ağı adlı bir model geliştirerek cilt kanserinin erken teşhisine katkı sunmaktadır. Yöntem, görüntü kalitesini artırmak için ön işleme teknikleriyle başlamakta ve ardından, geliştirilmiş yoğun bağlı bir ağ ile bir vizyon dönüştürücüsünü içeren iki kanallı bir ağ yapısı kullanmaktadır. Geliştirilen cilt lezyonu sınıflandırma modeli uygulanarak test edilmiş ve %86,00 doğruluk oranına ulaşmıştır [133]. Khan ve ark., araştırmalarında, mobil cihazlarda verimli uygulamalar için optimize edilmiş ViT kullanarak, cilt lezyonlarından kaba ve ince taneli öznitelikleri yakalayan Skin-Former adlı hibrit bir mimari önermiştir. Skin-Former, düşük gecikme süresi ve parametre verimliliği ile öne çıkmaktadır. Modelin ISIC 2019 veri seti üzerindeki doğruluk oranı %84,33 olarak hesaplanmıştır [134].

Nie ve ark., cilt lezyon görüntülerini sınıflandırmak için uçtan uca bir CNN ve ViT tabanlı hibrit model ve odak kaybı (Focal Loss, FL) fonksiyonu önermektedir. İlk aşamada, CNN mimarisi, dermoskopik görüntülerden düşük seviyeli, yerel öznitelik haritalarını çıkarmaktadır. İkinci aşamada ise ViT mimarisi, bu öznitelikleri küresel olarak modelleyip soyut ve yüksek seviyeli anlamsal bilgileri çıkarmaktadır. Ardından sınıflandırma için MLP'ye göndermektedir. Üç farklı kayıp fonksiyonunun değerlendirilmesine dayalı olarak FL tabanlı algoritma, HAM10000 veri setindeki aşırı sınıf dengesizliğini iyileştirmeyi amaçlamaktadır. Deneysel analizler, hibrit modelin ve FL stratejisinin kullanılmasıyla cilt lezyonu sınıflandırmada %89,48 doğruluk oranına ulaşıldığını göstermiştir [135].

Pacal ve ark., deneylerinde, swin dönüştürücü mimarisini, geleneksel kaydırılmış pencere tabanlı MHA yerine hibrit kaydırılmış pencere tabanlı MHA uygulayarak geliştirmiştir. Ayrıca, çalışmada, swin dönüştürücüdeki standart MLP yerine, kapılı doğrusal birim modülünün güncellenmiş bir versiyonu olan SwiGLU tabanlı bir MLP

kullanılmıştır. Değiştirilmiş swin modeli, ISIC 2019 cilt veri seti ile sekiz sınıf üzerinden değerlendirilmiş ve %89,36 doğruluk, %85,13 duyarlılık, %88,22 kesinlik ve %86,65 F1-skora ulaştığı değerlendirilmiştir [7].

Khan ve Khan, çalışmalarında cilt kanseri sınıflandırması için otomatik bir sistem geliştirmeyi hedeflemiştir. Model CNN mimarileri kullanılarak cilt hastalıklarının doğru sınıflandırılmasını sağlamakta, ancak CNN mimarilerinin küresel bağlamsal bilgi yakalama sınırlılıkları ViT modelleri ile giderilmektedir. Önerilen SkinViT mimarisi, hem yerel hem de küresel öznitelikleri yakalamakta %91,09 doğruluk oranlarını elde etmiştir [136]. Ansari ve ark., çalışmalarında, meta öğrenmeyi görüntü dönüştürücüsüne entegre eden MetaV adlı bir model geliştirmiştir. Modelde deformasyonel evrişim gibi yöntemler kullanılarak, az veriyle sınıflandırma yapılabilmesi ve aşırı öğrenmenin önlenmesi amaçlanmıştır. Ayrıca, nadir hastalıklara ait verilerin azlığı ve gürültülü yapısı için Grid Mask gibi veri artırma yöntemleri kullanılmıştır. Model, ISIC 2019 veri setinde değerlendirilmiş ve %87,33 doğruluk oranı göstermiştir [137].

Zhang ve ark., yerel öznitelik çıkarımı için swin dönüştürücülerin yama yerleştirme bölümünün yerine CNN mimarileri kullanan yeni bir cilt kanseri sınıflandırma algoritması önermiştir. Bu yöntem, CNN mimarilerinin yerel öznitelikleri çıkarmadaki avantajlarını kullanırken, dönüştürücülerin küresel öznitelikleri çıkarmadaki yeteneklerinden faydalanarak her iki yöntem arasındaki tamamlayıcı avantajları gerçekleştirmektedir. Ayrıca, CNN bölümüne SimAM öz-dikkat mekanizması entegre edilmiştir. ISIC 2019 veri setinde eğitim sonrası, hibrit model %90,73 doğruluk oranına ulaşmıştır [138].

İncelenen literatür çalışmaları, CNN ve ViT tabanlı hibrit yaklaşımların cilt kanseri tanısında önemli ilerlemeler sağladığını göstermektedir. Önerilen yöntemler, yerel ve küresel özniteliklerin etkin bir şekilde yakalanmasını mümkün kılmakta ve sınıflandırma doğruluğunu artırmaktadır. Çeşitli çalışmalar, farklı veri setlerinde yüksek başarı oranları elde etmiştir. Bu durum cilt lezyonlarının otomatik tespitinin gelecekteki uygulamalarında geliştirilen yöntemlerin önemini vurgulamaktadır. Hibrit mimariler, gelişmiş veri artırma teknikleri ve optimize edilmiş kayıp fonksiyonları ile desteklenerek, cilt kanserinin erken teşhisinde güvenilir çözümler sunmaktadır.

1.7.5. DL Tabanlı Topluluk Öğrenme Çalışmaları

Son dönemde DL algoritmalarındaki ilerlemeler, cilt kanseri tespiti ve sınıflandırmasında kayda değer iyileşmeler sağlamıştır. Bu literatür incelemesinin mevcut bölümü, cilt lezyonları üzerine yapılan DL tabanlı topluluk öğrenimi modellerini incelemektedir.

Mushtaq ve Singh, çalışmalarında, CNN mimarileri kullanarak cilt kanserinin daha erken aşamada sınıflandırılmasına yönelik bir çerçeve geliştirmeyi amaçlamıştır. Modelin performansını değerlendirmek için HAM10000 veri seti kullanılmıştır. Önerilen yöntem, VGG16 modelinin farklı hiper parametreler ile üç kez çalıştırılması ve sonuçların bir araya getirilmesi üzerine kurulmuştur. Deneysel sonuçlar, VGG16 modelinin ortalama %87,00 doğruluk ve %86,00 F1-skoru, topluluk VGG16 modelinin ise ortalama %88,00 doğruluk ve %88,00 F1-skoru elde ettiğini göstermiştir. Veri setine görüntü işleme tekniği uygulandığında, geliştirilen model ortalama %89,00 doğruluk ve %88,00 F1-skoru göstermiştir [139].

Shajimon ve ark., cilt kanseri tespitinde sınıflandırma doğruluğunu artırmak amacıyla ağırlıklı topluluk öğrenme CNN metodolojisi önermiştir. Bu yöntem, farklı CNN modellerinin güçlü yönlerini birleştirerek daha iyi performans gösteren modellere daha yüksek ağırlıklar atayarak, doğruluğu artırmayı hedeflemektedir. HAM10000 veri seti ile yapılan deneylerde, grid arama yöntemiyle belirlenen optimal ağırlık konfigürasyonu, %74,23 doğruluk oranına ulaşarak tekil CNN modellerin doğruluklarını geçmiştir [140].

Bechelli ve Delhommelle, cilt lezyonlarının sınıflandırılmasında ML ve DL modellerini değerlendirmiştir. ML algoritmaları, lojistik regresyon, LDA, kNN, DT ve NB sınıflandırıcısını içerirken, DL modelleri özel bir CNN veya VGG16, Xception ve ResNet50 gibi önceden eğitilmiş modellerin transfer öğrenimini kullanmaktadır. Sonuçlar, %88,00 doğruluğa ulaşan DL modellerinin ML modellerini geride bıraktığını göstermektedir. ML modellerinin doğruluğu %72,00'yi aşamazken, topluluk öğrenimi ile bu oran %75,00'e çıkarılabilmiştir. Özellikle VGG16 modeli, %88,00 F1-skoru ve %88,00 doğruluğa ulaşarak, diğer modellere göre yüksek başarım elde etmiştir [141].

Thwin ve Park, cilt kanseri arasında özellikle MEL tanısında erken teşhisin önemine vurgu yaparak VGG16, Inceptionv3 ve ResNet50 modellerini birleştiren bir sınıflandırma

sistemi geliştirmiştir. Bu topluluk öğreniminde, ISIC 2018 veri setinde %91,00 doğruluğa ulaşılmıştır. HAM10000 veri setinde ise orijinal veri setinde %90,00 doğruluk değerine erişilmiştir [142].

Bhargavi ve ark., çalışmalarında, tıbbi görüntülerden cilt kanseri tespiti gerçekleştirmiştir. Bu çalışmada, HAM10000 veri setindeki yedi farklı lezyon görüntüsü kullanılmıştır. DL ve CNN tabanlı modeller kullanılarak cilt kanseri sınıflandırılmış ve DL yöntemlerinin hastalık tanısında önemli bir potansiyele sahip olduğu gösterilmiştir. Veri setinde yapılan değerlendirmede model %81,30 doğruluk oranı elde etmiştir [143]. Chatterjee ve ark. cilt lezyonlarının tanısında, Inceptionv3 ve Xception modellerini birleştiren IncepX-Ensemble isimli bir topluluk öğrenme modeli geliştirmiştir. HAM10000 veri seti üzerinde orijinal verilerle %86,00 doğruluk sağlanırken, dengeli veri seti ile daha yüksek başarı elde edilmiştir [144].

Santos ve ark., çalışmalarında, çok sınıflı cilt lezyon sınıflandırmasında transfer öğrenme yöntemlerinin etkinliği araştırmıştır. Sonuçlar, önceden eğitilmiş modellerin yeniden yapılandırılma şekline bağlı olarak, CNN mimarilerinin DL sınıflandırıcılarının genel performansını önemli ölçüde artırabileceğini göstermektedir. Farklı modellerle yapılan deneyler, topluluk modellerinin tekil model yaklaşımlarına göre avantaj sağlayabileceğini göstermektedir. Geliştirilen topluluk öğrenme modeli, ISIC 2019 veri setinde %89,40 doğruluk elde etmiştir [145].

Pacheco ve ark., tıbbi görüntü sınıflandırmasında daha yüksek performans değeri sağlamak için CNN modellerinin topluluk öğrenimini önermiştir. Geleneksel topluluk öğrenimi yöntemlerinin, tüm modellere eşit ağırlık vererek zayıf modellerin olumsuz etkisini göz ardı etme sorununa dikkat çeken araştırmada, Dirichlet dağılımı ve Mahalanobis mesafesi kullanarak dinamik ağırlıklar öğrenmeyi amaçlayan yeni bir yöntem geliştirilmiştir. Bu yöntem, her yeni örneğin değerlendirilmesi sırasında zayıf modellerin etkisini azaltmayı ve çevrimiçi topluluk budamasını mümkün kılmaktadır. Bu yaklaşım, dört tıbbi görüntü veri setine uygulanan altı tanınmış derin modeli içeren bir koleksiyon kullanılarak değerlendirilmiş ve model, ISIC 2019 veri setinde %82,80 doğruluk elde etmiştir [146].

Gupta ve ark., çalışmalarında, şüpheli lezyonların analizi ve MEL tespiti için hibrit bir yöntem önermektedir. Model eğitimini veri artırma tekniği gerektirmeyen bir çerçevede sunarak grafik işlemci ünitesi süresini azaltan topluluk optimizasyon algoritması yöntemini önermektedir. ISIC 2019 veri seti üzerinde test edilen bu teknik, EfficientNet tabanlı bir yapı ile geleneksel tekil ve toplu modellerle kıyaslandığında %87,00 doğruluk oranı sağlamıştır [147]. Cauvery ve ark., cilt hastalıklarını sınıflandırmak için bir sistem geliştirmeyi hedeflemiştir. Önerilen sistem, veri setini 8 farklı kategoriye sınıflandırmak için transfer öğrenme tabanlı CNN mimarileri kullanmaktadır. Dört ileri düzey önceden eğitilmiş CNN model kullanılarak, bu alt modellerin daha büyük sinir ağına entegre edilmesi sağlanmaktadır. Ayrıca, alt modellerin tahminlerini birleştirmek için topluluk öğrenme yaklaşımı uygulanmaktadır. Sonuç olarak, ISIC 2019 veri seti üzerinde gerçekleştirilen çalışmada, %81,20 doğruluk oranı elde etmişlerdir [148].

Benyahia ve ark., çeşitli cilt lezyonları için birçok farklı öznitelik çıkarım yöntemini araştırmıştır. İki farklı veri seti üzerinde, on yedi yaygın önceden eğitilmiş CNN mimarisi öznitelik çıkarıcı olarak ve yirmi dört farklı ML sınıflandırıcısı ise sınıflandırma görevinde kullanılarak performansları detaylı bir şekilde incelenmiştir. Araştırma sonuçları, ISIC 2019 veri seti için DenseNet201 modelinin Fine kNN ile birleştirildiğinde %92,34 ve Cubic SVM ile birleştirildiğinde %91,71 doğruluk oranlarını elde ettiğini göstermektedir [149]. Yu ve ark., bilgi damıtma yönteminin cilt lezyonlarının sınıflandırmadaki etkisini incelemiştir. Önerilen varyasyonel AdaBoost bilgi damıtma yöntemi, ISIC 2019 veri setinde %91,04 doğruluk ve %84,72 F1-skor değeri ile daha iyi sınıflandırma sonuçları elde etmiştir [150].

Gerçekleştirilen literatür analizi, cilt kanserinin tanımlanmasında topluluk öğrenimi modellerinin etkinliğini vurgulamaktadır. Birden fazla DL mimarisinin entegrasyonu, transfer öğrenimi ve optimizasyon algoritmaları gibi yaklaşımların birleştirilmesi sayesinde, çeşitli veri setlerinde son derece yüksek sınıflandırma doğruluğu elde edilmiştir. Bu ilerlemeler, DL modellerinin klinik uygulamalarda kullanılma kapasitesine işaret etmekte ve daha güvenilir cilt kanseri tespit algoritmalarının geliştirilmesini kolaylaştırmaktadır. Bu bağlamda, topluluk öğrenimi yaklaşımlarının uygulanması, cilt kanserinin erken teşhisi ve tedavi süreçlerinin iyileştirilmesine katkıda bulunmaktadır.

1.8. Cilt Kanseri Veri Setleri

Tez çalışması kapsamında kullanılan açık erişimli ISIC 2018, HAM10000 ve ISIC 2019 veri setleri, cilt kanseri teşhisinde yapay zeka tabanlı yaklaşımlar geliştirmek için geniş çapta kabul gören ve sıkça kullanılan veri kaynaklarıdır. Bu veri setleri, cilt lezyonlarının bölütlenmesi, sınıflandırılması ve analiz edilmesi amacıyla, dermoskopik görüntüler içermekte ve araştırmacılara karşılaştırmalı çalışmalar yürütme imkânı sunmaktadır. Özellikle Uluslararası Cilt Görüntüleme İşbirliği (International Skin Imaging Collaboration, ISIC) [151], cilt kanseri görüntüleme çalışmalarında standart oluşturmayı hedefleyen geniş çaplı bir iş birliği platformu olup, düzenlediği yarışmalar ve sağladığı veri setleri ile alanın ilerlemesine önemli katkılar sağlamaktadır. Cilt kanseri araştırmalarında kullanılan bu veri setleri, model performansını değerlendirmek ve yeni yöntemlerin etkinliğini ölçmek açısından kritik rol oynamaktadır. Bu çalışmada da, geliştirilen yöntemlerin doğruluğunu ve genelleştirilebilirliğini sağlamak için bu veri setlerinden yararlanılmıştır. HAM10000 ve ISIC 2019 veri setlerinde sınıflandırma amacıyla belirlenen kategoriler, yalnızca cilt kanserlerini değil, cilt sağlığını etkileyebilecek diğer önemli lezyon türlerini de kapsamaktadır. Kanser dışı gruplar, genellikle zararsız olan veya cilt kanserine dönüşme potansiyeli taşıyan farklı cilt lezyonlarını ifade etmektedir. Bu tür lezyonların sınıflandırılması, yalnızca cilt kanseri teşhislerini değil, aynı zamanda ciltte oluşabilecek diğer lezyonların doğru bir şekilde tanımlanmasını sağlayarak tedavi süreçlerinin daha etkili bir şekilde planlanmasına olanak tanımaktadır. Bu durum, hem tanısal doğruluğu artırmakta hem de uygun tedavi yaklaşımlarının seçilmesini desteklemektedir.

1.8.1. ISIC 2018 Veri Seti

ISIC 2018 [152] veri seti, cilt kanseri araştırmalarında DL tabanlı yöntemlerin geliştirilmesi ve değerlendirilmesi amacıyla sunulan en önemli veri setlerinden biridir. ISIC tarafından organize edilen bu veri seti, üç farklı görev için yarışmaya açılmıştır. Bu görevler, lezyon sınır bölütleme, lezyon öznitelik tespiti ve lezyon sınıflandırılmasıdır.

Lezyon sınır bölütleme ve lezyon öznitelik tespiti olmak üzere iki farklı görev için sunulan veri seti 2.594 adet görüntü ve bu görüntülerin ikili görüntü maskelerini

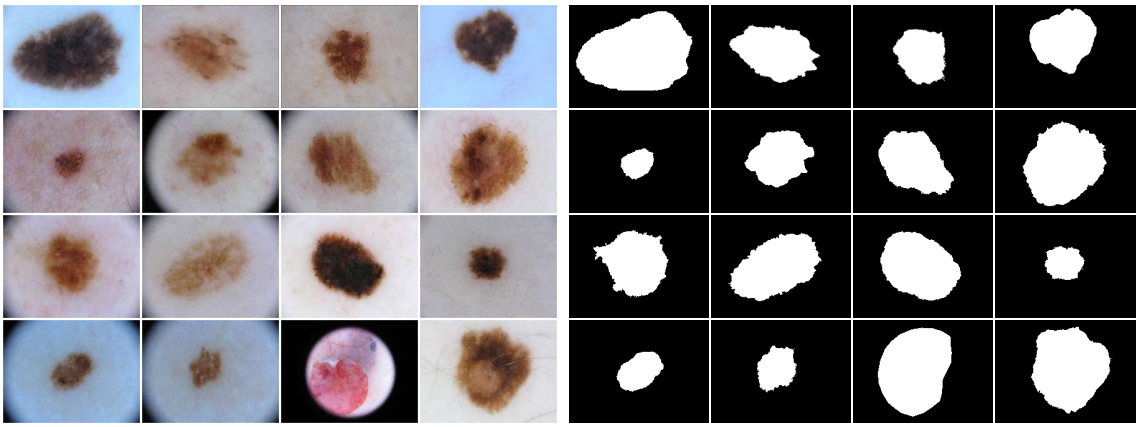

(a) (b)

Şekil 1.22. (a) ISIC 2018 veri setinden örnek dermoskopik lezyon görüntüleri, (b) lezyon görüntülerine ait ikili maske görüntüleri [153].

içermektedir. Şekil 1.22'de bu dermoskopik görüntülerin ve ikili maskelerinin örnekleri gösterilmektedir [153]. ISIC 2018 veri seti, cilt lezyonlarını doğru bir şekilde teşhis etmek ve bu alandaki modellerin performansını ölçmek için geniş çaplı bir yarışmanın temelini oluşturmuştur. İçerdiği zengin ve çeşitli dermoskopik görüntüler, model doğruluğu ve genelleştirilebilirliği açısından önemli bir kaynak sağlamaktadır. Ayrıca, ISIC 2018 veri seti, dermatologlar ve araştırmacılar arasında standardizasyonu desteklemekte ve yapay zeka sistemlerinin gerçek dünya uygulamalarındaki başarısını artırmaya yönelik önemli bir adım olarak kabul edilmektedir. Üçüncü görev için sunulan veri seti ise HAM10000 ismini alarak literatüre girmiştir. Bu veri seti hakkında detaylı bilgi bir sonraki başlıkta verilmektedir.

1.8.2. HAM10000 Veri Seti

HAM10000 [154] (10000 Eğitim Görüntüsü ile İnsan Makineye Karşı, Human Against Machine with 10000 training images) veri seti, cilt kanseri araştırmaları için değerli bir kaynak olarak hizmet vermektedir. Bu veri seti, yedi yaygın pigmentli cilt lezyon türünü temsil eden 10.015 dermoskopik görüntüden oluşmaktadır. Veri setinde bulunan sınıflar, aktinik keratoz (Actinic Keratosis, AK), BCC, iyi huylu keratoz (Benign Keratosis, BKL), dermatofibrom (Dermatofibroma, DF), MEL, melanositik nevüs (Melanocytic Nevus, NV) ve vasküler lezyonlar (Vascular Lesion, VASC)'dır. Bu sınıflara ait görüntü sayıları Tablo 1.2'de verilmektedir. Ayrıca, Şekil 1.23'te her sınıftan görüntü

örnekleri gösterilmektedir. HAM10000 veri seti büyük bir boyut ve çeşitlilik sunsa da, Şekil 1.24'te grafiksel olarak görüldüğü gibi sınıf dengesizliği sorunu barındırmaktadır. Bu dengesizlik, sınıflandırma modelleri geliştirilirken ve değerlendirilirken dikkatlice ele alınmalıdır. Sınıf dengesizliği, bazı lezyon türlerinin diğerlerine kıyasla daha fazla temsil edildiği durumları ifade etmekte ve bu durum, modelin performansını olumsuz etkileyebilmektedir. Bu nedenle, dengesizliği gidermek amacıyla veri artırma, ağırlıklandırma veya özel öğrenme stratejileri gibi yöntemler uygulanmalıdır.

Tablo 1.2. HAM10000 veri setindeki sınıflara göre görüntü sayıları.

Sınıflar	**İsim**	**Adet**
AK	Aktinik keratoz	327
BCC	Bazal hücreli karsinom	514
BKL	İyi huylu keratoz	1.099
DF	Dermatofibroma	115
MEL	Melanom	1.113
NV	Melanositik nevüs	6.705
VASC	Vasküler lezyon	142
Toplam		**10.015**

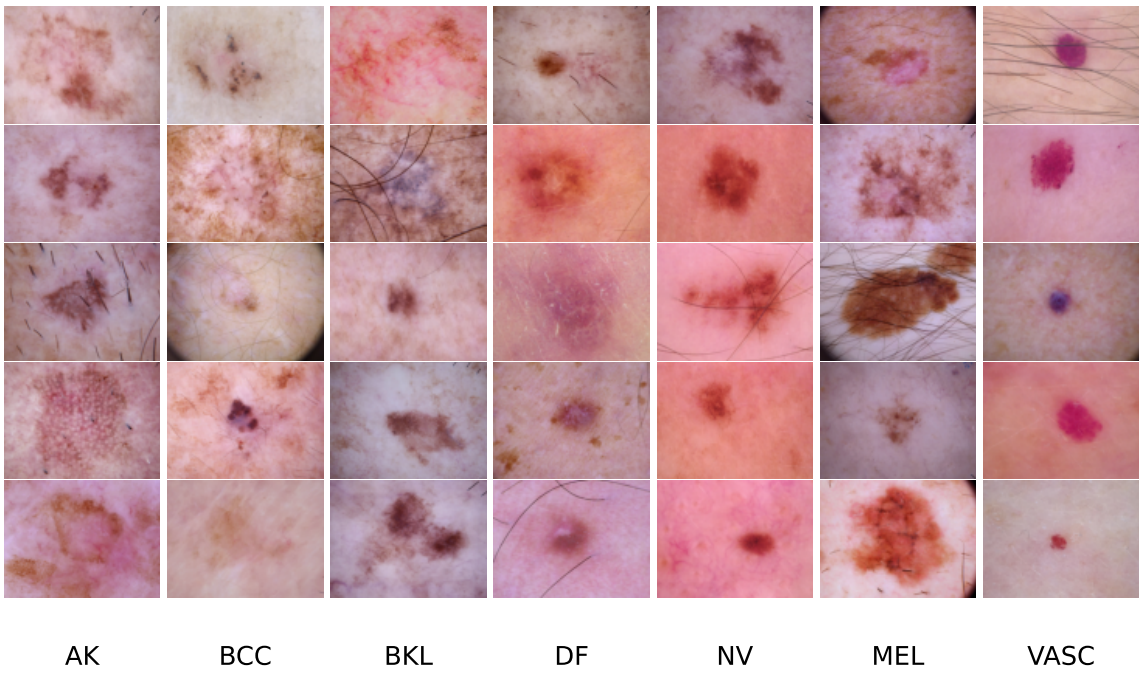

Şekil 1.23. HAM10000 veri setindeki yedi sınıfa ait örnek dermoskopik görüntüler [153].

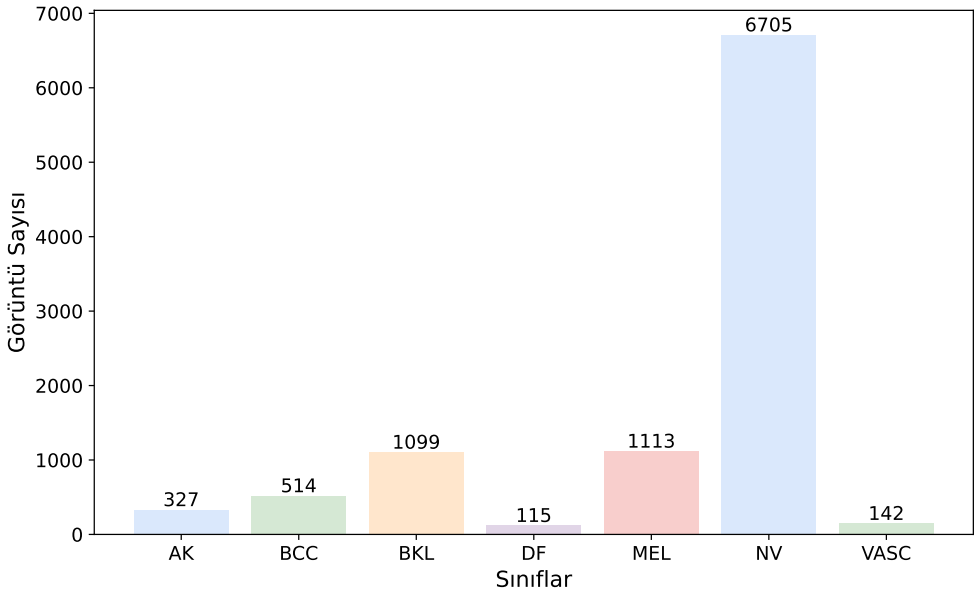

Şekil 1.24. HAM10000 veri kümesindeki her bir sınıfa ait görüntü sayıları.

1.8.3. ISIC 2019 Veri Seti

ISIC 2019 [154–156] veri seti, cilt lezyonlarının sınıflandırılması için sunulmuş olup, sekiz sınıfı kapsayan toplam 25.331 dermoskopik görüntüden oluşmaktadır. Bu veri setindeki sınıflar, AK, BCC, BKL, DF, MEL, NV, SCC ve VASC'dır. HAM10000 veri setine benzer şekilde, ISIC 2019 veri seti de ağırlıklı olarak açık tenli bireylerin görüntülerini içermektedir. Bu durum verilerin alındığı bölgelerin demografik yapısını yansıtmaktadır. Bu sınırlı demografik çeşitlilik, modelin performansını ve farklı cilt tiplerine uygulanabilirliğini etkileyebilecek önemli bir faktördür.

Tablo 1.3'te ISIC 2019 veri setinde bulunan her sınıfa ait görüntü sayıları verilmektedir. Ayrıca, Şekil 1.25, her sınıftan örnek görüntüleri ve Şekil 1.26 ise sınıfların görüntü sayılarının dağılımını grafiksel olarak göstermektedir. Bu görseller, veri setinin yapısını ve sınıflar arasındaki dağılımı daha iyi anlamaya yardımcı olmaktadır. Sınıf dağılımındaki dengesizlik, sınıflandırma modellerinin geliştirilmesi ve değerlendirilmesinde dikkate alınması gereken bir diğer önemli unsurdur.

Tablo 1.3. ISIC 2019 veri setindeki sınıflara göre görüntü sayıları.

Sınıflar	**İsim**	**Adet**
AK	Aktinik keratoz	867
BCC	Bazal hücreli karsinom	3.323
BKL	İyi huylu keratoz	2.624
DF	Dermatofibroma	239
MEL	Melanom	4.522
NV	Melanositik nevüs	12.875
VASC	Vasküler lezyon	253
SCC	Skuamöz hücreli karsinom	628
Toplam		**25.331**

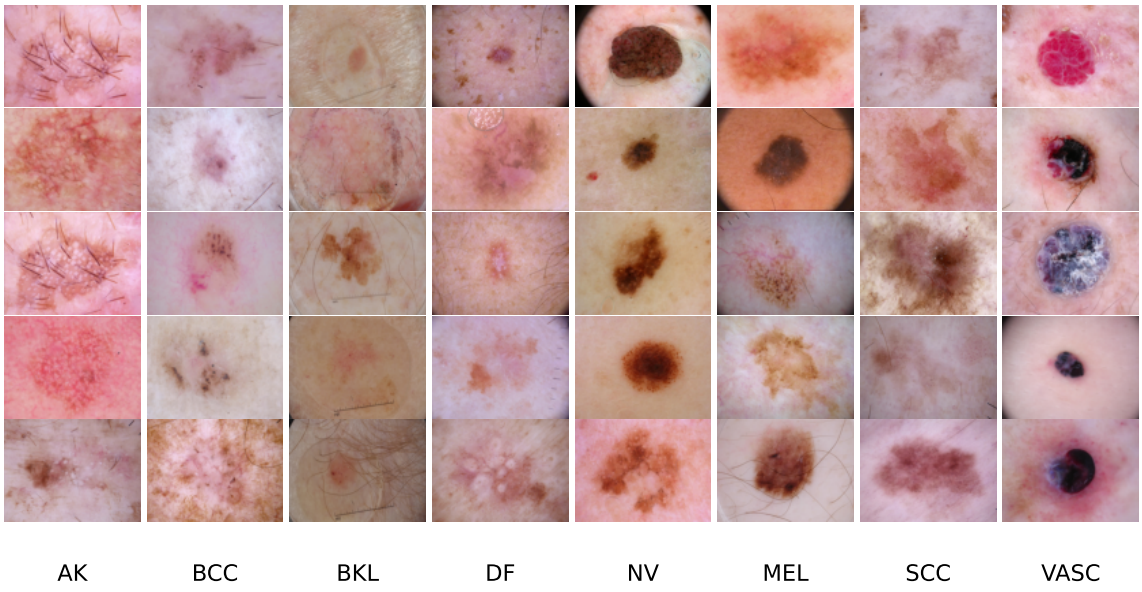

Şekil 1.25. ISIC 2019 veri setindeki sekiz sınıfa ait örnek dermoskopik görüntüler [153].

1.9. Değerlendirme Metrikleri

ML ve istatistikte, model performansını değerlendirmek için kullanılan dört ana sınıflandırma sonucu vardır. Bunlar, Gerçek Pozitif (True Positive, TP), Gerçek Negatif (True Negative, TN), Yanlış Pozitif (False Positive, FP) ve Yanlış Negatif (False Negative, FN)'tir. Bu değerler, model tahminlerinin gerçek sınıflar ile uyumluluğunu göstermekte ve sınıflandırma performansının farklı yönlerini değerlendirme için kullanılmaktadır.

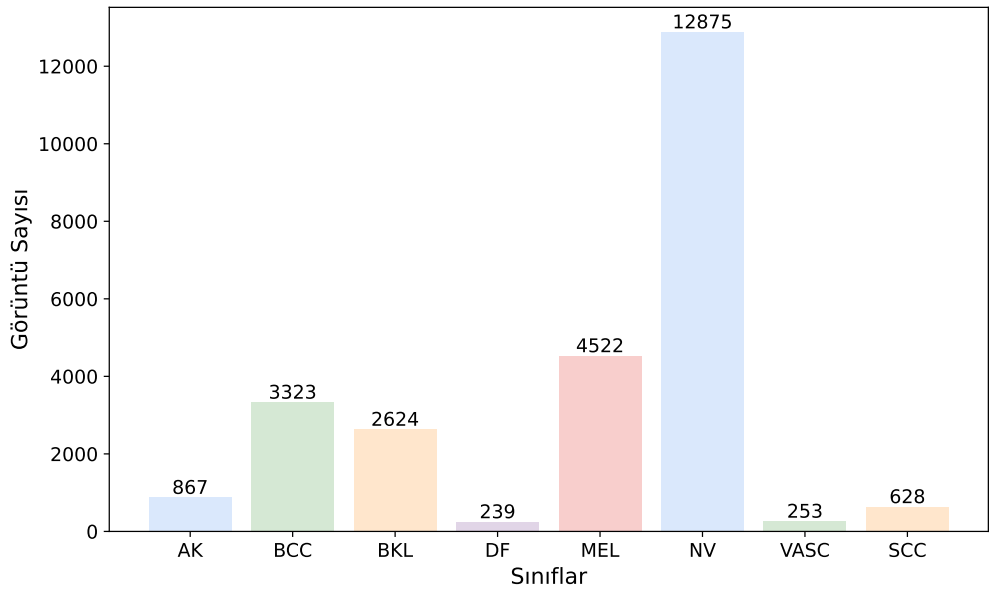

Şekil 1.26. ISIC 2019 veri setindeki her bir sınıfa ait görüntü sayıları.

TP, modelin pozitif olarak tahmin ettiği ve gerçekte de pozitif olan örneklerdir. Örneğin, cilt kanseri sınıflandırmasında modelin kanserli bir lezyonu doğru bir şekilde "kanserli" olarak sınıflaması bir TP olarak kabul edilir. Yüksek TP sayısı, modelin pozitif örnekleri doğru bir şekilde tanımlama kapasitesinin yüksek olduğunu göstermektedir.

TN, modelin negatif olarak tahmin ettiği ve gerçekten negatif olan örnekleri ifade etmektedir. Kanser teşhisinde, sağlıklı bir lezyonu "sağlıklı" olarak doğru bir şekilde sınıflandırmak bir TN örneğidir. TN'lerin yüksek olması, modelin negatif sınıfı doğru bir şekilde tanımlayabildiğini gösterir ve doğruluk gibi genel performans metriklerine katkı sağlamaktadır.

FP, modelin pozitif olarak tahmin ettiği, ancak gerçekte negatif olan örneklerdir. Bir sağlıklı lezyonun yanlışlıkla "kanserli" olarak sınıflandırılması bir FP örneğidir. Bu durum, özellikle sağlık gibi kritik alanlarda ciddi sonuçlara yol açabilmektedir. FP sayısının yüksek olması, modelin yanlış alarmlar verme eğiliminde olduğunu göstermekte ve bu da kesinlik gibi metriklerin düşmesine neden olmaktadır.

FN, modelin negatif olarak tahmin ettiği, ancak aslında pozitif olan örneklerdir. Bu durumda, kanserli bir lezyonun yanlışlıkla "sağlıklı" olarak sınıflandırılması örneği

FN olarak kabul edilmektedir. FN sayısının yüksek olması, modelin bazı pozitif durumları gözden kaçırdığı anlamına gelir ve bu durum duyarlılık gibi metriklerin düşük olmasına yol açmaktadır. Tıbbi sınıflandırmalarda FN'ler oldukça kritik sonuçlara neden olabileceğinden, duyarlılık ve F1-skor gibi metriklerde düşük FN oranına sahip olmak önemlidir.

Bu dört temel terim, değerlendirme metriklerinin temelini oluşturmakta ve sınıflandırma modellerinin performansını daha kapsamlı bir şekilde analiz etmemizi sağlamaktadır. Model performansı açısından TP ve TN değerlerinin yüksek olması arzu edilirken, FP ve FN değerlerinin mümkün olduğunca düşük olması beklenmektedir.

Cilt kanseri sınıflandırmasında kullanılan modellerin performansını değerlendirmek için çeşitli metrikler kullanılmaktadır. Bu metrikler, modelin doğruluğunu, güvenilirliğini ve genel başarısını ölçmek amacıyla kritik öneme sahiptir [157].

Doğruluk, en yaygın kullanılan değerlendirme metriklerinden biridir ve doğru sınıflandırılan örneklerin toplam örneklere oranını ifade etmektedir. Yüksek doğruluk oranı, modelin genel performansını gösterirken, veri setindeki sınıf dengesizliği durumunda yanıltıcı olabilmektedir. Doğruluk metriği aşağıdaki denklem kullanılarak hesaplanmaktadır:

$$Doğruluk = \frac{TP + TN}{TP + TN + FP + FN} \tag{1.22}$$

Kesinlik, pozitif olarak sınıflandırılan örneklerin ne kadarının gerçekten pozitif olduğunu göstermektedir. Bu metrik, FP etkisini azaltmak için önemlidir ve özellikle cilt kanseri gibi kritik durumlarda, yanlış tanıların önlenmesi açısından büyük bir öneme sahiptir. Kesinlik metriği aşağıdaki şekilde tanımlanmaktadır:

$$Kesinlik = \frac{TP}{TP + FP} \tag{1.23}$$

Duyarlılık, aynı zamanda hassasiyet olarak da bilinmektedir. Modelin pozitif örnekleri doğru bir şekilde tanımlama yeteneğini ölçen bir metriktir. Cilt kanseri teşhisinde kaçırılan vakaların azaltılması için kritik öneme sahiptir. Bu, TP tahminlerin TP ve

FN örneklerin toplamına oranı olarak hesaplanmaktadır. Duyarlılık aşağıdaki denklemle hesaplanır:

$$Duyarlılık = \frac{TP}{TP + FN} \tag{1.24}$$

Özgüllük, modelin negatif örnekleri doğru bir şekilde tanımlama yeteneğini ölçen bir metriktir. Özgüllük, TN tahminlerin, TN ve FP tahminlerin toplamına oranı olarak hesaplanır. Bu metrik, sağlıklı bireylerin doğru şekilde tanımlandığını göstermektedir. Özgüllük aşağıdaki denklemle ifade edilmektedir:

$$Özgüllük = \frac{TN}{TN + FP} \tag{1.25}$$

F1-skoru, kesinlik ve duyarlılığın harmonik ortalamasıdır ve her iki ölçümü dengeleyen tek bir metrik sağlamaktadır. Bu metrik, özellikle kesinlik ve duyarlılığın karşıtlık gösterdiği durumlarda modelin performansının kapsamlı bir değerlendirmesini sunmaktadır. Yüksek bir F1-skoru, modelin pozitif örnekleri doğru bir şekilde tanımlama yeteneğini göstermektedir. F1-skoru aşağıdaki şekilde ifade edilmektedir:

$$F1 - skor = 2 \times \frac{Kesinlik \times Duyarlılık}{Kesinlik + Duyarlılık} \tag{1.26}$$

Dice benzerlik katsayısı, görüntü işleme ve tıbbi görüntü analizinde yaygın olarak kullanılan bir değerlendirme metriğidir. İki kümenin benzerliğini hesaplayan bu metrik, tahmin edilen bölütleme ile gerçekte olması gereken bölütlemenin örtüşme oranını belirlemektedir. Dice, sıfır ile bir arasında bir değer almaktadır. Bir değeri, iki kümenin tamamen örtüştüğünü, sıfır ise hiçbir örtüşmenin olmadığını göstermektedir. Bu metrik, özellikle tıbbi görüntülerde lezyon gibi yapıların doğru bölütlenmesini değerlendirmek için kullanılmaktadır. Dice katsayısı, kullanılan modelin doğruluğunu değerlendirmede önemli bir rol oynamaktadır. Dice takip eden denklemle ifade edilmektedir:

$$Dice = \frac{2|A \cap B|}{|A| + |B|} \tag{1.27}$$

burada, A, gerçek bölütlemeyi, B ise model tarafından tahmin edilen bölütlemeyi ifade etmektedir. $|A \cap B|$, A ve B kümelerinin kesişimini, yani örtüşen piksel sayısını gösterirken, $|A|$ ve $|B|$ her iki kümenin toplam piksel sayılarını temsil etmektedir [158].

Jaccard katsayısı, Dice katsayısına benzer bir metriktir. Özellikle görüntü işleme, tıbbi görüntü bölütleme ve bilgi erişiminde kullanılan bu katsayı, iki kümenin kesişim miktarının birleşim miktarına oranı olarak hesaplanmaktadır. Jaccard benzerlik katsayısı sıfır ile bir arasında bir değer almaktadır. Bir değeri kümelerin tamamen örtüştüğünü, sıfır değeri ise kümeler arasında örtüşmenin olmadığını göstermektedir. Jaccard katsayısının denklemi aşağıdaki gibidir:

$$Jaccard = \frac{|A \cap B|}{|A \cup B|} \tag{1.28}$$

burada, A ve B, karşılaştırılan iki küme olup; $|A \cap B|$, A ve B kümelerinin kesişim kümesinin eleman sayısını, $|A \cup B|$ ise birleşim kümesinin eleman sayısını ifade etmektedir [159]. Bu katsayı, modelin doğruluğunu değerlendirmek ve tahmin edilen bölütleme ile gerçek bölütleme arasındaki benzerliği ölçmek amacıyla kullanılmaktadır.

Eğri Altındaki Alan (Area Under the Curve, AUC), sınıflandırma modellerinin performansını değerlendirmek için kullanılan önemli bir metriktir ve genellikle Alıcı İşletim Karakteristiği (Receiver Operating Characteristic, ROC) eğrisinin altındaki alan olarak tanımlanmaktadır. ROC eğrisi, modelin farklı sınıflandırma eşiklerinde TP ve FP oranlarını karşılaştırarak oluşturulmaktadır. AUC, bu eğrinin altındaki alanın büyüklüğünü ifade etmektedir ve sıfır ile bir arasında bir değer almaktadır [160]. AUC değeri ne kadar yüksekse, modelin sınıfları doğru ayırt etme başarısı o kadar yüksek olarak değerlendirilmektedir. AUC, sınıflar arasındaki dağılımın eşit olup olmadığına bakılmaksızın, modelin genel performansını değerlendirdiği için özellikle dengesiz veri setlerinde faydalı bir metriktir. Bu nedenle, AUC, farklı modellerin karşılaştırılmasında, performansın net ve objektif bir şekilde analiz edilmesini sağlamaktadır.

1.10. Cilt Kanseri Sınıflandırmasında Mevcut Problemler

Cilt kanseri, dünya genelinde hem yaygınlığı hem de ölüm oranları açısından ciddi bir sağlık sorunu oluşturmaktadır. Özellikle MEL gibi hızlı ilerleyen ve agresif türlerin erken

teşhisi, tedavi sürecinin etkinliği için kritik bir öneme sahiptir. Ancak, geleneksel teşhis yöntemlerinin büyük ölçüde dermatologların deneyimine bağlı olması, sürecin subjektif hale gelmesine ve tanı süresinin uzamasına neden olmaktadır. Bu durum, erken teşhisin sağlanması için temel engellerden biri olarak öne çıkmaktadır.

Cilt kanserinin tanısına yönelik mevcut yöntemler, performans ve güvenilirlik açısından sınırlı başarı göstermektedir. Özellikle dermoskopik görüntülerin otomatik analizi ve lezyonların doğru sınıflandırılması, yüksek doğruluk gerektiren ancak çeşitli zorluklarla karşılaşılan bir süreçtir. Bu süreçte, etiketlenmiş veri eksikliği ve sınıf dengesizlikleri gibi faktörler, cilt kanseri sınıflandırmasında doğru sonuçlara ulaşılmasını güçleştirmektedir. Dolayısıyla, medikal görüntü analizi alanında bu sorunların üstesinden gelmek için daha gelişmiş ve kapsamlı yöntemlere ihtiyaç duyulmaktadır.

Mevcut bilgisayarlı teşhis sistemleri, genellikle klinik uygulamalara entegrasyon ve güvenilirlik bakımından yeterli düzeye ulaşamamıştır. DL modelleri cilt kanseri tespitinde önemli bir potansiyel sunsa da, bu modellerin etkinliğini artırmaya yönelik kapsamlı çalışmalar gerekmektedir. Bu bağlamda, daha yüksek doğruluk, genelleştirilebilirlik ve klinik uyum sağlayan hibrit DL modellerinin geliştirilmesi, cilt kanseri teşhisindeki mevcut problemleri aşmanın temel bir gerekliliği olarak karşımıza çıkmaktadır.

2. BÖLÜM

CİLT KANSERİ SINIFLANDIRMASI İÇİN YENİ BİR HİBRİT EVRİŞİMSEL SİNİR AĞI MODELİ

Bu bölümde öncelikle, CNN modelleri ile oluşturulan hibrit yöntemin ayrıntıları açıklanmaktadır. Ardından, yöntemin ön işleme aşamasında cilt lezyonlarının bölütlenmesi amacıyla kullanılan görüntü bölütleme tekniği ele alınmaktadır. Daha sonra, önerilen hibrit modelde yer alan veri ön işleme ve veri artırma işlemleri ile modelin eğitiminde kullanılan parametreler tanıtılmaktadır. Ardından, cilt kanseri veri setleri üzerinde yapılan deneylere ait görsel ve sayısal sonuçlar sunulmaktadır. Son olarak, geliştirilen modelin literatürdeki güncel diğer yöntemlerle karşılaştırılması yapılmaktadır.

2.1. Çok Sınıflı Cilt Kanseri Sınıflandırması için Geliştirilen Hibrit Model

Cilt kanseri görüntülerinin sınıflandırma başarımını artırmak amacıyla, birden fazla CNN modelinden elde edilen özniteliklerin birleştirilerek tek bir yapı halinde kullanılması hibrit model olarak adlandırılmaktadır. Bu yaklaşım, farklı CNN modellerinin her birinin güçlü yönlerinden faydalanarak sınıflandırma doğruluğunu artırmayı hedeflemektedir. Hibrit modeller, farklı modellerin öznitelik çıkarma becerilerini bir araya getirerek daha başarılı ve kapsamlı bir analiz sağlamaktadır.

Bu çalışmada çok sınıflı cilt kanseri görüntülerinin sınıflandırılması için hibrit bir CNN model geliştirilmesi amaçlanmıştır. Bu amaç doğrultusunda, HAM10000 ve ISIC 2019 veri setleri için ayrı ayrı modeller geliştirilmiştir. Geliştirilen hibrit modeller görüntü bölütleme, derin öznitelik çıkarımı, öznitelik birleştirme, öznitelik seçme ve sınıflandırma işlemleri olmak üzere beş ana adımdan oluşmaktadır. HAM10000 ve ISIC 2019 veri setleri için geliştirilen hibrit modeller sırasıyla Şekil 2.1 ve Şekil 2.2'de verilmektedir.

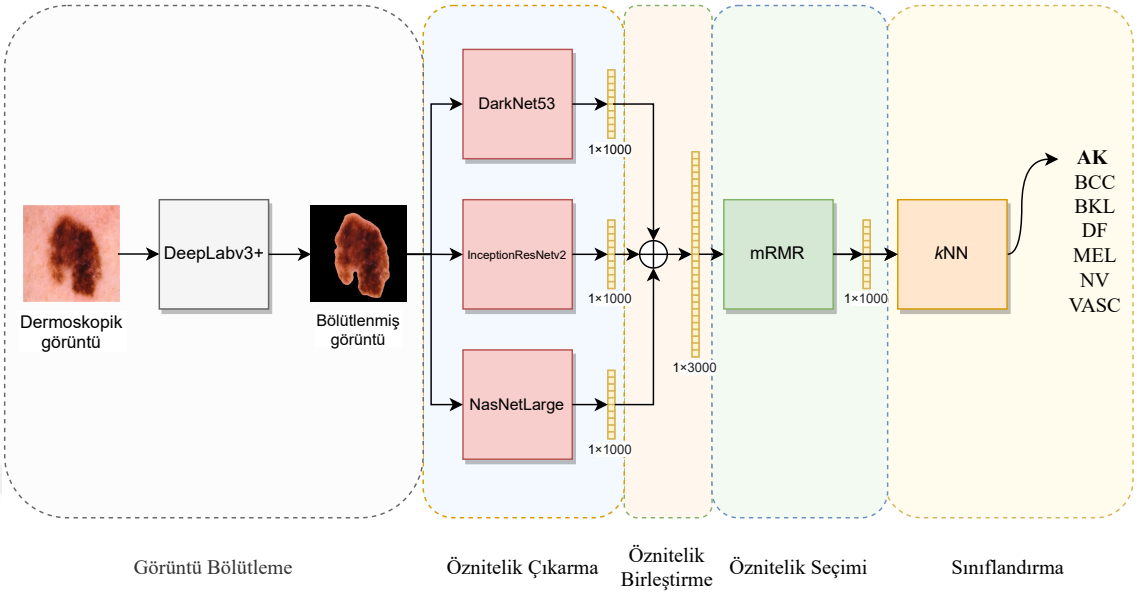

Şekil 2.1. HAM10000 veri seti için geliştirilen modelin şematik diyagramı.

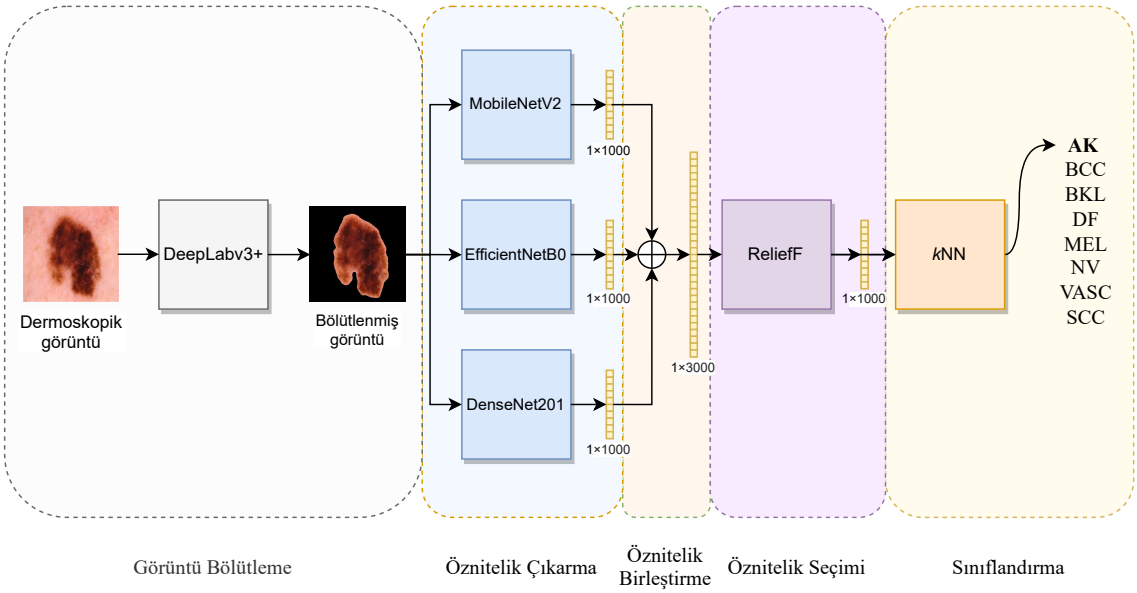

Şekil 2.2. ISIC 2019 veri seti için geliştirilen modelin şematik diyagramı.

Geliştirilen hibrit modellerin ilk aşamasında görüntü bölütleme işlemi yapılmaktadır. Dermoskopik görüntüler genellikle kalem izi, hava kabarcığı ve kıl gibi görüntünün yorumlanmasını zorlaştıran unsurlar içermektedir. Geleneksel olarak cilt kanseri tespitinde lezyonlardan şekil, sınır, renk, lezyon çapı ve doku gibi öznitelikleri manuel olarak çıkartılmaktadır. Ancak, bu süreç zaman alıcı olmakla birlikte uzman bilgisi

de gerektirmektedir. Ayrıca, uygun bir öznitelik çıkarıcı belirlemek karmaşık bir işlemdir. Görüntü bölütleme adımı, görüntüdeki ilgi alanlarını otomatik tanımlamaya ve istenmeyen kalem izi, kıl ve kabarcık gibi istenmeyen nesnelerin kaldırılmasına yardımcı olmaktadır. Bu işlemin amacı, lezyon bölgesine ait piksellerin belirlenmesi ile cilt kanseri sınıflandırma başarısını artırmaktır. Bu nedenle çalışmada, görüntü bölütlemesi için ResNet50 tabanlı DeepLabv3+ modeli kullanılmıştır.

Hibrit modellerin ikinci adımında, görüntü bölütleme işlemi sonucunda elde edilen lezyonlardan ayırt edici özniteliklerin çıkarılması gerçekleştirilmektedir. Öznitelik çıkarma yöntemleri genel olarak iki temel yaklaşıma ayrılmaktadır. Bunlar el ile tanımlanan öznitelik çıkarımı [161] ve DL tabanlı öznitelik çıkarımıdır [162]. Özellikle DL tabanlı yaklaşımlar, CNN mimarilerinin sağladığı otomatik öğrenme kapasitesi ile ham görüntü verilerinden düşük seviyeli (kenar, renk, doku) ve yüksek seviyeli (şekil, desen, bağlamsal bilgi) öznitelikleri etkili bir şekilde öğrenebilmektedirler [87]. Bölütleme aşamasında tanımlanan lezyon bölgeleri CNN modellerine giriş olarak verilmiş, modelin ara katmanlarında işlenen bilgiler aracılığıyla ayırt edici öznitelikler elde edilmiştir. Üretilen öznitelikler, modelin farklı katmanlarında öğrenilen görsel temsillerin bir çıktısı olup, sayısal vektörler şeklinde ifade edilmektedir. Bu öznitelik vektörleri, lezyonun geometrik yapısını, örüntülerini ve diğer ayırt edici özniteliklerini kodlamakta, bu sayede sınıflandırma gibi görevler için anlamlı bir temsil sağlamaktadır. Özellikle derin katmanlarda elde edilen öznitelikler, lezyonların sınıflandırma süreçlerinde kritik olan karmaşık yapısal ve bağlamsal bilgileri barındırarak model performansına önemli katkılar sunmaktadır.

Aynı koşullar altında gerçekleştirilen kapsamlı deneyler sonrasında en başarılı CNN modeller hibrit modelleri oluşturmak için seçilmiştir. Yapılan deneyler sonucunda HAM10000 veri seti için en iyi sonuçları veren modeller DarkNet53, InceptionResNetv2 ve NasNetLarge olarak belirlenmiştir. ISIC 2019 veri seti için ise en iyi sonuçları veren MobileNetv2, EfficientNetb0 ve DenseNet201 CNN modelleri seçilmiştir. Bahsi geçen mimarilerde kullanılan modellerin seçimi için gerçekleştirilen deneysel çalışmaların sonuçları Bölüm 2.5.1 ve Bölüm 2.5.2'de sunulmaktadır. Her modelin son tam bağlı katmanından 1×1000 boyutunda öznitelik vektörleri elde edilmiştir.

Önerilen yöntemin üçüncü aşamasında, öznitelik birleştirme işlemi uygulanmaktadır. Bu aşamanın amacı, tekil CNN modellerinden çıkarılan özniteliklerin tek bir vektörde toplanarak öznitelik seçme algoritmasına giriş olarak sunulmasını sağlamaktır. Bu bağlamda, kullanılan her iki veri seti için üç farklı CNN modelinden elde edilen 1 × 1000 boyutundaki öznitelik vektörleri birleştirilmiş ve 1 × 3000 boyutunda kapsamlı bir öznitelik vektörü elde edilmiştir.

Yöntemin dördüncü aşamasında, kapsamlı öznitelik vektöründen en belirleyici özniteliklerin seçimi için bir öznitelik seçme algoritması kullanılmaktadır. Bu aşamanın temel amacı, modelin hesaplama yükünü azaltmak ve sınıflandırma sürecine hazırlamaktır. Böylece model, en ilgili öznitelikleri seçerek verileri etkili bir şekilde sınıflandırma işlemi yapabilecek ve doğru tahminler üretebilecektir. Bu çalışmada yapılan deneylerde, mRMR, Fscchi2 ve ReliefF öznitelik seçme algoritmalarının başarımları karşılaştırılmıştır. Öznitelik seçme algoritmaları ile 1 × 3000 boyutundaki kapsamlı öznitelik vektöründen 1 × 1000 boyutunda en önemli öznitelikleri içeren vektörler elde edilmiştir. Deneyler sonucunda HAM10000 veri seti için mRMR öznitelik seçim algoritması, ISIC 2019 veri seti için ise ReliefF öznitelik seçim algoritması en yüksek başarımları elde etmiştir. HAM10000 veri seti için deney sonuçları Bölüm 2.5.1'de ve ISIC 2019 veri seti için deney sonuçları Bölüm 2.5.2'de sunulmaktadır.

Son aşamada ise, 1 × 1000 boyutunda en önemli öznitelikleri içeren vektörler üzerinde sınıflandırma süreci gerçekleştirilmiştir. Elde edilen öznitelikler, deneylerde en başarılı sonuçları veren kNN sınıflandırma algoritması ile sınıflandırılmıştır.

2.2. Veri Ön İşleme ve Veri Artırma

Küçük veya dengesiz veri kümeleri üzerinde CNN modelleri eğitilirken performans sorunları yaşanabilmektedir. Bu sorunları çözmek için veri artırma teknikleri kullanılmaktadır. Klinik olarak daha fazla veri toplamak maliyetli ve zaman alıcı bir süreç olduğundan, var olan verinin artırılması daha verimli bir çözüm olarak karşımıza çıkmaktadır. Mevcut örneklerden yeni veriler üreterek veri artırma işlemi, modelin aşırı öğrenmesini önleyebilmekte ve genelleme yeteneğini artırabilmektedir. Bu sayede model, yeni ve görülmemiş görüntüler üzerinde daha doğru tahminler yapabilmektedir.



a b c

Şekil 2.3. Veri artırımı işlemi: (a) orijinal görüntü, (b), döndürülmüş görüntü, (c) yakınlaştırılmış görüntü.

Bu çalışmada, HAM10000 ve ISIC 2019 veri setlerindeki görüntülere rastgele döndürme ve yakınlaştırma işlemleri uygulanarak veri setlerindeki görüntü sayısı artırılmıştır. Rastgele döndürme, veri setindeki lezyonların eğitim sırasında göründüğü açıları değiştirdiği için pratik bir artırma tekniğidir. Deneylerde, her bir kaynak görüntü, -90° ile $+90^{\circ}$ derece arasındaki rastgele seçilmiş bir açıyla saat yönünde veya saat yönünün tersi yönünde döndürülmüştür. Bu da lezyonun çerçevedeki konumunu değiştirmiştir. Bu çalışmada kullanılan diğer bir veri artırma tekniği rastgele yakınlaştırmadır. Bu teknik değişen yakınlaştırma seviyelerine sahip görüntüler üretmek için kullanılmıştır. Deneylerde, görüntüler $[1.2, 2.0]$ aralığında rastgele bir yakınlaştırma değeri ile oluşturulmuştur. Şekil 2.3'te veri artırımı işlemine ait orijinal görüntü ile, döndürülmüş ve yakınlaştırılmış görüntülere birer örnek görüntü gösterilmektedir. Tablo 2.1 ve Tablo 2.2'de sırasıyla HAM10000 ve ISIC 2019 veri setindeki tüm sınıflardan veri artırımı işlemi ile elde edilen görüntü sayıları verilmektedir.

2.3. Önerilen Yöntemdeki Temel Bileşenlerin Belirlenmesi ve Uygulama Ortamı

CNN modelleri üzerinde yapılan deneylerde, HAM10000 ve ISIC 2019 veri setleri rastgele olarak %70 oranında eğitim veri setine ve %30 oranında test veri setine bölünmüştür. Geliştirilen hibrit yöntem için en uygun CNN modellerini belirlemek amacıyla, literatürde yaygın olarak kullanılan on dokuz farklı ön eğitimli CNN modeli öznitelik çıkarıcı olarak karşılaştırılmıştır. Her modelden, 1×1000 boyutunda bir öznitelik vektörü elde edilmiştir. Daha sonra, seçilen CNN modellerinden çıkarılan

Tablo 2.1. HAM10000 veri setindeki sınıflara göre veri artırma ile elde edilen görüntü sayıları.

Sınıflar	Orijinal görüntü sayısı	Rasgele döndürme ile elde edilen görüntü sayısı	Rasgele yakınlaştırma ile elde edilen görüntü sayısı	Toplam elde edilen görüntü sayısı
AK	327	327	327	981
BCC	514	514	514	1.542
BKL	1.099	1.099	1.099	3.297
DF	115	115	115	345
MEL	1.113	1.113	1.113	3.339
NV	6.705	6.705	6.705	20.115
VASC	142	142	142	426
Toplam	10.015	10.015	10.015	30.045

Tablo 2.2. ISIC 2019 veri setindeki sınıflara göre veri artırma ile elde edilen görüntü sayıları.

Sınıflar	Orijinal görüntü sayısı	Rasgele döndürme ile elde edilen görüntü sayısı	Rasgele yakınlaştırma ile elde edilen görüntü sayısı	Toplam elde edilen görüntü sayısı
AK	867	867	867	2.601
BCC	3.323	3.323	3.323	9.969
BKL	2.624	2.624	2.624	7.872
DF	239	239	239	717
MEL	4.522	4.522	4.522	13.566
NV	12.875	12.875	12.875	38.625
VASC	253	253	253	759
SCC	628	628	628	1.884
Toplam	25.331	25.331	25.331	75.993

birleşik öznitelikler üzerinde ReliefF, mRMR ve Fscchi2 olmak üzere üç farklı öznitelik seçimi algoritması değerlendirilmiştir. Ardından, SVM, kNN, NB, LDA ve DT olmak üzere beş farklı sınıflandırma algoritmalarının performans değerleri karşılaştırılmıştır.

Bu bölüm kapsamında yapılan tüm deneysel çalışmalar MATLAB R2023b programında gerçekleştirilmiştir. Deneyler, 4.7 GHz hızında 12. nesil Intel Core i7-12650H işlemci, 8 GB grafik kartı ve 32 GB RAM'e sahip bir bilgisayar üzerinde yürütülmüştür.

2.4. Görüntü Bölütleme İşlemi ve Sonuçları

Dermoskopik görüntüler, sınıflandırma başarısını düşüren mürekkep lekesi, cetvel işareti, dermoskopik jelden kaynaklanan hava kabarcıkları ve kıl gibi nesneler içerebilmektedir. Bir dermoskopik görüntüden öznitelik çıkarma ve sınıflandırma aşamalarından önce bu

türden istenmeyen unsurlarından doğru bir şekilde ayrıştırılması kritik öneme sahiptir. Bu sebeple, önerilen hibrit yöntemde, görüntülerden lezyon sınırlarını elde etmek için bölütleme işlemi uygulanmaktadır. Bu amaç için, DeepLabv3+ tabanlı bir görüntü bölütleme ağı kullanılmıştır. Eğitilen DeepLabv3+ ağı, dermoskopik görüntülerdeki cilt lezyonlarının sınırlarını belirledikten sonra, lezyon sınırları dışındaki kalan bölgeler, siyah renk ile doldurulmuştur. Bu adım, görüntüdeki ilgi alanlarını tanımlamaya ve görüntüdeki istenmeyen unsurlar olan işaretlerin, kılların ve kabarcıkların kaldırılmasına yardımcı olmaktadır. Bu işlemin amacı, lezyonlara karşılık gelmeyen pikselleri doğru bir şekilde tanımlayıp kaldırarak, cilt kanseri sınıflandırmasının başarısını artırmaktır. Bu bölümde, görüntü bölütleme modelinin performansını değerlendirmek üzere yapılan deneylerin sonuçları detaylandırılmaktadır.

Görüntü bölütleme ağı, klinik uzmanlar tarafından manuel olarak oluşturulan bölütleme maskelerini içeren 2.594 dermoskopik görüntüden oluşan ISIC 2018 veri seti üzerinde eğitilmiştir. Deneylerde, veri setinin %80'i eğitim verisi için ve kalan %20'si test verisi için kullanılmıştır. Eğitilen modellerin tutarlılığını sağlamak amacıyla, tüm görüntüler ve bölütleme maskeleri 256×256 piksel çözünürlük boyutlarına yeniden boyutlandırılmıştır.

Farklı omurga mimarilerinin bölütleme doğruluğu üzerindeki etkisini değerlendirmek için, ResNet18, ResNet50 ve MobileNetv2 mimarilerini omurga derin ağı olarak kullanan üç farklı DeepLabv3+ modeli oluşturulmuştur. Bu ağların görüntü bölütleme performansını karşılaştırmak için Dice ve Jaccard benzerlik katsayıları ile genel ve ortalama piksel doğruluk oranları kullanılmıştır. Bu deneyler ile ilgili detaylar Tablo 2.3'te verilmiştir. Sonuçlar incelendiğinde, ResNet50 tabanlı modelin en yüksek performansı elde ettiği görülmektedir. Model ile, Dice katsayısı %94,40, Jaccard indeksi %89,55, genel piksel doğruluk oranı %93,35 ve ortalama piksel doğruluk oranı %91,90 olarak elde edilmiştir. ResNet18 modeli, ResNet50 modeline yakın sonuçlar sergilerken, MobileNetv2 modeli daha düşük performans göstermiştir. Bu sonuçlar, ResNet50 mimarisinin görüntü bölütleme işlemi için en etkili omurga ağı olduğunu göstermektedir.

DeepLabv3+ ile dermoskopik görüntülerden lezyonların elde edilmesi, istenmeyen nesnelerin ortadan kaldırılması yoluyla sınıflandırma ağının doğruluğunu artırmaktadır. Bölütleme işlemi sonunda elde edilen örnek görüntüler Şekil 2.4'te sunulmaktadır.

Tablo 2.3. DeepLabv3+ modelinin farklı omurga ağları ile bölütleme doğrulukları.

	Benzerlik katsayıları		**Piksel sınıflandırma doğruluğu**	
Omurga ağları	**Dice (%)**	**Jaccard (%)**	**Genel (%)**	**Ortalama (%)**
MobileNetv2	93,54	88,05	92,12	90,33
ResNet18	93,58	89,30	92,61	91,39
ResNet50	**94,40**	**89,55**	**93,35**	**91,90**

2.5. Çok Sınıflı Cilt Kanseri Sınıflandırması için Hibrit Model Deney Sonuçları

Bu bölümde, önerilen yöntem içerisindeki her bir bileşenin cilt kanseri sınıflandırma üzerindeki etkinliği incelenmektedir. Öznitelik çıkarma modellerinin, öznitelik seçiminin ve sınıflandırma algoritmalarının genel başarı üzerindeki etkilerini değerlendirmeyi amaçlamaktadır. Bu değerlendirme aracılığıyla, önerilen modelimiz için en etkili kombinasyonların belirlenmesi hedeflenmektedir. Veri setleri üzerinde AlexNet [163], DarkNet19 [164], DarkNet53 [164], DenseNet201 [57], EfficientNetb0 [54], GoogleNet [165], InceptionResNetv2 [76], Inceptionv3 [166], MobileNetv2 [53], NasNetLarge [61], NasNetMobile [61], ResNet18 [167], ResNet50 [167], ResNet101 [167], ShuffleNet [168], SqueezeNet [169], VGG16 [170], VGG19 [170] ve Xception [171] ön eğitimli CNN modelleri kullanılarak derin öznitelikler elde edilmiştir.

2.5.1. HAM10000 Veri Seti için Deney Sonuçları

HAM10000 veri seti için ilk önce on dokuz adet CNN modelin performansları tüm sınıflandırma algoritmaları ile değerlendirilmektedir. Veri artırımının model performanslarını nasıl etkilediği de görmek için sonuçlar veri artırımı yapılmadan önce ve veri artırımı yapıldıktan sonra olmak üzere Tablo 2.4'te detaylı bir şekilde verilmiştir.

Tablo 2.4'e göre, veri artırımı uygulanmadan önce CNN modellerinin farklı sınıflandırıcılarla doğruluk oranlarına baktığımızda, SVM ve kNN sınıflandırıcılarının genelde en yüksek performansı sağladığını görülmektedir. Özellikle ResNet50 ve EfficientNetb0 modelleri SVM ile en yüksek doğruluğa ulaşmıştır. Bu modeller sırasıyla %75,80 ve %75,77 doğruluk oranları elde etmiştir. DarkNet53, DenseNet201

Tablo 2.4. Farklı öznitelik sınıflandırıcılar açısından karşılaştırılan CNN modellerinin HAM10000 veri seti üzerindeki performansları.

	Veri artırma uygulaması olmadan					Veri artırma uygulaması ile				
CNN Modelleri	**SVM (%)**	**kNN (%)**	**NB (%)**	**DA (%)**	**DT (%)**	**SVM (%)**	**kNN (%)**	**NB (%)**	**DA (%)**	**DT (%)**
DarkNet53	75,00	71,44	52,50	58,53	61,68	83,79	**90,67**	50,67	50,67	67,40
InceptionResNetv2	74,47	68,01	43,18	46,96	61,75	82,87	**90,66**	43,21	43,21	67,98
NasNetLarge	73,00	67,18	43,64	53,46	61,45	81,75	**90,53**	43,91	43,91	67,51
Xception	73,00	69,91	45,84	45,84	60,45	80,55	90,50	46,16	46,16	68,21
Inceptionv3	71,27	68,54	44,44	52,39	61,19	80,37	90,05	44,46	44,46	65,73
VGG16	71,37	70,14	42,41	48,58	63,32	82,44	89,07	42,35	77,06	67,28
EfficientNetb0	75,77	71,27	51,86	59,63	63,95	83,24	88,44	54,36	80,13	67,61
AlexNet	72,07	67,21	38,08	45,67	62,58	81,79	88,21	42,64	76,74	67,85
DenseNet201	75,57	72,50	52,20	58,30	63,62	82,24	87,94	52,31	79,72	67,63
ResNet101	75,60	70,14	48,00	51,27	61,88	83,44	87,35	50,87	80,13	67,82
VGG19	71,64	69,17	39,08	49,12	60,12	81,22	86,15	38,63	76,56	66,00
ResNet18	73,70	69,54	45,41	53,64	61,55	79,12	85,73	46,13	76,47	65,64
NasNetMobile	71,27	66,15	39,05	44,69	59,65	78,45	84,58	38,61	38,62	62,75
ResNet50	75,80	70,34	48,77	53,65	63,02	83,40	84,30	49,50	80,59	66,54
MobileNetv2	71,77	69,54	48,34	54,64	62,22	77,37	83,87	49,05	77,14	63,05
ShuffleNet	75,10	70,04	48,93	55,28	62,72	80,52	83,06	48,93	48,93	65,61
GoogleNet	71,27	68,01	39,95	45,43	61,92	77,56	81,97	40,66	74,67	64,26
DarkNet19	67,01	59,62	24,97	20,25	60,45	67,17	69,98	30,31	66,94	66,36
SqueezeNet	67,98	59,19	21,47	66,94	63,02	68,44	62,22	20,75	66,94	65,50

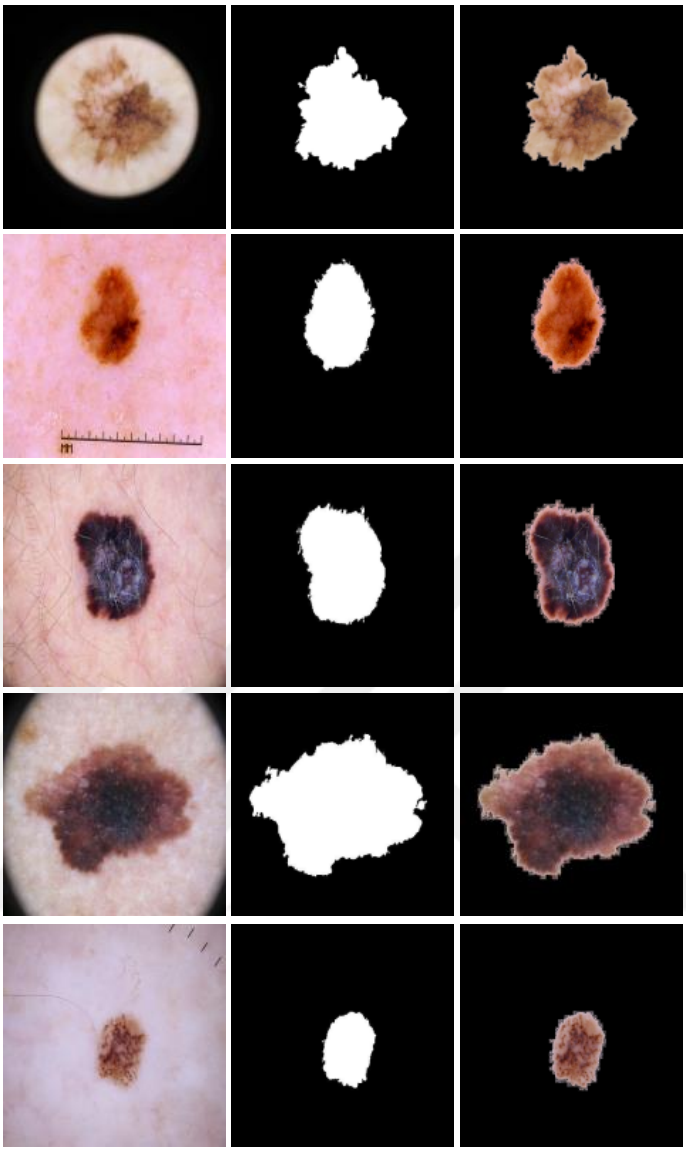

Şekil 2.4. Görüntü bölütleme işlemi: (a) orijinal RGB dermoskopik görüntüler (b) DeepLabv3+ tarafından elde edilen maskeler, (c) bölütlenmiş lezyonlar.

ve ResNet101 modelleri ise %75 civarında doğruluk oranlarıyla SVM ve kNN sınıflandırıcılarında iyi performans göstermiştir. Öte yandan, NB ve DA sınıflandırıcıları düşük doğruluk oranları ile zayıf sonuçlar üretmiştir. NB'nin genelde tüm modellerle düşük doğruluğa sahip olduğu gözlemlenmiş, SqueezeNet (%21,47) ve DarkNet19 (%24,97) modelleri ise en düşük performansla NB sınıflandırıcıda en başarısız modeller olmuştur. Bu durum, NB'nin veri dağılımını yeterince iyi öğrenememesi ve HAM10000 veri seti üzerindeki sınırlı uyumu nedeniyle ortaya çıkmış olabilmektedir. Veri artırımı olmadan en başarılı sonuçlar genelde SVM ve kNN sınıflandırıcılarında elde edilmiştir.

Veri artırımı uygulandıktan sonra doğruluk oranlarında genel bir artış gözlemlenmiştir. Özellikle kNN sınıflandırıcısı ile DarkNet53 (%90,67), InceptionResNetv2 (%90,66) ve NasNetLarge (%90,53) modelleri %90 üzerinde doğruluk oranlarına ulaşarak en iyi sonuçları sağlamıştır. Bu yüksek başarı oranları, veri artırmanın bu modellerin kNN ile birlikte sınıflandırma performansını önemli ölçüde artırdığını göstermektedir. Veri artırma uygulaması, verinin çeşitlenmesi sayesinde modellerin genel performansını artırmış, çoğu model kNN, SVM ve DA sınıflandırıcılarıyla veri artırma öncesine kıyasla daha yüksek doğruluk sağlamıştır. SqueezeNet ve DarkNet19, NB sınıflandırıcısı ile veri artırma uygulaması sonrasında da düşük doğruluk oranları göstermiştir. SqueezeNet %20,75, DarkNet19 ise %30,31 oranında doğruluk elde etmiştir. Bu durum NB'nin her iki modelle de zayıf performans sergilediğini ortaya koymaktadır. Veri artırımı uygulaması, VGG16 ile %89,07, Inceptionv3 ile %90,05 ve Xception ile %90,50 doğruluk oranları elde edilmesine olanak tanıyarak kNN ile genel performansın artmasına katkıda bulunmuştur.

NB sınıflandırıcısı ile DarkNet19 ve SqueezeNet modelleri incelendiğinde, veri artırımı uygulanmadan önceki modellerin doğruluk oranlarının oldukça düşük seviyelerde olduğu görülmektedir. DarkNet19 modeli %24,97 doğruluk oranına sahipken, SqueezeNet modeli için bu oran %21,47'dir. Bu değerler, her iki modelin de NB algoritması ile etkileşiminde sınırlı başarı sağladığını ve sınıflandırıcıya uygun öznitelik temsilleri üretemediğini göstermektedir. Veri artırımı uygulandıktan sonra, her iki modelde de NB sınıflandırıcısı için sınırlı bir iyileşme gerçekleşmiştir. DarkNet19 modeli doğruluk oranını %30,31'e çıkarırken, SqueezeNet modeli bu oranı %20,75 olarak korumuştur. Bu sonuçlar, veri artırmanın NB sınıflandırıcısı ile etkin bir şekilde genelleştirme yapamayan bu modellerde yalnızca kısmi iyileşmeler olduğunu göstermektedir. NB algoritması ile elde edilen bu doğruluk oranlarının veri artırımı öncesi ve sonrası arasında büyük bir fark olmaması, bu modellerin aşırı öğrenme eğilimi göstermediğini ifade etmektedir.

Veri artırmanın etkisi, özellikle yüksek performans gösteren kNN sınıflandırıcısında belirgin olarak gözlemlenmiştir. Veri artırımı, veri setinin farklı varyasyonlarını sağladığı için modellerin genelleme yeteneğini artırarak doğruluk oranlarını yükseltmiştir. Bununla birlikte, bazı modellerde NB sınıflandırıcısı düşük doğrulukta kalmaya devam etmiştir. Bu da NB'nin veri çeşitliliğine duyarlılığının sınırlı olabileceğini göstermektedir. Veri

artırma, kNN ve SVM gibi daha duyarlı sınıflandırıcılarla modellerin doğruluk oranlarını önemli ölçüde artırarak HAM10000 veri setindeki başarıyı olumlu yönde etkilemiştir. Değerlendirme sonrasında en yüksek başarım oranlarına kNN algoritması ile ulaşan DarkNet53, InceptionResNetv2 ve NasNetLarge modeli HAM10000 veri seti üzerinde gerçekleştireceğimiz hibrit modeli oluşturmak için seçilmiştir.

Farklı CNN modellerinin entegrasyonu, her bir modelin görüntüden kendine özgü bilgileri yakalayabilmesi nedeniyle yaygın bir yöntemdir. Bu birleşik öznitelik temsili, sınıflandırma sürecinde daha belirleyici hale gelebilmektedir. Önerilen hibrit model için, DarkNet53, InceptionResNetv2 ve NasNetLarge modellerinin tamamen bağlı katmanlarından elde edilen 1×1000 boyutundaki öznitelikler bir araya getirilerek 1×3000 boyutunda bir öznitelik vektörü oluşturulmuştur.

Öznitelik seçimi, model geliştirme sürecinde oldukça kritik bir aşama olarak öne çıkmaktadır. Bu sürecin iki temel amacı bulunmaktadır. İlk olarak, seçilen özniteliklerin sayısını azaltarak modelin hesaplama maliyetini düşürmek ve böylece modeli daha verimli bir hale getirmek amaçlanmaktadır. İkinci olarak, öznitelik seçimi ile modelin tahmin performansını artırmak ve daha doğru sonuçlar elde etmek mümkün hale gelmektedir. Bu bağlamda, başlangıçta 1×3000 boyutundaki geniş öznitelik vektöründe üç farklı öznitelik seçimi algoritması karşılaştırılmış ve bu algoritmalar yardımıyla, en anlamlı öznitelikleri içeren 1×1000 boyutunda bir öznitelik kümesi oluşturulmuştur.

Tablo 2.5'te, önerilen yaklaşımın HAM10000 veri seti üzerinde, kNN sınıflandırıcısı kullanılarak çeşitli öznitelik seçim algoritmaları ile veri artırımı olmadan ve veri artırımı ile yapılan sınıflandırma sonuçlarını göstermektedir.

Veri artırımı olmadan gerçekleştirilen sınıflandırma sonuçlarına göre, mRMR algoritması %73,10 doğruluk oranıyla en yüksek başarıyı göstermektedir. Bu algoritma ayrıca %46,88 kesinlik, %50,52 duyarlılık, %93,03 özgüllük ve %48,50 F1-skor elde etmiştir. mRMR algoritmasının diğer algoritmalardan daha yüksek doğruluk ve F1-skor sunması, öznitelik seçim sürecinde daha ayırt edici öznitelikleri seçebilme yeteneğini göstermektedir. Özgüllük değerlerinde tüm algoritmalar yüksek performans gösterse de, duyarlılık ve kesinlik oranları nispeten düşük kalmaktadır. Bu durum, veri setinin dengesiz sınıf dağılımı ve veri miktarının sınırlı olmasından kaynaklanabilmektedir.

Tablo 2.5. Önerilen yaklaşımın HAM10000 veri seti üzerinde kNN algoritması ile öznitelik seçim algoritmaları sınıflandırma sonuçları.

	Veri artırma uygulaması olmadan					**Veri artırma uygulaması ile**				
Algoritma	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**
ReliefF	72,30	44,48	49,83	92,63	46,97	93,24	84,98	**89,16**	98,14	86,96
mRMR	73,10	46,88	50,52	93,03	48,50	**93,63**	**89,07**	88,98	**98,33**	**87,26**
Fscchi2	72,57	46,58	50,32	92,85	48,24	90,81	85,68	84,81	97,44	81,77

ReliefF ve Fscchi2 algoritmalarına bakıldığında ise, sırasıyla %72,30 ve %72,57 doğruluk oranlarıyla mRMR algoritmasından biraz daha düşük performans sergilemektedirler. ReliefF algoritması %92,63 özgüllük ile güçlü bir negatif sınıf tanımlama yeteneği gösterirken, %44,48 kesinlik ve %49,83 duyarlılık değerleri ile pozitif sınıf belirlemede daha düşük başarı sergilemektedir. Fscchi2 algoritması, %46,58 kesinlik ve %50,32 duyarlılık oranıyla, özniteliklerin seçimi açısından genel performansı mRMR algoritmasına göre biraz daha düşük kalmıştır. Bu sonuçlar, veri artırımı yapılmadan, kNN algoritması ve öznitelik seçiminin tek başına sınıflandırma performansını artırmada yetersiz kalabileceğini göstermektedir.

Veri artırımı uygulandıktan sonra, sınıflandırma sonuçlarında belirgin bir iyileşme gözlemlenmiştir. mRMR algoritması veri artırımı sonrasında %93,63 doğruluk oranına ulaşarak en yüksek başarıyı elde etmiştir. mRMR algoritmasının veri artırımı ile birlikte %89,07 kesinlik, %88,98 duyarlılık, %98,33 özgüllük ve %87,26 F1-skor elde etmesi, bu algoritmanın yüksek doğrulukla birlikte dengeli bir kesinlik ve duyarlılık oranı sunduğunu göstermektedir. Özellikle özgüllük oranının %98,33 gibi yüksek bir seviyeye çıkması, bu yöntemin yanlış pozitif sayısının düşük olduğunu göstermektedir.

ReliefF algoritması veri artırımı sonrasında %93,24 doğruluk, %84,98 kesinlik, %89,16 duyarlılık, %98,14 özgüllük ve %86,96 F1-skor ile güçlü bir performans sergilemiştir. mRMR algoritmasına göre çok az bir farkla daha düşük başarı göstermesine rağmen, özellikle %89,16 duyarlılık oranıyla pozitif sınıf tanımlamada başarılı sonuçlar sunmaktadır. Bu durum, ReliefF algoritmasının veri artırımı sonrasında öznitelik seçiminde daha etkili hale geldiğini ve sınıflandırma başarısını önemli ölçüde artırdığını göstermektedir.

Fscchi2 algoritması da veri artırımı uygulandıktan sonra %90,81 doğruluk oranına ulaşmış ve diğer iki algoritmaya kıyasla daha düşük kalsa da yüksek doğruluk sağlamıştır. %85,68 kesinlik ve %97,44 özgüllük değerleri ile Fscchi2, yanlış pozitifleri tanımlamada etkili bir sonuç göstermektedir. Ancak %84,81 duyarlılık değeri, diğer algoritmaların duyarlılık oranlarına kıyasla daha düşük kalmaktadır. Bu durum veri artırımı sonrası dahi diğer algoritmalara göre daha düşük bir başarı sergilediğini göstermektedir.

Veri artırımı uygulaması, tüm öznitelik seçim algoritmalarında sınıflandırma performansını kayda değer ölçüde artırmıştır. Özellikle, mRMR algoritması veri artırımı sonrasında en yüksek doğruluk oranlarına ulaşmış ve dengeli bir kesinlik-duyarlılık performansı sağlamıştır. Bu sonuçlar, veri artırma tekniklerinin sınıflandırma başarısını iyileştirici etkisini ve sınıf dengesizliğinden kaynaklanan olası hataları azaltmada önemli bir rol oynadığını ortaya koymaktadır.

Tablo 2.6'da, HAM10000 veri setinde tekil modeller olan DarkNet53, InceptionResNetv2, NasNetLarge ve önerilen yöntemle gerçekleştirilen sınıflandırma sonuçları karşılaştırılmaktadır. DarkNet53 modelinin sonuçları incelendiğinde, AK sınıfı için %70,41 kesinlik, %75,55 duyarlılık, %99,24 özgüllük ve %72,89 F1-skoru elde edilmiştir. BCC sınıfında ise kesinlik %74,09, duyarlılık %82,86, özgüllük %99,17 ve F1-skoru %78,23 olarak kaydedilmiştir. BKL, DF, NV, MEL ve VASC sınıflarında da benzer şekilde performans değerleri sıralanmıştır. Özellikle NV sınıfında %99,09 kesinlik ve %96,45 F1-skoru dikkat çekmektedir. Ancak genel olarak DarkNet53, özgüllük açısından oldukça yüksek değerlere sahipken, diğer metriklerdeki performansı sınırlı kalmaktadır.

InceptionResNetv2 modelinin performansı, çoğunlukla DarkNet53 modeli ile benzer sonuçlar ortaya koymaktadır. AK sınıfındaki kesinlik %67,35, duyarlılık %70,97, özgüllük %99,08 ve F1-skoru %69,11 olarak kaydedilmiştir. BCC sınıfındaki kesinlik %75,81, duyarlılık %84,38, özgüllük %99,24 ve F1-skoru %79,87'dir. NV sınıfında ise %98,56 kesinlik oranı, %94,37 duyarlılık ve %96,42 F1-skoru ile oldukça etkili bir performans sergilenmiştir. Ancak, genel olarak, InceptionResNetv2 mimarisinin bazı sınıflarda daha düşük duyarlılık değerlerine sahip olduğu gözlemlenmiştir.

NasNetLarge modelinin sonuçları, diğer iki modelle paralellik göstermektedir. AK sınıfında %69,73 kesinlik, %76,21 duyarlılık, %99,27 özgüllük ve %72,83 F1-skoru elde edilmiştir. BCC sınıfındaki değerler %74,30 kesinlik, %82,30 duyarlılık, %99,14 özgüllük ve %78,10 F1-skoru olarak belirlenmiştir. Özellikle NV sınıfındaki %98,61 kesinlik ve %96,42 F1-skoru yüksek performans olarak karşımıza çıkmaktadır. Ancak diğer sınıflardaki performansları, DarkNet53 ve InceptionResNetv2 modellerine göre daha düşük kalmıştır.

Tablo 2.6. Önerilen yaklaşımın HAM10000 veri setinde tekil DarkNet53, InceptionResNetv2 ve NasNetLarge modelleriyle karşılaştırılması.

Modeller	**Sınıf İsmi**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**
DarkNet53	AK	70,41	75,55	99,24	72,89
	BCC	74,09	82,86	99,17	78,23
	BKL	72,60	83,40	98,22	77,63
	DF	76,93	83,34	99,83	80,00
	MEL	73,46	83,07	98,13	77,97
	NV	99,09	93,94	87,05	96,45
	VASC	85,94	93,23	99,91	89,44
	ORT	78,94	85,06	97,37	81,81
InceptionResNetv2	AK	67,35	70,97	99,08	69,11
	BCC	75,81	84,38	99,24	79,87
	BKL	75,94	82,26	97,99	78,97
	DF	70,20	83,91	99,85	76,44
	MEL	74,66	82,84	98,07	78,54
	NV	98,56	94,37	88,09	96,42
	VASC	81,25	91,23	99,89	85,96
	ORT	77,69	84,28	97,46	80,76
NasNetLarge	AK	69,73	76,21	99,27	72,83
	BCC	74,30	82,30	99,14	78,10
	BKL	73,92	82,23	98,04	77,85
	DF	70,20	80,22	99,80	74,88
	MEL	75,15	81,41	97,86	78,16
	NV	98,61	94,33	87,99	96,42
	VASC	81,25	91,23	99,89	85,96
	ORT	77,60	83,99	97,43	80,60
Önerilen Yöntem	AK	75,18	81,25	99,42	78,10
	BCC	83,81	88,59	99,42	86,13
	BKL	81,60	88,30	98,67	84,82
	DF	84,62	83,81	99,81	84,22
	MEL	83,14	86,96	98,44	85,00
	NV	99,19	96,44	92,59	97,80
	VASC	92,19	97,53	99,97	94,78
	ORT	**85,68**	**88,99**	**98,34**	**87,27**

Önerilen yöntemin sonuçları ise dikkat çekici bir şekilde tüm modellerden daha iyi performans göstermektedir. AK sınıfında %75,18 kesinlik, %81,25 duyarlılık, %99,42 özgüllük ve %78,10 F1-skoru elde edilmiştir. BCC sınıfındaki kesinlik %83,81, duyarlılık %88,59, özgüllük %99,42 ve F1-skoru %86,13 olarak kaydedilmiştir. En başarılı skorlardan birini elde eden VASC sınıfında %92,19 kesinlik ve %94,78 F1-skoru, önerilen yöntemin etkinliğini ortaya koymaktadır. Önerilen yöntemde en yüksek skoru NV sınıf elde etmiştir. %99,19 kesinlik, %96,44 duyarlılık, %92,59 özgüllük ve %97,80 F1-skoru ile tüm tekil CNN modellerinde daha üstün bir başarı sergilemiştir.

Değerlendirmeler önerilen yöntemin, DarkNet53, InceptionResNetv2 ve NasNetLarge modellerine göre, genel sınıflandırma performansında belirgin bir iyileşme sağlamıştır. Bu bulgular, önerilen yaklaşımın HAM10000 veri setinde cilt kanseri lezyonlarının sınıflandırılması için etkili bir yöntem olduğunu açıkça göstermektedir.

Şekil 2.5'te karışıklık matrisleri verilen modellerden üzerinden karşılaştırmalı analiz yapıldığında, Darknet53 modeli için, NV sınıfı en yüksek başarıyı göstermektedir. Bu sınıf için TP değeri 5.979 ve FP değeri 55 olarak kaydedilmiştir. Yüksek TP değeri, modelin bu sınıfı doğru bir şekilde ayırt etme kapasitesinin oldukça yüksek olduğunu göstermektedir. Bu durum, NV lezyonlarının belirgin özniteliklerinin, modelin bu sınıfı tanımasında etkili olduğunu ortaya koymaktadır. Diğer taraftan modelin en düşük başarıya sahip olduğu AK sınıfında TP değeri 207, FP değeri ise 87'dir. Bu sonuç, modelin AK sınıfına ait lezyonları tanımada zayıf bir performans sergilediğini ve yüksek FP değerinin, bu sınıfa ait lezyonların yanlışlıkla diğer sınıflara atama eğiliminde olduğunu göstermektedir. Bu sonuç, AK sınıfına ait görüntü özniteliklerinin diğer sınıflarla benzerlik göstermesi nedeniyle ortaya çıkabilmektedir. BKL sınıfı için TP değeri 718 ve FP değeri 271 olarak belirlenmiştir. BKL lezyonlarının diğer sınıflara benzerlik göstermesi, modelin yanlış sınıflandırma olasılığını artırmaktadır.

İkinci olarak, NasNetLarge modeli incelendiğinde, yine NV sınıfında en yüksek başarı elde edilmiştir. NV için TP değeri 5.950, FP değeri ise 84 olarak kaydedilmiştir. Bu yüksek başarı, NV lezyonlarının belirgin öznitelikleri sayesinde modelin bu sınıfı etkili bir şekilde tanımasını sağlamaktadır. AK sınıfı ise modelin en düşük başarıya sahip olduğu sınıf olup, TP değeri 205 ve FP değeri 89 olarak belirlenmiştir. Modelin bu

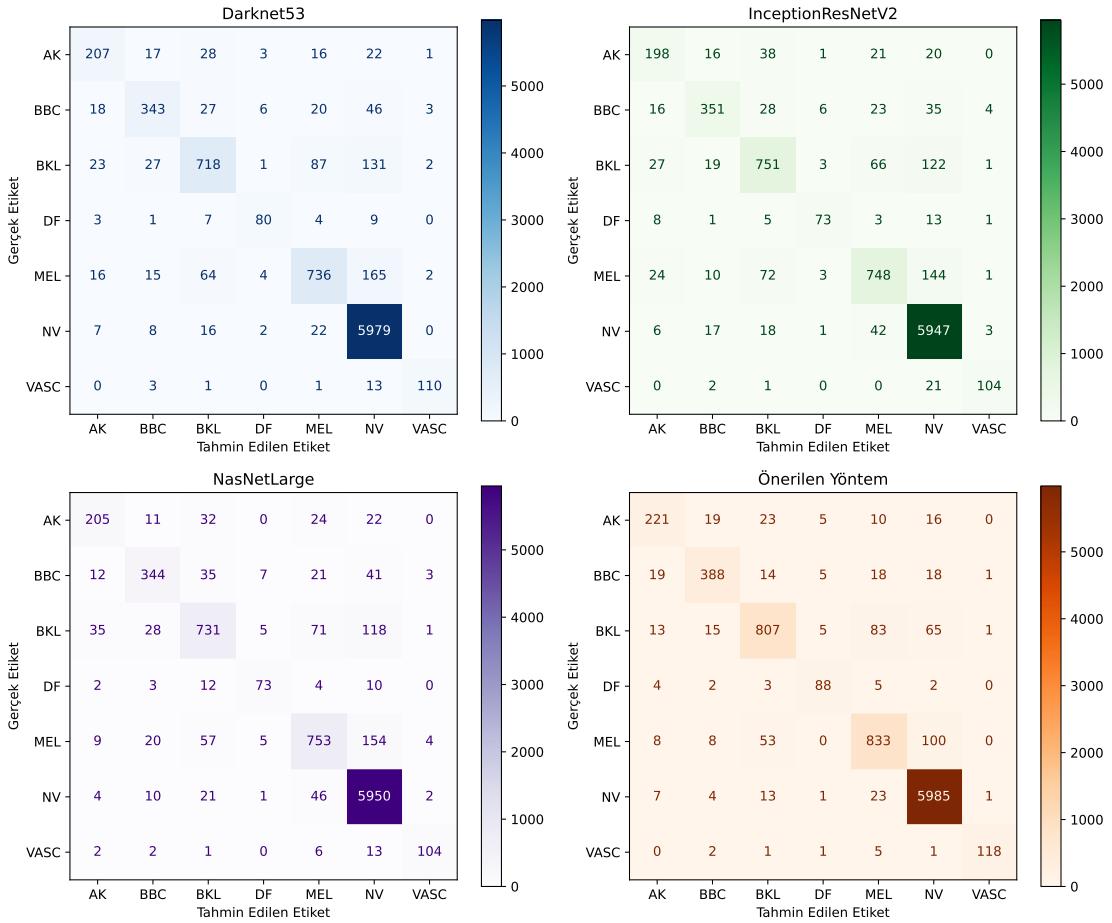

Şekil 2.5. DarkNet53, InceptionResNetv2, NasNetLarge ve önerilen yöntemin karışıklık matrisleri.

sınıfı tanımada gösterdiği zayıflık, diğer sınıflara ait lezyonlarla karıştırma olasılığını artırmaktadır. BKL sınıfı için TP değeri 731, FP değeri 258 olarak kaydedilmiştir. Bu sınıfın öznitelikleri, diğer sınıflarla karıştırılma olasılığını artırmakta ve bu durum modelin yanlış sınıflandırma yapmasına neden olmaktadır.

InceptionResNetv2 modeli NV sınıfında en yüksek başarıyı göstermektedir. NV için TP sayısı 5.947, yanlış sınıflandırılmış görüntü sayısı ise 87'dir. Bu yüksek TP, modelin bu sınıfı başarıyla tanıdığını ve doğruluğunun oldukça yüksek olduğunu göstermektedir. AK sınıfı için TP değeri 198, FP değeri 96 olarak belirlenmiştir. Modelin AK sınıfını tanıma konusundaki zayıflığı, yanlış teşhis olasılığını artırmakta ve bu durum klinik sonuçları olumsuz etkileyebilmektedir. VASC sınıfında ise TP değeri 104, FP değeri 24 olarak kaydedilmiştir. Bu durum, modelin VASC lezyonlarını tanımadaki yeterliliğinin olumlu olduğunu ancak bazı yanlış sınıflandırmalara yol açabileceğini göstermektedir.

Son olarak, önerilen yöntem değerlendirildiğinde, NV sınıfı yine en yüksek başarıyı göstermektedir. NV için TP değeri 5.985 ve FP değeri 49'dur. Yüksek TP, modelin bu sınıfı doğru bir şekilde tanıma yeteneğinin oldukça güçlü olduğunu ortaya koymaktadır. AK sınıfı için TP değeri 221 ve FP değeri 73'tür. Bu durum, modelin bu sınıfı tanımada zayıf olduğunu ve diğer sınıflarla karıştırma olasılığının yüksek olduğunu göstermektedir. MEL sınıfında ise TP değeri 833, FP değeri 169 olarak kaydedilmiştir. MEL lezyonlarının özniteliklerinin diğer sınıflarla benzerlik göstermesi, yanlış sınıflandırmalara neden olmaktadır.

Değerlendirmeler sonucunda, tüm modellerde NV sınıfındaki yüksek TP değerleri güçlü bir performansı işaret ederken, AK sınıfındaki düşük TP ve yüksek FP değerleri iyileştirilmesi gereken alanları göstermektedir. Bu analizler, cilt kanseri gibi kritik sağlık alanlarında, erken teşhis ve tedavi süreçlerinin iyileştirilmesine yönelik önemli bilgiler sağlamaktadır.

Önerilen modelin cilt kanseri sınıflarının ayırt etme performansı, ROC eğrisi analizi kullanılarak değerlendirilmiştir. Şekil 2.6'da görülen grafikten de anlaşılacağı üzere modelin sınıflandırma performansı, cilt kanseri türleri arasında önemli farklılıklar göstermektedir. Elde edilen AUC değerlerine göre en yüksek performans, VASC ve NV sınıflarında elde edilmiştir. Modeller sırasıyla 0,9608 ve 0,9589 AUC değeri göstermişlerdir. Bu yüksek AUC değerleri, modelin VASC ve NV sınıflarını başarılı bir şekilde tanıyabildiğini ve bu lezyonları ayırt etmede güçlü bir doğruluk sergilediğini göstermektedir.

DF ve BCC sınıfları sırasıyla 0,9221 ve 0,9161 AUC değerleri alarak en iyi performans gösterilen sınıfları takip etmektedir. Bu durum, modelin bu kanser türlerinin özniteliklerini doğru şekilde yakalayabilmesine rağmen, diğer sınıflara göre daha fazla zorlandığını göstermektedir.

Diğer taraftan, MEL sınıfı 0,9079 ve BKL sınıfı 0,9013 AUC değerleri ile, modelin bu lezyonları ayırt etme konusunda orta seviyede bir başarı gösterdiğini ortaya koymaktadır. Bu sınıfların ayırt edilmesinde yaşanan zorlukların, diğer cilt kanseri türleri ile olan benzerliklerden kaynaklanmaktadır.

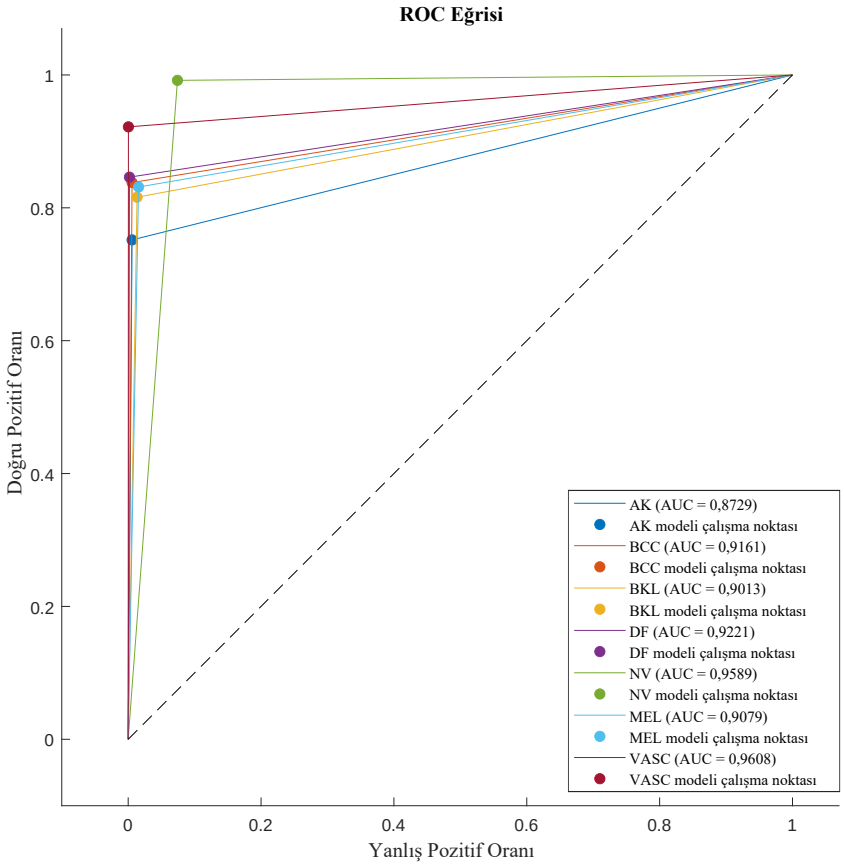

Şekil 2.6. HAM10000 veri seti için önerilen modelin tüm sınıflarının ROC eğrileri.

Geliştirilen model en düşük sınıflandırma performansını AK sınıfında 0,8729 AUC değeri alarak göstermiştir. Modelin bu sınıfı tanıma konusundaki performansının diğer sınıflara kıyasla daha düşük olduğunu anlaşılmaktadır.

2.5.2. ISIC 2019 Veri Seti için Deney Sonuçları

ISIC 2019 veri seti kullanılarak yapılan deney sonuçlarını gösteren Tablo 2.7 incelendiğinde, veri artırma uygulanmadan yapılan değerlendirmelerde CNN modelleri arasında en yüksek doğruluğu EfficientNetb0 ve ResNet101 modelleri sağlamıştır. EfficientNetb0 modelinde SVM sınıflandırıcısı ile %67,61, kNN sınıflandırıcısı ile %65,71 doğruluk oranlarına ulaşılmıştır. ResNet101 modelinde ise SVM ile %67,57 ve kNN ile %63,65 doğruluk elde edilmiştir. NB ve DA sınıflandırıcıları ise genel olarak düşük performans göstermiştir. Özellikle NB, modellerin çoğunda %40'ın altında doğruluk oranlarıyla zayıf sonuçlar vermiştir. VGG16 ve VGG19 modelleri kNN

sınıflandırıcısı ile sırasıyla %61,77 ve %61,03 oranında doğruluğa ulaşmış, fakat diğer sınıflandırıcılarla daha düşük sonuçlar vermiştir.

Veri artırma uygulaması sonrasında tüm modellerin doğruluk oranlarının belirgin bir şekilde yükseldiği görülmektedir. DenseNet201, EfficientNetb0 ve MobileNetv2 modelleri kNN sınıflandırıcısı ile %90 oranının üzerine çıkmayı başarmıştır. EfficientNetb0 modelinde kNN ile %93,30 doğruluk oranı elde edilerek veri artırmanın bu model için çok etkili olduğu görülmüştür. DenseNet201 modelinde kNN %91,59 doğruluğa ulaşmış, MobileNetv2 modelinde ise yine kNN sınıflandırma algoritması ile %90,36 doğruluk sağlamıştır. Veri artırma işleminin, özellikle kNN ve SVM sınıflandırıcılarının performansını önemli ölçüde artırdığı belirgin bir şekilde görülmektedir. Bununla birlikte, NB sınıflandırıcısı veri artırımına rağmen çoğu modelde %50'nin altında kalarak düşük doğruluk oranlarını sürdürmüştür. DA ve DT sınıflandırıcıları da veri artırımından olumlu etkilenmiş fakat kNN ve SVM kadar yüksek performans artışı gösterememiştir.

Veri artırma, özellikle kNN ve SVM gibi sınıflandırıcılarda doğruluk oranlarını yükseltmiş ve EfficientNetb0, DenseNet201 ile MobileNetv2 gibi modellerin ISIC 2019 veri setindeki genelleme performansını önemli ölçüde artırmıştır. NB sınıflandırıcısı veri artırmadan sınırlı şekilde faydalanırken, kNN ve SVM, veri artırma ile %90 ve üzeri doğruluk oranlarına ulaşarak en yüksek başarıyı elde etmiştir.

Elde edilen sonuçlar neticesinde, EfficientNetb0, DenseNet201 ve MobileNetv2 yöntemimizde kullanacağımız CNN modelleri olarak seçilmiştir. Ayrıca, sınıflandırma işlemi için, yüksek performansıyla öne çıkan kNN algoritması tercih edilmiştir. Bu modellerin başarısı, bilgi akışını optimize eden ve öznitelik öğrenme yeteneklerini artıran çoklu yol mimarileri sayesinde açıklanabilmektedir. Ayrıca, EfficientNetb0 ölçekleme stratejileri kullanırken, DenseNet201 yoğun bağlantılı bir yapıya sahip ve MobileNetv2, verimli derinlik ayrılmış evrişimler kullanmaktadır. Bu faktörler, modellerin güçlü performanslarına katkıda bulunmaktadır. Bu modeller, hibrit bir yaklaşımda birleştirildiğinde, tamamlayıcı güçlü yönlerini kullanarak sağlam ve etkili bir öznitelik çıkarım hattı oluşturabilirler.

Tablo 2.7. Farklı öznitelik sınıflandırıcılar açısından karşılaştırılan CNN modellerinin ISIC 2019 veri seti üzerindeki doğruluk oranları.

	Veri artırma uygulaması olmadan					Veri artırma uygulaması ile				
CNN Modelleri	**SVM (%)**	**kNN (%)**	**NB (%)**	**DA (%)**	**DT (%)**	**SVM (%)**	**kNN (%)**	**NB (%)**	**DA (%)**	**DT (%)**
EfficientNetb0	67,61	65,71	41,89	41,89	51,03	74,12	**93,30**	42,82	69,58	58,70
DenseNet201	64,56	64,53	41,44	41,43	50,02	57,37	**91,59**	42,03	69,28	58,15
MobileNetv2	63,02	62,19	39,58	39,58	48,27	68,67	**90,36**	39,88	66,54	54,40
ResNet50	66,30	63,00	41,23	41,23	51,66	71,91	90,26	41,99	69,51	58,67
ResNet101	67,57	63,65	43,86	43,86	50,24	71,40	90,12	44,58	70,06	59,99
VGG16	57,23	61,77	34,61	34,61	49,77	66,03	89,94	32,97	66,98	59,88
Xception	63,76	60,32	39,66	39,66	48,41	69,99	89,85	40,63	65,77	55,02
ResNet18	64,85	62,26	39,32	39,32	49,74	61,34	89,63	40,16	67,43	57,86
VGG19	55,89	61,03	29,83	29,83	48,68	54,72	89,10	28,29	63,85	59,44
InceptionResNetv2	66,51	59,32	36,99	36,99	49,16	72,01	88,68	38,21	67,13	57,76
NasNetLarge	64,52	57,90	38,07	38,07	48,18	70,64	88,68	38,35	66,32	57,35
ShuffleNet	65,98	62,85	39,29	39,29	50,88	60,40	88,56	40,23	66,98	57,60
Inceptionv3	62,69	59,18	37,11	37,10	46,78	69,17	88,49	38,45	66,50	52,78
AlexNet	61,92	58,89	31,56	63,43	49,52	56,89	86,86	32,23	65,86	57,00
GoogleNet	62,48	57,69	33,54	33,54	47,55	56,83	86,11	32,97	64,37	53,90
NasNetMobile	63,43	55,85	33,94	39,94	47,84	68,45	84,33	34,60	64,84	54,79
DarkNet53	65,44	60,02	42,87	42,86	42,43	69,32	77,47	44,33	67,90	50,87
SqueezeNet	51,20	44,32	16,29	50,82	47,56	53,35	50,28	16,36	50,72	52,81
DarkNet19	51,78	43,52	18,45	50,82	47,16	52,31	47,55	19,50	50,72	50,33

Öznitelik birleştirme aşamasında, modelimiz için seçilen MobileNetv2, EfficientNetb0 ve DenseNet201 DL ağlarının tamamen bağlı katmanlarından alınan 1 × 1000 öznitelikleri birleştirerek, 1 × 3000 boyutunda bir vektör elde edilmiştir.

Öznitelik birleştirme işleminden sonra, üç öznitelik seçimi algoritmasının performansları karşılaştırarak, en önemli öznitelikleri barındıran 1 × 1000 boyutunda bir öznitelik vektörü elde edilmiştir. Tablo 2.8'de, ISIC 2019 veri seti üzerinde kNN sınıflandırıcısı kullanarak farklı öznitelik seçim algoritmalarının performansları karşılaştırılmaktadır. Bu değerlendirme, hem veri artırma uygulanmadan hem de veri artırma uygulandıktan sonraki sonuçları içermektedir. Her iki durumda da öznitelik seçim algoritmalarının sınıflandırma sonuçları, doğruluk, kesinlik, duyarlılık, özgüllük ve F1-skor gibi performans metrikleriyle ölçülmüştür.

Veri artırma uygulanmadan önce elde edilen sonuçlar, ReliefF algoritmasının %69,11 doğruluk oranıyla en yüksek performansı sergilediğini göstermektedir. Bu algoritmanın kesinlik, duyarlılık, özgüllük ve F1-skor değerleri sırasıyla %52,30, %56,07, %94,57 ve %53,77 olarak tespit edilmiştir. Özellikle özgüllük değerinin yüksek olması, modelin negatif sınıfları doğru bir şekilde tanıma yeteneğini vurgulamaktadır. Bununla birlikte, diğer metriklerde görülen daha düşük değerler, modelin olumlu sınıfları tanımada daha az etkili olduğunu ortaya koymaktadır.

mRMR algoritması ise, %68,61 doğruluk oranıyla ReliefF algoritmasının ardından gelmektedir. Kesinlik ve duyarlılık değerleri sırasıyla %51,34 ve %57,73 olarak belirlenmiştir. Özgüllük değeri %94,54 iken F1-skoru %52,65 olarak kaydedilmiştir. Bu sonuçlar, mRMR algoritmasının özgüllük açısından başarılı olduğunu, ancak diğer performans metriklerinde sınırlı kaldığını göstermektedir. Bu durum, mRMR algoritmasının belirli durumlarda etkili bir öznitelik seçimi sağlasa da, genel sınıflandırma performansını yeterince artırmadığını göstermektedir.

Fscchi2 algoritması ise veri artırma olmadan yapılan sınıflandırmada en düşük doğruluk oranı olan %64,64 ile performans göstermiştir. Kesinlik %46,39, duyarlılık %48,81, özgüllük %93,71 ve F1-skoru %47,31 olarak ölçülmüştür. Bu sonuç, Fscchi2 algoritmasının öznitelik seçiminde beklenen etkinliği gösteremediğini ve genel olarak sınıflandırma başarısını artırmada sınırlı kaldığını göstermektedir.

Tablo 2.8. Önerilen yaklaşımın ISIC 2019 veri seti üzerinde kNN algoritması ile öznitelik seçim algoritmaları sınıflandırma sonuçları.

	Veri artırma uygulaması olmadan					**Veri artırma uygulaması ile**				
Algoritma	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık (%)**	**Özgüllük(%)**	**F1-skor(%)**
ReliefF	69,11	52,30	56,07	94,57	53,77	**94,42**	**94,13**	**93,00**	**98,96**	**93,50**
mRMR	68,61	51,34	57,73	94,54	52,65	83,93	78,80	78,72	97,11	78,68
Fscchi2	64,64	46,39	48,81	93,71	47,31	93,34	92,77	91,51	98,76	92,06

Veri artırma uygulaması sonrası elde edilen sonuçlar dikkat çekicidir. ReliefF algoritması, %94,42 doğruluk oranına ulaşarak önceki performansına göre büyük bir iyileşme göstermiştir. Kesinlik %94,13, duyarlılık %93,00, özgüllük %98,96 ve F1-skoru %93,50 olarak kaydedilmiştir. Bu bulgular, ReliefF algoritmasının veri artırma uygulaması ile birlikte önemli bir performans artışı sağladığını ve olumlu sınıfları tanımadaki etkinliğini artırdığını göstermektedir.

ReliefF algoritmasından sonra en yüksek performans gösteren Fscchi2 algoritması, veri artırma işleminden sonra %93,34 doğruluk oranına ulaşmıştır. Ayrıca, %92,77 kesinlik, %91,51 duyarlılık, %98,76 özgüllük ve %92,06 F1-skor değerleriyle başarılı bir performans göstermiştir.

mRMR algoritması ise veri artırma sonrası %83,93 doğruluk oranına ulaşmıştır. Kesinlik değeri %78,80, duyarlılık %78,72, özgüllük %97,11 ve F1-skoru %78,68 olarak belirlenmiştir. Bu sonuçlar, mRMR algoritmasının veri artırma uygulamasıyla birlikte performansında bir iyileşme yaşadığını, ancak ReliefF ve Fscchi2 algoritmaları ile karşılaştırıldığında daha düşük bir başarı gösterdiğini ortaya koymaktadır.

Veri artırma uygulaması ile birlikte ReliefF algoritması, ISIC 2019 veri setinde en yüksek performansı göstererek kNN sınıflandırıcısı için etkili bir öznitelik seçim yöntemi olduğunu kanıtlamıştır. ReliefF algoritmasının üstün performansı birkaç faktöre bağlanabilmektedir. Cilt lezyonlarının tipik olarak karmaşık ve ayrıntılı görsel örüntüleri, detaylı öznitelik ilişkilerini yakalayabilen bir öznitelik seçimi yöntemini gerektirmektedir. ReliefF algoritmasının öznitelik etkileşimlerini dikkate alma yeteneği ve dengesiz veri kümelerine uyum sağlama potansiyeli, bu görev için yüksek bir performans göstermektedir. Öte yandan, mRMR ve Fscchi2 algoritmalarının performansları, özellikle özgüllük ve doğruluk açısından daha zayıf kalmıştır. Bu bulgular, öznitelik seçim algoritmalarının performansının, veri artırma teknikleriyle önemli ölçüde iyileştirilebileceğini göstermektedir.

Tablo 2.9, önerilen yaklaşımın ISIC 2019 veri setinde tekil MobileNetv2, EfficientNetb0 ve DenseNet201 modelleriyle karşılaştırılmasını sunmaktadır. Bu tabloda her bir modelin sınıf isimlerine göre performans metrikleri detaylı bir şekilde yer almakta olup, kesinlik, duyarlılık, özgüllük ve F1-skoru gibi kritik değerlere odaklanılmıştır.

Tablo 2.9. Önerilen yaklaşımın ISIC 2019 veri setinde tekil MobileNetv2, EfficientNetb0 ve DenseNet201 modelleriyle karşılaştırılması.

Modeller	**Sınıf İsmi**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**
MobileNetv2	AK	84,91	84,91	99,47	84,91
	BCC	81,31	88,84	98,48	84,91
	BKL	90,31	85,68	98,26	87,94
	DF	95,69	86,21	99,85	90,70
	NV	97,60	92,18	91,48	94,82
	MEL	76,49	90,77	98,27	83,02
	SCC	90,52	82,95	99,52	86,57
	VASC	95,87	88,19	99,87	91,87
	ORT	89,09	87,47	98,15	88,09
EfficientNetb0	AK	91,72	89,11	99,61	90,39
	BCC	89,93	92,17	98,86	91,03
	BKL	93,54	89,33	98,71	91,39
	DF	96,65	90,18	99,90	93,30
	NV	98,14	95,02	94,71	96,56
	MEL	82,24	93,39	98,71	87,46
	SCC	90,52	86,05	99,62	88,23
	VASC	99,54	96,02	99,96	97,75
	ORT	92,79	91,41	98,76	92,01
DenseNet201	AK	89,19	81,86	99,31	85,37
	BCC	83,50	90,82	98,74	87,01
	BKL	93,06	86,78	98,37	89,81
	DF	94,26	91,20	99,91	92,71
	NV	97,79	93,60	93,12	95,65
	MEL	79,34	91,78	98,42	85,11
	SCC	89,98	85,84	99,62	87,86
	VASC	99,54	96,02	99,96	97,75
	ORT	90,83	89,74	98,43	90,16
Önerilen Yöntem	AK	93,72	87,64	99,54	90,58
	BCC	92,08	93,51	99,05	92,79
	BKL	94,85	91,31	98,96	93,05
	DF	97,13	91,44	99,91	94,20
	NV	98,42	95,73	95,48	97,05
	MEL	84,72	95,00	99,01	89,56
	SCC	92,13	91,15	99,77	91,64
	VASC	100,00	98,20	99,98	99,09
	ORT	**94,13**	**93,00**	**98,96**	**93,50**

Öncelikle MobileNetv2 modeli AK sınıfında %84,91'lik kesinlik oranı ile dikkat çekmektedir. Duyarlılığı ise %84,91 olarak kaydedilmiş. Bu da modelin pozitif sınıfları ne derece iyi tespit edebildiğini göstermektedir. Özgüllük değeri %99,47 ile oldukça yüksek olup, bu durum modelin negatif sınıfları doğru bir şekilde sınıflandırma yeteneğini yansıtmaktadır. F1-skoru %84,91 olarak hesaplanmış, bu da modelin genel performansını destekleyen bir metrik olarak önem kazanmaktadır. Öte yandan, MobileNetv2 mimarisinin performansı ortalama değerler açısından değerlendirdiğinde, DF, NV, ve VASC sınıfları için yüksek başarılar elde ettiği görülmektedir.

EfficientNetb0 modeli ise genel performans açısından dikkat çekici sonuçlar sergilemektedir. AK sınıfı için %91,72'lik bir kesinlik oranı ile bu model, duyarlılık ve özgüllük değerleri ile de öne çıkmaktadır. Özellikle NV sınıfında %98,14'lük bir kesinlik ve %95,02'lik bir duyarlılık ile modelin başarısını ortaya koymaktadır. F1-skoru ise %96,56'ya ulaşarak, modelin hem pozitif hem de negatif sınıflarda dengeli bir performans gösterdiğini göstermektedir.

DenseNet201 modeli%90,83'lük bir ortalama kesinlik değeri sunmaktadır. Ortalama duyarlılık değeri %89,74 olarak belirlenmişken, özgüllüğü %98,43 seviyesindedir. Bu modelin VASC sınıfında %99,54'lük yüksek bir kesinlik sunması, dikkat çekicidir. F1-skoru ise 97,75 ile etkileyici bir sonuç elde etmiştir. Genel olarak, DenseNet201 mimarisinin iyi bir denge sağladığı ve çeşitli sınıflarda tutarlı bir performans sergilediği söylenebilir.

Önerilen yöntemin performansı ise tüm modeller arasında en yüksek değerleri göstermektedir. Önerilen yöntemin DF sınıfında %97,13, NV sınıfında %98,42 ve VASC sınıfında %100,00 kesinlik oranı elde etmesi, bu yöntemin genel olarak oldukça etkili olduğunu ortaya koymaktadır. Ortalama değerlere baktığımızda ise %94,13'lük bir kesinlik, %93,00'lük bir duyarlılık ve %93,50'lik bir F1-skoru ile en yüksek başarıyı temsil etmektedir. Bu sonuçlar, önerilen yaklaşımın tekil modellerle karşılaştırıldığında belirgin bir üstünlük sağladığını göstermektedir ve bu da daha ileri düzeyde araştırmalara zemin hazırlamaktadır.

Şekil 2.7'de, MobileNetv2, EfficientNetb0 ve DenseNet201 modellerinin yanı sıra önerilen yaklaşımımızın karışıklık matrisleri yer almaktadır. İlk olarak, MobileNetv2

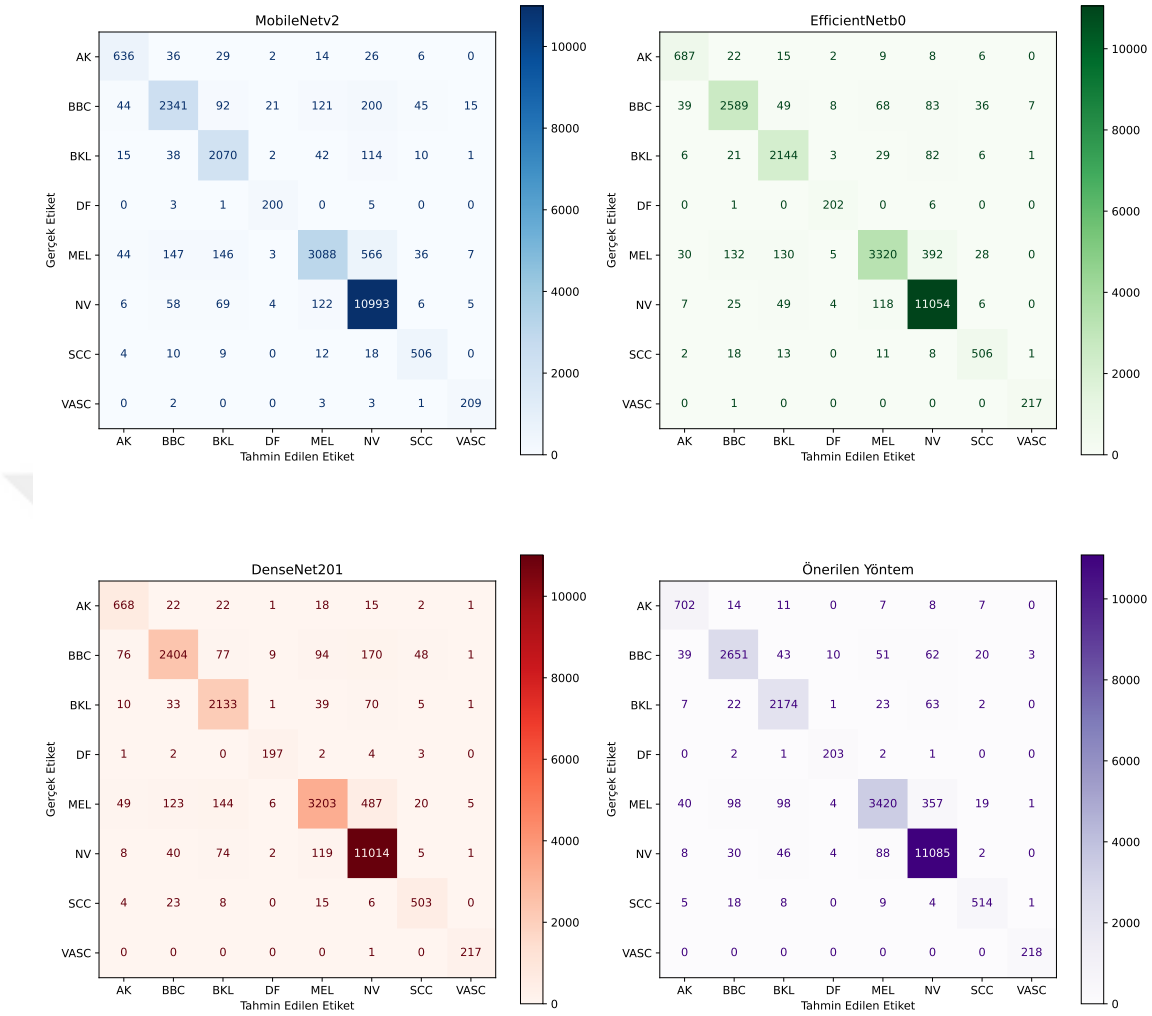

Şekil 2.7. MobileNetv2, EfficientNetb0, DenseNet201 ve önerilen hibrit yaklaşımın karışıklık matrisleri.

modeli değerlendirildiğinde, NV sınıfında en yüksek başarıyı göstermektedir. NV için TP değeri 10.993, FP değeri ise 270 olarak kaydedilmiştir. Bu yüksek TP değeri, modelin bu sınıfı doğru bir şekilde tanıma yeteneğinin oldukça güçlü olduğunu göstermektedir. Diğer taraftan, modelin en düşük başarıya sahip olduğu AK sınıfında TP değeri 636, FP değeri ise 113'tür. Bu durum, modelin AK sınıfını tanımada zayıf bir performans sergilediğini ve yüksek FP değerinin bu sınıfa ait lezyonların yanlışlıkla diğer sınıflara atama eğiliminde olduğunu göstermektedir. MEL sınıfı için TP değeri 3.088, FP değeri 946 olarak belirlenmiştir. MEL sınıfının tanınmasında genel bir başarı sağlansa da, FP değerinin yüksek olması yanlış sınıflandırma olasılığını artırmaktadır.

EfficientNetb0 modeli incelendiğinde, NV sınıfında yine en yüksek başarı sergilenmektedir. NV için TP değeri 11.054, FP değeri ise 209 olarak kaydedilmiştir. Bu yüksek başarı, NV lezyonlarının belirgin özellikleri sayesinde modelin bu sınıfı etkili bir şekilde tanımasını sağlamaktadır. Model MEL sınıfında ise en düşük başarıya sahip olup, TP değeri 3.320 ve FP değeri 717 olarak belirlenmiştir. Modelin bu sınıfı tanımada gösterdiği zayıflık, diğer sınıflara ait lezyonlarla karıştırma olasılığını artırmaktadır. SCC sınıfı için TP değeri 506, FP değeri 53 olarak kaydedilmiştir. Bu durum, modelin SCC sınıfını tanımada genel bir yeterlilik gösterdiğini ancak FP değerinin oldukça yüksek olduğunu ve bu sınıfa ait lezyonların yanlış sınıflandırma olasılığını artırdığını göstermektedir.

DenseNet201 modeli NV sınıfında en yüksek başarıyı göstermektedir. NV için TP değeri 11.014, FP değeri ise 249'dur. Yüksek TP, modelin bu sınıfı başarıyla tanıdığını ve doğruluğunun oldukça yüksek olduğunu göstermektedir. BCC sınıfı için TP değeri 2.404, FP değeri 475 olarak belirlenmiştir. Modelin BCC sınıfında gösterdiği zayıf performans, yanlış teşhis olasılığını artırmakta ve bu durum klinik sonuçları olumsuz etkileyebilmektedir. AK sınıfında ise TP değeri 668, FP değeri 81 olarak kaydedilmiştir. Bu durumda modelin AK sınıfını tanımada yeterliliği ortalama seviyelerde kalmakta ve yanlış sınıflandırmaların önüne geçebilmek için iyileştirme gerektirmektedir.

Son olarak, önerilen yöntem değerlendirildiğinde, NV sınıfında 11.085 TP ve 178 FP değeri ile yüksek başarı göstermektedir. VASC sınıfında ise 218 TP değeri ve 0 FP değeri ile en yüksek performans sonucunu elde edilmiştir. Bu yüksek TP, modelin bu sınıfı doğru bir şekilde tanıma yeteneğinin güçlü olduğunu ortaya koymaktadır. MEL sınıfı için TP değeri 3.420 ve FP değeri 617'dir. Bu durum, modelin MEL sınıfını tanıma kapasitesinin kabul edilebilir seviyede olduğunu ancak hala iyileştirilmesi gereken alanlar olduğunu göstermektedir. SCC sınıfı için TP değeri 514 ve FP değeri 45'tir. Bu durum, modelin SCC sınıfını tanıma yeteneğinin yeterli olduğunu ancak FP değerinin bir miktar yüksek olduğunu gösterir. Bu nedenle, SCC sınıfında daha fazla veri toplanması ve modelin bu sınıfı daha iyi öğrenmesi adına veri artırma tekniklerinin uygulanması gerekebilir. Bu analizler, cilt kanseri gibi kritik sağlık alanlarında, erken teşhis ve tedavi süreçlerinin iyileştirilmesine yönelik önemli bilgiler sağlamaktadır.

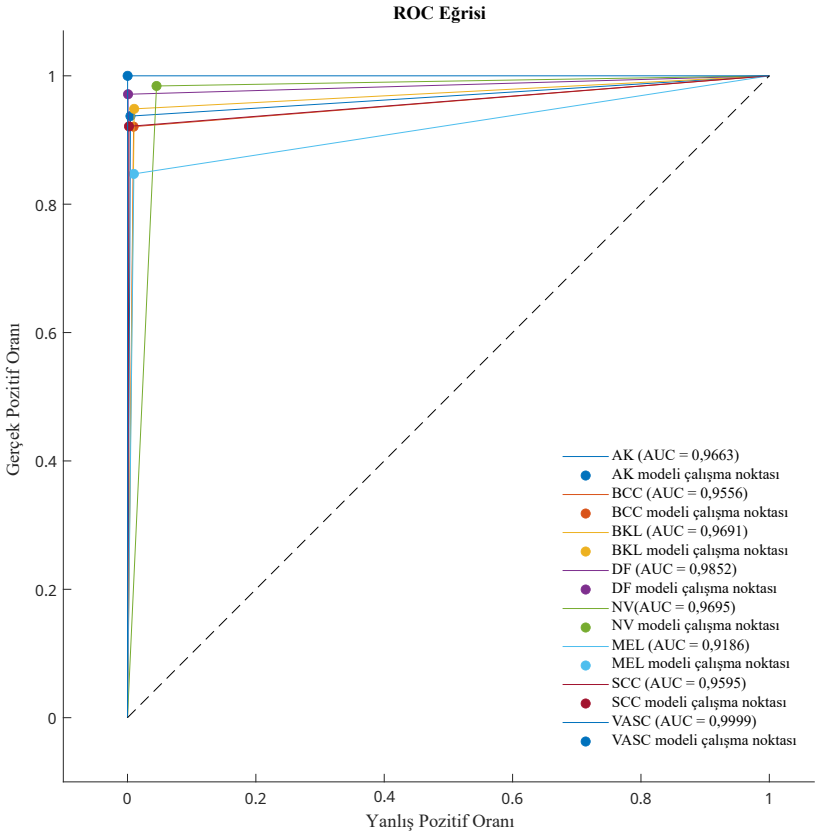

Şekil 2.8. ISIC 2019 veri seti için önerilen modelin tüm sınıflarının ROC eğrileri.

Önerilen modelin her cilt kanseri sınıfı için tanı performansı, ROC eğrisi analizi kullanılarak değerlendirilmiştir. Şekil 2.8'de gösterildiği gibi genel olarak, yöntemin çoğu sınıf için oldukça yüksek bir performans gösterdiği görülmüştür. Ancak, sınıflar arasındaki performans farklılıkları, modelin her cilt kanseri türünü aynı doğrulukla ayırt etmediğini ortaya koymaktadır.

VASC sınıfı 0,9999 değeri ile, modelin çok üstün bir sınıflandırma yeteneğine sahip olduğunu gösteren en yüksek AUC değerine ulaşmıştır. Bu, modelin VASC sınıfındaki lezyonları neredeyse kusursuz bir şekilde ayırt ettiğini ve bu sınıf için doğru sınıflandırmalar yapma konusunda son derece etkili olduğunu ortaya koymaktadır. DF sınıfı 0,9852 değeri ile oldukça yüksek bir AUC değerine sahip olup, modelin bu sınıfı doğru bir şekilde sınıflandırma başarısını sürdürdüğünü göstermektedir.

MEL sınıfı ise 0,9186 değeri ile diğer sınıflara göre en düşük AUC değerine sahiptir. Bu, modelin MEL lezyonlarını sınıflandırmada daha düşük doğruluk sergilediğini ve diğer

sınıflarla karşılaştırıldığında bu sınıfın tanınmasında zorluklar yaşadığını göstermektedir.

NV sınıfı 0,9695, BKL sınıfı 0,9691, AK sınıfı 0,9663 ve SCC sınıfı 0,9595 gibi yüksek AUC değerlerine sahip olup, modelin bu sınıfları başarılı bir şekilde sınıflandırma yeteneğini yansıtmaktadır. Bu sınıflar için elde edilen AUC değerleri, modelin bu türlerin tanınmasında genellikle iyi bir performans sergilediğini, ancak en yüksek performansa sahip sınıflara kıyasla bir miktar daha düşük doğruluk elde ettiğini göstermektedir.

2.6. Görüntü Bölütlemesinin Performans Üzerindeki Etkisi

Bu bölümde, sınıflandırma öncesinde gerçekleştirilen görüntü bölütlemesi yöntemin model performansı üzerindeki etkisini değerlendirmek için yapılan parametre belirleme çalışmalarının sonuçlarını sunulmaktadır. Görüntü bölütleme aşamasının ana hedefi, dermoskopik görüntülerde bulunan kalem işaretleri, hava kabarcıkları ve saç gibi gürültüleri ortadan kaldırarak yerlerini siyah bir arka planla değiştirmeyi ve bu şekilde yöntemin doğruluğunu artırmayı sağlamaktır.

Tablo 2.10'da, HAM10000 veri setinde görüntü bölütlemesi yapılmadan ve yapıldıktan sonra farklı CNN modellerinin sınıflandırma sonuçlarını karşılaştırmaktadır. Görüntü bölütlemesi olmadan en yüksek doğruluğu %73,10 ile önerilen yöntem elde etmiş, doğruluğun yanı sıra diğer metriklerde de dengeli bir performans sergilemiştir. DarkNet53 modeli %71,44 doğruluk ile önerilen yöntemin hemen ardından gelirken, yüksek özgüllük sunmasına rağmen pozitif sınıfları ayırt etme konusunda sınırlı kalmıştır. InceptionResNetv2 ve NasNetLarge modelleri sırasıyla %68,01 ve %67,18 doğrulukla daha düşük performans göstermiş, düşük kesinlik ve duyarlılık değerleri ile pozitif sınıfları belirlemede yetersiz kalmıştır.

Görüntü bölütlemesi uygulandığında ise tüm modellerde belirgin bir performans artışı gözlenmiştir. Önerilen yöntem %93,63 doğruluk ile diğer modelleri geride bırakmıştır. DarkNet53, %90,67 doğrulukla önerilen yöntemin hemen arkasından gelerek iyi bir performans sağlamıştır. InceptionResNetv2 ve NasNetLarge ise yaklaşık doğruluk değerleri ile birbirine benzer sonuçlar vermiştir. Bu sonuçlar, görüntü bölütlemesinin sınıflandırma performansını önemli ölçüde artırdığını ve önerilen yöntemin özellikle bu işlemden sonra diğer modellere göre üstün performans sağladığını göstermektedir.

Tablo 2.10. Önerilen yaklaşımın HAM10000 veri seti üzerindeki görüntü bölütlemeli/bölütlemesiz sınıflandırma sonuçları.

	Görüntü bölütlemesi olmadan					Görüntü bölütlemesi ile				
CNN Model	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**
DarkNet53	71,44	42,27	46,62	92,36	44,15	90,67	78,93	85,06	97,36	81,80
InceptionResNetv2	68,01	38,73	42,08	91,77	40,14	90,66	77,68	84,28	97,46	80,76
Nasnetlarge	67,18	37,16	39,93	91,43	38,18	90,53	77,59	83,99	97,43	80,60
Önerilen Yöntem	73,10	46,88	50,52	93,03	48,50	**93,63**	**85,68**	**88,98**	**98,33**	**87,26**

Tablo 2.11'de, ISIC 2019 veri setini kullanarak görüntü bölütlemesi ile ve görüntü bölütlemesi olmadan CNN modellerinin sınıflandırma sonuçlarını karşılaştırılmaktadır. Tabloya göre, görüntü bölütlemesi olmadan elde edilen sonuçlar değerlendirildiğinde, önerilen yöntem, %88,10 doğruluk, %82,45 kesinlik, %85,11 duyarlılık, %97,85 özgüllük ve %83,65 F1-skoru ile diğer modellerin önünde yer almıştır. EfficientNetb0 ve DenseNet201 gibi DL modelleri, önerilen yöntemle karşılaştırıldığında özellikle duyarlılık ve kesinlik açısından daha düşük değerler elde etmiştir. MobileNetv2 modeli %87,27 doğruluk ve %81,83 F1-skoru ile önerilen yönteme yakın bir performans sergilese de duyarlılık ve kesinlik açısından önerilen yöntemin gerisinde kalmıştır. Özgüllük değerlerinin tüm modeller için oldukça yüksek olması, yanlış pozitiflerin etkili bir şekilde azaltıldığını gösterirken, önerilen yöntemin duyarlılık ve kesinlik arasındaki dengeli performansı, doğru pozitiflerin de başarılı bir şekilde ayırt edildiğini ortaya koymaktadır. Bu durum, görüntü bölütlemesi olmaksızın önerilen yöntemin sınıflandırmada üstün bir genel başarı sağladığını göstermektedir.

Görüntü bölütlemesi ile elde edilen sonuçlar, sınıflandırma performansında belirgin bir artışa işaret etmektedir. Önerilen yöntem %94,42 doğruluk, %94,13 kesinlik, %93,00 duyarlılık, %98,96 özgüllük ve %93,50 F1-skoru ile tüm metriklerde en yüksek değerlere ulaşmıştır. EfficientNetb0 modeli %93,30 doğruluk ve %92,01 F1-skoru ile ikinci sırada yer alırken, DenseNet201 ve MobileNetv2 modelleri, önerilen yöntemin gerisinde kalmıştır. Görüntü bölütlemesinin tüm modellerde performansı artırıcı bir etkisi bulunmasına karşın, önerilen yöntemin diğer modellerden belirgin bir farkla üstünlük sağlaması, bu yöntemin görüntü bölütlemesi ile birleştiğinde sınıflandırma doğruluğunu optimize etme potansiyelini açıkça ortaya koymaktadır.

2.7. Önerilen Hibrit Modelin Güncel Yöntemlerle Karşılaştırılması

Bu bölümde, önerilen hibrit CNN yönteminin çok sınıflı cilt kanseri sınıflandırma sonuçları, literatürde yer alan HAM10000 ve ISIC 2019 veri setlerini kullanan hibrit CNN yöntemlerinin sonuçları ile karşılaştırılarak performans analizi yapılmaktadır. Tablo 2.12 ve Tablo 2.13'te, karşılaştırılan yöntemlerin ortalama doğruluk, kesinlik, duyarlılık, özgüllük ve F1-skora ilişkin sonuçlarını verilmektedir. Karşılaştırılan çalışmaların sonuçları, kendi orijinal makalelerinden alınmıştır. Ancak kullanılan veri setlerindeki

Tablo 2.11. Önerilen yaklaşımın ISIC 2019 veri seti üzerindeki görüntü bölütlemeli/bölütlemesiz sınıflandırma sonuçları.

	Görüntü bölütlemesi olmadan					**Görüntü bölütlemesi ile**				
CNN Model	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**
EfficientNetb0	83,17	74,25	78,10	96,98	75,86	93,30	92,79	91,41	98,76	92,01
DenseNet201	81,94	74,61	77,10	96,75	75,75	91,59	90,83	89,74	98,43	90,16
MobileNetv2	87,27	80,79	83,02	97,73	81,83	90,36	89,09	87,47	98,15	88,09
Önerilen Yöntem	88,10	82,45	85,11	97,85	83,65	**94,42**	**94,13**	**93,00**	**98,96**	**93,50**

görüntüler açık erişim şekilde eğitim ve test verisi olarak ayrılmadığından, her çalışmada kullanılan test setleri birbirinden farklı olabilmektedir. Tablo, her satırdaki en iyi sonuçları kalın olarak göstermekte olup, "-" sembolü raporlanmamış sonuçları temsil etmektedir.

HAM10000 veri seti üzerinde yapılan değerlendirmelerde önerilen yöntem, %93,63 doğruluk oranı ve %98,33 özgüllük ile tüm çalışmalarda en iyi performansı sergilemektedir. Bu sonuçlar, önerilen yöntemin özellikle yanlış pozitifleri ayırt etmede yüksek bir başarıya sahip olduğunu göstermektedir. Ayrıca, doğruluğu destekleyen %85,68 kesinlik, %88,98 duyarlılık ve %87,26 F1-skoru ile modelin dengeli bir sınıflandırma performansı sunduğu görülmektedir. Ramamurthy ve ark. tarafından sunulan hibrit CNN modeli, %93,20 doğruluk oranı ile önerilen modele oldukça yakın bir başarı sergilemiştir. Bu çalışma, %95,30 kesinlik ve %91,40 duyarlılık değerleriyle başarılı bir performans göstermektedir. Özgüllük değeri verilmemiş olsa da, doğruluk açısından yüksek sonuçlar elde etmesi, modelin genel olarak güvenilir bir yapıda olduğunu ortaya koymaktadır. Yu ve ark. tarafından geliştirilen model ise %89,27 doğruluk ve %91,33 F1-skoru ile öne çıkan çalışmalardandır. Özellikle yüksek F1-skoru, modelin dengeli bir sınıflandırma başarısına sahip olduğunu göstermektedir.

Kumar ve ark. ile De ve ark. çalışmalarında doğruluk değerleri sırasıyla %89,71 ve %89,00 olarak ölçülmüştür. Bu modeller, orta seviyede bir performans sergilemektedir. Kumar ve ark.'nın çalışması, %92,68 özgüllük değeriyle yanlış pozitifleri iyi bir şekilde ayırma yeteneğine sahiptir ve duyarlılık açısından da %89,24 gibi başarılı bir sonuç sunmaktadır. Bu dengeli yapı, yöntemin tüm sınıflarda benzer başarıya sahip olduğunu göstermektedir. De ve ark.'nın çalışmasında ise %84,00 kesinlik ve duyarlılık değerleriyle daha düşük bir performans sergilendiği gözlenmektedir. Ancak yöntem yine de kabul edilebilir bir doğruluğa sahiptir.

Gajera ve ark. ve Pandey ve ark. tarafından geliştirilen hibrit CNN modelleri, sırasıyla %81,00 ve %85,61 doğruluk oranlarıyla düşük performans sergileyen çalışmalar arasında yer almaktadır. Her iki çalışmada da özgüllük gibi bazı metriklerin eksik olması nedeniyle tam bir değerlendirme yapılamasa da, genel doğruluk değerleri diğer yöntemlerin altında kalmaktadır. Bu sonuçlar, her iki modelin de HAM10000 veri setindeki bazı sınıfları ayırt etmede zorlandığını göstermektedir.

Tablo 2.12. HAM10000 veri seti kullanılarak önerilen yaklaşımın literatürdeki en son çalışmalarla karşılaştırmalı analizi.

Yöntem	**Yıl**	**Model**	**Veri seti**	**Veri artırımı**	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**
Ramamurthy ve ark. [120]	2024	Hibrit CNN	HAM10000	Var	93,20	**95,30**	**91,40**	-	**93,30**
Kumar ve ark. [121]	2024	Hibrit CNN	HAM10000	Var	89,71	89,00	89,24	92,68	89,12
De ve ark. [123]	2024	Hibrit CNN	HAM10000	Var	89,00	84,00	84,00	-	83,00
Gajera ve ark. [87]	2023	Hibrit CNN	HAM10000	Yok	81,00	-	-	-	-
Pandey ve ark. [128]	2024	Hibrit CNN	HAM10000	Var	85,61	-	-	-	-
Yu ve ark. [124]	2023	Hibrit CNN	HAM10000	Yok	89,27	92,17	90,51	-	91,33
Önerilen Yöntem	2024	Hibrit CNN	HAM10000	Var	**93,63**	85,68	88,98	**98,33**	87,26

Önerilen yöntemin tüm metriklerde sağladığı yüksek değerler, özellikle yanlış pozitif oranını azaltan özgüllük başarısıyla literatürdeki diğer hibrit CNN modellerine göre oldukça öne çıkmaktadır. Ramamurthy ve Yu'nun çalışmaları önerilen modele yakın sonuçlar elde etmiş olsa da, özgüllük ve genel doğruluk bağlamında önerilen yöntem daha üstün bir başarı sergilemiştir. Eksik metriklere rağmen, elde edilen verilere göre önerilen modelin HAM10000 veri setindeki dermoskopik lezyonları sınıflandırmada en güvenilir model olduğu görülmektedir.

Tablo 2.13'te görüldüğü üzere, önerilen yöntem, %94,42 doğruluk oranı ile en yüksek başarıyı sergilemekte olup, özgüllükte %98,96 gibi oldukça etkileyici bir seviyeye ulaşmıştır. Bu yüksek özgüllük değeri, modelin yanlış pozitifleri ayırt etme konusunda son derece başarılı olduğunu vurgulamaktadır. Önerilen model, %94,13 kesinlik, %93,00 duyarlılık ve %93,50 F1-skoru ile sınıflandırma performansında tutarlılık sağlarken aynı zamanda yüksek güvenilirlik sunmaktadır. Özellikle bu değerler, önerilen yöntemin ISIC 2019 veri setinde farklı deri lezyonlarını başarılı bir şekilde ayrıştırmada güçlü bir potansiyel taşıdığını göstermektedir.

Seeja ve ark. tarafından geliştirilen hibrit CNN modeli, %93,65 doğruluk ve %93,69 F1-skoru ile oldukça iyi bir performans ortaya koymaktadır. %93,64 kesinlik ve %93,52 duyarlılık değerleri de yüksek olan bu model, önerilen yönteme yakın bir doğruluk oranına ulaşsa da özgüllük konusunda eksik bilgi sunmaktadır. Bununla birlikte, yüksek F1-skoru değeri, modelin dengeli bir sınıflandırma yeteneğine sahip olduğuna işaret etmektedir. Benzer şekilde Subhashini ve Chandrasekar tarafından geliştirilen model, %94,23 doğruluk ve %90,45 F1-skoru ile dikkate değer bir başarı sergilemektedir. Ancak özgüllük ve duyarlılık bağlamında önerilen yöntemin altında kalmaktadır.

Yu ve ark. tarafından geliştirilen model %87,48 doğruluk oranı ve %90,49 F1-skoru ile diğer çalışmalara göre orta seviyede bir performans göstermektedir. Bu model, %92,01 kesinlik ile pozitif sınıflamaları doğru şekilde belirleme eğilimindeyken, özgüllük değeri rapor edilmemiştir. Benzer bir şekilde Li ve ark. çalışmasında, %87,07 doğruluk ve %87,66 özgüllük değerleri ile sınıflandırma yapabilmiş. Ancak duyarlılık ve F1-skoru daha düşük kalmıştır. Bu durum, bu modelinin bazı sınıflarda daha sınırlı bir ayırt etme kapasitesine sahip olduğunu göstermektedir.

Tablo 2.13. ISIC 2019 veri seti kullanılarak önerilen yaklaşımın literatürdeki en son çalışmalarla karşılaştırmalı analizi.

Yöntem	**Yıl**	**Model**	**Veri seti**	**Veri artırımı**	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**Özgüllük(%)**	**F1-skor(%)**
Subhashini ve C. [122]	2023	Hibrit CNN	ISIC 2019	Yok	94,23	91,88	90,31	90,77	90,45
Pandey ve ark. [128]	2024	Hibrit CNN	ISIC 2019	Var	81,23	-	-	-	-
Yu ve ark. [124]	2023	Hibrit CNN	ISIC 2019	Yok	87,48	92,01	89,01	-	90,49
Seeja ve ark. [125]	2023	Hibrit CNN	ISIC 2019	Yok	93,65	**93,64**	**93,52**	-	**93,69**
Abdelhafeez ve ark. [126]	2023	Hibrit CNN	ISIC 2019	Var	85,74	84,00	76,10	-	89,60
Li ve ark. [127]	2024	Hibrit CNN	ISIC 2019	Yok	87,07	-	76,63	87,66	70,86
Önerilen Yöntem	2024	Hibrit CNN	ISIC 2019	Var	**94,42**	94,13	93,00	**98,96**	93,50

Pandey ve ark. tarafından sunulan hibrit CNN modeli %81,23 doğruluk ile diğer çalışmalara kıyasla en düşük başarıyı göstermektedir. Kesinlik, duyarlılık veya özgüllük gibi metriklerin rapor edilmemesi, bu modelin başarısının daha detaylı analizini zorlaştırmaktadır. Benzer şekilde Abdelhafeez ve ark. tarafından geliştirilen model %85,74 doğruluk ve %84,00 kesinlik ile kabul edilebilir bir başarı sunsa da, %76,10 duyarlılık ile özellikle pozitif örnekleri doğru tespit etmede diğer çalışmalara göre daha düşük bir performans sergilemektedir.

Bu sonuçlar doğrultusunda, önerilen modelin ISIC 2019 veri setinde tüm sınıflandırma ölçütlerinde sağladığı yüksek değerler, onu literatürdeki diğer çalışmalardan üstün kılmaktadır. Özgüllük başta olmak üzere tüm metriklerde güçlü bir performans sergileyen bu yöntem, deri lezyonlarının sınıflandırılmasında yüksek başarı elde etmek isteyen diğer çalışmalara kıyasla daha güvenilir bir alternatif olarak öne çıkmaktadır.

2.8. Değerlendirme

Bu çalışmada, cilt kanseri sınıflandırması için yeni hibrit bir CNN modelin geliştirilmesi ve cilt kanseri sınıflandırmasındaki etkinliği ele alınmıştır. Görüntü bölütleme ağı, ISIC 2018 veri seti üzerinde eğitilmiştir. Görüntü bölütleme aşamasında kullanılan ResNet50 tabanlı DeepLabv3+ modeli, görüntülerdeki istenmeyen nesneleri azaltarak, ilgi alanlarını belirleme konusunda önemli bir rol oynamaktadır.

Öznitelik çıkarım aşamasında, HAM10000 veri seti üzerinde en iyi başarımları gösteren DarkNet53, InceptionResNetv2 ve NasNetLarge modelleri ile ISIC 2019 veri seti için en iyi başarım oranlarına ulaşılan, MobileNetv2, EfficientNetb0 ve DenseNet201 modellerinden elde edilen özniteliklerin birleştirilmesiyle cilt kanseri sınıflandırması için bir hibrit model oluşturulmuştur.

Birleştirilen bu özniteliklerden en önemli olanları, birinci modelde mRMR, ikinci modelde ise ReliefF öznitelik seçimi algoritması ile seçilmiştir. Son olarak, sınıflandırma işlemi kNN algoritması ile gerçekleştirilmiştir. Üç farklı CNN modellerinin birleştirildiği hibrit mimariler, modelin güvenirliğini ve sınıflandırma doğruluğunu artırmıştır. Yapılan deneylerde, önerilen birinci hibrit model HAM10000 veri setinde %93,63 doğruluk oranı elde ederken, önerilen ikinci hibrit model, ISIC 2019 veri setinde %94,42

doğruluk oranıyla en iyi performansı göstermiş ve karşılaştırılan güncel yöntemleri geride bırakmıştır.

Deneysel sonuçlar, önerilen hibrit modelin performansının, veri artırma teknikleri ile önemli ölçüde iyileştirildiğini göstermektedir. Veri artırma uygulamaları, hem modelin genel doğruluğunu artırmakta hem de aşırı uyum riskini azaltmaktadır. Bu sonuçlar, cilt kanseri sınıflandırmasında daha iyi performans sergileyen hibrit modellerin geliştirilmesi için önemli bir temel oluşturmaktadır.

3. BÖLÜM

CİLT KANSERİNİN TANIMLANMASI İÇİN CONVNEXT BLOKLARI ENTEGRE EDİLMİŞ METAFORMER TABANLI CAFORMER MODELİ

Bu bölümde, öncelikle cilt kanseri tanımlaması için önerilen ConvNeXt blokları ile güçlendirilen MetaFormer tabanlı CAFormer modelinin mimarisi ele alınmaktadır. Ardından, oluşturulan hibrit modelin eğitimi için kullanılan veri ön işleme, veri artırma ve diğer işlemler detaylandırılmaktadır. Daha sonra, yöntemin parametrelerinin belirlenmesine yönelik çalışmalar ile önerilen yöntemin cilt kanseri sınıflandırma performansının değerlendirilmesi için gerçekleştirilen deneylerin görsel ve sayısal sonuçları sunulmaktadır. Son olarak, modelin mevcut yöntemlerle karşılaştırılmasına yer verilmektedir.

3.1. Önerilen ConvNeXt Blokları ile Güçlendirilmiş MetaFormer Tabanlı CAFormer Modeli

Bu bölümde, cilt kanseri sınıflandırması için temel DL mimarileri olan CNN ve ViT tabanlı hibrit bir model önerilmektedir. Şekil 3.1'de verilen model mimarisinde görüldüğü üzere, MetaFormer tabanlı CAFormer mimarisinin performansını artırmak amacıyla modele ConvNeXt blokları eklenmiş ve model ölçeklendirilmiştir. Bu değişikliğin temel amacı, ConvNeXt bloklarının geliştirilmiş evrişimsel işlemlerinden faydalanarak modelin öznitelik çıkarma yeteneklerini ve genel performansını artırmaktır. Ayrıca, modelin karmaşık öznitelik öğrenimi potansiyelini güçlendirmek için her aşamadaki blok sayısı artırılarak ölçeklendirilmiştir.

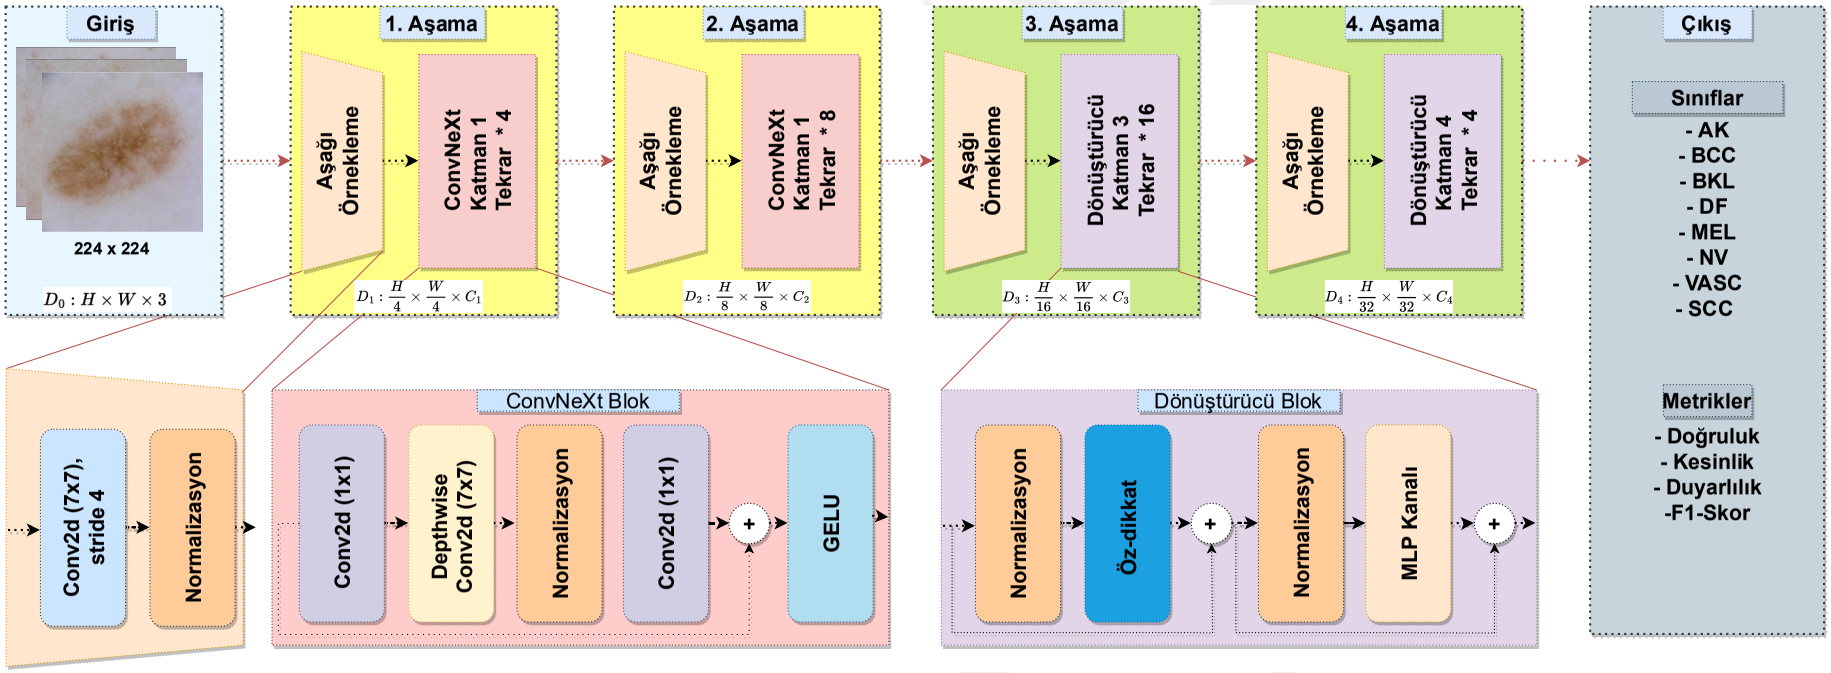

Şekil 3.1. Önerilen ConvNeXt blokları ile güçlendirilmiş MetaFormer tabanlı CAFormer modeli.

Önerilen MetaFormer tabanlı CAFormer modeli, giriş ve çıkış blokları hariç olmak üzere dört ana aşamadan oluşmaktadır. Her aşama aşağı örnekleme ve bir dizi ConvNeXt bloğu veya dönüştürücü bloğu içermektedir. Model, 224 × 224 piksel ve 3 kanallı (RGB) bir cilt lezyonu görüntüsünü girdi olarak almaktadır. Başlangıçta giriş görüntüsü, çekirdek boyutu 7 ve adım sayısı 4 olan bir evrişim katmanı kullanarak aşağı örnekleme yapan kök tarafından işlenmektedir. Bu adım, giriş tensörünün uzamsal boyutlarını azaltarak $D_1 = \frac{H}{4} \times \frac{W}{4} \times C_1$ boyutlarında bir çıkış tensörü üretmektedir. Dört ayrı aşamadan geçtikten sonra modelin çıktısı elde edilmektedir.

Önerilen modelin birinci aşamasında, dört ConvNeXt bloğu bulunmaktadır. Her ConvNeXt bloğu, bir dizi gelişmiş işlem içererek evrişimsel işlemeyi geliştirmek için tasarlanmıştır. Bu blokları, çekirdek boyutu 3 ve adım sayısı 2 olan bir evrişim katmanı kullanan bir aşağı örnekleme katmanı takip etmektedir. Bu aşağı örnekleme işlemi uzamsal boyutları daha da azaltarak $D_2 = \frac{H}{8} \times \frac{W}{8} \times C_2$ boyutlarında bir çıktı tensörü elde edilmesini sağlamaktadır.

İkinci aşamada, sekiz ConvNeXt bloğu ve ardından benzer bir aşağı örnekleme katmanından oluşmaktadır. Bu aşamadaki ConvNeXt bloklarının sayısının artması, daha karmaşık örüntü tanıma ve öznitelik çıkarma işlemlerine olanak sağlamaktadır. Bu aşamadaki aşağı örnekleme katmanı da çekirdek boyutu 3 ve adım sayısı 2 olan bir evrişim katmanı kullanmaktadır ve $D_4 = \frac{H}{32} \times \frac{W}{32} \times C_4$ boyutlarında bir çıktı tensörü üretmektedir.

Önerilen modelin üçüncü aşaması on altı dönüştürücü blok içermektedir. Bu dönüştürücü bloklar, girdi verilerindeki uzun menzilli bağımlılıkları ve karmaşık öznitelikleri yakalamak için öz-dikkat mekanizmalarını kullanmaktadır. Bu aşama ayrıca çekirdek boyutu 3 ve adım sayısı 2 olan bir evrişim katmanı kullanarak $D_4 = \frac{H}{32} \times \frac{W}{32} \times C_4$ boyutlarında çıktı tensörü veren bir aşağı örnekleme işlemi içermektedir.

Dördüncü ve son aşama ise, önceki aşamalarda çıkarılan öznitelik haritalarını daha da iyileştiren dört dönüştürücü bloktan oluşmaktadır. Bu aşama, öznitelik temsilini geliştirirken uzamsal çözünürlüğü korumaya odaklandığı için ek alt örnekleme içermemektedir. Önerilen modeldeki sınıflandırıcı başlığı, küresel ortalama ortaklama, normalleştirme ve tam bağlı katmanları içermektedir. Bu yapı, önceki aşamalarda çıkarılan öznitelikleri bir araya getirmek ve modelin nihai çıktısını oluşturmak için

tasarlanmıştır. Küresel ortalama ortaklama katmanı, uzamsal boyutları tek bir vektöre indirgemekte, bu vektör daha sonra normalleştirilmekte ve sınıf puanlarını üretmek için tam bağlı bir katmandan geçirilmektedir.

Önerilen modeldeki her ConvNeXt bloğu birkaç temel bileşenden oluşmaktadır. Bunlar, kanal sayısını ayarlamak için noktasal bir evrişim katmanı (Conv2D 1×1), uzamsal öznitelikleri yakalamak için derinlemesine bir evrişim katmanı (Depthwise Conv2D 7×7), LN, başka bir noktasal evrişim katmanı (Conv2D 1×1) ve bir GELU aktivasyon fonksiyonudur. Ayrıca blok, giriş tensörünü evrişim katmanlarının çıkışına ekleyerek artık öğrenmeyi kolaylaştıran bir kısayol bağlantısı içermektedir. Bir ConvNeXt bloğundan ileri geçiş şu şekilde tanımlanabilir: giriş tensörü önce 1×1 evrişim katmanı, ardından 7×7 derinlemesine evrişim katmanı tarafından işlenir. Elde edilen tensör LN için permütasyona tabi tutulur, ardından tekrar permütasyona tabi tutulur ve başka bir 1×1 evrişim katmanı tarafından işlenir. Kısayol bağlantısı orijinal giriş tensörünü bu çıktıya ekler ve sonuç bir GELU aktivasyon fonksiyonundan geçirilir.

ConvNeXt blokları, uzamsal hiyerarşileri geleneksel evrişim katmanlarından daha etkili bir şekilde yakalayan gelişmiş evrişim işlemleri nedeniyle etkili olmaktadır. Derinlemesine evrişim daha verimli hesaplama ve parametrelerin daha iyi kullanılmasını sağlarken, LN kullanılması eğitim sürecini stabilize etmektedir. Bu özellikler ConvNeXt bloklarını cilt lezyonu sınıflandırması gibi karmaşık görüntü verilerini içeren görevler için son derece uygun hale getirmektedir.

Önerilen modelde, aşamalar ve ilgili bloklar şu şekildedir: Birinci aşama, 64 boyutlu bir öznitelik haritasına sahip dört ConvNeXt bloğu içermektedir. İkinci aşama, 128 boyutlu öznitelik haritasına sahip sekiz ConvNeXt bloğundan oluşmaktadır. Üçüncü aşama, 320 boyutlu bir öznitelik haritasını artıran on altı dikkat bloğuna sahiptir. Dördüncü aşama ise, 512 boyutlu bir öznitelik haritasına sahip dört dikkat bloğundan oluşmaktadır.

Önerilen yaklaşım, HAM10000 ve ISIC 2019 veri seti olmak üzere iki önemli cilt lezyonu veri setinde değerlendirilmiştir. Blok sayısının artırılması ve ConvNeXt bloklarının eklenmesi, modelin daha ayrıntılı öznitelikleri çıkarmasına olanak tanıyarak sınıflandırma performansını artırmaktadır. Böylece, modelin farklı cilt lezyon türleri

üzerinde genelleme yapabilme kapasitesi önemli ölçüde iyileştirilmiştir.

3.2. Veri Ön İşleme ve Veri Artırma

DL modellerinin performansı, veri setinin boyutu ve çeşitliliği gibi faktörlere bağlı olarak önemli ölçüde değişmektedir. Çünkü bu faktörler aşırı uyumun önlenmesinde kritik rol oynamaktadır. Cilt kanseri sınıflandırması gibi tıbbi alanlarda, yeterli etiketli veri toplamak oldukça zorlu bir süreçtir. Ancak, veri artırma teknikleri bu sorunu etkili bir şekilde ele alarak veri setini yapay olarak genişletmekle birlikte modellerin daha sağlam ve genellenebilir öznitelikleri öğrenmelerini sağlamaktadır. Böylece, modelin farklı hastalık türlerini ve özniteliklerini ayırt etme yeteneğini artırabilmektedir. Çalışmamızda rastgele döndürme, yeniden boyutlandırma, yansıtma, ve gürültü ekleme veri artırma teknikleri ile, görüntü verilerinden yeni veri örnekleri oluşturulmuştur. Bu teknikler sayesinde, cilt kanseri lezyonları farklı açılardan, farklı boyutlarla ve farklı aydınlatma koşullarıyla temsil edilebilmektedir. Böylece model, farklı örüntü ve varyasyonları öğrenerek cilt lezyonu görüntülerini doğru bir şekilde sınıflandırabilmektedir.

Bu çalışmada, HAM10000 ve ISIC 2019 veri setlerinin her ikisi de eğitim, doğrulama ve test veri setleri olmak üzere üç farklı veri setine bölünmüştür. Böylece, DL modellerinin etkili bir şekilde eğitilmesi ve yeni verilere adapte olabilmesi sağlanmıştır. Ayrıca, modellerin adil bir şekilde değerlendirilebilmesini sağlamak için bu işlem oldukça önemlidir. Bu sayede, çalışmanın nesnelliği güçlendirilmekte ve modellerin genelleme yeteneklerini etkin bir şekilde değerlendirme olanağı elde edilmektedir.

Ayrıca, veri bölme yaklaşımımız, modellerin genelleme kapasitesini önemli ölçüde artırmaktadır. Böylece, sadece yeni verilere uyum sağlama yeteneklerini geliştirmekle kalınmamakta, aynı zamanda aşırı uyum ve veri yetersizliği gibi sorunlara karşı güçlü bir savunma sağlamaktadır. Elde edilen veri setlerinden, eğitim veri seti modelin parametrelerini ayarlamak, öğrenme algoritmalarını optimize etmek ve genelleştirilmiş bir model oluşturmak için kullanılmaktadır. Doğrulama veri seti, modelin aşırı uyumunu azaltmak, farklı mimarileri ve hiper parametreleri değerlendirmek amacıyla kullanılmaktadır. Son olarak, test veri seti, modelin daha önce hiç görmediği veriler üzerindeki performansını ve genelleme yeteneğini değerlendirmek için kullanılmaktadır.

Değerlendirme için kullanılan ilk veri seti olan HAM10000 veri setinde toplam 10.015 görüntü bulunmaktadır. Bunlardan rastgele olarak %70'i (7.010 görüntü) eğitim veri seti için ayrılmış, %10'u (1.105 görüntü) doğrulama veri seti olarak ayrılmış ve geri kalan %20'si (2.000 görüntü) test veri seti olarak belirlenmiştir. İkinci veri seti olan ISIC 2019 veri setindeki toplam 25.331 görüntüden %70'i (17.731 görüntü) eğitim veri seti için ayrılmış, %10'u (2.533 görüntü) doğrulama veri seti olarak belirlenmiş ve geri kalan %20'si (5.067 görüntü) test veri seti olarak ayrılmıştır. DL modelleri için eğitim, doğrulama ve test süreçleri bu dağıtım sistemine sıkı sıkıya bağlı kalarak gerçekleştirilmiştir. Tablo 3.1 HAM10000 veri setinin eğitim, doğrulama ve test amaçları için kullanılan görüntü sayılarını gösterirken, Tablo 3.2 ISIC 2019 veri seti için benzer bilgileri sunmaktadır.

Tablo 3.1. HAM10000 veri setinin eğitim, doğrulama, test ve toplam dağılımı.

Sınıflar	**AK**	**BCC**	**BKL**	**DF**	**MEL**	**NV**	**VASC**	**Toplam**
Eğitim verisi (%70)	229	360	769	80	779	4.694	99	7.010
Doğrulama verisi (%10)	34	51	111	13	112	670	14	1.005
Test verisi (%20)	64	103	219	21	223	1.341	29	2.000
Toplam	327	514	1.099	115	1.113	6.705	142	10.015

Tablo 3.2. ISIC 2019 veri setinin eğitim, doğrulama, test ve toplam dağılımı.

Sınıflar	**AK**	**BCC**	**BKL**	**DF**	**MEL**	**NV**	**VASC**	**SCC**	**Toplam**
Eğitim verisi (%70)	607	2.326	1.837	167	3.165	9.012	177	440	17.731
Doğrulama verisi (%10)	87	332	262	24	453	1.288	25	62	2.533
Test verisi (%20)	173	665	525	48	904	2.575	51	126	5.067
Toplam	867	3.323	2.624	239	4.522	12.875	253	628	25.331

3.3. Oluşturulan Hibrit Modelin Eğitimi

DL modellerini etkili bir şekilde eğitmek, çeşitli gelişmiş tekniklerin ve parametrelerin özenle ele alınmasını gerektirmektedir. Bu bağlamda veri artırma ve transfer öğrenme iki temel strateji olarak öne çıkmaktadır. Transfer öğrenme, veri sınırlamaları bulunan durumlarda, önceden eğitilmiş modellerin yeniden kullanılmasıyla eğitimi hızlandırmakta ve genelleme yeteneğini güçlendirmektedir. Bu yöntem, başka görevlerde öğrenilmiş bilgileri hedef göreve aktararak modelin performansını artırmaktadır. Veri artırma ise,

veri setini çeşitli işlemlerle genişleterek modelin dayanıklılığını artırmakta ve aşırı uyumu önlemektedir. Böylece model, farklı veri varyasyonlarına uyum sağlamakta ve sınırlı veri ile daha güçlü bir performans sergilemektedir. Bu iki stratejinin uyumlu kullanımı, DL modellerinde başarıya ulaşmak için kritik önem taşımaktadır.

Giriş görüntüsünün boyutu, epok sayısı, optimizasyon algoritması, öğrenme oranı, ağırlık azalması gibi kritik parametrelerin ayarlanması model performansını önemli ölçüde etkileyebilmektedir. Ağırlıkların azaltılması, aşırı uyumu en aza indirirken, öğrenme oranını, öğrenme sürecinin hızını ve doğruluğunu etkilemektedir. Tablo 3.3 önerilen yöntemin eğitiminde kullanılan hiper parametreleri göstermektedir.

Tablo 3.3. Modellerin eğitim hiper parametreleri.

Parametreler	**Değerler**
Varsayılan giriş çözünürlüğü	224×224
Öğrenme oranı	0,001
Temel öğrenme oranı	0,1
Momentum	0,9
Optimizasyon algoritması	SGD
Ağırlık azalması	2,0e-05
Epok	5
Epok öğrenme oranı	1,0e-05
Yığın boyutu	16

Bu çalışmada, tüm deneyler, Linux tabanlı DL yazılımlarıyla uyumlu olması nedeniyle Ubuntu 22.04 işletim sistemi yüklü bir bilgisayarda gerçekleştirilmiştir. Donanım olarak, 5200 MHz hızında çalışan 64 GB DDR5 RAM ve 10.496 CUDA çekirdeği ile 328 tensör çekirdeğine sahip, 24 GB GDDR6X belleği bulunan NVIDIA RTX 3090 ekran kartı kullanılmıştır. Sistem, Intel® Core™ i7-12700K işlemciye sahiptir. Çalışmada Python programlama dili, PyTorch çerçevesi ve NVIDIA CUDA Toolkit 11.7 sürümü kullanılmıştır.

3.4. Yöntemin Parametrelerinin Belirlenmesi için Gerçekleştirilen Çalışmalar

Bu bölümde, önerilen ConvNeXt blokları ile güçlendirilmiş MetaFormer tabanlı CAFormer modelinin HAM10000 ve ISIC 2019 veri setlerinde farklı MetaFormer

varyasyonları karşısındaki verimlilikleri ve performansları değerlendirilmektedir. Bu araştırma, yöntemimizin avantajlarını ortaya koyarken, farklı model yapılandırmalarının hesaplama verimliliğine dair önemli bulgular sağlamaktadır.

Tablo 3.4'te sunulan HAM10000 veri seti üzerinde elde edilen bulgular incelendiğinde, ConvFormer versiyonlarının daha düşük performans sergilediği görülmektedir. ConvFormer-s18 modeli %91,07 doğruluk ve %83,43 F1-skora ulaşırken, ConvFormer-s36 modeli %90,97 doğruluk ve %83,67 F1-skora ulaşmıştır. Model karmaşıklığı ConvFormer-m36 ve ConvFormer-b36 ile arttıkça, yalnızca küçük bir iyileşme gözlemlenmiş ve her iki model de %91,17 doğruluğa ulaşırken F1-skorda hafif farklılıklar göstermiştir.

Tablo 3.4. Önerilen modelin ve MetaFormer varyantlarının HAM10000 veri seti üzerindeki verimliliği.

Modeller	**Parametre(Milyon)**	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**F1-skor(%)**
ConvFormer-s18	24,74	91,07	89,56	78,68	83,43
ConvFormer-s36	37,98	90,97	89,13	79,63	83,67
ConvFormer-m36	54,76	91,17	86,99	84,01	85,39
ConvFormer-b36	96,83	91,17	88,95	79,64	83,73
CaFormer-s18	**24,31**	91,97	90,11	83,93	86,76
CaFormer-s36	37,27	91,67	87,71	82,34	84,80
CaFormer-m36	53,92	92,42	90,73	85,27	87,68
CaFormer-b36	95,71	90,92	85,68	82,63	84,06
CAFormer-s32 modeli	37,18	93,25	92,26	87,38	89,55
Önerilen ConvNeXt bloklu CAFormer-s32 modeli	38,01	**94,30**	**93,00**	**89,59**	**91,11**

CaFormer varyasyonları, performans açısından üstün sonuçlar elde etmiş ve özellikle CaFormer-m36 modeli %92,42 doğruluk ile %87,68 F1-skora ulaşmıştır. Daha basit bir yapıya sahip olan CaFormer-s18 ve CaFormer-s36 modelleri de tatmin edici sonuçlar üretmiş olmakla birlikte, daha karmaşık modellerin bu performansları geride bıraktığı gözlemlenmiştir. Bu durum, CaFormer mimarisinin artan derinlik ve karmaşıklıktan olumlu şekilde etkilendiğini ortaya koymaktadır.

CAFormer-s32 yapılandırması, %93,25 doğruluk ve %89,55 F1-skoru ile önemli bir iyileşme sergileyerek etkinliğini kanıtlamaktadır. ConvNeXt bloklarının entegrasyonu ile oluşturulan önerilen model ise %94,30 doğruluk ve %91,11 F1-skora ulaşarak en iyi performansı elde etmekte ve ConvNeXt bloklarının değerini artırdığını göstermektedir.

Tablo 3.4'te gösterildiği gibi, model karmaşıklığı ile verimlilik arasındaki dengeyi anlamak amacıyla parametre sayısına odaklanarak çeşitli modellerin performansı değerlendirildiğinde, 24,74 milyon ile 96,83 milyon parametre arasında değişen ConvFormer modelleri, artan parametre sayısının her zaman daha iyi performansla sonuçlanmadığını göstermektedir. Özellikle, 24,74 milyon parametreli ConvFormer-s18 modeli %91,07 doğruluk ve %83,43 F1-skora ulaşırken, 96,83 milyon parametreli ConvFormer-b36 modeli benzer doğruluk elde etmiş ancak biraz daha düşük bir F1-skoru olan %83,73 göstermiştir.

Benzer şekilde, CaFormer modelleri de 24,31 milyon ile 95,71 milyon arasında geniş bir parametre sayısı aralığına sahiptir. Karmaşıklık arttıkça performansta daha tutarlı bir iyileşme gözlemlenmektedir. 53,92 milyon parametreye sahip CaFormer-m36 modeli, daha küçük modelleri geride bırakarak %92,42 doğruluk ve %87,68 F1-skoru ile daha yüksek performans göstermiştir. Bu durum, daha büyük parametre sayılarının performansı olumlu yönde etkilediğini göstermektedir.

37,18 milyon parametreli önerilen CAFormer-s32 modeli, önceki modellere göre dikkate değer kazanımlar sergileyerek %93,25 doğruluk ve %89,55 F1-skoru elde etmiştir. Bu iyileşme, ConvNeXt bloğuyla güçlendirilen CAFormer-s32 modelinde daha da belirgin hale gelmiş ve parametre sayısındaki sadece küçük bir artışla (38,01 milyon) en yüksek performans metriklerine ulaşılmıştır. Bu model %94,30 doğruluk ve %91,11 F1-skoru gibi etkileyici sonuçlar elde etmiştir. Bu bulgular, ConvNeXt bloklarının CAFormer tasarımıyla birleştirilmesinin, model karmaşıklığını verimli bir şekilde kullanarak performansı önemli ölçüde artırdığını göstermektedir.

Tablo 3.5'te ISIC 2019 veri seti için elde edilen bulgular incelendiğinde, ConvFormer varyantlarının makul performans sergilediği görülmektedir. ConvFormer-s18 %90,39 doğruluk ve %86,27 F1-skoru elde ederken, ConvFormer-s36 %90,21 doğruluk ve %85,94 F1-skoru elde etmiştir. Model karmaşıklığının ConvFormer-m36 ve ConvFormer-b36 ile artırılması, %90,19 ve %90,35 doğruluk ve sırasıyla %86,21 ve %86,01 F1-skora sahip tutarlı bir performans sunmaktadır.

CaFormer varyantları, ISIC 2019 veri setinde yüksek performans sergilemiştir. CaFormer-s18 %89,86 doğruluk ve %86,25 F1-skoru elde ederken, CaFormer-s36

Tablo 3.5. Önerilen modelin ve MetaFormer varyantlarının ISIC 2019 veri seti üzerindeki verimliliği.

Modeller	**Parametre(Milyon)**	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**F1-skor(%)**
ConvFormer-s18	24,74	90,39	90,59	82,73	86,27
ConvFormer-s36	37,98	90,21	89,73	82,82	85,94
ConvFormer-m36	54,76	90,19	88,98	83,79	86,21
ConvFormer-b36	96,83	90,35	90,77	82,25	86,01
CaFormer-s18	**24,31**	89,86	89,68	83,45	86,25
CaFormer-s36	37,27	90,68	90,19	83,16	86,31
CaFormer-m36	53,92	90,37	90,30	82,61	86,01
CaFormer-b36	95,71	90,43	90,81	82,97	86,43
CAFormer-s32 modeli	37,18	91,32	90,61	86,62	88,51
Önerilen ConvNeXt bloklu CAFormer-s32 modeli	38,01	**92,50**	**92,07**	**88,85**	**90,38**

%90,68 doğruluk ve %86,31 F1-skoruna ulaşmıştır. Ayrıca, CaFormer-m36 yapılandırması %90,37 doğruluk ve %86,01 F1-skoruna, CaFormer-b36 ise %90,43 doğruluk ve %86,43 F1-skoruna ulaşmıştır.

Önerilen CAFormer-s32 yapılandırması performansı daha da artırarak %91,32 doğruluk ve %88,51 F1-skora ulaşmıştır. Ancak, ConvNeXt bloklarının entegrasyonu en büyük performans artışlarını sağlamış ve model %92,50 doğruluk ve %90,38 F1-skora ulaşmıştır. Bu sonuçlar, ConvNeXt bloklarının entegrasyonunun modelin genel performansı üzerindeki önemli etkisini vurgulamaktadır.

Tablo 3.5, model performansının parametre sayısı ve veri setine dayalı karşılaştırmalı analizini sunmaktadır. 24,74 milyon parametreye sahip ConvFormer-s18 modeli, %90,39 doğruluk ve %86,27 F1-skora ulaşmıştır. ConvFormer-s36 ve ConvFormer-m36 gibi modellerde parametrelerin artırılması önemli performans iyileştirmelerine yol açmamış, doğruluk oranları sırasıyla %90,21 ve %90,19, F1-skorları ise %85,94 ve %86,21 olmuştur. 96,83 milyon parametreye sahip ConvFormer-b36 modeli, %90,35 doğruluk oranı ile benzer bir performans göstermiş ancak F1-skoru %86,01 ile biraz daha düşük kalmıştır. Bu bulgular, ConvFormer modellerinin model karmaşıklığı ile performans arasında sınırlı bir ilişki sergilediğini ve parametre artışlarının sadece küçük performans kazanımları sağladığını göstermektedir.

Öte yandan, CaFormer modelleri artan karmaşıklıkla daha tutarlı bir performans iyileştirmesi göstermiştir. 24,31 milyon parametreye sahip CaFormer-s18 modeli %89,86 doğruluk ve %86,25 F1-skoruna ulaşmıştır. 53,92 milyon parametreye sahip CaFormer-m36 modeli, %90,37 doğruluk ve %86,01 F1-skora ulaşarak artan parametrelerle performansın iyileştiğini göstermektedir. 95,71 milyon parametreye sahip CaFormer-b36 modeli ise en yüksek doğruluk oranı olan %90,43 ve %86,43 F1-skoruna ulaşmıştır.

37,18 milyon parametreye sahip önerilen CAFormer-s32 modeli, %91,32 doğruluk ve %88,51 F1-skoru ile önemli kazanımlar sağlamıştır. En büyük iyileşme ise sadece küçük bir parametre artışıyla 38,01 milyon parametreye ulaşan önerilen modelde (CAFormer-s32 ve ConvNeXt Bloğu) görülmüştür. Bu model, %92,50 doğruluk ve %90,38 F1-skoru ile en yüksek performans metriklerine ulaşmıştır. Bu durum, ConvNeXt bloklarının entegrasyonunun parametre kullanımını önemli ölçüde optimize ettiğini ve cilt kanseri teşhisinde daha yüksek performansa yol açtığını göstermektedir.

Parametre belirleme çalışmalarının sonuçları, özellikle ConvNeXt bloklarının entegrasyonu ile önerilen modelin, çeşitli MetaFormer ve CAFormer varyasyonlarını büyük ölçüde geride bıraktığını ortaya koymaktadır. ConvNeXt bloğunu CAFormer-s32 ile birleştirerek geliştirilen model, HAM10000 veri setinde %94,30 doğruluk ve %91,11 F1-skoruna, ISIC 2019 veri setinde ise %92,50 doğruluk ve %90,38 F1-skoruna ulaşarak en yüksek sonuçları elde etmektedir. Bu durum, CAFormer mimarisine ConvNeXt bloklarının dahil edilmesinin modelin cilt kanseri sınıflandırma performansının artırılmasında önemli bir katkı sağladığını göstermektedir.

3.5. ConvNeXt Blokları ile Güçlendirilmiş MetaFormer Tabanlı CAFormer Modeli Deney Sonuçları

Bu bölümde, literatürde iyi bilinen on adet CNN modeli ve on adet ViT modeli ile önerilen modelinde dahil olduğu toplam yirmi bir model için gerçekleştirilen deneylerin sonuçları sunulmaktadır. Değerlendirmelerde kullanılan CNN modelleri ResNetv2-50 [172], Inceptionv4 [173], Xception [171], EfficientNetv2-Medium [174], MobileNetv3-Large [175], ConvNeXt-Base [65], InceptionNext-Base [176], RepghostNet-200 [177], RexNet-100 [178] ve GhostNetv2-130 [179] modelleridir.

ViT tabanlı modeller ise MobileViT-Small [180], DeiT3-Base [181], Swin-Base [66], BeiTv2-Base [182], PiT-Base [183], NextViT-Base [184], MViTv2-Base [185], TinyViT-21m [186], ConViT-Base [187] ve CoaT-Small [188] modelleridir. Objektif bir değerlendirme yapmak amacıyla, HAM10000 ve ISIC 2019 veri setleri eğitim, doğrulama ve test veri setlerine önceden ayrılmıştır. Modellerin daha önce hiç görmediği test verileri kullanılarak yapılan değerlendirmeleri, gerçek performanslarının daha doğru bir değerlendirmesini sağlamaktadır. Önerilen modelin performansı hem CNN tabanlı hem de ViT tabanlı modellerle karşılaştırılmaktadır. Bu karşılaştırmada kullanılan değerlendirme metrikleri arasında doğruluk, kesinlik, duyarlılık ve F1-skoru bulunmaktadır. Bu metrikler her modelin cilt kanseri sınıflandırma konusundaki etkinliğini kapsamlı bir şekilde değerlendirmek amacıyla kullanılmıştır.

3.5.1. HAM10000 Veri Seti için Deney Sonuçları

Bu bölümde, önerilen MetaFormer tabanlı modelin HAM10000 veri seti üzerinde sınıflandırma performansı değerlendirilmektedir. Tablo 3.6'da önerilen MetaFormer tabanlı modellerin literatürde yaygın olarak kullanılan CNN ve ViT modelleri ile HAM10000 veri seti üzerindeki karşılaştırma sonuçlarını vermektedir. Tabloda görülebileceği üzere, önerilen MetaFormer tabanlı model, tüm değerlendirme metriklerinde karşılaştırılan diğer modelleri büyük bir farkla geride bırakmaktadır. Önerilen model, %94,30 doğruluk, %93,00 kesinlik, %89,59 duyarlılık ve %91,11 F1-skoru elde etmiştir. Bu sonuçlar, modelin cilt kanseri lezyonlarını güvenilir bir şekilde sınıflandırma kapasitesini göstermekte ve klinik uygulamalar için güçlü bir araç olduğunu ortaya koymaktadır.

CNN tabanlı modeller arasında en yüksek başarıyı gösteren RexNet-100 modeli, %91,92 doğruluk oranı ile öne çıkmaktadır. Bu model, DL mimarisi açısından sağlam bir temel sunarak, özellikle görüntü sınıflandırma görevlerinde etkinliğini kanıtlamaktadır. RexNet-100 modelini takip eden RepGhostNet-200 modeli, %91,62 doğruluk ile benzer bir başarı sergilemektedir. Bu sonuçlar CNN tabanlı mimarilerin yüksek performans potansiyelini ortaya koymaktadır. ResNetv2-50 modeli %87,57 doğruluk ve %76,60 F1-skor değeri ile tüm CNN ve ViT modelleri içerisinde en düşük başarıyı göstermiştir.

Tablo 3.6. Tüm DL modellerinin HAM10000 veri seti üzerindeki sonuçları.

Modeller	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**F1-skor(%)**
ResNetv2-50	87,57	79,77	74,20	76,60
Inceptionv4	90,37	84,76	78,70	81,28
Xception	90,22	87,04	81,46	83,85
EfficientNetv2-Medium	90,17	84,39	77,76	80,53
MobileNetv3-Large	90,32	86,49	80,75	83,24
ConvNeXt-Base	91,17	87,60	83,11	85,13
InceptionNext-Base	90,17	86,68	78,13	81,82
RepGhostNet-200	91,62	88,17	80,14	83,67
RexNet-100	91,92	89,51	83,12	85,99
GhostNetv2-130	91,22	87,24	82,41	84,67
MobileViT-Small	91,12	88,86	81,51	84,79
DeiT3-Base	92,12	90,35	83,54	86,60
Swin-Base	92,12	89,33	84,64	86,76
BeiTv2-Base	89,77	86,94	76,44	80,47
PiT-Base	91,37	88,90	82,75	85,48
NextViT-Base	88,52	83,57	75,20	79,01
MViTv2-Base	91,62	86,86	83,13	84,64
Tiny-ViT-21m	91,57	87,74	82,13	84,62
ConViT-Base	91,72	88,78	83,11	85,62
CoaT-Small	91,77	88,23	82,89	85,32
Önerilen Yöntem	**94,30**	**93,00**	**89,59**	**91,11**

ViT tabanlı modeller arasında en yüksek başarıyı elde eden Swin-Base mimarisi, %92,12 doğruluk ve %86,76 F1-skor değeri ile yüksek performans göstermektedir. Bu model, dikkat mekanizmalarını etkili bir şekilde kullanarak, görüntü verilerini işleme yeteneğini artırmaktadır. %92,12 doğruluk oranıyla Swin-Base mimarisi ile benzer performans sergileyen DeiT3-Base modeli, Swin-Base mimarisinden daha yüksek kesinlik değeri, diğer taraftan, daha düşük duyarlılık ve F1-skor değerleri elde etmiştir. NextViT-Base %88,52 doğruluk ve %79,01 F1-skor değeri ile ViT modelleri içerisinde en düşük performansı sergilemiştir.

Tablodan görüleceği üzere MobileViT-Small, ConViT-Base, Tiny-ViT-21m ve CoaT-Small mimarileri, %91,12 ile %91,77 arasında değişen doğruluk oranları ile

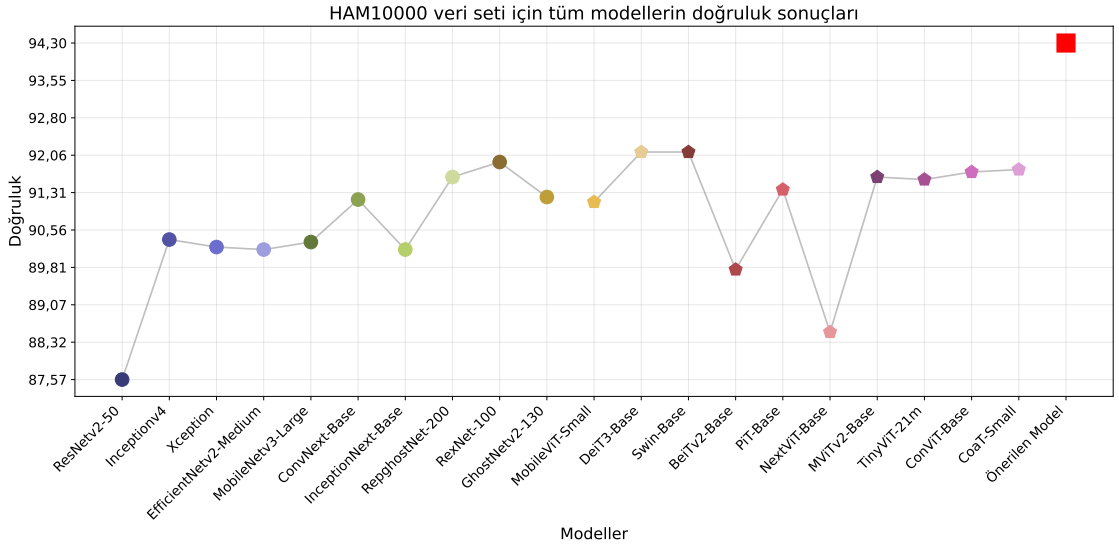

Şekil 3.2. Önerilen modelin HAM10000 veri seti üzerinde CNN tabanlı ve ViT tabanlı modellerle doğruluk değerlerinin karşılaştırması.

birbirine yakın cilt kanseri sınıflandırma performansı sergilemektedir. Bu durum mimari tasarımlarının ve eğitim süreçlerinin benzer stratejilerle optimize edildiğini göstermektedir.

Şekil 3.2 ve Şekil 3.3, HAM10000 veri seti kullanılarak karşılaştırılan modellerin doğruluk ve F1-skoru açısından kıyaslamalarını detaylandırarak sunmaktadır. Bu grafiklerde, önerilen modelin diğer mimarilerden daha yüksek doğruluk ve F1-skoruna ulaşarak açık bir üstünlük sağladığı gözlenmektedir. Özellikle, ResNetv2-50, NextViT-Base ve BeiTv2-Base gibi bazı modellerin doğruluk ve F1-skorunda daha düşük performans gösterdiği fark edilmektedir. Diğer yandan, Swin-Base, DeiT3-Base ve PiT-Base gibi modeller rekabetçi performanslarıyla dikkat çekmektedir.

Önerilen modelin sağladığı yüksek doğruluk ve F1-skoru, cilt lezyonlarının doğru sınıflandırılması ve teşhis süreçlerinin güvenilirliği açısından önemli bir katkı sağlamaktadır. Grafiklerde önerilen modelin istikrarlı üstünlüğü, genelleme kapasitesinin diğer modellere kıyasla daha yüksek olduğunu göstermektedir. Bu bulgular, önerilen modelin tıbbi tanı süreçlerinde etkili bir araç olarak kullanılma potansiyeline işaret ederken, cilt kanseri teşhisinde yüksek doğruluk ve duyarlılık gerektiren klinik uygulamalarda yararlı bir araç olduğunu ortaya koymaktadır.

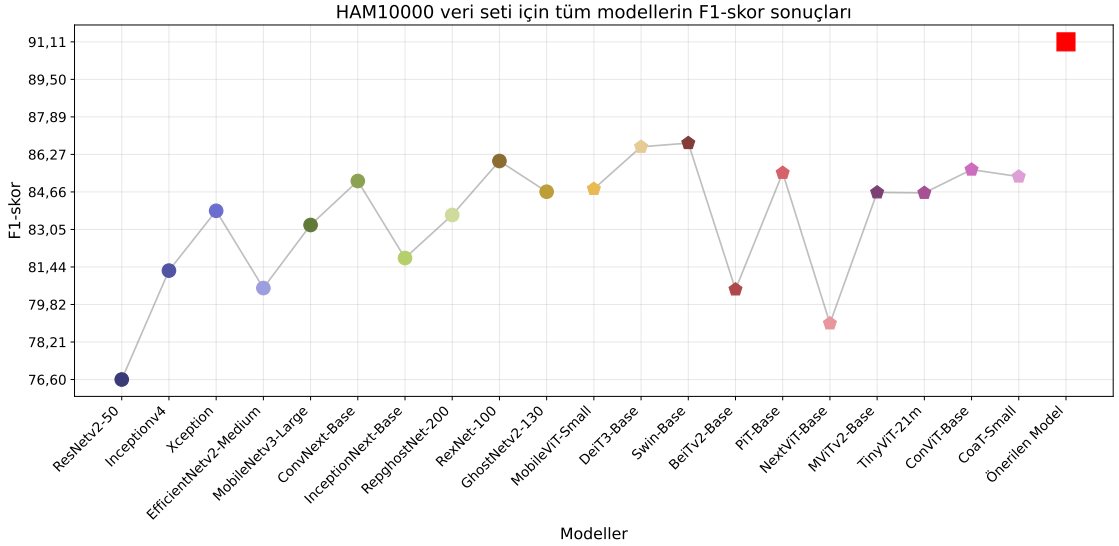

Şekil 3.3. Önerilen modelin HAM10000 veri seti üzerinde CNN tabanlı ve ViT tabanlı modellerle F1-skor değerlerinin karşılaştırması.

Şekil 3.4'te verilen karışıklık matrisi, önerilen hibrit modelin HAM10000 veri setindeki sınıflar bazında sergilediği performansını göstermektedir. Karışıklık matrisinin analizi, modelin farklı cilt kanseri türlerini doğru bir şekilde sınıflandırma yeteneğini açıkça ortaya koymaktadır. Ayrıca Tablo 3.7'de HAM10000 veri setinde bulunan tüm sınıfların, sınıf bazında performans değerlendirme sonuçları verilmektedir.

Şekil 3.4 ve Tablo 3.7 birlikte değerlendirildiğinde önerilen modelin NV sınıfında %99,18 ile diğer sınıflara göre en yüksek kesinlik değeri elde ettiği görülmektedir. 1.330 TP ve sadece 11 görüntüyü yanlış sınıflandırması, NV sınıfında net bir başarı gösterildiğini kanıtlamaktadır. %97,33 F1-skoru, sınıfın doğru bir şekilde tanımlandığını ve modelin tutarlı bir başarı sergilediğini doğrulamaktadır. VASC sınıfında ise, %100 duyarlılık ve %98,25 F1-skoru, modelin bu sınıfta en yüksek başarıyı sergilediğini göstermektedir. Karışıklık matrisinde 28 doğru sınıflandırmaya karşılık sadece 1 yanlış sınıflandırma olması, modelin VASC sınıfını diğer sınıflardan neredeyse tamamen ayırabildiğini kanıtlamaktadır.

HAM10000 veri setinde bulunan MEL sınıfında %76,23 kesinlik ve %88,08 duyarlılık değerleri, modelin sınıfı tanımada en düşük doğruluk değerini sergilediğini göstermektedir. 170 doğru sınıflandırmanın yanı sıra toplam 53 görüntünün yanlış

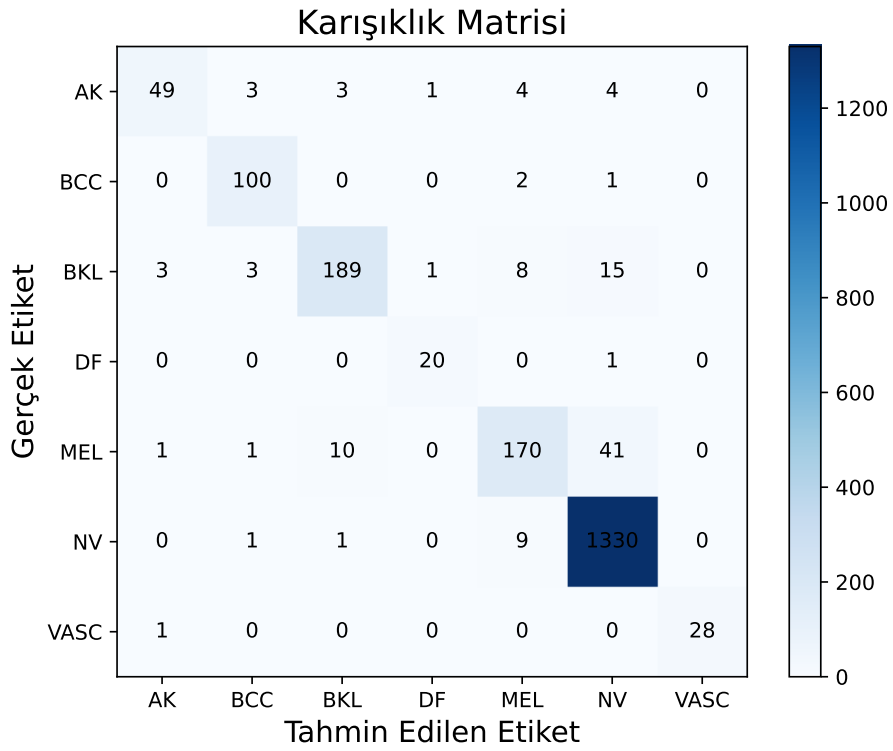

Şekil 3.4. HAM10000 veri seti üzerinde önerilen model için karışıklık matrisi.

sınıflandırılması, sınıfın tanınmasında yüksek duyarlılığa rağmen kesinliğin nispeten düşük kaldığını net bir şekilde ortaya koymaktadır. %81,73 F1-skoru ise, modelin sınıf ayrımındaki karışıklılığının giderilmesi gerektiğine işaret etmektedir. Modelin bir diğer düşük başarım elde ettiği AK sınıfında %76,56 kesinlik ve %90,74 duyarlılık değerleri, sınıfı belirlemede düşük bir başarı gösterdiğini ortaya koymaktadır. Karışıklık matrisinde 49 görüntünün doğru sınıflandırılmasına karşın, MEL ve NV sınıflarına ait 8 görüntünün yanlış sınıflandırılması, modelin AK sınıfı ile özellikle bu iki sınıfı ayrım yapmada belirli bir zorluk yaşadığını göstermektedir. %83,05 F1-skoru, bu sınıfın genel olarak başarılı bir şekilde tanındığını, ancak belirgin bir sınıflar arası karışıklık bulunduğunu göstermektedir.

BCC sınıfında %97,09 kesinlik ve %92,59 duyarlılık oranları ile model, yüksek doğrulukla sınıfı tanımlamaktadır. Karışıklık matrisinde 100 doğru sınıflandırma ve yalnızca 3 FP değeri gözlenmiş olup, modelin bu sınıfı büyük bir doğrulukla ayırt ettiği görülemektedir. %94,79 F1-skoru, modelin BCC sınıfını yüksek bir doğruluk ve duyarlılık dengesi ile tanıdığını doğrulamaktadır. DF sınıfında ise %95,24 kesinlik, %90,91 duyarlılık ve %93,02 F1-skoru değeri ile model, sınıfı net bir şekilde ayırt

Tablo 3.7. Önerilen modelin HAM10000 veri setindeki sınıf bazında performans metrikleri sonuçları

Sınıf	Kesinlik (%)	Duyarlılık (%)	F1-skor (%)
AK	76,56	90,74	83,05
BCC	97,09	92,59	94,79
BKL	86,30	93,10	89,57
DF	95,24	90,91	93,02
MEL	76,23	88,08	81,73
NV	**99,18**	95,55	97,33
VASC	96,55	**100,00**	**98,25**

etmektedir. Karışıklık matrisinde yalnızca 1 FP ve 20 TP bulunması, sınıfın doğru bir şekilde tanındığını açık bir şekilde doğrulamaktadır.

Değerlendirmeler sonucunda, önerilen MetaFormer tabanlı model, CAFormer mimarisine ConvNeXt bileşenlerini entegre ederek tüm metriklerde başarılı performans sergilemektedir. Bu entegrasyon, hem CNN hem de ViT mimarilerinin yeteneklerinden yararlanarak sınırlamalarını aşmaktadır. Önerilen modelin doğruluk, kesinlik, duyarlılık ve F1-skoru, onu cilt kanserinin hassas ve güvenilir bir şekilde tanımlanması için güçlü bir uygulama olarak öne çıkarmaktadır.

3.5.2. ISIC 2019 Veri Seti için Deney Sonuçları

Bu bölümde, önerilen MetaFormer tabanlı modelin sağlamlığını pekiştirmek için ISIC 2019 veri seti üzerinde analiz genişletilmektedir. Daha geniş bir cilt kanseri görüntü çeşitliliği sunan bu veri seti, modelin yeteneklerinin daha derinlemesine değerlendirilmesine olanak tanımaktadır. Tablo 3.8, önerilen modelin ISIC 2019 veri setindeki çeşitli CNN ve ViT tabanlı mimarilerle kapsamlı bir karşılaştırmasını sunmaktadır. Her modelin cilt kanserini sınıflandırma etkinliğini kapsamlı bir şekilde değerlendirmek için doğruluk, kesinlik, duyarlılık ve F1-skoru metrikleri kullanılmıştır. Önerilen model, karşılaştırılan modelleri tüm performans metriklerinde önemli ölçüde geride bırakarak %92,50 doğruluk, %92,07 kesinlik, %88,85 duyarlılık ve %90,38 F1-skor sonuçlarına ulaşmıştır. ConvNeXt bloklarının CAFormer mimarisine entegrasyonu, modelin tanı doğruluğunu artırmada etkili olmuştur. Elde edilen sonuçlar, yöntemin klinik uygulamalarda kullanılma potansiyelini göstermektedir.

Tablo 3.8. Tüm DL modellerinin ISIC 2019 veri seti üzerindeki sonuçları.

Modeller	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**F1-skor(%)**
ResNetv2-50	83,74	86,97	72,70	74,53
Inceptionv4	86,78	83,96	78,24	80,68
Xception	88,57	86,10	79,03	82,07
EfficientNetv2-Medium	89,28	87,03	84,09	85,45
MobileNetv3-Large	88,83	86,61	80,73	83,42
ConvNeXt-Base	89,28	88,72	78,42	82,61
InceptionNext-Base	88,89	88,81	81,06	84,41
RepghostNet-200	89,36	87,47	82,71	84,92
RexNet-100	87,45	82,32	81,26	81,69
GhostNetv2-130	89,62	88,01	82,26	84,89
MobileViT-Small	87,88	83,12	80,73	81,79
DeiT3-Base	90,19	90,04	82,48	85,89
Swin-Base	90,74	81,73	84,35	87,50
BeiTv2-Base	88,93	89,52	78,87	83,19
PiT-Base	90,37	90,30	86,21	86,01
NextViT-Base	88,43	86,12	81,64	83,69
MViTv2-Base	90,74	89,37	85,20	87,16
TinyViT-21m	89,46	85,88	82,36	83,92
ConViT-Base	89,88	89,00	82,94	85,66
CoaT-Small	90,92	90,34	84,44	87,12
Önerilen Yöntem	**92,50**	**92,07**	**88,85**	**90,38**

Önerilen modelden sonra ikinci sırada en yüksek başarımı CoaT-Small modeli göstermektedir. Bu model, %90,92 doğruluk ile başarılı bir performans sergilemekte olup, %90,34 kesinlik, %84,44 duyarlılık ve %87,12 F1-skoru değerleri ile dikkat çekmektedir. Bir diğer yüksek performans gösteren MViTv2-Base modeli, %90,74 doğruluk oranı ile CoaT-Small modeline oldukça yakın bir başarı göstermektedir. Bu modelin kesinliği %89,37, duyarlılığı ise %85,20 olarak belirlenmiştir. Bu bulgular, ViT tabanlı modellerin genel olarak yüksek başarı potansiyeline sahip olduğunu ortaya koymaktadır.

Değerlendirilen tüm modeller içerisinde en düşük başarıyı %83,74 doğruluk ve %74,53 F1-skor değeri ile ResNetv2-50 modeli sergilemiştir. Diğer yandan, düşük başarıya sahip olan modeller arasında RexNet-100 modeli, %87,45 doğruluk oranı ile dikkat

çekmektedir. Bu modelin kesinliği %82,32 ve duyarlılığı %81,26 olarak kaydedilmiştir. Üçüncü en düşük başarıyı elde eden MobileViT-Small modeli, %87,88 doğruluk ile %83,12 kesinlik ve %80,73 duyarlılık seviyelerinde kalmıştır.

Tablodaki diğer modeller, belirli aralıklarla birbirlerine benzer doğruluk oranları göstermektedir. Örneğin, EfficientNetv2-Medium, %89,28 doğruluk ve %85,45 F1-skor değeri ile istikrarlı bir performans sergilemekteyken, Xception modeli ise %88,57 doğruluk ve %82,07 F1-skor değeri sağlamaktadır.

Tabloda sunulan verilerden anlaşılacağı üzere, ViT tabanlı modellerin, genellikle daha yüksek başarı oranları elde etmesi, bu modellerin karmaşık veri ilişkilerini öğrenme kapasitelerinin bir yansımasıdır. Bununla birlikte, CNN tabanlı modellerin de belirli veri setlerinde etkili sonuçlar sunduğu değerlendirilmektedir. Uygulama gereksinimlerine göre en uygun modelin seçimi, her iki mimarinin de güçlü ve zayıf yönlerinin dikkate alınmasını gerektirmektedir. Bu nedenle, hem CNN hem de ViT tabanlı yaklaşımlar, belirli bağlamlarda etkili olabilmektedir.

Şekil 3.5 ve Şekil 3.6, ISIC 2019 veri seti üzerinde farklı modellerin doğruluk ve F1-skoru performanslarını görsel bir şekilde sunmaktadır. Grafiklerde, önerilen modelin sağladığı değerler belirgin bir şekilde diğer modellerden ayrılmakta ve oldukça yüksek performans sergilemektedir. Bu durum, önerilen modelin cilt kanseri tanısında öne çıktığını göstermektedir.

Şekil 3.5'te verilen doğruluk grafiğinde, önerilen modelin değerinin belirgin bir yükseklikte olduğu görülmekte ve bu durum, cilt lezyonlarının doğru bir şekilde sınıflandırılması açısından önemli bir başarıyı simgelemektedir. Diğer modeller arasında ise bazıları tatmin edici sonuçlar elde etse de, bu değerlerin önerilen modelin gerisinde kaldığı gözlemlenmektedir. F1-skoru grafiği ise, modelin hem duyarlılık hem de kesinlik açısından gösterdiği performansı ortaya koymakta ve bu iki metrik arasında dengeli bir başarı sağladığını göstermektedir.

Grafiklerin gösterdiği üzere, farklı modellerin F1-skorları da rekabetçi sonuçlar sergilese de, önerilen modelin sunduğu yüksek sonuçlar, cilt kanseri tanısında güvenilirliğini ve etkinliğini vurgulamaktadır. Görsel veriler, önerilen modelin bu alanda sahip olduğu

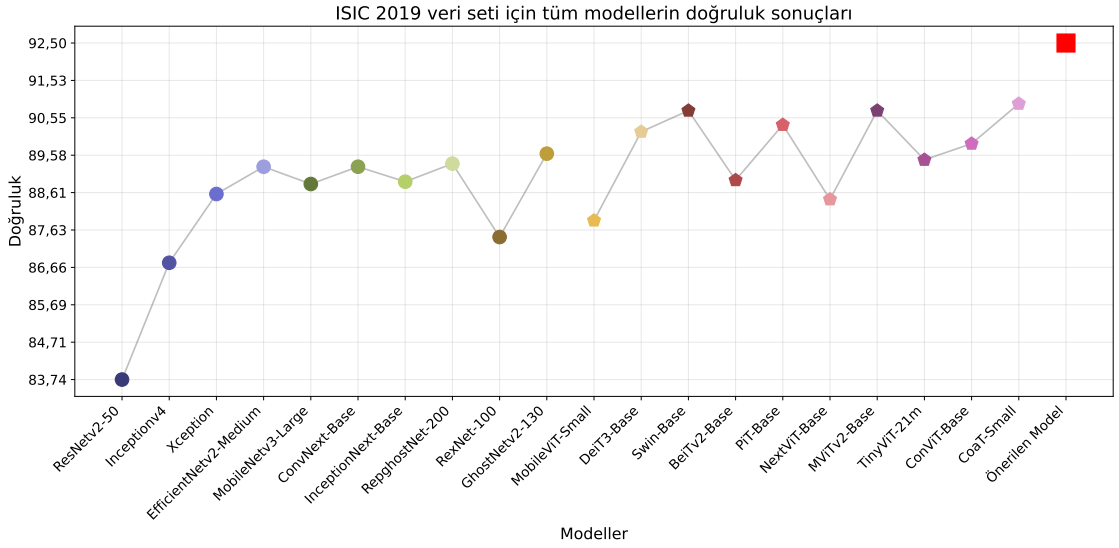

Şekil 3.5. Önerilen modelin ISIC 2019 veri seti üzerinde CNN tabanlı ve ViT tabanlı modellerle doğruluk değerlerinin karşılaştırması.

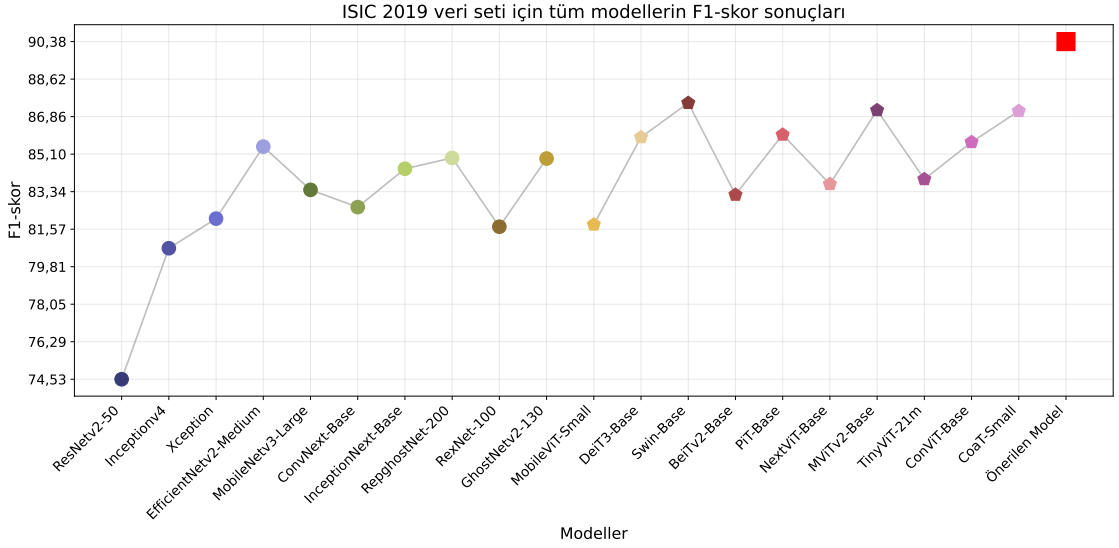

Şekil 3.6. Önerilen modelin ISIC 2019 veri seti üzerinde CNN tabanlı ve ViT tabanlı modellerle F1-skor değerlerinin karşılaştırması.

potansiyeli daha da pekiştirirken, diğer modellerin sunduğu sınırlı başarıları da gözler önüne sermektedir.

Şekil 3.7, önerilen MetaFormer tabanlı modelin ISIC 2019 veri setindeki karışıklık matrisini göstermektedir. Bu matris, modelin çeşitli cilt kanseri türlerinde güçlü performansını vurgulamaktadır. Ayrıca Tablo 3.9 önerilen modelin her bir sınıf için kesinlik, duyarlılık ve F1-skor değerlerini sunmaktadır. Şekil 3.7 ve Tablo 3.9 beraber değerlendirildiğinde, DF sınıfı %100 duyarlılık ve %95,65 kesinlik ile modelin en yüksek

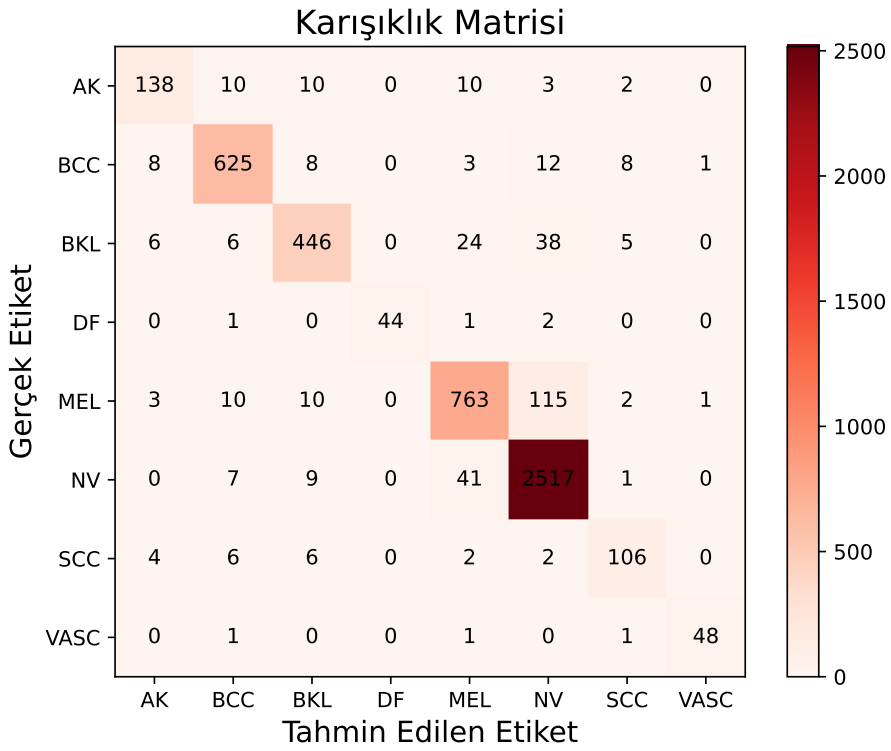

Şekil 3.7. ISIC 2019 veri seti üzerinde önerilen model için karışıklık matrisi.

performans sergilediği sınıf olup, TP sayısı 44 ve yanlış sınıflandırma sayısı yalnızca 4'tür. Bu sınıf, modelin yüksek doğrulukla sınıflandırdığı ve karışıklık yaşamadığı sınıf olarak dikkat çekmektedir. NV sınıfı ise, modelin yüksek performans gösterdiği diğer bir sınıf olarak öne çıkmaktadır. %97,75 kesinlik ve %93,60 duyarlılık ile bu sınıf, TP sayısı 2.517 ve FP sayısı yalnızca 58 ile son derece yüksek bir başarı elde etmiştir. F1-skoru %95,63 ile oldukça yüksek olup, modelin NV sınıfını ayırt etme konusunda son derece başarılı olduğunu göstermektedir.

AK ve SCC sınıfları ise modelin en düşük performans gösterdiği iki sınıf olarak yer almaktadır. Model AK sınıfında, %79,77 kesinlik ve %86,79 duyarlılık ile diğer sınıflara kıyasla daha düşük performans sergilemektedir. 138 görüntünün doğru sınıflandırılmasına rağmen 35 yanlış sınıflandırma ile kesinlik açısından düşük performans görülmektedir. Model SCC sınıfında ise %84,13 kesinlik ve %84,80 duyarlılık ile daha yüksek bir duyarlılığa sahip olsa da, 20 hatalı sınıflandırma neticesinde sınıf ayrımında zorlandığı belirgin olarak görülmektedir. Modelin bu iki sınıf lezyonlarını diğer sınıflara ait lezyonlara karıştırdığı açıkça anlaşılmaktadır.

Tablo 3.9. Önerilen modelin ISIC 2019 veri setindeki sınıf bazında performans metrikleri sonuçları

Sınıf	**Kesinlik (%)**	**Duyarlılık (%)**	**F1-skor (%)**
AK	79,77	86,79	83,13
BCC	93,98	93,84	93,91
BKL	84,95	91,21	87,97
DF	91,67	**100,00**	**95,65**
MEL	84,40	90,30	87,25
NV	**97,75**	93,60	95,63
SCC	84,13	84,80	84,46
VASC	94,12	96,00	95,05

Önerilen MetaFormer tabanlı model, ConvNeXt bileşenlerini entegre ederek mevcut yöntemlerden önemli ölçüde üstün performans sergilemektedir. CNN ve ViT mimarilerinin güçlü yönlerini etkili bir şekilde birleştirerek, model üstün doğruluk, kesinlik, duyarlılık ve F1-skoru elde etmektedir. Bu bulgular, modelin erken ve doğru cilt kanseri tanısı için değerli bir araç olarak potansiyelini vurgulamakta ve nihayetinde hasta sonuçlarını iyileştirmekte olduğunu göstermektedir.

3.6. Önerilen Modelin Güncel Hibrit Yöntemlerle Karşılaştırılması

Bu bölümde, önerilen hibrit model literatürdeki güncel hibrit modeller ile karşılaştırılmaktadır. Bu amaçla HAM10000 ve ISIC 2019 veri setlerini kullanan CNN ve ViT mimarilerine dayalı hibrit modeller seçilmiştir. Tablo 3.10, HAM10000 veri setinde test edilen çeşitli yöntemlerin performansının ayrıntılı bir karşılaştırmasını sunmaktadır. Tabloda verilen sonuçlar ilgili yayınlarda sunulan sonuçlardan alınmıştır. Araştırmacıların sunduğu sonuçlar doğrultusunda, önerilen model %94,30 doğruluk ile karşılaştırılan tüm modelleri geride bırakmıştır. Diğer taraftan %91,11 F1-skoru ile Khan ve ark. tarafından önerilen yöntemden sonra en yüksek skoru elde etmiştir. Bu sonuçlar, önerilen yöntemin karşılaştırılan yöntemleri geride bırakarak dengeli ve başarılı bir performans ortaya koyduğunu göstermektedir.

Tablo 3.10'da görüleceği üzere, Khan ve ark. tarafından geliştirilen model, %92,38 doğruluk ve %95,62 F1-skoru sunarak, yüksek F1-skoru ile öne çıkan bir çalışma olmuştur. Ancak, doğruluk açısından önerilen yöntemin biraz gerisinde kalmaktadır.

Tablo 3.10. HAM10000 veri seti üzerinde CNN ve ViT tabanlı hibrit yöntemlerin karşılaştırılması.

Yöntem	Yıl	Model	Veri seti	Doğruluk(%)	F1-skor(%)
Khan ve ark. [129]	2024	Hibrit (CNN-ViT)	HAM10000	92,38	**95,62**
Sajol ve ark. [130]	2024	Hibrit (CNN-ViT)	HAM10000	90,75	72,00
Tada and Han [131]	2023	Hibrit (CNN-ViT)	HAM10000	91,10	90,70
Guchhait ve ark. [132]	2024	Hibrit (CNN-ViT)	HAM10000	86,68	83,00
Gairola ve ark. [133]	2024	Hibrit (CNN-ViT)	HAM10000	86,00	84,00
Nie ve ark. [135]	2022	Hibrit (CNN-ViT)	HAM10000	89,48	89,09
Önerilen yöntem	2024	Hibrit (CNN-ViT)	HAM10000	**94,30**	91,11

Sajol ve ark. sunduğu model ise %90,75 doğruluk ve %72,00 F1-skoru ile dengeli sonuçlar sunma konusunda sınırlı kalmıştır.

Özellikle Tada ve Han'ın çalışması %91,10 doğruluk ve %90,70 F1-skoru ile dengeli bir sonuç ortaya koymuş, ancak önerilen yöntemin gerisinde kalmıştır. Guchhait ve ark. %86,68 doğruluk ve %83,00 F1-skoruna sahip modeli, sınıflandırma başarısının yanında doğruluk bakımından daha düşük seviyede kalırken, Gairola ve ark. tarafından yapılan çalışma %86,00 doğruluk ve %84,00 F1-skoru ile benzer bir sonuç sunmuştur.

Nie ve ark. çalışması ise %89,48 doğruluk ve %89,09 F1-skoru ile dengeli bir performans gösterse de, doğruluk açısından önerilen yöntemin altında kalmaktadır. Tablodaki veriler ışığında, önerilen hibrit CNN-ViT modelinin HAM10000 veri setinde rakiplerine kıyasla hem doğruluk hem de F1-skor açısından önemli bir gelişme sunduğu, dolayısıyla bu veri setinde cilt lezyonu sınıflandırmasında daha etkili bir çözüm sağladığı görülmektedir.

Tablo 3.11'de, önerilen yöntemin güncel CNN ve ViT tabanlı hibrit yöntemlerle karşılaştırması yapılmaktadır. Tablodaki ISIC 2019 veri seti üzerinde yapılan değerlendirme sonuçları, ilgili orijinal makalelerden alınmış değerlerdir. Sonuçlardan görüleceği üzere önerilen yöntem %92,50 doğruluk oranı ile karşılaştırılan hibrit yöntemleri geride bırakmıştır. Ayrıca %90,38 F1-skoru ile Khan ve Khan ile Zhang ve ark. tarafından önerilen yöntemler ile birlikte yüksek bir F1-skoruna ulaşmıştır.

Tabloda elde edilen sonuçlardan, Tada ve Han tarafından önerilen hibrit model, %87,20 doğruluk ve %79,80 F1-skoru elde etmiştir. Bu sonuçlar, genel olarak cilt lezyonu

sınıflandırmasında hibrit yaklaşımların temel potansiyelini yansıtmaktadır. Ancak, bu performans, diğer çalışmalarla karşılaştırıldığında daha düşük kalmaktadır. Pacal ve ark., hibrit CNN-ViT yöntemini kullanarak %89,36 doğruluk ve %86,65 F1-skoru elde etmişlerdir. Bu çalışma, hibrit modelin genel başarısını artırmaya yönelik önemli bir adım teşkil etmektedir.

Tablo 3.11. ISIC 2019 veri seti üzerinde CNN ve ViT tabanlı hibrit yöntemlerin karşılaştırılması.

Yöntem	**Yıl**	**Model**	**Veri seti**	**Doğruluk(%)**	**F1-skor(%)**
Tada and Han [131]	2023	Hibrit (CNN-ViT)	ISIC 2019	87,20	79,80
Pacal et al. [7]	2024	Hibrit (CNN-ViT)	ISIC 2019	89,36	86,65
Khan ve ark. [134]	2024	Hibrit (CNN-ViT)	ISIC 2019	84,33	-
Ansari ve ark. [137]	2024	Hibrit (CNN-ViT)	ISIC 2019	87,33	87,26
Zhang ve ark. [138]	2023	Hibrit (CNN-ViT)	ISIC 2019	90,73	90,61
Khan ve Khan [136]	2023	Hibrit (CNN-ViT)	ISIC 2019	91,09	**91,58**
Önerilen yöntem	2024	Hibrit (CNN-ViT)	ISIC 2019	**92,50**	90,38

Khan ve ark. tarafından gerçekleştirilen çalışma, %84,33 doğruluk ile sınırlı kalmış ve F1-skoru rapor edilmemiştir. Ansari ve ark., hibrit yaklaşım ile %87,33 doğruluk ve %87,26 F1-skoru elde ederek, cilt lezyonu sınıflandırmasında belirgin bir ilerleme kaydetmişlerdir. Zhang ve ark., %90,73 doğruluk ve %90,61 F1-skoru ile elde ettikleri sonuçlarla, hibrit CNN-ViT yönteminin uygulama alanında sağladığı faydaları ortaya koymuşlardır. Bu çalışma, daha önceki yöntemlerin etkinliğini artırarak, araştırma alanında önemli bir katkı sağlamaktadır. Khan ve Khan tarafından geliştirilen model, %91,09 doğruluk ve %91,58 F1-skoru ile dikkat çekici bir başarı elde etmiştir. Hibrit modelin cilt lezyonu sınıflandırmasında sağlam bir temel oluşturduğunu göstermektedir. Bu sonuç, hibrit yaklaşımların öğrenme süreçlerindeki verimliliğini desteklemektedir.

Yapılan değerlendirmeler önerilen hibrit CNN ve ViT tabanlı yönteminin ISIC 2019 veri seti üzerindeki etkinliğini açıkça ortaya koymaktadır. Elde edilen sayısal sonuçlar, geliştirilen modelin, diğer çalışmalarla karşılaştırıldığında üstünlük sağladığını göstermektedir. Önerilen yöntemin başarısı, hibrit CNN ve ViT tabanlı yöntemlerin cilt lezyonu sınıflandırmasındaki potansiyelini ortaya koymaktadır.

3.7. Değerlendirme

Bu çalışmada, cilt kanseri sınıflandırması için önerilen MetaFormer tabanlı CAFormer modelinin performansı, ConvNeXt blokları ile güçlendirilmiş bir mimari üzerinden detaylı bir şekilde incelenmiştir. Önerilen model mimarisi, DL alanındaki en son teknolojilerin entegrasyonunu yansıtmaktadır. Bu bağlamda, ConvNeXt bloklarının eklenmesi, modelin öznitelik çıkarma yeteneklerini ve genel performansını artırma amacı taşımaktadır. Bu durum, modelin cilt lezyonlarının sınıflandırılmasında daha etkili bir çözüm sunduğunu göstermiştir.

Yöntemin parametrelerini belirleme çalışmaları, her bir bileşenin modelin genel performansına katkısını anlamak için gerçekleştirilmiştir. Bu çalışmalar, özellikle ConvNeXt bloklarının entegrasyonunun modelin başarısında önemli bir rol oynadığını göstermiştir. Modelin karmaşıklığının artırılmasıyla birlikte, sınıflandırma performansında gözlemlenen iyileşmeler, DL mimarilerinin yapılandırılmasında dikkate alınması gereken önemli bir faktör olmuştur.

Deney sonuçları, önerilen modelin hem HAM10000 hem de ISIC 2019 veri setlerinde diğer mevcut yöntemlerle karşılaştırıldığında üstün performans sergilediğini göstermiştir. Özellikle, modelin HAM10000 veri setindeki elde ettiği %94,30 doğruluk, %93,00 kesinlik, %89,59 duyarlılık ve %91,11 F1-skoru, cilt kanseri lezyonlarını güvenilir bir şekilde sınıflandırma kapasitesini vurgulamıştır. Ayrıca, ISIC 2019 veri setinde %92,50 doğruluk, %92,07 kesinlik, %88,85 duyarlılık ve %90,38 F1-skoru elde edilmiştir. Bu bulgular, modelin klinik uygulamalar için güçlü bir araç olduğunu ortaya koymuştur.

Yukarıdaki bulgulara dayanarak, önerilen MetaFormer tabanlı modelin hem HAM10000 hem de ISIC 2019 veri setlerinde güncel CNN ve ViT tabanlı yöntemlerini geride bıraktığı ve cilt kanseri sınıflandırmasındaki üstün performansını gösterdiği sonucuna varılabilmektedir. Modelin, CNN ve ViT mimarilerini etkili bir şekilde entegre etmesi ve veri dengesizliğini ele alma yeteneği, başarısına önemli ölçüde katkıda bulunmuştur. Bu sonuçlar, önerilen yaklaşımın cilt kanseri teşhisini ve klinik sonuçları iyileştirme potansiyelini vurgulamaktadır.

4. BÖLÜM

CİLT KANSERİNİN SINIFLANDIRILMASI İÇİN YENİ BİR HİBRİT TOPLULUK ÖĞRENME MODELİ

Bu bölümde öncelikle, geliştirilen topluluk öğrenmesi tabanlı hibrit model tanıtılmaktadır. Ardından, önerilen yöntemde yer alan CNN ve ViT mimarilerinin eğitiminde kullanılan veri ön işleme ve veri artırma aşamaları sunulmaktadır. Daha sonra, önerilen topluluk öğrenme tabanlı hibrit model ile gerçekleştirilen deneylerin görsel ve sayısal sonuçları verilmektedir. Son olarak, önerilen modelin literatürdeki güncel yöntemlerle karşılaştırılması ve bu bağlamda yapılan değerlendirmeler sunulmaktadır.

4.1. Geliştirilen CNN ve ViT Tabanlı Hibrit Topluluk Öğrenme Modeli

Önerilen hibrit topluluk öğrenme modeli cilt kanseri sınıflandırılmasında yüksek doğruluk ve güvenilirlik elde etmeyi hedefleyen, farklı CNN ve ViT mimarilerinin birlikte kullanıldığı bir modeldir. Cilt kanseri sınıflandırmasında derin öğrenme mimarilerinin kullanımı, özellikle CNN ve ViT gibi modellerin avantajları ile, bu alanın tanı doğruluğunu artırmada önemli bir rol oynamaktadır. CNN mimarileri, görüntü işleme görevlerinde etkinlikleri ile öne çıkarak, yerel öznitelikleri yakalama ve görsel örüntüleri öğrenme konularında üstün performans göstermektedir. Özellikle evrişim katmanları, yerel özniteliklerin etkin şekilde algılanmasını sağlayarak, kenar bilgileri ve dokusal yapılar gibi cilt görüntülerinde kritik öneme sahip özniteliklerin doğru bir şekilde öğrenilmesine olanak tanımaktadır.

ViT mimarileri ise, dikkat mekanizmaları sayesinde uzun menzilli bağıntıları modelleyebilme kapasitesine sahiptir. Bu yapı, özellikle cilt kanseri sınıflandırmasında tümör boyutu, çevresel dokular ve renk farklılıkları gibi daha karmaşık ve bağlamsal

bilgilerin analiz edilmesini mümkün kılmaktadır. Ayrıca, ViT modellerinin öğrenme kapasitesinin büyük ölçekli veri setlerinde etkili olduğu ve modelin genelleme yeteneğini artırdığı gözlemlenmektedir.

Bu iki modelin, topluluk öğrenme tabanlı hibrit mimari yaklaşımlarında bir araya getirilmesi, CNN ile ViT mimarilerinin öğrenme yeteneğini birleştirerek, cilt kanseri sınıflandırmasında tanı doğruluğunu ve modelin genelleme kabiliyetini artırma potansiyeline sahiptir. Topluluk öğrenmesi sayesinde, farklı modellerin avantajlarından birlikte faydalanılarak daha güvenilir, dayanıklı ve yüksek performanslı sınıflandırma modelleri geliştirilebilmektedir. Buradan hareketle, tez çalışmasının bu bölümünde, topluluk öğrenme tabanlı, CNN ve ViT mimarileri ile oluşturulmuş hibrit bir model önerilerek hem CNN hem de ViT modellerinin artılarının bir araya getirilmesi amaçlanmaktadır.

Önemli topluluk öğrenmesi tekniklerinden biri olan esnek oylama, farklı modellerin sonuçlarını ağırlıklandırılarak birleştirilmesi prensibine dayanan bir yaklaşımdır. Bu yöntem, her bir modelin ürettiği sınıf olasılıklarının ortalamasını alarak en yüksek olasılığa sahip sınıfı nihai tahmin olarak belirlemektedir. Bu nedenle esnek oylama, daha kesin ve genelleştirilebilir sonuçlar elde etme potansiyeline sahiptir. Şekil 4.1'de mimarisi görülen önerilen esnek oylama topluluk öğrenme modeli, cilt kanseri görüntülerin otomatik sınıflandırılması amacıyla CNN ve ViT modelleri kullanılarak tasarlanmıştır.

Topluluk öğrenme yöntemlerinden diğer önemli bir yaklaşımı ise katı oylama yöntemidir. Katı oylama, topluluk öğrenmesi yöntemlerinde farklı modellerin tahmin ettiği sınıflar arasından çoğunluk kuralına göre nihai sınıfı belirleyen bir yaklaşımdır. Bu yöntemde, her bir modelin oy hakkı eşit olup, hangi sınıf en fazla oy alırsa o sınıf topluluğun kararı olarak kabul edilmektedir. Katı oylama, sınıf olasılıkları yerine modellerin kesin tahminlerine dayanmaktadır. Bu yaklaşımın önemi, özellikle hızlı ve basit topluluk öğrenme stratejileri gerektiren durumlarda öne çıkmasıdır. Modeller arasında bir denge sağlamak ve aşırı karmaşık hesaplamalardan kaçınmak isteyen sistemlerde etkili bir yöntemdir. Cilt kanseri lezyonlarının sınıflandırılması için CNN ve ViT modelleri kullanılarak tasarlanmış önerilen katı oylama topluluk öğrenme modelinin mimarisi Şekil 4.2'de görülmektedir.

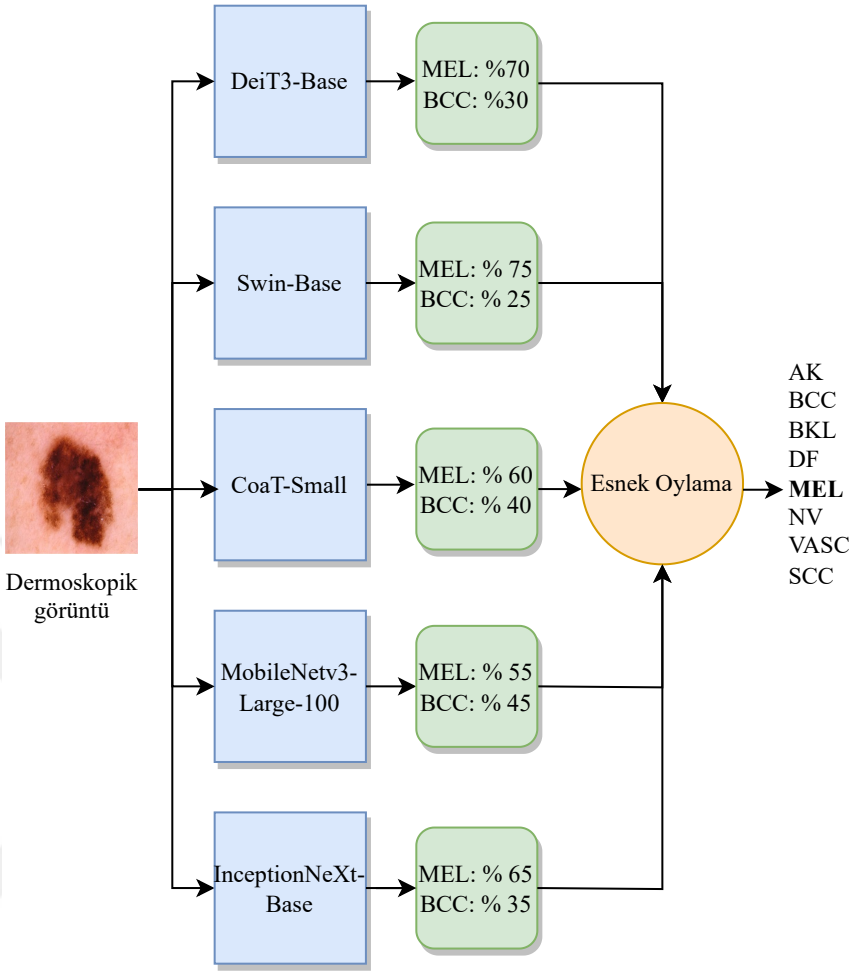

Şekil 4.1. Önerilen CNN ve ViT tabanlı hibrit esnek oylama topluluk öğrenme mimarisi.

Bu bölümde gerçekleştirilen deneylerde, literatürde başarılı sonuçlar veren Res2NeXt-50, MobileNetv3-Large, EfficientNetV2-Medium, InceptionNeXt-Base ve ConvNeXt-Base CNN modelleri ile, PiT-Base, MViTv2-Base, CoaT-Small, DeiT3-Base ve Swin-Base ViT modelleri kullanılmıştır. Ön eğitimli modeller kullanılarak yapılan deneylerin sonuçları takip eden bölümlerde verilmektedir.

4.2. Veri Ön İşleme ve Veri Artırma

Çalışmamızda, veri setini zenginleştirmek ve modelin genelleme yeteneğini artırmak amacıyla çevrimiçi veri artırma yöntemleri kullanılmıştır. Çevrimiçi veri artırma, eğitim sırasında dinamik olarak yeni veri türevleri oluşturmayı mümkün kılarak modelin her eğitim döngüsünde farklı örneklerle beslenmesini sağlamaktadır. Bu süreçte, görüntü döndürme, kırpma ve ölçekleme teknikleri uygulanmıştır. Böylece modelin çeşitli gürültü

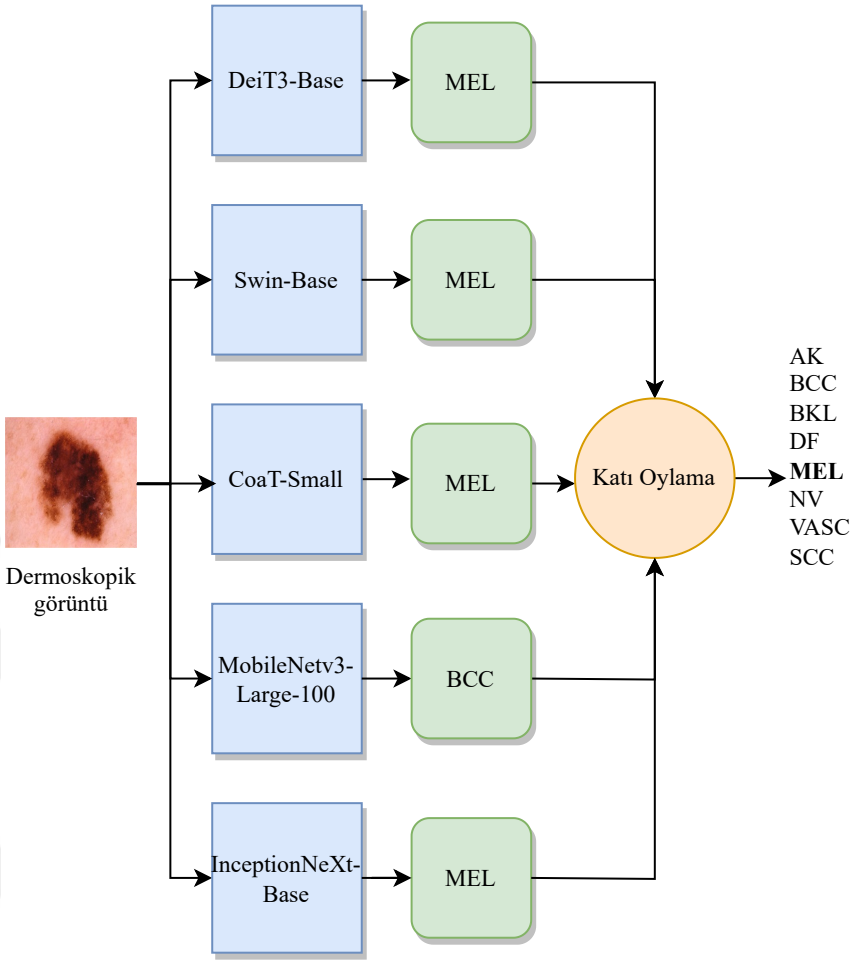

Şekil 4.2. Önerilen CNN ve ViT tabanlı hibrit katı oylama topluluk öğrenme mimarisi.

ve sapmalara karşı dayanıklılığı artırılmıştır. Bu strateji, hem modelin aşırı öğrenme riskini azaltmış hem de doğruluğunu ve genelleme performansını yükseltmiştir.

HAM10000 veri seti, toplamda 10.015 adet görüntü içermektedir. Bu görüntülerin %80'i (8.011 görüntü) eğitim aşamasında kullanılmak üzere ayrılmış, %10'u (1.002 görüntü) doğrulama veri seti olarak belirlenmiş ve geri kalan %10'u (1.002 görüntü) test veri seti amacıyla ayrılmıştır. ISIC 2019 veri setinde ise 25.331 görüntü mevcuttur. Bunların %80'i (20.263 görüntü) eğitim veri seti için, %10'u (2.534 görüntü) doğrulama veri seti olarak ve %10'u (2.534 görüntü) test veri seti olarak ayrılmıştır. DL modellerinin eğitim, doğrulama ve test süreçleri, bu dağılım sistemine titizlikle uyularak yürütülmüştür. Tablo 4.1, HAM10000 veri setinin için, Tablo 4.2 ise ISIC 2019 veri seti için eğitim, doğrulama ve test amaçları için kullanılan görüntü sayılarını göstermektedir.

Tablo 4.1. HAM10000 veri setinin eğitim, doğrulama, test ve toplam dağılımı.

Sınıflar	**AK**	**BCC**	**BKL**	**DF**	**MEL**	**NV**	**VASC**	**Toplam**
Eğitim verisi (%80)	261	412	879	91	890	5.364	114	8.011
Doğrulama verisi (%10)	32	52	110	11	112	671	14	1.002
Test verisi (%10)	32	52	110	11	112	671	14	1.002
Toplam	327	514	1.099	115	1.113	6.705	142	10.015

Tablo 4.2. ISIC 2019 veri setinin eğitim, doğrulama, test ve toplam dağılımı.

Sınıflar	**AK**	**BCC**	**BKL**	**DF**	**MEL**	**NV**	**VASC**	**SCC**	**Toplam**
Eğitim verisi (%80)	693	2.659	2.100	191	3.616	10.297	203	504	20.263
Doğrulama verisi (%10)	86	333	263	24	452	1.287	26	63	2.534
Test verisi (%10)	86	333	263	24	452	1.287	26	63	2.534
Toplam	867	3.323	2.624	239	4.522	12.875	253	628	25.331

4.3. Oluşturulan Hibrit Modelin Eğitimi

Önerilen yöntemde, veri artırma ve transfer öğrenme gibi stratejiler kullanılarak modelin doğruluğu, genelleme yeteneği ve performansı artırılmaya çalışılmıştır. Değerlendirilen tüm modellerin kararlılığını ve performansını artırmak için görüntü döndürme, kırpma ve ölçekleme veri artırma teknikleri uygulanmıştır. Ayrıca, transfer öğrenme sürecinde modellerin ImageNet'ten hesaplama ağırlıklarını ekleyerek yakınsamanın hızlanmasını ve doğruluğun artması sağlanmıştır. Tüm modellere 224 × 224 boyutlarında giriş çözünürlüğünü verilmiştir. Tüm modellerin eğitimi için temel parametreler arasında öğrenme oranı olarak 0,001, temel öğrenme oranı olarak 0,1, optimizasyon algoritması olarak SGD optimizasyon algoritması, momentum değeri olarak 0,9, epok sayısı olarak 5, epok öğrenme oranı olarak 1,0e-05 ve yığın boyutu olarak 16 seçilmiştir.

Deneyler, Intel Core i5 13600K işlemci, 32 GB DDR5 RAM ve NVIDIA RTX 3090 grafik kartına sahip, Ubuntu 22.04 işletim sistemli bir Linux bilgisayarda yürütülmüştür. Deneylerde, NVIDIA CUDA desteği ile PyTorch çerçevesi kullanılarak tüm modeller aynı parametrelerle eğitilmiştir. Böylece hem eğitim hem de test aşamalarında tutarlı bir ortam sağlanmıştır.

4.4. Geliştirilen Topluluk Öğrenmesi Tabanlı Hibrit Model Deney Sonuçları

Bu bölümde, önerilen topluluk öğrenme tabanlı hibrit modelin HAM10000 ve ISIC 2019 cilt lezyonu veri setleri üzerindeki performansı değerlendirilmektedir. Modelin genel performansı, doğruluk, kesinlik, duyarlılık ve F1-skoru gibi metrikler ile ölçülmektedir. Ayrıca, deneylerde kullanılan veri ön işleme ve veri artırma stratejilerinin modelin öğrenme sürecine katkıları incelenmiş ve topluluk öğrenme yaklaşımının sınıflandırma doğruluğuna olan etkisi analiz edilmiştir. Elde edilen sonuçlar ile modelin genelleme yeteneği ayrıntılı olarak ele alınmıştır.

4.4.1. Önerilen Topluluk Öğrenmesi Tabanlı Modelin HAM10000 Veri Seti için Deney Sonuçları

Bu bölümde literatürde başarılı olduğu görülmüş beş CNN ve beş ViT tabanlı model karşılaştırılmaktadır. Tablo 4.3'te HAM10000 veri seti üzerindeki CNN ve ViT tabanlı modellerin performans sonuçları verilmiştir. Tablo incelendiğinde, CNN modelleri arasında en yüksek performansa sahip olan modelin, %92,32 doğruluk ile MobileNetv3-Large modeli olduğu görülmüştür. Bu model, %92,18 kesinlik ve %92,32 duyarlılık değerleri ile dengeli bir performans sergilemekte ve genel sınıflandırma görevlerinde en iyi sonuçları elde etmektedir. Diğer başarılı modeller arasında %92,22 doğrulukla InceptionNeXt-Base modeli ve %91,72 doğrulukla ConvNeXt-Base modeli yer almaktadır. Bu modeller, sırasıyla %92,05 ve %91,71 kesinlik ile %92,22 ve %91,72 duyarlılık değerlerine sahip olarak, yüksek doğruluk oranlarıyla dikkat çekmektedir.

Tabloya göre tüm mimariler içerisinde en düşük performansı gösteren modelin Res2NeXt-50 olduğu görülmüştür. Bu model, %90,22 doğruluk ile birlikte %84,94 kesinlik ve %78,48 duyarlılık değerlerine sahiptir. Bu sonuçlar ile modelin cilt kanseri sınıflandırmasında diğer modellere nazaran başarısız olduğu görülmüştür. Bununla birlikte, EfficientNetv2-Medium modeli %91,42 doğruluk ile iyi bir performans sergilemesine rağmen, %86,82 kesinlik ve %82,32 duyarlılık değerlerinin MobileNetv3-Large gibi en iyi modellerin altında kalması, bu modelin de belirli sınıflar üzerinde zayıf kaldığını ortaya koymaktadır.

Tablo 4.3. CNN ve ViT tabanlı modellerin HAM10000 veri seti üzerindeki sonuçları.

Modeller	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**F1-skor(%)**
Res2NeXt-50	90,22	84,94	78,48	81,43
MobileNetv3-Large	92,32	92,18	92,32	92,20
EfficientNetv2-Medium	91,42	86,82	82,32	84,29
InceptionNeXt-Base	92,22	92,05	92,22	92,10
ConvNeXt-Base	91,72	91,71	91,72	91,65
PiT-Base	92,42	89,79	86,01	87,78
MViTv2-Base	92,42	89,28	85,48	87,11
CoaT-Small	92,61	92,53	92,61	92,51
DeiT3-Base	**92,81**	**92,70**	**92,81**	**92,71**
Swin-Base	92,61	92,60	92,61	92,57

ViT modelleri arasında ise en iyi performansı %92,81 doğruluk ile DeiT3-Base modeli elde etmiştir. Bu model, %92,70 kesinlik, %92,81 duyarlılık ve %92,71 F1-skor değeri sunarak güçlü bir performans sergilemektedir. CoaT-Small modeli ile Swin-Base modeli, %92,61 doğruluk ile benzer bir performans sergilemiştir. Bu modeller, sırasıyla %92,53 ve %92,60 kesinlik değeri ile %92,61 ortak duyarlılık değerleri sunarak güçlü bir performans göstermiştir. Bu durum, modellerin genel sınıflandırma performansının iyi olduğunu göstermektedir.

ViT tabanlı modeller içerisinde nispeten en düşük performansa sahip olan modeller olarak PiT-Base ve MViTv2-Base görülmektedir. Bu modeller %92,42 doğruluk değeri ile aynı sonucu vermişlerdir. Modeller sırasıyla %89,79 ve %89,28 kesinlik ile yine yakın sonuçlar elde etmiştir. Duyarlılık değerleri olarak sırasıyla %86,01 ile %85,48 oranları ile diğer güçlü modellerden daha düşük bir performans sergilemektedirler.

Tablo 4.4'te HAM10000 veri seti üzerinde gerçekleştirilen topluluk öğrenme sonuçları, çeşitli model kombinasyonlarının esnek ve katı oylama yöntemleriyle değerlendirilmesini içermektedir. Esnek oylama yöntemiyle elde edilen en yüksek başarı, %94,31 doğruluk ile DeiT3-Base, Swin-Base, CoaT-Small ve MobileNetv3-Large, InceptionNeXt-Base modellerinin bir araya gelmesiyle sağlanmıştır. Bu kombinasyon, %94,43 F1-skoru ile de dikkat çekmektedir. Bu kombinasyonda, tüm modellerin katkıları, sınıflandırma görevinde etkili bir yapı oluşturarak yüksek bir performans göstermiştir. Diğer dikkat

çekici bir topluluk ise DeiT3-Base, Swin-Base, CoaT-Small ve MobileNetv3-Large modellerinin bir araya geldiği kombinasyon olup, %94,01 doğruluk ve %93,94 F1-skoru elde etmiştir.

Katı oylama yöntemiyle en iyi sonuç, yine DeiT3-Base, Swin-Base, CoaT-Small, MobileNetv3-Large ve InceptionNeXt-Base modellerinin kombinasyonunda elde edilmiştir. Bu topluluk modeli, %94,01 doğruluk ve %93,92 F1-skoru ile birlikte önemli bir başarı göstermektedir. Ayrıca, DeiT3-Base, Swin-Base ve MobileNetv3-Large modellerinin bir arada kullanıldığı grup, %93,91 doğruluk ve %93,84 F1-skoru elde etmiştir. Bu durum, bu modellerin topluluk içinde önemli bir yer tuttuğunu göstermektedir.

Esnek oylama ile yapılan deneylerde, InceptionNeXt-Base ve MobileNetv3-Large modellerinin kombinasyonu %93,41 doğruluk sağlamıştır. Ayrıca, DeiT3-Base ve CoaT-Small modellerinin kombinasyonu %93,91 doğruluk elde ederek etkileyici bir performans sergilemiştir.

Diğer önemli sonuçlar arasında, ConvNeXt-Base ve MobileNetv3-Large modellerinin kombinasyonu %93,01 doğruluk elde ederken, InceptionNeXt-Base ve MobileNetv3-Large kombinasyonu %93,41 doğrulukla dikkat çekmiştir. Bu da gösteriyor ki, en başarılı model olan MobileNetv3-Large başka modeller ile bir araya geldiğinde de başarısını önemli ölçüde artırabilmektedir. Topluluk öğrenme yöntemlerinin model performansını artırma potansiyelini açıkça ortaya koymakta ve hangi modellerin belirli görevlerde daha etkili olduğunu göstermektedir.

Şekil 4.3'te, önerilen topluluk öğrenme modelin HAM10000 veri setindeki karışıklık matrisini göstermektedir. Ayrıca Tablo 4.5'te verilen sınıf performansları, modelin çeşitli sınıflar üzerindeki başarısını ve sınıflandırma doğruluğunu yansıtmaktadır. Bu değerlendirme, her bir sınıfın kesinlik, duyarlılık ve F1-skoru gibi önemli metriklere dayalı olarak incelenmesini sağlamaktadır. Modelin genel performansı, her sınıf için elde edilen başarıları karşılaştırarak, hangi sınıflarda iyi sonuçlar elde edildiğini ve hangi sınıflarda iyileştirme yapılması gerektiğini ortaya koymaktadır. Aşağıda, her bir sınıfın performansına dair detaylı analizler sunulmaktadır.

Tablo 4.4. HAM10000 veri seti üzerindeki topluluk öğrenme sonuçları.

Kombinasyonlar	**Esnek oylama**				**Katı oylama**			
	Doğruluk (%)	**Kesinlik (%)**	**Duyarlılık (%)**	**F1-skor (%)**	**Doğruluk (%)**	**Kesinlik (%)**	**Duyarlılık (%)**	**F1-skor (%)**
ConvNeXt-Base MobileNetv3-Large	93,01	92,96	93,01	92,93	91,72	91,71	91,72	91,65
InceptionNeXt-Base MobileNetv3-Large	93,41	93,27	93,41	93,29	92,51	92,63	92,51	92,52
InceptionNeXt-Base MobileNetv3-Large ConvNeXt-Base	93,01	92,94	93,01	92,95	92,61	92,54	92,61	92,54
DeiT3-Base Swin-Base	93,31	93,29	93,31	93,26	92,81	93,03	92,81	92,88
DeiT3-Base CoaT-Small	93,91	93,75	93,91	93,79	92,71	92,98	92,71	92,79
DeiT3-Base Swin-Base CoaT-Small	93,41	93,33	93,41	93,34	93,21	93,24	93,21	93,18
DeiT3-Base MobileNetv3-Large	92,81	92,68	92,81	92,69	93,11	93,34	93,11	93,19
DeiT3-Base Swin-Base MobileNetv3-Large	93,91	93,83	93,91	93,84	93,51	93,49	93,51	93,47
DeiT3-Base Swin-Base CoaT-Small MobileNetv3-Large	94,01	93,92	94,01	93,94	93,61	93,69	93,61	93,62
DeiT3-Base Swin-Base CoaT-Small MobileNetv3-Large InceptionNeXt-Base	**94,31**	**94,44**	**94,31**	**94,43**	**94,01**	**93,91**	**94,01**	**93,92**

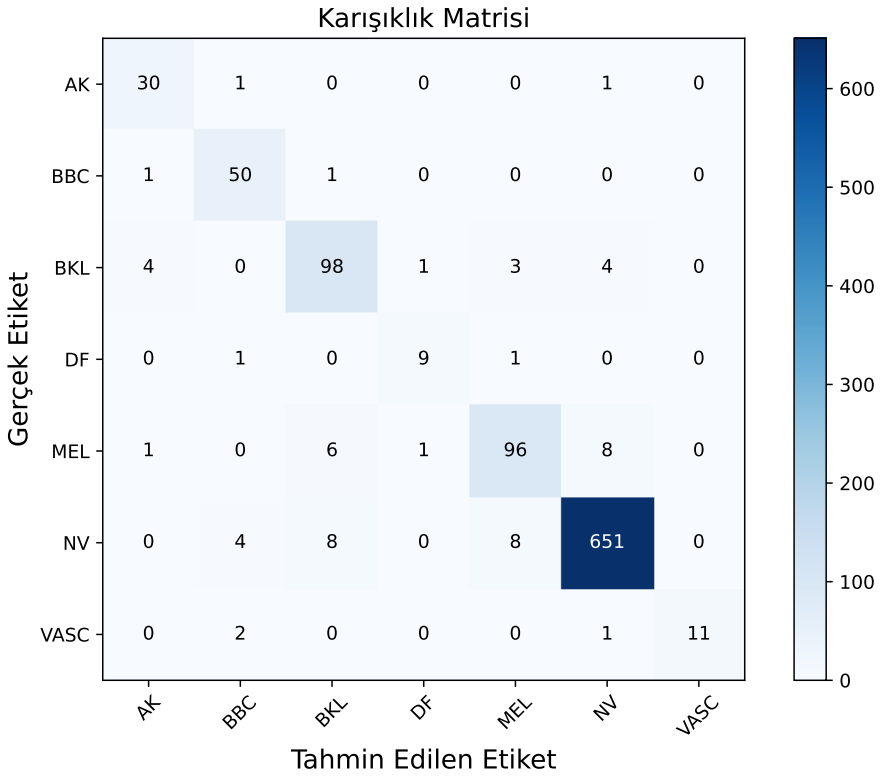

Şekil 4.3. HAM10000 veri seti üzerinde önerilen CNN ve ViT tabanlı topluluk öğrenme modelinin karışıklık matrisi.

NV sınıfı, modelin en iyi performans gösterdiği sınıf olarak öne çıkmaktadır. %97,02 kesinlik ve %97,89 duyarlılık ile yüksek doğruluk ve duyarlılık elde edilmiştir. 651 TP ve yalnızca 20 yanlış sınıflandırma ile model bu sınıfı oldukça doğru bir şekilde tanımaktadır. F1-skoru %97,46 olup, modelin NV sınıfını ayırt etme konusunda başarılı olduğunu göstermektedir.

BBC ve VASC sınıfları, modelin yüksek doğrulukla sınıflandırdığı ancak farklı performans dinamiklerine sahip sınıflardır. BBC sınıfında model, %96,15 kesinlik ve %86,21 duyarlılık ile oldukça başarılı bir performans sergilemiştir. 50 TP ve 2 FP ile bu sınıf doğru bir şekilde tanınmıştır. VASC sınıfı ise %78,57 kesinlik ile düşük bir kesinlik oranına sahipken, %100 duyarlılık oranı dikkat çekicidir. 11 TP ve 3 FP ile model, bu sınıfı tanımakta zorluk çekmemiştir, ancak kesinlik açısından bazı zorluklar yaşanmıştır. Duyarlılığın yüksek olması, modelin bu sınıfı doğru tanımakta güçlü olduğunu fakat yanlış pozitiflerin sayısının artmasının modelin kesinliğini olumsuz etkilediğini göstermektedir.

Tablo 4.5. Önerilen modelin HAM10000 veri setindeki sınıf bazında performans metrikleri sonuçları

Sınıf	**Kesinlik (%)**	**Duyarlılık (%)**	**F1-skor (%)**
AK	93,75	83,33	88,24
BBC	96,15	86,21	90,91
BKL	89,09	86,73	87,89
DF	81,82	81,82	81,82
MEL	85,71	88,89	87,27
NV	**97,02**	97,89	**97,46**
VASC	78,57	**100,00**	88,00

AK ve MEL sınıfları, modelin daha düşük performans gösterdiği sınıflardır. AK sınıfı, %93,75 kesinlik ve %83,33 duyarlılık ile modelin ortalama performans sergilediği bir sınıftır. 30 doğru ve 2 yanlış sınıflandırma ile iyi bir tanıma sağlanmıştır. Ancak duyarlılık açısından diğer sınıflara kıyasla daha zayıf kalmıştır. F1-skoru %88,24 ile düşük bir seviyede yer almaktadır. MEL sınıfı ise %85,71 kesinlik ve %88,89 duyarlılık ile daha yüksek bir duyarlılığa sahip olsa da, 16 FP ile modelin yanlış tanıma oranı biraz daha yüksektir. F1-skoru %87,27 olup, modelin bu sınıfı doğru tanımada iyi olduğunu ancak yanlış pozitiflerin kesinlik açısından zayıflık oluşturduğunu göstermektedir.

BKL ve DF sınıfları, modelin zorlandığı diğer sınıflardır. BKL sınıfı, %89,09 kesinlik ve %86,73 duyarlılık ile iyi bir performans gösterirken, 12 FP ile doğru tanınma oranı biraz düşüktür. F1-skoru %87,89 ile model BKL sınıfında, iyi bir performans sergilese de, daha fazla iyileştirmeye ihtiyaç duyduğunu göstermektedir. DF sınıfında ise %81,82 kesinlik ve %81,82 duyarlılık ile model oldukça zayıf bir performans sergilemektedir. 9 TP ve 2 FP ile sınıfın doğru tanınmasında sıkıntılar yaşamıştır, F1-skoru %81,82 ile bu zayıflıkları ortaya koymaktadır. Modelin DF sınıfında iyileştirilmesi gereken çok alan olduğu açıktır.

4.4.2. Önerilen Topluluk Öğrenmesi Tabanlı Modelin ISIC 2019 Veri Seti için Deney Sonuçları

ISIC 2019 veri seti üzerinde değerlendirilen CNN ve ViT tabanlı modellerin performans sonuçları Tablo 4.6'da verilmektedir. Çeşitli metrikler kullanılarak incelenen CNN modelleri arasında en yüksek başarıyı %91,91 doğruluk ile EfficientNetv2-Medium modeli elde etmiştir. Bu model, %91,94 kesinlik ve %91,91 duyarlılık değerleri

ile dengeli bir performans sunarak genel sınıflandırma görevlerinde en iyi sonuçları sağlamaktadır. Bunun yanında, ConvNeXt-Base modeli %90,81 doğruluk ile dikkat çekmektedir. %90,71 kesinlik ve %90,81 duyarlılık değerleri, bu modelin sınıflandırma görevinde oldukça başarılı olduğunu göstermektedir. Diğer güçlü modeller arasında %89,78 doğrulukla MobileNetv3-Large öne çıkmaktadır. Bu model, %84,81 kesinlik ve %82,60 duyarlılık değerleri ile orta derecede performans sergilemektedir.

Tablo 4.6. CNN ve ViT tabanlı modellerin ISIC 2019 veri seti üzerindeki sonuçları.

Modeller	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**F1-skor(%)**
Res2NeXt-50	89,46	86,73	83,24	84,88
MobileNetv3-Large	89,78	84,81	82,60	83,56
EfficientNetv2-Medium	91,91	91,94	91,91	91,86
InceptionNeXt-Base	89,70	87,40	83,12	85,09
ConvNeXt-Base	90,81	90,71	90,81	90,73
PiT-Base	91,91	91,81	91,91	91,79
MViTv2-Base	91,52	87,83	86,75	87,08
CoaT-Small	91,79	91,77	91,79	91,74
DeiT3-Base	91,04	87,74	84,14	85,67
Swin-Base	**92,30**	**92,28**	**92,30**	**92,26**

En düşük performansa sahip model ise %89,46 doğruluk ile Res2NeXt-50 modelidir. Bu model, %86,73 kesinlik ve %83,24 duyarlılık değerleri ile diğer modellere kıyasla daha zayıf bir sonuç ortaya koymaktadır. Ayrıca, MobileNetv3-Large modeli %89,78 doğrulukla benzer bir seviyede kalmakta, ancak %84,81 kesinlik ve %82,60 duyarlılık değerlerinin daha düşük olması, bu modelin sınıflandırmada bazı güçlüklerle karşılaştığını göstermektedir.

ViT modelleri arasında en yüksek performansı Swin-Base ve PiT-Base modelleri göstermektedir. Swin-Base, %92,30 doğruluk ve %92,26 F1-skoru ile veri setindeki en iyi performansa sahiptir. Bu yüksek skorlar, Swin-Base modelinin dikkat mekanizmasının, görüntü boyunca detaylı öznitelikleri verimli şekilde öğrenebildiğini ve tanıyabildiğini göstermektedir. PiT-Base de %91,91 doğruluk, %91,81 kesinlik ve %91,79 F1-skoru ile üst düzeyde başarılıdır. Bu sonuçlar, PiT-Base modelinin geniş bağlamlı pikseller arasındaki ilişkileri yakalayabildiğini ve yüksek bir genel başarı sağladığını işaret etmektedir.

Orta düzey performans gösteren modeller arasında MViTv2-Base ve DeiT3-Base yer almaktadır. MViTv2-Base modeli %91,52 doğruluk, %87,83 kesinlik ve %87,08 F1-skoru ile dengeli bir performans sunarken, DeiT3-Base %91,04 doğruluk, %87,74 kesinlik ve %85,67 F1-skoru ile dikkat çekmektedir. Bu modellerin duyarlılık ve F1-skorları nispeten düşük kalmakla birlikte, doğruluk oranlarının %91,00'in üzerinde olması bu modellerin sınıflandırma kapasitesinin iyi olduğunu ancak belirli durumlarda sınıfları ayırt etmekte sınırlı kaldığını göstermektedir.

ViT modeller içerisinde en düşük performansı gösteren model ise %91,79 doğruluk, %91,77 kesinlik ve %91,74 F1-skoruna sahip olan CoaT-Small modelidir. Bu modelin tüm metrikleri yüksek olmakla birlikte, diğer ViT modelleri ile kıyaslandığında sınırlı başarısı dikkat çekmektedir. Bu durum, CoaT-Small modelinin belirli sınıflara daha az duyarlılık gösterdiğini ve sınıflandırma doğruluğunu kısmen düşürebildiğini ortaya koymaktadır.

Tablo 4.7'deki topluluk öğrenme modeli sonuçları, ISIC 2019 veri seti üzerinde CNN ve ViT tabanlı modellerin farklı kombinasyonlarının esnek ve katı oylama tekniklerine göre performansını ayrıntılı bir şekilde göstermektedir. Sonuçlar içerisinde, esnek oylamada en yüksek sonuç Swin-Base, PiT-Base, ConvNeXt-Base ve EfficientNetv2-Medium modellerinin kombinasyonu ile elde edilmiştir. Bu kombinasyon %93,49 doğruluk ve %93,48 F1-skoruna ulaşmıştır. Bu sonuçlar, ViT ve CNN tabanlı modellerinini topluluk öğrenme metotları ile sınıflandırma başarısını artırabileceğini göstermektedir. Swin-Base ve EfficientNetv2-Medium kombinasyonu ise, esnek oylama ile %93,45 doğruluk ve %93,39 F1-skoruyla dikkat çeken bir performans sağlamıştır.

Katı oylama yöntemindeki sonuçlara bakıldığında, performans değerlerinin esnek oylamaya göre bir miktar düştüğü gözlemlenmektedir. Özellikle, ConvNeXt-Base ve MobileNetv3-Large kombinasyonu %90,81 doğruluk ile diğer kombinasyonlara göre daha düşük bir sonuç elde etmiştir. Bu kombinasyonun kesinlik ve duyarlılık gibi diğer metriklerde de nispeten düşük performans göstermesi, daha karmaşık modellerle birlikte uygulanmasının sınırlı başarı sunduğunu göstermektedir. Katı oylamada en yüksek doğruluk ve F1-skoru %92,66 ve %92,61 ile ViT tabanlı modeller olan Swin-Base, PiT-Base ve CoaT-Small kombinasyonu tarafından elde edilmiştir. Bu durum,

Tablo 4.7. ISIC 2019 veri seti üzerindeki topluluk öğrenme sonuçları.

Kombinasyonlar	Esnek oylama				Katı oylama			
	Doğruluk (%)	**Kesinlik (%)**	**Duyarlılık (%)**	**F1-skor (%)**	**Doğruluk (%)**	**Kesinlik (%)**	**Duyarlılık (%)**	**F1-skor (%)**
ConvNeXt-Base EfficientNetv2-Medium	92,30	92,20	92,30	92,21	90,81	90,71	90,81	90,73
ConvNeXt-Base MobileNetv3-Large	91,00	90,87	91,00	90,84	90,81	90,71	90,81	90,73
ConvNeXt-Base EfficientNetv2-Medium inception_next_base	93,13	93,11	93,13	93,06	91,48	91,50	91,48	91,46
Swin-Base PiT-Base	93,33	93,28	93,33	93,27	92,30	92,28	92,30	92,26
Swin-Base CoaT-Small	93,05	93,04	93,05	93,01	92,30	92,28	92,30	92,26
PiT-Base CoaT-Small	93,01	92,95	93,01	92,93	91,91	91,81	91,91	91,79
Swin-Base PiT-Base CoaT-Small	93,25	93,20	93,25	93,18	**92,66**	**92,64**	**92,66**	**92,61**
Swin-Base EfficientNetv2-Medium	93,45	93,40	93,45	93,39	92,30	92,28	92,30	92,26
Swin-Base ConvNeXt-Base	92,70	92,64	92,70	92,63	92,30	92,28	92,30	92,26
Swin-Base PiT-Base ConvNeXt-Base EfficientNetv2-Medium	**93,49**	**93,52**	**93,49**	**93,48**	92,19	92,11	92,19	92,12

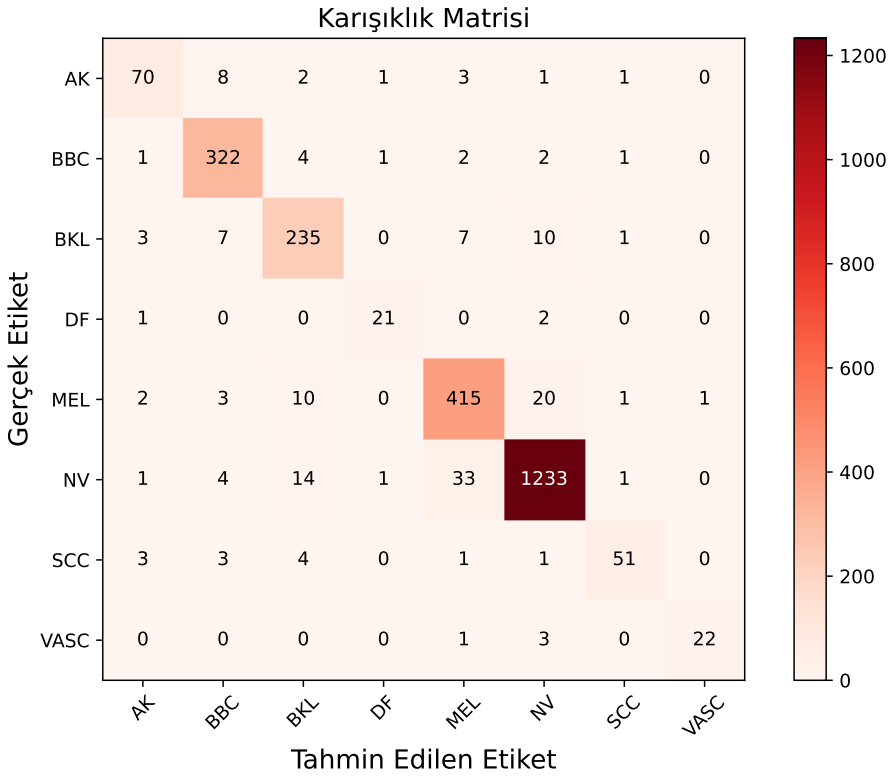

Şekil 4.4. ISIC 2019 veri seti üzerinde önerilen CNN ve ViT tabanlı topluluk öğrenme modelinin karışıklık matrisi.

katı oylamanın bazı sınıflandırma görevlerinde esnekliğin azalması nedeniyle sınırlı performans sağlayabileceğini göstermektedir.

Swin-Base modeli birçok kombinasyonda güçlü sonuçlar sağlamış ve PiT-Base, CoaT-Small ve EfficientNetv2-Medium modelleriyle yapılan entegrasyonlar, sınıflandırma başarısını daha da artırmıştır. Esnek oylama sonuçlarının daha yüksek olması, model çıktılarına göre ağırlıklı bir yaklaşımın, farklı öznitelikleri yakalayarak modeli optimize edebildiğini göstermektedir.

Önerilen topluluk öğrenme modelin ISIC 2019 veri setindeki karışıklık matrisi Şekil 4.4'te ve tekil sınıf performansları Tablo 4.8'de sunulmaktadır. NV sınıfı, modelin genel performans açısından en yüksek başarıyı gösterdiği sınıf olarak dikkat çekmektedir. Model, %95,80 kesinlik ve %96,93 duyarlılık oranları ile oldukça başarılı bir performans sergilemiştir. 1.233 TP ve yalnızca 54 yanlış sınıflandırma ile model, NV sınıfını doğru bir şekilde sınıflandırmıştır. Ayrıca, yöntemin elde ettiği %96,37 F1-skoru, modelin istikrarlı ve güvenilir olduğunu göstermektedir.

Tablo 4.8. Önerilen modelin ISIC 2019 veri setindeki sınıf bazında performans metrikleri sonuçları

Sınıf	**Kesinlik (%)**	**Duyarlılık (%)**	**F1-skor (%)**
AK	81,40	86,42	83,83
BBC	96,70	92,80	94,71
BKL	89,35	87,36	88,35
DF	87,50	87,50	87,50
MEL	91,81	89,83	90,81
NV	**95,80**	**96,93**	**96,37**
SCC	80,95	91,07	85,71
VASC	84,62	95,65	89,80

BBC sınıfı, %96,70 kesinlik ve %92,80 duyarlılık ile modelin yüksek doğruluk oranı sergilediği bir sınıf olarak öne çıkmaktadır. 322 görüntü doğru ve 11 görüntü yanlış sınıflandırılmıştır. F1-skoru %94,71 ile de model oldukça yüksek bir başarı oranı göstermektedir. MEL sınıfı ise %91,81 kesinlik ve %89,83 duyarlılık oranları ile oldukça başarılı bir şekilde sınıflandırılmıştır. 415 TP ve 37 FP ile model bu sınıfı doğru bir şekilde tanımakla birlikte, yanlış pozitiflerin sayısı biraz daha yüksektir. F1-skoru %90,81 ile güçlü bir performans sergilenmiştir. Bu durum, modelin MEL sınıfını doğru bir şekilde tanıdığı ancak bazı yanlış pozitiflerin bulunduğu anlamına gelmektedir.

BKL ve DF sınıfları, modelin orta düzeyde başarı sergilediği sınıflardır. BKL sınıfı, %89,35 kesinlik ve %87,36 duyarlılık ile iyi bir sonuç elde etmiş olsa da, 10 FP ile kesinlik oranı biraz düşmüştür. 235 TP ile sınıf doğru bir şekilde tanınırken, 28 yanlış negatif sınıflandırma yapılmıştır. F1-skoru %88,35 ile yeterli bir başarıya sahip olsa da, modelin bu sınıfta daha fazla iyileştirme yapması gerekebilir. DF sınıfında, %87,50 kesinlik ve %87,50 duyarlılık ile model dengeli bir performans göstermektedir. 21 TP ve 3 FP ile sınıf doğru bir şekilde tanınmış, ancak 3 yanlış negatif yine kesinlik üzerinde bir etki oluşturmuştur. Model, %87,50 F1-skoru ile ortalama bir başarıya sahiptir.

VASC ve SCC sınıfları, modelin daha düşük performans sergilediği sınıflardır. VASC sınıfında model, %84,62 kesinlik ve %95,65 duyarlılık ile güçlü bir duyarlılık oranı göstermektedir, ancak 4 FP ile kesinlik açısından bazı eksiklikler bulunmaktadır. F1-skoru %89,80 ile oldukça iyi olsa da, bu sınıfta modelin yanlış pozitif sayısının azaltılması gerektiğini göstermektedir. SCC sınıfı, %80,95 kesinlik ve %91,07 duyarlılık

ile modelin düşük doğruluk oranlarına sahip olduğu bir sınıftır. 51 TP ile modelin bu sınıfı doğru bir şekilde tanıması sağlanmış, ancak 12 yanlış negatif sınıflandırma yapılmıştır. F1-skoru %85,71 ile tatmin edici bir seviyede kalmaktadır, ancak modelin SCC sınıfında daha fazla doğruluk sağlaması gerektiği görülmektedir.

AK sınıfı, modelin zayıf performans gösterdiği bir diğer sınıf olarak dikkat çekmektedir. %81,40 kesinlik ve %86,42 duyarlılık ile diğer sınıflara kıyasla daha düşük bir başarıya sahiptir. Model AK sınıfını 70 TP ve 16 FP değeri ile sınıflandırmıştır. F1-skoru %83,83 ile makul bir seviyeye ulaşırken, bu sınıfta modelin iyileştirilmesi gereken noktalar bulunmaktadır.

4.5. Önerilen Hibrit Topluluk Modelin Güncel Yöntemlerle Karşılaştırılması

Bu bölümde, geliştirilen hibrit topluluk modelinin mevcut literatürde HAM10000 ve ISIC 2019 veri setleri üzerinde önerilen yöntemlerle karşılaştırmalı performans analizi sunulmaktadır. Değerlendirmeler yöntemlerinin sınıflandırma doğruluğu ve F1-skor performansları karşılaştırılarak yapılmıştır.

Tablo 4.9'daki çalışmalar incelendiğinde, HAM10000 veri seti üzerinde %94,31 doğruluk ve %94,23 F1-skoru ile önerilen yöntem en yüksek değerlere ulaşmıştır. Bu sonuç, önerilen yöntemin doğruluk ve sınıflandırma dengesi açısından en başarılı sonuçları sağladığını göstermektedir. Önerilen yöntemin doğruluğa ek olarak yüksek bir F1-skoru sunması, modelin yanlış pozitif ve yanlış negatif oranlarını optimize ettiğini ve dengesiz sınıf dağılımında dahi güçlü bir performans sergilediğini ortaya koymaktadır.

Tablo 4.9. HAM10000 veri seti üzerinde topluluk öğrenme yöntemlerin karşılaştırılması.

Yöntem	**Yıl**	**Model**	**Veri seti**	**Doğruluk(%)**	**F1-skor(%)**
Mushtaq ve Singh [139]	2024	Topluluk öğrenme	HAM10000	89,00	88,00
Samushonga ve ark. [140]	2024	Topluluk öğrenme	HAM10000	74,23	-
Bechelli ve Delhommelle [141]	2022	Topluluk öğrenme	HAM10000	86,00	70,00
Thwin ve Park [142]	2024	Topluluk öğrenme	HAM10000	90,00	-
Bhargavi ve ark. [143]	2023	Topluluk öğrenme	HAM10000	81,30	81,31
Chatterjee ve ark. [144]	2024	Topluluk öğrenme	HAM10000	86,00	86,00
Önerilen Yöntem	2024	Topluluk öğrenme	HAM10000	**94,31**	**94,43**

Diğer çalışmalardan en yüksek doğruluğu %90,00 ile Thwin ve Park elde etmiş ancak F1-skorları çalışmalarında belirtilmemiştir. Bu sonuçlar, Thwin ve Park'ın yönteminin yüksek doğruluğa sahip olduğunu, ancak önerilen modelin F1-skoru ile genel sınıflandırma başarımında daha üstün olduğunu göstermektedir. Mushtaq ve Singh ise %89,00 doğruluk ve %88,00 F1-skoru ile önerilen yönteme yakın bir performans sergilese de, doğruluk ve sınıflandırma dengesi bakımından önerilen modelin altında kalmaktadır.

Chatterjee ve ark. çalışmasında %86,00 doğruluk ve %86,00 F1-skoru değerleri kaydedilmiştir. Bu sonuçlar, önerilen yönteme göre daha düşük bir doğruluğa işaret etmektedir. F1-skorunun doğruluk ile uyumlu olması, Chatterjee ve ark.'nın yöntemiyle modelin istikrarını ve sınıflandırma dengesini koruduğunu gösterse de, önerilen modelin F1-skorunda daha başarılı bir performans sergilediği görülmektedir. Bhargavi ve ark. çalışması ise %81,30 doğruluk ve %81,31 F1-skoru ile orta düzeyde bir başarı sergileyerek, sınıflandırma başarımı açısından önerilen yöntemin gerisinde kalmıştır.

En düşük doğruluğa sahip çalışma ise %74,23 doğruluk oranıyla Samushonga ve ark. çalışmasıdır ve F1-skoru çalışma sonuçlarında verilmemiştir. Bu düşük doğruluk oranı, yöntemin sınıflandırma dengesi konusunda yetersiz kaldığını göstermektedir. Bechelli ve Delhommelle ise %86,00 doğruluk ve %70,00 F1-skoru ile dengeli bir sınıflandırma performansı sergileyememiştir.

Değerlendirmeler önerilen topluluk öğrenme yönteminin yalnızca en yüksek doğruluk oranını değil, aynı zamanda yüksek F1-skoru ile sınıflandırma dengesi ve doğruluğu sağladığını göstermektedir. Bu bağlamda önerilen yöntem, HAM10000 veri seti üzerinde güçlü bir sınıflandırma başarımı sunarken, mevcut literatürdeki diğer yaklaşımlara göre sınıf dağılımını daha dengeli bir şekilde ayarlayarak üstünlük sağlamaktadır.

ISIC 2019 veri seti ile yapılmış çalışmaları gösteren Tablo 4.10 incelendiğinde önerilen model, %93,49 doğruluk ve %93,41 F1-skor oranları ile en yüksek başarıyı sergileyerek önceki çalışmalara göre belirgin bir performans üstünlüğü göstermektedir. Bu sonuç, modelin hem doğruluk hem de genel sınıflandırma kararlılığında diğer yöntemleri geride bıraktığını göstermektedir.

Tablo 4.10. ISIC 2019 veri seti üzerinde topluluk öğrenme yöntemlerin karşılaştırılması.

Yöntem	**Yıl**	**Model**	**Veri seti**	**Doğruluk(%)**	**F1-skor(%)**
Santos ve ark. [145]	2021	Topluluk öğrenme	ISIC 2019	89,40	-
Pacheco ve ark. [146]	2020	Topluluk öğrenme	ISIC 2019	82,80	-
Gupta ve ark. [147]	2023	Topluluk öğrenme	ISIC 2019	87,00	62,00
Cauvery ve ark. [148]	2021	Topluluk öğrenme	ISIC 2019	81,20	56,00
Benyahia ve ark. [149]	2022	Topluluk öğrenme	ISIC 2019	92,34	86,94
Yu ve ark. [150]	2024	Topluluk öğrenme	ISIC 2019	91,04	84,72
Önerilen Yöntem	2024	Topluluk öğrenme	ISIC 2019	**93,49**	**93,48**

Benyahia ve ark. geliştirdiği model, %92,34 doğruluk ve %86,94 F1-skor değerleri ile oldukça etkili bir performans sunarak mevcut modeller arasında önerilen yönteme en yakın başarıyı göstermektedir. Bu çalışma, yüksek doğruluk ve F1-skoru açısından, veri kümesi üzerindeki özniteliklerin güçlü bir şekilde yakalandığını işaret etmektedir. Yu ve ark. tarafından geliştirilen yöntem ise %91,04 doğruluk ve %84,72 F1-skoru ile, literatürde yüksek performans gösteren modellerden bir diğeridir. Bu çalışma, doğruluk açısından oldukça başarılı olsa da, F1-skor bakımından önerilen modelin gerisinde kalmaktadır. Santos ve ark. geliştirdiği yöntem %89,40 doğruluk değeriyle yüksek bir doğruluk oranına ulaşmış olsa da, çalışmada F1-skor değerine dair bilgi verilmemiştir. Bu eksiklik, yöntemin sınıflandırma performansını dengeleme kabiliyeti hakkında daha az bilgi sunmaktadır. Benzer şekilde, Pacheco ve ark. geliştirdiği model %82,80 doğruluk oranı ile önceki yıllara göre daha düşük bir performans sergilemiş ve bu çalışmada da F1-skor değeri belirtilmemiştir.

Gupta ve ark. tarafından geliştirilen model, %87,00 doğruluk ve %62,00 F1-skoru sunarak, nispeten dengesiz sonuçlar ortaya koymuştur. Düşük F1-skor oranı, sınıflandırma kararlılığında zayıf bir performans göstergesi olarak değerlendirilebilir. Cauvery ve ark. modeli de %81,20 doğruluk ve %56,00 F1-skoru ile, özellikle F1-skor açısından düşük ve dengesiz performans sergileyen çalışmalardan biridir.

Önerilen hibrit topluluk modelinin ISIC 2019 veri seti üzerinde, mevcut literatürde yer alan diğer yöntemlere kıyasla doğruluk ve F1-skor açısından belirgin bir üstünlük sağladığı görülmektedir. Literatürde yer alan diğer modellerin özellikle F1-skor

bakımından sınırlı kaldığı bu karşılaştırmada, önerilen modelin daha tutarlı ve yüksek doğrulukla çalıştığı kanıtlanmaktadır. Bu bağlamda, önerilen yöntemin, sınıflandırma kararlılığı ve doğruluk anlamında literatüre katkı sağladığı değerlendirilmektedir.

4.6. Değerlendirme

Geliştirilen hibrit topluluk öğrenme modeli, cilt kanseri sınıflandırmasında önemli bir yenilik sunmaktadır. Bu çalışmada, DL tekniklerinin entegrasyonu ile dermoskopik görüntülerin otomatik analizine yönelik etkili bir yaklaşım geliştirilmiştir. Modelin performansını artırmak amacıyla kullanılan farklı CNN ve ViT kombinasyonları, hem esnek hem de katı oylama mekanizmaları ile desteklenmiştir. Elde edilen sonuçlar, modelin genel başarısını önemli ölçüde artırmıştır.

Veri ön işleme ve veri artırma aşamaları, modelin genelleme yeteneğini güçlendirmiştir. Çevrimiçi veri artırma yöntemleri sayesinde, eğitim sürecinde dinamik olarak yeni veri türevleri oluşturulmuş ve modelin çeşitli gürültü ve sapmalara karşı dayanıklılığı artırılmıştır. Bu strateji, modelin aşırı öğrenme riskini azaltarak, genel performansını yükseltmiştir. HAM10000 ve ISIC 2019 veri setleri üzerinde gerçekleştirilen deneyler, bu yaklaşımların modelin öğrenme sürecine olan katkılarını açıkça ortaya koymaktadır.

Deneysel bulgular, önerilen topluluk öğrenme modelinin, mevcut yöntemlerle karşılaştırıldığında belirgin bir üstünlük sağladığını göstermektedir. HAM10000 veri setinde elde edilen %94,31 doğruluk ve %94,23 F1-skoru, modelin sınıflandırma dengesi açısından etkili olduğunu ortaya koymaktadır. Diğer çalışmalarla yapılan karşılaştırmalar, önerilen modelin hem doğruluk hem de F1-skoru bakımından daha yüksek performans sergilediğini göstermektedir.

ISIC 2019 veri setinde elde edilen sonuçlar, önerilen modelin karşılaştırılan diğer yöntemlere kıyasla üstünlük sağladığını bir kez daha kanıtlamaktadır. Önerilen model, %93,49 doğruluk ve %93,41 F1-skoru ile, daha tutarlı sonuçlar verdiğini ve sınıflandırma kararlılığını artırdığını ortaya koymaktadır. Geliştirilen hibrit topluluk öğrenme modeli, cilt kanseri sınıflandırmasında önemli bir adım atmaktadır. Her iki veri setinde elde edilen yüksek başarımlar, yöntemin klinik uygulamalarda kullanılma potansiyelini ortaya koymaktadır.

5. BÖLÜM

TARTIŞMA, SONUÇ ve ÖNERİLER

Bu tez çalışmasında, cilt kanseri sınıflandırma problemine yönelik olarak farklı hibrit derin öğrenme yöntemlerinin ve hibrit topluluk öğrenme mimarilerinin etkinliği detaylı bir şekilde incelenmiştir. Cilt kanseri sınıflandırması ile ilgili geniş kapsamlı bir literatür taraması gerçekleştirilmiş, mevcut yaklaşımların eksiklikleri değerlendirilmiş ve bu doğrultuda yeni modeller önerilmiştir. Çalışmada, farklı veri setleri üzerinde yapılan deneyler sonucunda geliştirilen hibrit modellerin performansları analiz edilmiş ve önerilen modellerin mevcut tanı süreçlerini iyileştirmede önemli katkılar sağladığı ortaya konulmuştur. Bu modellerin, cilt kanseri tanısında kullanılan tekniklerin geliştirilmesine katkıda bulunmakla birlikte, gelecekteki çalışmalar için sağlam bir temel oluşturduğu görülmüştür. Bu bölümde, tez kapsamında elde edilen bulgular, araştırma alanına yapılan katkılar ve gelecekteki çalışmalar için öneriler verilmektedir.

5.1. Tartışma ve Sonuç

Tez çalışması kapsamında, cilt kanseri sınıflandırmasında kullanılan hibrit derin öğrenme mimarileri ayrıntılı bir şekilde analiz edilmiştir. Bu bölümde, geliştirilen üç farklı hibrit modelin performansları birbiriyle karşılaştırılmıştır. Tablo 5.1, önerilen hibrit yöntemlerin HAM10000 veri seti üzerindeki, Tablo 5.2 ise ISIC 2019 veri seti üzerindeki doğruluk, kesinlik, duyarlılık ve F1-skor sonuçlarını sunmaktadır. Ayrıca, önerilen yöntemlerin metrik sonuçları Şekil 5.1 ve Şekil 5.2'de grafiksel olarak verilmiştir. Grafiksel veriler, sayısal sonuçların daha etkili bir şekilde yorumlanmasına katkıda bulunmakta ve modellerin güçlü ve zayıf yönlerinin daha detaylı incelenmesine olanak tanımaktadır.

Tablo 5.1. Tez çalışmamızda önerilen modellerin HAM10000 veri seti üzerindeki sonuçlarının birbirleri ile karşılaştırılması.

Önerilen Hibrit Yöntemler	**Veri seti**	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**F1-skor(%)**
CNN Tabanlı Hibrit Model	HAM10000	93,63	85,68	88,98	87,26
MetaFormer tabanlı CAFormer modeli	HAM10000	94,30	93,00	89,59	91,11
Hibrit Topluluk Öğrenme Modeli	HAM10000	**94,31**	**94,44**	**94,31**	**94,43**

Tablo 5.2. Tez çalışmamızda önerilen modellerin ISIC 2019 veri seti üzerindeki sonuçlarının birbirleri ile karşılaştırılması.

Önerilen Hibrit Yöntemler	**Veri seti**	**Doğruluk(%)**	**Kesinlik(%)**	**Duyarlılık(%)**	**F1-skor(%)**
CNN Tabanlı Hibrit Model	ISIC 2019	**94,42**	**94,13**	93,00	**93,50**
MetaFormer tabanlı CAFormer modeli	ISIC 2019	92,50	92,07	88,85	90,38
Hibrit Topluluk Öğrenme Modeli	ISIC 2019	93,49	93,52	**93,49**	93,48

HAM10000 veri seti üzerinde gerçekleştirilen değerlendirmeler, CNN ve ViT tabanlı hibrit topluluk öğrenme modelinin en yüksek performansı sağladığını göstermektedir. Bu model, %94,31 doğruluk, %94,44 kesinlik, %94,31 duyarlılık ve %94,43 F1-skoru ile dikkat çekmektedir. Grafiksel analizler, modelin tüm metriklerde diğer modelleri geride bıraktığını ve üstün bir performans sergilediğini açıkça ortaya koymaktadır. CNN ve ViT tabanlı hibrit topluluk öğrenme modelinin tüm metrikler için gösterdiği yüksek başarı modelin genelleme yeteneğini ortaya koymaktadır.

ConvNeXt bloklarıyla güçlendirilen MetaFormer tabanlı CAFormer modeli, %94,30 doğruluk ve %93,00 kesinlik ile oldukça başarı bir performans sergilemektedir. Bununla birlikte, %89,59 duyarlılık ve %91,11 F1-skoru değerleri, diğer metriklere kıyasla biraz daha düşük kalmaktadır. Grafiksel analizler, modelin doğruluk ve kesinlikteki güçlü performansı ile duyarlılık ve F1-skoru arasındaki belirgin farkları net bir şekilde göstermektedir. Bu durum, modelin genel olarak doğru sınıflandırmalarda başarılı olduğunu ancak bazı sınıflarda hatalı sonuçlar elde ettiğini göstermektedir.

CNN tabanlı hibrit model, %93,63 doğruluk, %85,68 kesinlik, %88,98 duyarlılık ve %87,26 F1-skoru ile diğer modellere kıyasla daha düşük bir performans sergilemektedir. Grafiksel analizler, modelin bazı durumlarda hatalı sonuçlar verdiğini göstermektedir. Düşük kesinlik ve F1-skoru, modelin diğer modellere göre verileri hatalı bir şekilde sınıflandırdığını ortaya koymaktadır.

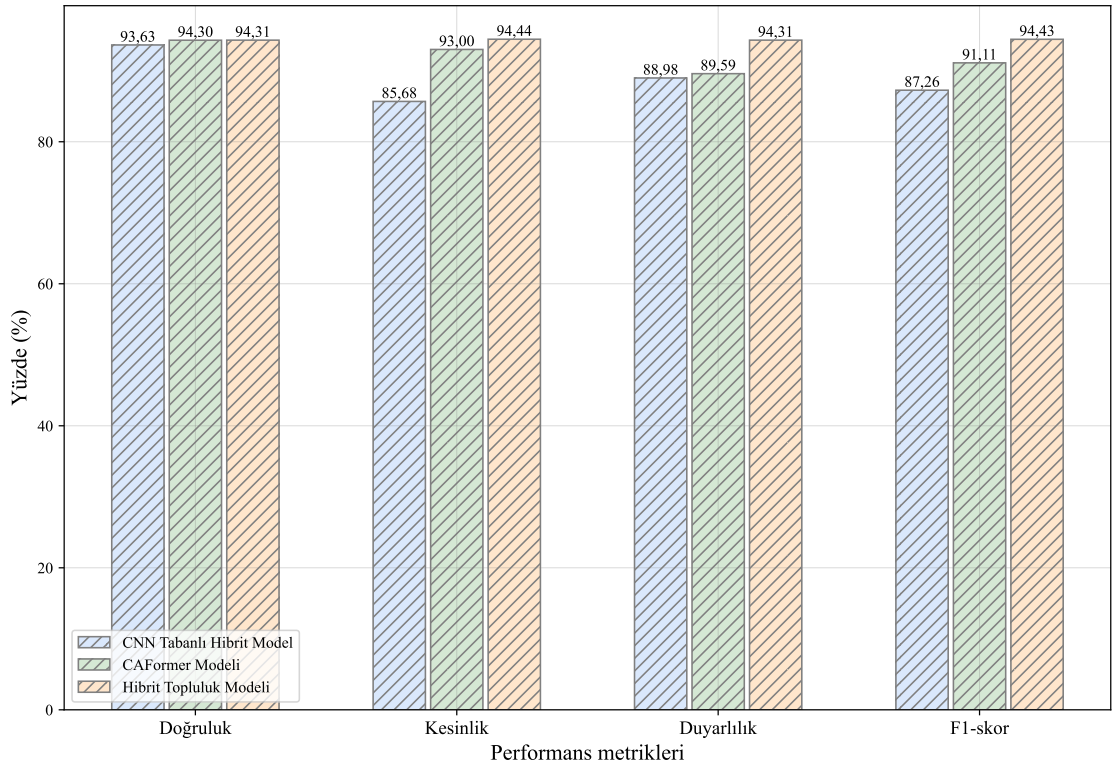

Şekil 5.1. Önerilen hibrit yöntemlerin HAM10000 veri seti üzerindeki performanslarının karşılaştırma grafiği.

ISIC 2019 veri seti ile gerçekleştirilen deneyler sonucunda CNN tabanlı hibrit model, %94,42 doğruluk, %94,13 kesinlik, %93,00 duyarlılık ve %93,50 F1-skoru ile en yüksek performansı elde eden model olmuştur. Bu sonuçlar, manuel veri artırımı ve görüntü bölütlemenin, modelin HAM10000 veri setinde ulaştığı değerlere kıyasla daha üstün bir performans sergilediğini göstermektedir. Grafiklerde de modelin genel olarak yüksek başarı sağladığı gözlemlenmektedir. Ancak duyarlılık metriği açısından biraz geride kalması, modelin bazı sınıflarda daha fazla hata yapabileceğini göstermektedir.

CNN ve ViT tabanlı hibrit topluluk öğrenme modeli, %93,49 doğruluk, %93,52 kesinlik, %93,49 duyarlılık ve %93,48 F1-skoru ile ISIC 2019 veri setinde ikinci en yüksek performansı sergileyen modeldir. Grafiksel analizler, bu modelin dengeli bir başarı ortaya koyduğunu göstermektedir. Doğruluk ve kesinlik açısından elde edilen yüksek değerler, duyarlılık ve F1-skorundaki dengeli performansla birleşerek, modelin tüm sınıflara yönelik güçlü bir tespit yeteneğine sahip olduğunu göstermektedir.

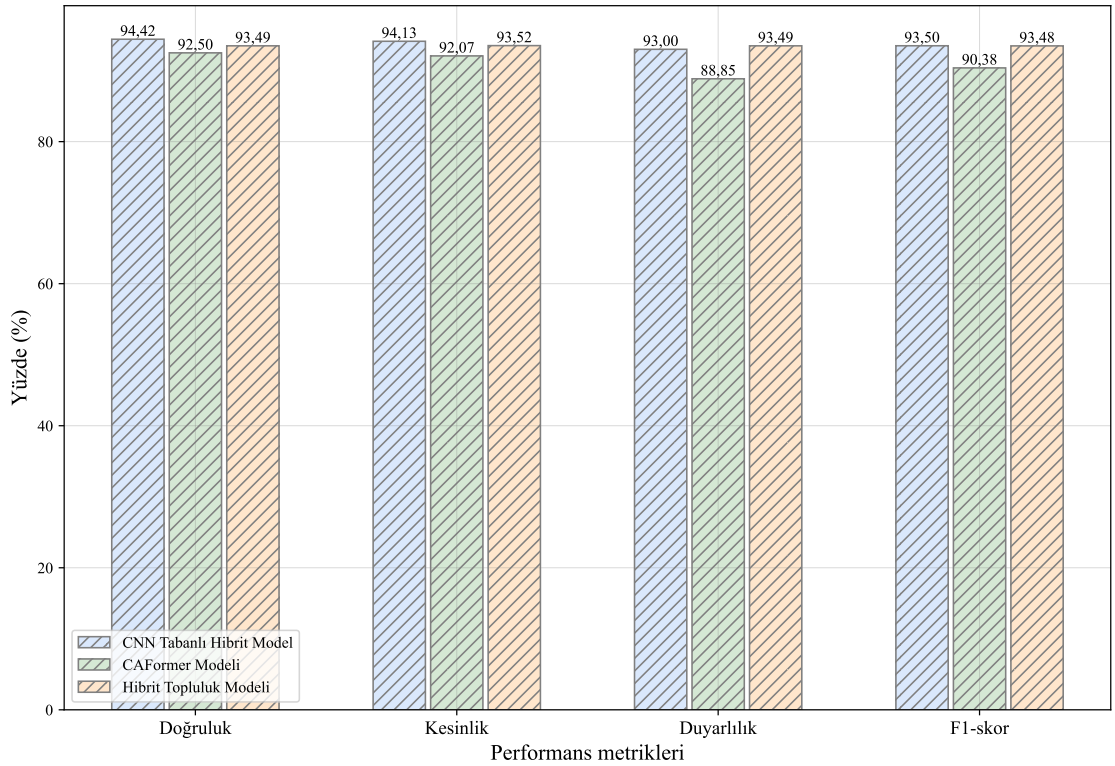

Şekil 5.2. Önerilen hibrit yöntemlerin ISIC 2019 veri seti üzerindeki performanslarının karşılaştırma grafiği.

ConvNeXt bloklarıyla güçlendirilen MetaFormer tabanlı CAFormer modeli, %92,50 doğruluk, %92,07 kesinlik, %88,85 duyarlılık ve %90,38 F1-skoru ile en düşük performans sergileyen model olmuştur. Grafiklerde, modelin genel performansı görselleştirilmiştir. Bu model, doğruluk ve kesinlikte yüksek performans sağlasa da, bazı sınıfların yanlış tanımlandığı ve bu nedenle duyarlılık ve F1-skorunda düşük sonuçlar elde edildiği görülmektedir.

Görüntü ön işleme ve veri artırma tekniklerinin kullanımı, modelin genelleme yeteneğini artırmış ve aşırı uyum sorununu minimize etmiştir. Elde edilen sonuçlar, DL tabanlı yaklaşımların cilt kanseri tanısında güvenilir bir araç olma potansiyelini vurgulamaktadır.

Ayrıca, bu çalışmada kullanılan hibrit DL mimarileri, geleneksel yöntemlere göre belirgin avantajlar sunmaktadır. Özellikle, modelin öğrenme sürecinde daha fazla katman ve parametre kullanılması, karmaşık veri yapılarının daha etkili bir şekilde işlenmesini sağlamaktadır. Bu durum, modelin daha derinlemesine öznitelikleri öğrenmesine ve cilt lezyonlarının daha doğru bir şekilde sınıflandırılmasına olanak tanımaktadır.

Tez çalışması kapsamında geliştirilen yöntemlerin literatüre yaptığı katkılar aşağıdaki gibi sıralanabilir:

- Farklı CNN modellerinin güçlü yönlerini birleştirerek cilt kanseri sınıflandırması için yeni bir hibrit CNN model sunulmuştur. Bu model, tekil CNN modellerin öznitelik çıkarım yeteneklerini bir araya getirerek çeşitli cilt lezyonu türlerini yüksek doğrulukla sınıflandırmaktadır.
- Cilt kanseri sınıflandırma doğruluğunu artırmak amacıyla, CNN ve ViT yaklaşımlarını birleştiren ConvNeXt blokları ve MetaFormer tabanlı CAFormer mimarisini etkili bir şekilde entegre eden yenilikçi bir hibrit model sunulmuştur.
- CNN ve ViT mimarilerinin güçlü yönlerini topluluk öğrenme yöntemleri ile birleştiren yeni hibrit bir model geliştirilmiştir.
- Literatürdeki başarılı CNN ve ViT mimarilerin performansları detaylı bir şekilde birbirleriyle karşılaştırılmıştır.

5.2. Öneriler

Bu bölümde, cilt kanseri sınıflandırmasında DL yöntemlerinin etkinliğini artırmaya yönelik çeşitli öneriler sunulmaktadır. Gelecekteki çalışmalar için daha fazla ve çeşitli veri setlerinin oluşturulması, modelin genelleme yeteneğini önemli ölçüde artırabilir. Özellikle, farklı etnik gruplardan ve yaş aralıklarından gelen verilerin dahil edilmesi, model performansını iyileştirebilecek kritik bir adımdır. Veri setlerinin güncellenmesiyle yeni lezyon türlerinin ve varyasyonlarının tanınması sağlanarak sınıflandırma doğruluğunun artırılması mümkündür.

Hibrit modellerin performansını artırabilecek bir diğer yöntem de hiper parametre optimizasyonudur. Parametrelerin doğru şekilde ayarlanması, hem model doğruluğunu hem de öğrenme sürecinin verimliliğini olumlu yönde etkileyebilir. Ayrıca, transfer öğrenme tekniklerinin uygulanması, modellerin genel başarısını ve dengesiz veri setlerine uyum yeteneğini güçlendirebilir.

Geliştirilen yöntemlerin klinik ortamlardaki uygulanabilirliği de önemli bir araştırma alanı olarak öne çıkmaktadır. Gerçek zamanlı çalışan sınıflandırma modelleri, tanı süreçlerini hızlandırmanın yanı sıra, mobil cihazlar veya bulut tabanlı sistemlerle entegre edilerek anında geri bildirim sağlama potansiyeline sahiptir. Bu tür yaklaşımlar, tanı ve tedavi süreçlerinin daha etkili hale getirilmesine katkı sağlayabilir.

Hasta ile ilgili farklı bilgilerin bir arada kullanılması, sınıflandırma modellerinin doğruluğunu ve genel performansını artırabilecek bir diğer önemli stratejidir. Dermoskopik görüntüler, cilt lezyonlarının yapısal özniteliklerini belirginleştirirken, genetik bilgiler ve hastanın tıbbi geçmişi gibi ek veri kaynakları, lezyonların biyolojik ve klinik özniteliklerini yansıtarak sınıflandırma sürecine daha geniş bir perspektif kazandırabilir. Bu tür çoklu veri entegrasyonu, sınıflandırma modellerinin daha kapsamlı ve hassas analizler yapmasını sağlayarak daha başarılı sonuçlar elde edilmesine imkan tanımaktadır.

Son olarak, klasik ve derin öğrenme tabanlı öznitelik çıkarım tekniklerinin birleştirilmesi, sınıflandırma modellerinin performansını iyileştirebilecek etkili bir yaklaşımdır. Klasik öznitelik çıkarım yaklaşımlarıyla, görüntüden asimetri, kenar, renk ve lezyon çapı gibi temel yapısal öznitelikler elde edilebilirken, derin öğrenme yöntemleri daha karmaşık ve yüksek düzeyde soyutlama gerektiren öznitelikleri öğrenme avantajına sahiptir. Bu iki yöntemin birlikte kullanımı, modelin öznitelikleri daha etkin şekilde öğrenmesini sağlayarak sınıflandırma doğruluğunu artırabilir. Özellikle hibrit modellerde bu entegrasyonun uygulanması, daha başarılı ve genelleştirilebilir sonuçlar elde edilmesine katkıda bulunabilir.

KAYNAKÇA

1. The Skin Cancer Foundation, 2024, Skin cancer facts & statistics, (Web sayfası: **https://www.skincancer.org/skin-cancer-information/skin-cancer-facts)**, (Erişim tarihi: Eylül 2024).

2. Mayo Foundation for Medical Education and Research (MFMER), 2024, Skin cancer, (Web sayfası: **https://www.mayoclinic.org/diseases-conditions/skin-cancer/symptoms-causes/syc-20377605)**, (Erişim tarihi: Ekim 2024).

3. The Skin Cancer Foundation, 2024, Skin cancer, (Web sayfası: **https://www.skincancer.org/skin-cancer-information)**, (Erişim tarihi: Eylül 2024).

4. Cancer Research UK, 2024, What is skin cancer?, (Web sayfası: **https://www.cancerresearchuk.org/about-cancer/skin-cancer/about-skin-cancer)**, (Erişim tarihi: Ekim 2024).

5. Zhang, L., Zhang, J., Gao, W., Bai, F., Li, N., and Ghadimi, N., 2024. A deep learning outline aimed at prompt skin cancer detection utilizing gated recurrent unit networks and improved orca predation algorithm, **Biomedical Signal Processing and Control**, **90**:105858.

6. Haenssle, H., Fink, C., Schneiderbauer, R., Toberer, F., Buhl, T., Blum, A., Kalloo, A., Hassen, A.B.H., Thomas, L., Enk, A., Uhlmann, L., Alt, C., Arenbergerova, M., Bakos, R., Baltzer, A., Bertlich, I., Blum, A., Bokor-Billmann, T., Bowling, J., Braghiroli, N., Braun, R., Buder-Bakhaya, K., Buhl, T., Cabo, H., Cabrijan, L., Cevic, N., Classen, A., Deltgen, D., Fink, C., Georgieva, I., Hakim-Meibodi, L.E., Hanner, S., Hartmann, F., Hartmann, J., Haus, G., Hoxha, E., Karls, R., Koga, H., Kreusch, J., Lallas, A., Majenka, P., Marghoob, A., Massone, C., Mekokishvili, L., Mestel, D., Meyer, V., Neuberger, A., Nielsen, K., Oliviero, M., Pampena, R., Paoli, J., Pawlik, E., Rao, B., Rendon, A., Russo, T., Sadek, A., Samhaber, K., Schneiderbauer, R., Schweizer, A., Toberer, F., Trennheuser, L., Vlahova, L., Wald, A., Winkler, J., Wölbing, P., and Zalaudek, I., 2018.

Man against machine: diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists, **Annals of Oncology**, **29**(8):1836–1842.

7. Pacal, I., Alaftekin, M., and Zengul, F.D., 2024. Enhancing skin cancer diagnosis using swin transformer with hybrid shifted window-based multi-head self-attention and SwiGLU-Based MLP, **Journal of Imaging Informatics in Medicine**, 1–19.

8. Panneerselvam, R., Balasubramaniam, S., et al., 2023. Multi-class skin cancer classification using a hybrid dynamic salp swarm algorithm and weighted extreme learning machines with transfer learning, **Acta Informatica Pragensia**, **12**(1):141–159.

9. Leblebicioglu Kurtulus, I., Lubbad, M., Yilmaz, O.M.D., Kilic, K., Karaboga, D., Basturk, A., Akay, B., Nalbantoglu, U., Yilmaz, S., Ayata, M., and Pacal, I., 2024. A robust deep learning model for the classification of dental implant brands, **Journal of Stomatology, Oral and Maxillofacial Surgery**, **125**(5, Supplement 1):101818.

10. Ozcan, T., Toprak, A.N., Aruk, I., Sahin, O., and Ozcan, I., 2024. Applications of deep learning techniques in healthcare systems: A review, **Journal of Clinical Practice & Research**, **46**(6).

11. Toprak, A.N. and Aruk, I., 2024. A hybrid convolutional neural network model for the classification of multi-class skin cancer, **International Journal of Imaging Systems and Technology**, **34**(5):e23180.

12. Hermosilla, P., Soto, R., Vega, E., Suazo, C., and Ponce, J., 2024. Skin cancer detection and classification using neural network algorithms: A systematic review, **Diagnostics**, **14**(4):454.

13. Hameed, M., Zameer, A., and Raja, M.A.Z., 2024. A comprehensive systematic review: Advancements in skin cancer classification and segmentation using the isic dataset., **CMES-Computer Modeling in Engineering & Sciences**, **140**(3).

14. Hussain, S.I. and Toscano, E., 2024. An extensive investigation into the use of machine learning tools and deep neural networks for the recognition of skin cancer: challenges, future directions, and a comprehensive review, **Symmetry**, **16**(3):366.

15. Houssein, E.H., Abdelkareem, D.A., Emam, M.M., Hameed, M.A., and Younan, M., 2022. An efficient image segmentation method for skin cancer imaging using improved golden jackal optimization algorithm, **Computers in Biology and Medicine**, **149**:106075.

16. Bibi, S., Khan, M.A., Shah, J.H., Damaševičius, R., Alasiry, A., Marzougui, M., Alhaisoni, M., and Masood, A., 2023. MSRNet: multiclass skin lesion recognition using additional residual block based fine-tuned deep models information fusion and best feature selection, **Diagnostics**, **13**(19):3063.

17. Houssein, E.H., Oliva, D., Samee, N.A., Mahmoud, N.F., and Emam, M.M., 2023. Liver cancer algorithm: A novel bio-inspired optimizer, **Computers in Biology and Medicine**, **165**:107389.

18. Siegel, R.L., Giaquinto, A.N., and Jemal, A., 2024. Cancer statistics, 2024., **CA: a cancer journal for clinicians**, **74**(1):12–49.

19. National Cancer Institute, 2024, Skin cancer treatment (PDQ®)–patient version, (Web sayfası: **https://www.cancer.gov/types/skin/patient/skin-treatment-pdq)**, (Erişim tarihi: Eylül 2024).

20. Zeng, L., Gowda, B.J., Ahmed, M.G., Abourehab, M.A., Chen, Z.S., Zhang, C., Li, J., and Kesharwani, P., 2023. Advancements in nanoparticle-based treatment approaches for skin cancer therapy, **Molecular Cancer**, **22**(1):10.

21. The Skin Cancer Foundation, 2024, The skin cancer foundation, what you need to know about cancers of the skin, (Web sayfası: **https://www.skincancer.org/skin-cancer-information)**, (Erişim tarihi: Eylül 2024).

22. Khan, N.H., Mir, M., Qian, L., Baloch, M., Khan, M.F.A., Ngowi, E.E., Wu, D.D., Ji, X.Y., et al., 2022. Skin cancer biology and barriers to treatment:

Recent applications of polymeric micro/nanostructures, **Journal of Advanced Research**, **36**:223–247.

23. Hussain, M., Khan, M.A., Damaševičius, R., Alasiry, A., Marzougui, M., Alhaisoni, M., and Masood, A., 2023. SkinNet-INIO: multiclass skin lesion localization and classification using fusion-assisted deep neural networks and improved nature-inspired optimization algorithm, **Diagnostics**, **13**(18):2869.

24. Cancer Research UK, 2024, Types of skin cancer, (Web sayfası: **https://www.cancerresearchuk.org/about-cancer/skin-cancer/types)**, (Erişim tarihi: Ekim 2024).

25. Jones, O.T., Ranmuthu, C.K., Hall, P.N., Funston, G., and Walter, F.M., 2020. Recognising skin cancer in primary care, **Advances in therapy**, **37**(1):603–616.

26. Khayyati Kohnehshahri, M., Sarkesh, A., Mohamed Khosroshahi, L., HajiEsmailPoor, Z., Aghebati-Maleki, A., Yousefi, M., and Aghebati-Maleki, L., 2023. Current status of skin cancers with a focus on immunology and immunotherapy, **Cancer Cell International**, **23**(1):174.

27. Mayo Foundation for Medical Education and Research (MFMER), 2024, Basal cell carcinoma, (Web sayfası: **https://www.mayoclinic.org/diseases-conditions/basal-cell-carcinoma/symptoms-causes/syc-20354187)**, (Erişim tarihi: Ekim 2024).

28. Family Caregivers Online, 2024, What is melanoma? Learn the ABCDE of moles, (Web sayfası: **https://familycaregiversonline.net/what-is-melanoma-learn-the-abcde-of-moles)**, (Erişim tarihi: Ekim 2024).

29. American Cancer Society, 2024, Risk factors for melanoma skin cancer, (Web sayfası: **https://www.cancer.org/cancer/types/melanoma-skin-cancer/causes-risks-prevention/risk-factors.html)**, (Erişim tarihi: Ekim 2024).

30. Society, A.C., 2024, Melanoma skin cancer stages, (Web sayfası: **https://www.cancer.org/cancer/types/melanoma-skin-cancer/detection-**

diagnosis-staging/melanoma-skin-cancer-stages.html), (Erişim tarihi: Eylül 2024).

31. Ahmad, N., Shah, J.H., Khan, M.A., Baili, J., Ansari, G.J., Tariq, U., Kim, Y.J., and Cha, J.H., 2023. A novel framework of multiclass skin lesion recognition from dermoscopic images using deep learning and explainable AI, **Frontiers in oncology**, **13**:1151257.

32. Dildar, M., Akram, S., Irfan, M., Khan, H.U., Ramzan, M., Mahmood, A.R., Alsaiari, S.A., Saeed, A.H.M., Alraddadi, M.O., and Mahnashi, M.H., 2021. Skin cancer detection: A review using deep learning techniques, **International journal of environmental research and public health**, **18**(10):5479.

33. Nie, Y., Sommella, P., Carratu, M., Ferro, M., O'nils, M., and Lundgren, J., 2022. Recent advances in diagnosis of skin lesions using dermoscopic images based on deep learning, **IEEE Access**, **10**:95716–95747.

34. Dong, S., Wang, P., and Abbas, K., 2021. A survey on deep learning and its applications, **Computer Science Review**, **40**:100379.

35. LeCun, Y., Bengio, Y., and Hinton, G., 2015. Deep learning, **Nature**, **521**(7553):436–444.

36. Schmidhuber, J., 2015. Deep learning in neural networks: An overview, **Neural networks**, **61**:85–117.

37. Pacal, I., 2024. MaxCerVixT: A novel lightweight vision transformer-based Approach for precise cervical cancer detection, **Knowledge-Based Systems**, **289**:111482.

38. Qi, S., Ning, X., Yang, G., Zhang, L., Long, P., Cai, W., and Li, W., 2021. Review of multi-view 3D object recognition methods based on deep learning, **Displays**, **69**:102053.

39. Anaya-Isaza, A., Mera-Jiménez, L., and Zequera-Diaz, M., 2021. An overview of deep learning in medical imaging, **Informatics in medicine unlocked**, **26**:100723.

40. Fernandes, J.d.C.V., de Moura Junior, N.N., and de Seixas, J.M., 2022. Deep learning models for passive sonar signal classification of military data, **Remote Sensing**, **14**(11):2648.

41. Huang, J., Chai, J., and Cho, S., 2020. Deep learning in finance and banking: A literature review and classification, **Frontiers of Business Research in China**, **14**(1):13.

42. Chen, D. and Lv, Z., 2022. Artificial intelligence enabled digital twins for training autonomous cars, **Internet of Things and Cyber-Physical Systems**, **2**:31–41.

43. Attri, I., Awasthi, L.K., Sharma, T.P., and Rathee, P., 2023. A review of deep learning techniques used in agriculture, **Ecological Informatics**, **77**:102217.

44. Yuan, Q., Shen, H., Li, T., Li, Z., Li, S., Jiang, Y., Xu, H., Tan, W., Yang, Q., Wang, J., et al., 2020. Deep learning in environmental remote sensing: Achievements and challenges, **Remote sensing of Environment**, **241**:111716.

45. Piccialli, F., Di Somma, V., Giampaolo, F., Cuomo, S., and Fortino, G., 2021. A survey on deep learning in medicine: Why, how and when?, **Information Fusion**, **66**:111–137.

46. Khan, S., Naseer, M., Hayat, M., Zamir, S.W., Khan, F.S., and Shah, M., 2022. Transformers in vision: A survey, **ACM Comput. Surv.**, **54**(10s).

47. Gonçalves, C.B., Souza, J.R., and Fernandes, H., 2022. CNN architecture optimization using bio-inspired algorithms for breast cancer detection in infrared images, **Computers in Biology and Medicine**, **142**:105205.

48. Cong, S. and Zhou, Y., 2023. A review of convolutional neural network architectures and their optimizations, **Artificial Intelligence Review**, **56**(3):1905–1969.

49. Valizadeh, M. and Wolff, S.J., 2022. Convolutional neural network applications in additive manufacturing: A review, **Advances in Industrial and Manufacturing Engineering**, **4**:100072.

50. Kunduracioglu, I. and Pacal, I., 2024. Advancements in deep learning for accurate classification of grape leaves and diagnosis of grape diseases, **Journal of Plant Diseases and Protection**, **131**(3):1061–1080.

51. Chen, L., Li, S., Bai, Q., Yang, J., Jiang, S., and Miao, Y., 2021. Review of image classification algorithms based on convolutional neural networks, **Remote Sensing**, **13**(22).

52. Indraswari, R., Rokhana, R., and Herulambang, W., 2022. Melanoma image classification based on MobileNetV2 network, **Procedia Computer Science**, **197**:198–207, sixth Information Systems International Conference (ISICO 2021).

53. Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L.C., 2018. MobileNetV2: inverted residuals and linear bottlenecks, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4510–4520.

54. Tan, M. and Le, Q., 2019. EfficientNet: rethinking model scaling for convolutional neural networks, *K. Chaudhuri and R. Salakhutdinov, Eds:, Proceedings of the 36th International Conference on Machine Learning*, volume 97 of Proceedings of Machine Learning Research, 6105–6114, PMLR.

55. Khan, M.S., Alam, K.N., Dhruba, A.R., Zunair, H., and Mohammed, N., 2022. Knowledge distillation approach towards melanoma detection, **Computers in Biology and Medicine**, **146**:105581.

56. Jaiswal, A., Gianchandani, N., Singh, D., Kumar, V., and Kaur, M., 2021. Classification of the COVID-19 infected patients using DenseNet201 based deep transfer learning, **Journal of Biomolecular Structure and Dynamics**, **39**(15):5682–5689.

57. Huang, G., Liu, Z., van der Maaten, L., and Weinberger, K.Q., 2017. Densely connected convolutional networks, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 4700–4708.

58. Pathak, D. and Raju, U., 2023. Shuffled-Xception-DarkNet-53: A content-based image retrieval model based on deep learning algorithm, **Computers and Electrical Engineering**, **107**:108647.

59. Rajkumar, R., Gopalakrishnan, S., Praveena, K., Venkatesan, M., Ramamoorthy, K., and Hephzipah, J.J., 2024. DarkNet-53 convolutional neural network-based image processing for breast cancer detection, **Mesopotamian Journal of Artificial Intelligence in Healthcare**, **2024**:59–68.

60. Demir, A. and Yilmaz, F., 2020. Inception-ResNet-v2 with leakyrelu and averagepooling for more reliable and accurate classification of chest x-ray images, *2020 Medical Technologies Congress (TIPTEKNO)*, 1–4.

61. Zoph, B., Vasudevan, V., Shlens, J., and Le, Q.V., 2018. Learning transferable architectures for scalable image recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 8697–8710.

62. Chen, Z., Jiang, Y., Zhang, X., Zheng, R., Qiu, R., Sun, Y., Zhao, C., and Shang, H., 2021. ResNet18DNN: prediction approach of drug-induced liver injury by deep neural network with resnet18, **Briefings in Bioinformatics**, **23**(1):bbab503.

63. Ullah, A., Elahi, H., Sun, Z., Khatoon, A., and Ahmad, I., 2022. Comparative analysis of AlexNet, ResNet18 and SqueezeNet with diverse modification and arduous implementation, **Arabian journal for science and engineering**, **47**(2):2397–2417.

64. Raihan, M. and Suryanegara, M., 2021. Classification of COVID-19 patients using deep learning architecture of Inceptionv3 and ResNet50, *2021 4th International Conference of Computer and Informatics Engineering (IC2IE)*, 46–50.

65. Liu, Z., Mao, H., Wu, C.Y., Feichtenhofer, C., Darrell, T., and Xie, S., 2022. A convnet for the 2020s, *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition*, 11976–11986.

66. Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., and Guo, B., 2021. Swin transformer: Hierarchical vision transformer using shifted windows,

Proceedings of the IEEE/CVF International Conference on Computer Vision, 10012–10022.

67. Chavarro, A., Renza, D., and Moya-Albor, E., 2024. ConvNext as a Basis for Interpretability in Coffee Leaf Rust Classification., **Mathematics (2227-7390)**, **12**(17).

68. Ba, J.L., Kiros, J.R., and Hinton, G.E., 2016. Layer normalization, **arXiv preprint arXiv:1607.06450**.

69. Hendrycks, D. and Gimpel, K., 2016. Gaussian error linear units (gelus), **arXiv preprint arXiv:1606.08415**.

70. Vaswani, A., 2017. Attention is all you need, **arXiv preprint arXiv:1706.03762**.

71. Rubab, S., Khan, M.A., Hamza, A., Albarakati, H.M., Saidani, O., Alshardan, A., Alasiry, A., Marzougui, M., and Nam, Y., 2024. A novel network-level fusion architecture of proposed self-attention and vision transformer models for land use and land cover classification from remote sensing images, **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, **17**:13135–13148.

72. Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., et al., 2020. An image is worth 16x16 words: Transformers for image recognition at scale, **arXiv preprint arXiv:2010.11929**.

73. Touvron, H., Cord, M., Douze, M., Massa, F., Sablayrolles, A., and Jégou, H., 2021. Training data-efficient image transformers & distillation through attention, *International Conference on Machine Learning*, 10347–10357, PMLR.

74. Yao, D. and Shao, Y., 2024. A data efficient transformer based on swin transformer, **The Visual Computer**, **40**(4):2589–2598.

75. Regmi, S., Subedi, A., Bagci, U., and Jha, D., 2023. Vision transformer for efficient chest X-ray and gastrointestinal image classification, **arXiv preprint arXiv:2304.11529**.

76. Fan, Z., Hu, G., Sun, X., Wang, G., Dong, J., and Su, C., 2022. Self-attention neural architecture search for semantic image segmentation, **Knowledge-Based Systems**, **239**:107968.

77. Li, Y., Miao, N., Ma, L., Shuang, F., and Huang, X., 2023. Transformer for object detection: Review and benchmark, **Engineering Applications of Artificial Intelligence**, **126**:107021.

78. Yu, W., Si, C., Zhou, P., Luo, M., Zhou, Y., Feng, J., Yan, S., and Wang, X., 2024. MetaFormer baselines for vision, **IEEE Transactions on Pattern Analysis and Machine Intelligence**, **46**(2):896–912.

79. Latha, C.B.C. and Jeeva, S.C., 2019. Improving the accuracy of prediction of heart disease risk based on ensemble classification techniques, **Informatics in Medicine Unlocked**, **16**:100203.

80. Mahajan, P., Uddin, S., Hajati, F., and Moni, M.A., 2023. Ensemble learning for disease prediction: A review, **Healthcare**, **11**(12).

81. Tanuku, S.R., Kumar, A.A., Somaraju, S.R., Dattuluri, R., Reddy, M.V.K., and Jain, S., 2022. Liver disease prediction using ensemble technique, *2022 8th International Conference on Advanced Computing and Communication Systems (ICACCS)*, volume 1, 1522–1525, IEEE.

82. Jani, R., Shanto, M.S.I., Kabir, M.M., Rahman, M.S., and Mridha, M., 2022. Heart disease prediction and analysis using ensemble architecture, *2022 International Conference on Decision Aid Sciences and Applications (DASA)*, 1386–1390, IEEE.

83. Verma, R. and Chandra, S., 2023. RepuTE: A soft voting ensemble learning framework for reputation-based attack detection in fog-IoT milieu, **Engineering Applications of Artificial Intelligence**, **118**:105670.

84. Mohammed, A. and Kora, R., 2023. A comprehensive review on ensemble deep learning: Opportunities and challenges, **Journal of King Saud University-Computer and Information Sciences**, **35**(2):757–774.

85. Ali, A.H., Yaseen, M.G., Aljanabi, M., and Abed, S.A., 2023. Transfer learning: A new promising techniques, **Mesopotamian Journal of Big Data**, **2023**:29–30.

86. Wang, D. and Zheng, T.F., 2015. Transfer learning for speech and language processing, *2015 Asia-Pacific Signal and Information Processing Association Annual Summit and Conference (APSIPA)*, 1225–1237.

87. Gajera, H.K., Nayak, D.R., and Zaveri, M.A., 2023. A comprehensive analysis of dermoscopy images for melanoma detection via deep CNN features, **Biomedical Signal Processing and Control**, **79**:104186.

88. Chen, L.C., Papandreou, G., Kokkinos, I., Murphy, K., and Yuille, A.L., 2017. Deeplab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs, **IEEE transactions on pattern analysis and machine intelligence**, **40**(4):834–848.

89. Oliveira, R.B., Mercedes Filho, E., Ma, Z., Papa, J.P., Pereira, A.S., and Tavares, J.M.R., 2016. Computational methods for the image segmentation of pigmented skin lesions: A review, **Computer methods and programs in biomedicine**, **131**:127–141.

90. Mahmud, M.N., Azim, M.H., Hisham, M., Osman, M.K., Ismail, A.P., Ahmad, F., Ahmad, K.A., Ibrahim, A., and Rabiani, A.H., 2022. Altitude analysis of road segmentation from UAV images with deepLab V3+, *2022 IEEE 12th International Conference on Control System, Computing and Engineering (ICCSCE)*, 219–223.

91. Shia, W.C., Hsu, F.R., Dai, S.T., Guo, S.L., and Chen, D.R., 2022. Semantic segmentation of the malignant breast imaging reporting and data system lexicon on breast ultrasound images by using DeepLab v3+, **Sensors**, **22**(14):5352.

92. Yuan, H., Zhu, J., Wang, Q., Cheng, M., and Cai, Z., 2022. An improved DeepLab v3+ deep learning network applied to the segmentation of grape leaf black rot spots, **Frontiers in Plant Science**, **13**:795410.

93. Barbieri, M.C., Grisci, B.I., and Dorn, M., 2024. Analysis and comparison of feature selection methods towards performance and stability, **Expert Systems with Applications**, **249**:123667.

94. Kira, K. and Rendell, L.A., 1992. The feature selection problem: Traditional methods and a new algorithm, *Proceedings of the Tenth National Conference on Artificial Intelligence*, AAAI'92, 129–134, AAAI Press.

95. Kononenko, I., 1994. Estimating attributes: Analysis and extensions of RELIEF, *F. Bergadano and L. De Raedt, Eds:, Machine Learning: ECML-94*, 171–182, Springer Berlin Heidelberg, Berlin, Heidelberg.

96. Zhang, Y., Ren, X., and Zhang, J., 2019. Intrusion detection method based on information gain and ReliefF feature selection, *2019 International Joint Conference on Neural Networks (IJCNN)*, 1–5, IEEE.

97. Wu, H., Yang, T., Li, H., and Zhou, Z., 2023. Air quality prediction model based on mRMR–RF feature selection and ISSA–LSTM, **Scientific Reports**, **13**(1):12825.

98. Çalışkan, A., 2023. Diagnosis of malaria disease by integrating chi-square feature selection algorithm with convolutional neural networks and autoencoder network, **Transactions of the Institute of Measurement and Control**, **45**(5):975–985.

99. Palanivinayagam, A., El-Bayeh, C.Z., and Damaševičius, R., 2023. Twenty years of machine-learning-based text classification: A systematic review, **Algorithms**, **16**(5):236.

100. Cortes, C. and Vapnik, V., 1995. Support-vector networks, **Machine learning**, **20**:273–297.

101. Maswadi, K., Ghani, N.A., Hamid, S., and Rasheed, M.B., 2021. Human activity classification using decision tree and naive bayes classifiers, **Multimedia Tools and Applications**, **80**(14):21709–21726.

102. Zhao, S., Zhang, B., Yang, J., Zhou, J., and Xu, Y., 2024. Linear discriminant analysis, **Nature Reviews Methods Primers**, **4**(1):70.

103. Boateng, E.Y., Otoo, J., and Abaye, D.A., 2020. Basic tenets of classification algorithms k-nearest-neighbor, support vector machine, random forest and neural network: A review, **Journal of Data Analysis and Information Processing**, **8**(4):341–357.

104. Azeem, M., Kiani, K., Mansouri, T., and Topping, N., 2023. SkinLesNet: classification of skin lesions and detection of melanoma cancer using a novel multi-layer deep convolutional neural network, **Cancers**, **16**(1):108.

105. Gopikha, S. and Balamurugan, M., 2023. Regularised layerwise weight norm based skin lesion features extraction and classification., **Computer Systems Science & Engineering**, **44**(3).

106. Qasim Gilani, S., Syed, T., Umair, M., and Marques, O., 2023. Skin cancer classification using deep spiking neural network, **Journal of Digital Imaging**, **36**:1137–1147.

107. Jui, A.H., Sharnami, S., and Islam, A., 2022. A CNN based approach to classify skin cancers using transfer learning, *2022 25th International Conference on Computer and Information Technology (ICCIT)*, 1063–1068.

108. Suleman, M., Ullah, F., Aldehim, G., Shah, D., Abrar, M., Irshad, A., and Ayouni, S., 2023. Smart mobiNet: a deep learning approach for accurate skin cancer diagnosis, **CMC-Computers Materials & Continua**, **77**(3):3533–3549.

109. Tuncer, T., Barua, P.D., Tuncer, I., Dogan, S., and Acharya, U.R., 2024. A lightweight deep convolutional neural network model for skin cancer image classification, **Applied Soft Computing**, **162**:111794.

110. Desale, R. and Patil, P., 2024. An efficient multi-class classification of skin cancer using optimized vision transformer, **Medical & Biological Engineering & Computing**, **62**(3):773–789.

111. Dagnaw, G.H., El Mouhtadi, M., and Mustapha, M., 2024. Skin cancer classification using vision transformers and explainable artificial intelligence, **Journal of Medical Artificial Intelligence**.

112. La Salvia, M., Torti, E., Marenzi, E., Danese, G., and Leporati, F., 2024. Edge and cloud computing approaches in the early diagnosis of skin cancer with attention-based vision transformer through hyperspectral imaging, **The Journal of Supercomputing**, **80**:16368–16392.

113. Ghosh, S., Dhar, S., Yoddha, R., Kumar, S., Thakur, A.K., and Jana, N.D., 2024. Melanoma skin cancer detection using ensemble of machine learning models considering deep feature embeddings, **Procedia Computer Science**, **235**:3007–3015.

114. Flosdorf, C., Engelker, J., Keller, I., and Mohr, N., 2024. Skin cancer detection utilizing deep learning: Classification of skin lesion images using a vision transformer, **arXiv preprint arXiv:2407.18554**.

115. Reis, H.C. and Turk, V., 2024. Fusion of transformer attention and CNN features for skin cancer detection, **Applied Soft Computing**, **164**:112013.

116. Shobhit, P. and Kumar, N., 2023. Vision transformer and attention-based melanoma disease classification, *2023 4th International Conference on Communication, Computing and Industry 6.0 (C216)*, 1–6, IEEE.

117. Kusumastuti, R. and Sunyoto, A., 2023. Skin cancer classification using efficientNetV2 and ViT B16, *2023 6th International Conference on Information and Communications Technology (ICOIACT)*, 395–400, IEEE.

118. Nikitin, V. and Danilov, V., 2023. Integration of fractal dimension in vision transformer for skin cancer classification, **Electronics and Control Systems**, **2**(76):15–20.

119. Vachmanus, S., Noraset, T., Piyanonpong, W., Rattananukrom, T., and Tuarob, S., 2023. DeepMetaForge: A deep vision-transformer metadata-fusion network for automatic skin lesion classification, **IEEE Access**, **11**:145467–145484.

120. Ramamurthy, K., Thayumanaswamy, I., Radhakrishnan, M., Won, D., and Lingaswamy, S., 2024. Integration of localized, contextual, and hierarchical features in deep learning for improved skin lesion classification, **Diagnostics**, **14**(13):1338.

121. Kumar, A., Vishwakarma, A., Bajaj, V., and Mishra, S., 2024. Novel mixed domain hand-crafted features for skin disease recognition using multiheaded CNN, **IEEE Transactions on Instrumentation and Measurement**, **73**:1–13.

122. Subhashini, G. and Chandrasekar, A., 2024. Hybrid deep learning technique for optimal segmentation and classification of multi-class skin cancer, **The Imaging Science Journal**, **72**(8):1043–1064.

123. De, A., Mishra, N., and Chang, H.T., 2024. Hybridized CNN-densenet model for dermatological classification of histopathological skin images, *2024 International Conference on Advancements in Smart, Secure and Intelligent Computing (ASSIC)*, 1–6.

124. Yu, L., Wang, Y., Zhou, L., Wu, J., and Wang, Z., 2023. Residual neural network-assisted one-class classification algorithm for melanoma recognition with imbalanced data, **Computational Intelligence**, **39**(6):1004–1021.

125. Seeja, R. and Geetha, A., 2024. Effective melanoma classification using inter neighbour mean order interleaved pattern on dermoscopy images, **Multimedia Tools and Applications**, **83**:27481–27505.

126. Abdelhafeez, A., Mohamed, H.K., Maher, A., and Khalil, N.A., 2023. A novel approach toward skin cancer classification through fused deep features and neutrosophic environment, **Frontiers in Public Health**, **11**:1123581.

127. Li, S., Kou, P., Ma, M., Yang, H., Huang, S., and Yang, Z., 2024. Application of semi-supervised learning in image classification: Research on fusion of labeled and unlabeled data, **IEEE Access**, **12**:27331–27343.

128. Pandey, A., Teja, M.S., Sahare, P., Kamble, V., Parate, M., and Hashmi, M.F., 2024. Skin cancer classification using non-local means denoising and

sparse dictionary learning based CNN, **Journal of Electrical Systems and Information Technology**, **11**(1):36.

129. Khan, S., Fazal, A.S., Khan, A., and Khan, A., 2024. An automated skin lesions classification using hybrid CNN and transformer based deep learning model, *Proceedings of the 2023 8th International Conference on Biomedical Imaging, Signal Processing*, ICBSP '23, 26–31, Association for Computing Machinery, New York, NY, USA.

130. Sajol, M.S.I., Alvi, S.T., and Era, C.A.A., 2024. Performance assessment of advanced CNN and transformer architectures in skin cancer detection, **TechRxiv**.

131. Tada, M. and Han, X.H., 2023. Bottleneck transformer model with channel self-attention for skin lesion classification, *2023 18th International Conference on Machine Vision and Applications (MVA)*, 1–5, IEEE.

132. Guchhait, A., Barman, A., and Roy, S.K., 2024. Masksemble-aided cross-viT for uncertainty estimation in skin cancer diagnosis, **Available at SSRN 4956250**.

133. Gairola, A.K., Kumar, V., and Sahoo, A.K., 2024. MLFF-Net: a multi-model late feature fusion network for skin disease classification, **Indonesian Journal of Electrical Engineering and Computer Science**, **35**(3):1906–1914.

134. Khan, M., Ahmad, J., Saddik, A.E., and Gueaieb, W., 2024. Skin-former: mobile-friendly transformer for skin lesion diagnosis, *2024 IEEE International Conference on Consumer Electronics (ICCE)*, 1–6.

135. Nie, Y., Sommella, P., Carratù, M., O'Nils, M., and Lundgren, J., 2022. A deep CNN transformer hybrid model for skin lesion classification of dermoscopic images using focal loss, **Diagnostics**, **13**(1):72.

136. Khan, S. and Khan, A., 2023. SkinViT: A transformer based method for melanoma and nonmelanoma classification, **PLOS ONE**, **18**(12):1–19.

137. Ansari, S.A., Agrawal, A.P., Wajid, M.A., Wajid, M.S., and Zafar, A., 2024. MetaV: A Pioneer in feature augmented meta-learning based vision transformer for

medical image classification, **Interdisciplinary Sciences: Computational Life Sciences**, **16**:469–488.

138. Zhang, C., Wang, S., Zhang, Y., and Hu, H., 2023. Research on dermatological classification algorithm based on the fusion model, *2023 WRC Symposium on Advanced Robotics and Automation (WRC SARA)*, 408–413.

139. Mushtaq, S. and Singh, O., 2024. A deep learning based architecture for multi-class skin cancer classification, **Multimedia Tools and Applications**, **83**:87105–87127.

140. Shajimon, G.M., Ufumaka, I., and Raza, H., 2023. An improved vision-transformer network for skin cancer classification, *2023 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)*, 2213–2216, IEEE.

141. Bechelli, S. and Delhommelle, J., 2022. Machine learning and deep learning algorithms for skin cancer classification from dermoscopic images, **Bioengineering**, **9**(3):97.

142. Thwin, S.M. and Park, H.S., 2024. Skin lesion classification using a deep ensemble model, **Applied Sciences**, **14**(13):5599.

143. Bhargavi, M., Renugadevi, R., Sivabalan, S., Phani, P., Ganesh, J., and Bhanu, K., 2023. Ensemble learning for skin lesion classification: A robust approach for improved diagnostic accuracy (ELSLC), *2023 3rd International Conference on Innovative Mechanisms for Industry Applications (ICIMIA)*, 390–395, IEEE.

144. Chatterjee, S., Gil, J.M., and Byun, Y.C., 2024. Early detection of multiclass skin lesions using transfer learning-based incepX-ensemble model, **IEEE Access**, **12**:113677–113693.

145. Santos, F., Silva, F., and Georgieva, P., 2021. Transfer learning for skin lesion classification using convolutional neural networks, *2021 International Conference on Innovations in Intelligent SysTems and Applications (INISTA)*, 1–6, IEEE.

146. Pacheco, A.G., Trappenberg, T., and Krohling, R.A., 2020. Learning dynamic weights for an ensemble of deep models applied to medical imaging classification, *2020 International Joint Conference on Neural Networks (IJCNN)*, 1–8, IEEE.

147. Gupta, S., Jayanthi, R., Verma, A.K., Saxena, A.K., Moharana, A.K., and Goswami, S., 2023. Ensemble optimization algorithm for the prediction of melanoma skin cancer, **Measurement: Sensors**, **29**:100887.

148. Cauvery, K., Siddalingaswamy, P., Pathan, S., and D'souza, N., 2021. A multiclass skin lesion classification approach using transfer learning based convolutional neural network, *2021 Seventh International Conference on Bio Signals, Images, and Instrumentation (ICBSII)*, 1–6, IEEE.

149. Benyahia, S., Meftah, B., and Lézoray, O., 2022. Multi-features extraction based on deep learning for skin lesion classification, **Tissue and Cell**, **74**:101701.

150. Yu, X., Xiong, G., Wu, J., Zheng, J., Liang, M., Qiu, L., Yu, L., and Xu, Q., 2024. Variational AdaBoost knowledge distillation for skin lesion classification in dermatology images, **Complex & Intelligent Systems**, **10**:6787–6804.

151. The International Skin Imaging Collaboration, 2024, The international skin imaging collaboration, (Web sayfası: **https://www.isic-archive.com**), (Erişim tarihi: Eylül 2024).

152. Codella, N., Rotemberg, V., Tschandl, P., Celebi, M.E., Dusza, S., Gutman, D., Helba, B., Kalloo, A., Liopyris, K., Marchetti, M., et al., 2019. Skin lesion analysis toward melanoma detection 2018: A challenge hosted by the international skin imaging collaboration (isic), **arXiv preprint arXiv:1902.03368**.

153. The International Skin Imaging Collaboration, 2024, ISIC challenge datasets, (Web sayfası: **https://challenge.isic-archive.com/data**), (Erişim tarihi: Ekim 2024).

154. Tschandl, P., Rosendahl, C., and Kittler, H., 2018. The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions, **Scientific data**, **5**(1):1–9.

155. Codella, N.C., Gutman, D., Celebi, M.E., Helba, B., Marchetti, M.A., Dusza, S.W., Kalloo, A., Liopyris, K., Mishra, N., Kittler, H., et al., 2018. Skin lesion analysis toward melanoma detection: A challenge at the 2017 international symposium on biomedical imaging (isbi), hosted by the international skin imaging collaboration (isic), *2018 IEEE 15th International Symposium on Biomedical Imaging (ISBI 2018)*, 168–172, IEEE.

156. Combalia, M., Codella, N.C., Rotemberg, V., Helba, B., Vilaplana, V., Reiter, O., Carrera, C., Barreiro, A., Halpern, A.C., Puig, S., et al., 2019. Bcn20000: Dermoscopic lesions in the wild, **arXiv preprint arXiv:1908.02288**.

157. Rainio, O., Teuho, J., and Klén, R., 2024. Evaluation metrics and statistical tests for machine learning, **Scientific Reports**, **14**(1):6086.

158. Zou, K.H., Warfield, S.K., Bharatha, A., Tempany, C.M., Kaus, M.R., Haker, S.J., Wells III, W.M., Jolesz, F.A., and Kikinis, R., 2004. Statistical validation of image segmentation quality based on a spatial overlap index1: scientific reports, **Academic radiology**, **11**(2):178–189.

159. Besta, M., Kanakagiri, R., Mustafa, H., Karasikov, M., Rätsch, G., Hoefler, T., and Solomonik, E., 2020. Communication-efficient jaccard similarity for high-performance distributed genome comparisons, *2020 IEEE International Parallel and Distributed Processing Symposium (IPDPS)*, 1122–1132, IEEE.

160. Muschelli III, J., 2020. ROC and AUC with a binary predictor: A potentially misleading metric, **Journal of classification**, **37**(3):696–708.

161. Salau, A.O. and Jain, S., 2019. Feature extraction: A survey of the types, techniques, applications, *2019 International Conference on Signal Processing and Communication (ICSC)*, 158–164.

162. Mahbod, A., Schaefer, G., Ellinger, I., Ecker, R., Pitiot, A., and Wang, C., 2019. Fusing fine-tuned deep features for skin lesion classification, **Computerized Medical Imaging and Graphics**, **71**:19–29.

163. Krizhevsky, A., Sutskever, I., and Hinton, G.E., 2017. ImageNet classification with deep convolutional neural networks, **Commun. ACM**, **60**(6):84–90.

164. Redmon, J., Divvala, S., Girshick, R., and Farhadi, A., 2016, You only look once: Unified, real-time object detection, eprint:1506.02640.

165. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., 2015. Going deeper with convolutions, *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 1–9.

166. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z., 2016. Rethinking the inception architecture for computer vision, *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2818–2826.

167. He, K., Zhang, X., Ren, S., and Sun, J., 2016. Deep residual learning for image recognition, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778.

168. Zhang, X., Zhou, X., Lin, M., and Sun, J., 2017, ShuffleNet: An extremely efficient convolutional neural network for mobile devices, eprint:1707.01083.

169. Iandola, F.N., Han, S., Moskewicz, M.W., Ashraf, K., Dally, W.J., and Keutzer, K., 2016, SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and <0.5MB model size, eprint:1602.07360.

170. Simonyan, K. and Zisserman, A., 2015, Very deep convolutional networks for large-scale image recognition, eprint:1409.1556.

171. Chollet, F., 2017. Xception: Deep learning with depthwise separable convolutions, *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 1251–1258.

172. He, K., Zhang, X., Ren, S., and Sun, J., 2016. Identity mappings in deep residual networks, *Computer Vision–ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, October 11–14, 2016, Proceedings, Part IV 14*, volume 9908, 630–645, Springer.

173. Szegedy, C., Ioffe, S., Vanhoucke, V., and Alemi, A., 2017. Inception-v4, inception-resnet and the impact of residual connections on learning, **Proceedings of the AAAI Conference on Artificial Intelligence**, **31**(1).

174. Tan, M. and Le, Q., 2021. EfficientNetV2: Smaller models and faster training, *M. Meila and T. Zhang, Eds:, Proceedings of the 38th International Conference on Machine Learning*, volume 139 of Proceedings of Machine Learning Research, 10096–10106, PMLR.

175. Howard, A., Sandler, M., Chu, G., Chen, L.C., Chen, B., Tan, M., Wang, W., Zhu, Y., Pang, R., Vasudevan, V., Le, Q.V., and Adam, H., 2019. Searching for mobileNetV3, *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 1314–1324.

176. Yu, W., Zhou, P., Yan, S., and Wang, X., 2024. InceptionNeXt: When inception meets convnext, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 5672–5683.

177. Chen, C., Guo, Z., Zeng, H., Xiong, P., and Dong, J., 2024, RepGhost: A hardware-efficient ghost module via re-parameterization, eprint:2211.06088.

178. Sattarzadeh, S., Shalmani, S.M., and Azad, S., 2022. Mitigating paucity of data in sinusoid characterization using generative synthetic noise, *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops*, 4840–4849.

179. Tang, Y., Han, K., Guo, J., Xu, C., Xu, C., and Wang, Y., 2022. GhostNetv2: Enhance cheap operation with long-range attention, **Advances in Neural Information Processing Systems**, **35**:9969–9982.

180. Mehta, S. and Rastegari, M., 2022, MobileViT: Light-weight, general-purpose, and mobile-friendly vision transformer, eprint:2110.02178.

181. Touvron, H., Cord, M., and Jégou, H., 2022, DeiT III: Revenge of the ViT, eprint:2204.07118.

182. Bao, H., Dong, L., Piao, S., and Wei, F., 2022, BEiT: BERT pre-training of image transformers, eprint:2106.08254.

183. Heo, B., Yun, S., Han, D., Chun, S., Choe, J., and Oh, S.J., 2021. Rethinking spatial dimensions of vision transformers, *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 11936–11945.

184. Li, J., Xia, X., Li, W., Li, H., Wang, X., Xiao, X., Wang, R., Zheng, M., and Pan, X., 2022, Next-ViT: Next generation vision transformer for efficient deployment in realistic industrial scenarios, eprint:2207.05501.

185. Li, Y., Wu, C.Y., Fan, H., Mangalam, K., Xiong, B., Malik, J., and Feichtenhofer, C., 2022, MViTv2: Improved multiscale vision transformers for classification and detection, eprint:2112.01526.

186. Wu, K., Zhang, J., Peng, H., Liu, M., Xiao, B., Fu, J., and Yuan, L., 2022. Tinyvit: Fast pretraining distillation for small vision transformers, *European Conference on Computer Vision*, 68–85, Springer.

187. d'Ascoli, S., Touvron, H., Leavitt, M.L., Morcos, A.S., Biroli, G., and Sagun, L., 2021. Convit: Improving vision transformers with soft convolutional inductive biases, *International Conference on Machine Learning*, 2286–2296, PMLR.

188. Xu, W., Xu, Y., Chang, T., and Tu, Z., 2021. Co-scale conv-attentional image transformers, *Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)*, 9981–9990.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı	:	İbrahim ARUK
Uyruğu	:	Türkiye (T.C.)
Doğum Tarihi ve Yeri	:	
Medeni Durum	:	
e-mail	:	
Yazışma Adresi	:	

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	Trakya Üniversitesi, Bilgisayar Mühendisliği	2008
Lisans	Gazi Üniversitesi, Bilişim Sistemleri Bölümü	2004
Lise	Merkez Endüstri Meslek Lisesi, Adana	1999

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2008-Halen	Şehit İdari Ataşe Galip Özmen MTAL	Bilişim Teknolojileri Öğretmeni
2004-2008	Edirne Endüstri Meslek Lisesi	Bilişim Teknolojileri Öğretmeni

YABANCI DİL

İngilizce

YAYINLAR

SCI, SSCI, AHCI İndekslerine Giren Dergilerde Yayınlanan Makaleler

1. Toprak A.N., Aruk I, "A Hybrid Convolutional Neural Network Model for the Classification of Multi-Class Skin Cancer", International Journal of Imaging Systems and Technology, 34.5 (2024) : e23180.

SCI İndekslerine Giren Dergi Sistemlerine Yüklenen ve İncelemedeki Makaleler

1. Aruk I., Pacal I., Toprak A. N., "A novel hybrid ConvNeXt-based approach for enhanced skin lesion classification", Alexandria Engineering Journal, 2024. (İncelemede)

1. Aruk I., Pacal I., Toprak A. N., "A Comprehensive Comparison of Convolutional Neural Networks and Visual Transformers on Skin Cancer Classification", Medical & Biological Engineering & Computing, 2024. (İncelemede)

Diğer Dergilerde Yayınlanan Makaleler

1. Ozcan T., Toprak A. N., Aruk I., Sahin O., Ozcan I. "Applications of deep learning techniques in healthcare systems: A review", Journal of Clinical Practice and Research, J Clin Pract Res 2024; 46(6): 527-536.

2. Aruk I., Toprak A. N. 2024. "Cilt Kanseri Tanısı için Farklı Evrişimsel Sinir Ağı Modellerinin Karşılaştırılması", Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi. (Kabul edildi).

Hakemli Kongre/Sempozyum Bildiri Kitaplarında Yer Alan Yayınlar

1. Aruk I., Okdem S., Ozturk C., "Akademik Benlik Kavramı Ölçeği Uygulaması İçin Uzman Sistem Tasarımı", III. Uluslararası Mesleki ve Teknik Bilimler Kongresi (UMTEB), 21-22 Haziran 2018, Gaziantep.

2. Aruk I., Mulayim M.K., Selcuk T., Okdem S., "Dermoskopik Görüntülerden Melanomun Semantik Segmentasyonu", International Symposium on Advanced Engineeıing Technologies (ISADET), 16-18 June 2022 Kahramanmaras.