

T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

YAPAY ZEKÂ VE AKILLI SİSTEMLER ANA BİLİM DALI

GHOSTNET TABANLI CNN MODELLERİ İLE
CİLT KANSERİ SINIFLANDIRILMASI

YÜKSEK LİSANS

Heba ALMASANI

ŞUBAT-2026
GÜMÜŞHANE



**T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

YAPAY ZEKÂ VE AKILLI SİSTEMLER ANA BİLİM DALI

**GHOSTNET TABANLI CNN MODELLERİ İLE
CİLT KANSERİ SINIFLANDIRILMASI**

**SKIN CANCER CLASSIFICATION USING
GHOSTNET-BASED CNN MODELS**

YÜKSEK LİSANS

Heba ALMASANI

**ŞUBAT-2026
GÜMÜŞHANE**



**T.C.
GÜMÜŞHANE ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

YAPAY ZEKÂ VE AKILLI SİSTEMLER ANA BİLİM DALI

**GHOSTNET TABANLI CNN MODELLERİ İLE
CİLT KANSERİ SINIFLANDIRILMASI**

**SKIN CANCER CLASSIFICATION USING
GHOSTNET-BASED CNN MODELS**

YÜKSEK LİSANS

Heba ALMASANI

Danışman: Dr. Öğr. Üyesi Hayati TÜRE

**ŞUBAT-2026
GÜMÜŞHANE**

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Yüksek Lisans Tezi olarak hazırlamış olduğum “**Ghostnet Tabanlı CNN Modelleri İle Cilt Kanseri Sınıflandırılması**” isimli bu tezimin, tamamen kendi çalışmam olduğunu, her alıntıya kaynak gösterdiğimi, alıntı yaptığım tüm çalışmalarını kaynakçada belirttiğimi ve Gümüşhane Üniversitesi’nin lisanslı kullanıcısı olduğum intihal yazılım programı ile Lisansüstü Eğitim Enstitüsü’nün belirlediği kısıtlara uygun olarak raporladığımı taahhüt ederim. Tezimin kâğıt ve elektronik kopyalarının Gümüşhane Üniversitesi Lisansüstü Eğitim Enstitüsü arşivinde saklanmasına izin verdiğimi onaylarım.

Lisansüstü Eğitim ve Öğretim Yönetmeliği’nin ilgili maddeleri uyarınca gereğinin yapılmasını arz ederim.

04/02/2026

.....
Heba ALMASANI

TEŞEKKÜR

Resmî bir sorumluluğu veya danışmanlık görevi olmamasına rağmen, kritik bir aşamada zaman ayırarak bazı kavramları benim için büyük bir açıklıkla anlatan Dr. Beker'a içten teşekkür ederim. Onun anlaşılır açıklamaları, kavramsal tıkanıklıkları aşmamı ve çalışmama güvenle devam etmemi sağladı; nezaketi ve meslektaşça desteği için minnettarım.

Bu çalışma süresince yol göstericiliği için danışmanım Hayati Türe'ye derin şükranlarımı sunarım. Planlamadan nihai yazıma kadar araştırmanın her aşamasında sunduğu yapıcı geri bildirim, yöntemsel yönlendirme ve teşvik, tezin bugünkü hâline ulaşmasında belirleyici olmuştur. Destek ve sabrı olmasaydı, bu çalışma bu düzeye erişemezdi.

HEBA ALMASANI
GÜMÜŞHANE – 2026

ÖZET

Bu tez, dermoskopik görüntülerden cilt kanserini otomatik olarak teşhis edebilen derin öğrenme tabanlı hibrit bir model önermektedir. Amaç; tanısal doğruluğu artırırken hesaplama maliyetini azaltmaktır. Bunun için, önceden eğitilmiş (pretrained) büyük CNN modelleri ile SMOTE-ENN veri dengelemesiyle optimize edilen hafif GhostNet mimarileri birlikte kullanılmıştır. İlk yaklaşımda, ISIC 2019 veri kümesi üzerinde altı model değerlendirilmiştir: VGG16, DenseNet201, EfficientNetB7, EfficientNetV2L, ConvNeXtBase ve MobileNet. Bu aşamada ConvNeXtBase, %84,63 doğruluk ve %78 duyarlılık ile güçlü bir başlangıç performansı göstermiştir. Ancak bu büyük modellerin gerçek zamanlı uygulamalarda kullanımı, yüksek hesaplama maliyeti nedeniyle zor olmuştur. Bu kısıtlamayı aşmak için ikinci yaklaşımda, GhostNet (V1–V3) mimarileri kullanılmıştır. Bu aşamada SMOTE-ENN dengelemesi uygulanmış ve yalnızca eğitim verisi üzerinde kullanılan Ayrık Tam Bağlantılı (DFC) dikkat mekanizmasıyla model performansı artırılmıştır. Sonuç olarak GhostNet V2, büyük CNN modellerine kıyasla parametre sayısını yaklaşık %90 azaltmasına rağmen daha yüksek performans elde etmiş; %95 doğruluk, %93,9 duyarlılık ve 0,99 AUC değerlerine ulaşmıştır. Deneysel sonuçlar, hafif ve verimli modellerin yüksek doğrulukla dermatolog düzeyine yakın tanısal performans sağlayabildiğini göstermektedir. Önerilen sistem; teletıp uygulamaları ve cilt kanseri taramaları için pratik, yorumlanabilir ve gerçek zamanlı bir yapay zekâ çözümü sunmaktadır.

Anahtar Kelimeler: Cilt kanseri, Derin öğrenme, GhostNet, SMOTE-ENN, Yapay zekâ

SUMMARY

This thesis presents a deep learning hybrid model for the automated diagnosis of skin cancer from dermoscopic images. The research seeks to enhance diagnostic precision as well as lower computational expenses by combining pretrained CNNs with lightweight GhostNet architectures optimized using SMOTE-ENN data balancing. The first approach utilized six pre-trained CNNs VGG16, DenseNet201, EfficientNetB7, EfficientNetV2L, ConvNeXtBase, and MobileNet on the ISIC 2019 dataset to set a strong baseline with 84.63% accuracy and 78% sensitivity of ConvNeXtBase. But these models were costly to deploy in real time. To overcome this constraint, the second approach utilized GhostNet architectures (V1–V3) with Decoupled Fully Connected (DFC) attention and SMOTE-ENN balancing only on the training data. GhostNet V2 obtained 95% accuracy, 93.9% sensitivity, and AUC of 0.99, outperforming big CNNs with parameter reduction of almost 90%. The experiments confirm that efficient models can achieve dermatologist-level diagnostic performance with high efficiency. The suggested model shows a practical, interpretable, and real-time artificial intelligence solution for teledermatology and skin cancer screening.

Keywords: Skin cancer, Deep learning, GhostNet, SMOTE-ENN, Artificial intelligence

İÇİNDEKİLER

KABUL VE ONAY	III
BİLİMSEL ETİĞE UYGUNLUK BEYANI	IV
TEŞEKKÜR	V
ÖZET	VI
SUMMARY	VII
İÇİNDEKİLER	VIII
ŞEKİLLER DİZİNİ	XII
SİMGELER VE KISALTMALAR DİZİNİ	XIII
1. GİRİŞ	1
1.1. Cilt Kanserinin Arka Planı	1
1.2. Motivasyon	2
1.3. Çalışmanın Kapsamı	3
1.4. Çalışmanın Amacı	3
1.5. Araştırma Hedefleri	3
1.6. Çalışmanın Katkıları	4
1.7. Güçlükler ve Zorluklar	4
1.8. Sonuç	5
2. LİTERATÜR İNCELEMESİ	6
2.1. Genel Bakış	6
2.2. Kanser: Genel Çerçeve	6
2.3. Cilt Kanseri: Epidemiyoloji ve Klinik Etki	7
2.4. Klasik ve Erken Dönem CAD Yaklaşımları	7
2.5. Dermatolojide Derin Öğrenme	8
2.6. Sınıf Dengesizliği ile Mücadele	9
2.6.1. Sınıf Dengesizliği Probleminin Doğası	9
2.6.2. Klasik Örnekleme Stratejileri	10
2.6.3. Hibrit Örnekleme Yaklaşımları	11
2.6.4. Literatürdeki Genel Gözlemler	13
2.7. Modeller	13
2.7.1. VGG-16	13
2.7.2. DenseNet-201	14
2.7.3. EfficientNet-B7	15

2.7.4. EfficientNetV2-L	15
2.7.5. ConvNeXt-Base	16
2.7.6. MobileNetV2	17
2.7.7. GhostNet V1	17
2.7.8. GhostNet V2	18
2.7.9. GhostNet V3	18
2.8. Temsilî Önceki Çalışmalar	19
2.9. Sonuç	23
3. MATERYAL VE YÖNTEMLER	24
3.1. Genel Bakış	24
3.2. Veri Kümesi ve Hazırlık	25
3.2.1. Veri Seti Açıklaması	25
3.2.2. Veri Seti Bölünmesi	26
3.2.3. Ön İşlem Adımları	27
3.3. Çerçeve I: Önceden Eğitilmiş CNN'lerle Transfer Öğrenme	28
3.3.1. Genel Bakış	28
3.3.2. Model Seçimi ve Adaptasyonu	31
3.3.3. Eğitim Konfigürasyonu	32
3.3.4. Değerlendirme Ölçütleri	33
3.3.5. Sonuçların Özeti	33
3.4. Çerçeve II: Hafif Mimari (GhostNet) + SMOTE-ENN	34
3.4.1. Genel Bakış	34
3.4.2. Sınıf Dengesizliğinin Giderilmesi	37
3.4.3. Ağ Mimarisi	38
3.4.4. Eğitim Süreci	39
3.4.5. Değerlendirme Metrikleri ve Sonuçlar	39
3.5. Karşılaştırmalı Özet ve Tartışma	40
4. SONUÇ VE DEĞERLENDİRME	41
4.1. Önceden Eğitilmiş CNN Çerçevesinin Sonuçları	41
4.1.1. Kantitatif Performans	41
4.2. Hafif GhostNet + SMOTE-ENN Yaklaşımının Sonuçları	43
4.2.1. Kantitatif Performans	43
4.2.2. Karşılaştırmalı Değerlendirme	44
4.3. Sonuç	47
5. TARTIŞMA	49

5.1. Genel Bakış	49
5.2. Önceden Eğitilmiş CNN Sonuçlarının Yorumlanması	49
5.3. GhostNet + SMOTE-ENN Sonuçlarının Yorumlanması	50
5.4. Önceki Çalışmalarla Karşılaştırma	50
5.5. Klinik Çıkarımlar	51
5.6. Sınırlamalar	51
5.7. Gelecek Çalışmalar	51
5.8. Genel Değerlendirme	52
6. SINIRLILIKLAR VE GELECEK ÇALIŞMALAR	53
6.1. Genel Bakış	53
6.2. Önemli Bulguların Özeti	53
6.2.1. Transfer Öğrenimi Temel Modeli	53
6.2.2. Hafif GhostNet + SMOTE-ENN İşlem Hattı	53
6.3. Bilimsel ve Klinik Katkıları	54
6.4. Sınırlamalar	54
6.5. Gelecek Çalışmalar İçin Öneriler	55
6.6. Son Değerlendirmeler	55
KAYNAKÇA	56
ÖZGEÇMİŞ	60

TABLÖLAR DİZİNİ

Tablo 1. Yapay Zekâ ve Derin Öğrenme Yaklaşımlarıyla Cilt Kanseri Sınıflandırmasına Yönelik Temel Çalışmaların Özeti	22
Tablo 2. Metodoloji Ayrıntıları (Veri Bölünmesi, Hiperparametreler)	27
Tablo 3. Önceden Eğitilmiş Omurgaların Hesaplama Karmaşıklığı (Parametre ve FLOP'lar)	32
Tablo 4. GhostNet modellerinin hesaplama profili ve çalışma gecikmesi	39
Tablo 5. Altı önceden eğitilmiş CNN modelinin nicel performansını özetlemektedir ...	41
Tablo 6. Çerçeve II (GhostNet) test sonuçları	44
Tablo 7. En iyi ağır omurga (ConvNeXt-Base; Çerçeve I) ile en iyi hafif modelin (GhostNet-V2; Çerçeve II) ISIC-2019 (ikili) üzerindeki doğrudan karşılaştırması	44

ŞEKİLLER DİZİNİ

Şekil 1. İyi huylu ve kötü huylu örneklerin sınıf dağılımı histogramı	10
Şekil 2. SMOTE-ENN'in etkisinin kavramsal gösterimi: solda özgün dengesiz dağılım, sağda SMOTE ile artırılmış ve ENN ile sınırı temizlenmiş veri	13
Şekil 3. Çerçeve I ve Çerçeve II için Birleştirilmiş Veri Akış Diyagramı	24
Şekil 4. ISIC 2019 dermoskopik veri kümesinden temsili örnekler	26
Şekil 5. Çalışmada kullanılan temel veri artırma (augmentation) işlemlerinin örnek görüntüleri	36
Şekil 6. Altı önceden eğitilmiş CNN modelinin ROC eğrilerini karşılaştırmaktadır	42
Şekil 7. (ISIC 2019) test seti üzerinde ConvNeXtBase modelinin sınıflandırma sonuçlarını gösteren karışıklık matrisi (confusion matrix)	43
Şekil 8. ISIC 2019 test seti üzerinde ChostNet V2 modelinin sınıflandırma sonuçlarını gösteren karışıklık matrisi (confusion matrix)	45
Şekil 9. Test kümesinde GhostNet V1–V3 modellerinin ROC eğrilerinin karşılaştırılması	46
Şekil 10. Grad-CAM'li temsili dermoskopi olguları: DP, YP ve YN (malign odak düzensiz yapılarda)	47

SİMGELER VE KISALTMALAR DİZİNİ

AI	: Artificial Intelligence (Yapay zekâ)
AK	: Aktinik keratoz
AUC	: Area Under the ROC Curve (Eğri altındaki alan)
BCC	: Bazal hücreli karsinom
CAD	: Computer-Aided Diagnosis (Bilgisayar destekli tanı)
CNN	: Convolutional Neural Network (Evrışimsel sinir ağı)
DF	: Dermatofibrom
DP	: Doğru pozitif (True positive)
ENN	: Edited Nearest Neighbor (Düzenlenmiş en yakın komşu)
YN	: Yanlış negatif
YP	: Yanlış pozitif
GhostNet	: GhostNet derin öğrenme mimarisi (lightweight CNN modeli)
ISIC	: International Skin Imaging Collaboration
MEL	: Melanom
NV	: Melanositik nevüs (ben, mole)
SMOTE	: Synthetic Minority Over-sampling Technique (Sentetik azınlık aşırı örnekleme)
SCC	: Skuamöz hücreli karsinom
VASC	: Vasküler lezyon (damarsal benign lezyon)
VGG16	: Visual Geometry Group 16-katmanlı CNN modeli
YN	: Yanlış negatif (False negative)
YP	: Yanlış pozitif (False positive)

1. GİRİŞ

1.1. Cilt Kanserinin Arka Planı

Kanser, kontrolsüz hücre proliferasyonu, lokal invazyon ve uzak organlara metastaz yapabilme kapasitesi ile karakterize edilen heterojen bir hastalık grubudur. Kanser hücreleri, köken aldıkları dokunun biyolojik özelliklerini büyük ölçüde koruyarak yayılma eğilimindedir. Bu durum, birçok kanser türünün yaşamı tehdit edici hâle gelmesinin temel nedenlerinden biri olarak kabul edilmektedir (National Cancer Institute, 2025). Küresel ölçekte kanser, en yaygın ve en ciddi sağlık sorunlarından biri olmaya devam etmektedir. Dünya Sağlık Örgütü verilerine göre 2022 yılında yaklaşık 20 milyon yeni kanser vakası ve 9,7 milyon kanserle ilişkili ölüm bildirilmiştir (World Health Organization, 2025). Ayrıca nüfus artışı, yaşlanma ve risk faktörlerindeki değişimler nedeniyle yeni vaka sayısının 2050 yılına kadar yaklaşık 35 milyona ulaşması beklenmektedir (World Health Organization / International Agency for Research on Cancer, 2024).

Cilt kanseri, dünya genelinde en sık teşhis edilen kanser türlerinden biridir ve her yıl milyonlarca kişiye cilt kanseri tanısı konulmaktadır. Cilt kanseri genel olarak melanom ve melanom dışı cilt kanserleri olmak üzere iki ana grupta incelenmektedir. Melanom dışı cilt kanserleri arasında bazal hücreli karsinom (Basal Cell Carcinoma, BCC) ve skuamöz hücreli karsinom (Squamous Cell Carcinoma, SCC) yer almakta olup, vakaların büyük çoğunluğunu bu türler oluşturmaktadır. Melanom ise yüksek metastaz potansiyeli nedeniyle en ölümcül cilt kanseri türü olarak kabul edilmekte ve cilt kanserine bağlı ölümlerin önemli bir bölümünden sorumlu olmaktadır (American Cancer Society, 2023; Siegel vd., 2022). Dünya Sağlık Örgütü (WHO, 2023), cilt kanseri vakalarındaki küresel artışa dikkat çekmekte ve bu artışı özellikle ultraviyole (UV) radyasyon gibi çevresel faktörler, genetik yatkınlık ve yaşam tarzındaki değişikliklerle ilişkilendirmektedir.

Melanomda yaşam süresi (sağkalım) büyük ölçüde erken tanıya bağlıdır. Erken evrede tanı alan hastalarda beş yıllık sağkalım oranı %95'in üzerindeyken, ileri evre melanomda bu oran %30'un altına düşmektedir (Siegel vd., 2022). Klinik tanıda dermoskopi ve histopatolojik inceleme yaygın olarak kullanılmasına rağmen, bu yöntemlerin bazı sınırlılıkları bulunmaktadır. Bu değerlendirmeler belirli ölçüde öznel

olabilir, gözlemci deneyimine bağlıdır ve zaman alıcıdır. Bu durum, gözlemciler arası farklılıklara ve tanı sürecinde gecikmelere yol açabilmektedir (Haenssle vd., 2018).

Yapay zekânın (Artificial Intelligence, AI), özellikle derin öğrenme yöntemleri aracılığıyla tıp alanında kullanılmaya başlanması, tanı hızını ve doğruluğunu artırmak açısından önemli fırsatlar sunmuştur. Evrişimsel sinir ağları (Convolutional Neural Networks, CNN'ler), bazı koşullarda dermoskopik görüntüleri dermatolog düzeyinde sınıflandırabilmiş ve kontrollü ortamlarda insan uzmanların performansını aşabilmiştir (Esteva vd., 2017; Litjens vd., 2017). Bununla birlikte, gerçek dünya uygulamalarında hâlâ önemli sınırlılıklar bulunmaktadır. Veri kümeleri çoğu zaman ciddi ölçüde dengesizdir; benign örneklerin sayısı malign örneklerden çok daha fazladır. Bu durum, modellerin nadir fakat klinik açıdan kritik öneme sahip malign lezyonları gözden kaçırmaya neden olabilmektedir (Nguyen vd., 2022). Ayrıca ResNet, DenseNet ve EfficientNet gibi yüksek performanslı CNN mimarileri önemli hesaplama kaynakları gerektirmektedir. Bu durum, nokta-bazlı tanı sistemleri veya mobil uygulamalar gibi kaynak kısıtlı ortamlarda bu modellerin kullanımını zorlaştırabilmektedir (He vd., 2016).

1.2. Motivasyon

Bu tezin motivasyonu iki temel sınırlılığa dayanmaktadır. Birincisi, gerçek dünya koşullarında ve kaynakların kısıtlı olduğu ortamlarda güvenilir biçimde çalışabilecek otomatik tanı sistemlerinin yeterince yaygın olmamasıdır. Dermatologlara erişimin sınırlı olduğu bölgelerde, hızlı ve doğru sonuçlar üreten otomatik bir sistem erken tanıyı destekleyerek hasta sonuçlarının iyileştirilmesine katkı sağlayabilir.

İkinci sınırlılık ise, ISIC 2019 gibi büyük dermoskopik veri kümelerinde belirgin sınıf dengesizliğinin bulunmasıdır. Geleneksel derin öğrenme modelleri genel doğruluk açısından yüksek performans gösterebilse de, klinik açıdan kritik öneme sahip malign sınıflarda daha düşük başarı sergileyebilmektedir. Bu durum, modellerin genellenebilirliğini sınırlandıran önemli bir faktör olarak değerlendirilmektedir.

Bu çalışma, hem hesaplama açısından verimli hem de tanısal açıdan güçlü bir çözüm geliştirmeyi amaçlamaktadır. Bu kapsamda, GhostNet gibi hafif evrişimsel sinir ağı (CNN) mimarilerinin, SMOTE-ENN gibi sınıf dengesizliği giderme yöntemleri ile birlikte kullanılmasıyla verimlilik ile yüksek doğruluğun aynı anda elde edilebileceği gösterilmeye çalışılmaktadır.

1.3. Çalışmanın Kapsamı

Bu çalışma, ISIC 2019 veri kümesinden elde edilen dermoskopik görüntüler kullanılarak cilt lezyonlarının ikili sınıflandırılmasında (benign = iyi huylu, malign = kötü huylu) derin öğrenme yöntemlerinin uygulanmasına odaklanmaktadır. Tez kapsamında hem önceden eğitilmiş yüksek kapasiteli evrimsel sinir ağı (CNN) modelleri (VGG16, DenseNet201, EfficientNetB7, EfficientNetV2L, ConvNeXtBase ve MobileNet) hem de hafif CNN modelleri (GhostNet V1, GhostNet V2 ve GhostNet V3) değerlendirilmiştir. Çalışmada yalnızca sınıflandırma doğruluğu değil, aynı zamanda bu modellerin klinik iş akışlarında ve mobil ya da kaynak kısıtlı ortamlarda uygulanabilirliği de incelenmiştir.

Araştırma yalnızca görüntü tabanlı analiz ile sınırlıdır; lezyonun konumu, hastanın yaşı veya aile öyküsü gibi klinik metaveriler kullanılmamıştır. Bununla birlikte, gelecekte yapılacak çalışmalarda bu tür klinik bilgilerin modele dâhil edilmesinin tanısıl performansı artırabileceği değerlendirilmektedir. Ayrıca sınıf dengesizliğini gidermek amacıyla yalnızca SMOTE ve SMOTE-ENN yöntemleri kullanılmıştır. ADASYN ve Borderline-SMOTE gibi diğer yaklaşımlar literatürde tartışılmış olmakla birlikte, bu çalışmada uygulanmamıştır.

1.4. Çalışmanın Amacı

Bu tezin temel amacı, cilt lezyonu sınıflandırma görevinde hem yüksek kapasiteli derin öğrenme modellerinin hem de hafif mimarilerin nasıl uygulanabileceğini incelemektir. Özellikle çalışma, GhostNet gibi hafif modellerin geleneksel evrimsel sinir ağı (CNN) mimarileri ile benzer ya da daha yüksek performans gösterip gösteremeyeceğini ve bunu gerçekleştirirken gerçek dünya uygulamaları için gerekli olan hesaplama verimliliğini koruyup koruyamayacağını değerlendirmektedir.

Tez kapsamında ayrıca sınıf dengesizliğini azaltmaya yönelik yöntemler uygulanarak malign lezyonlara karşı duyarlılığın artırılması ve yanlış negatif sonuçların azaltılması hedeflenmiştir. Genel olarak bu çalışma, doğru, verimli ve klinik uygulamalara uygun tanı sistemlerinin geliştirilmesi için pratik bir yaklaşım sunmayı amaçlamaktadır.

1.5. Araştırma Hedefleri

Bu araştırmanın hedefi, cilt kanseri sınıflandırmasında doğruluk ile hesaplama verimliliği arasındaki dengeyi iyileştirmektir. Bu tez kapsamında, aynı deneysel koşullar altında birden fazla önceden eğitilmiş evrimsel sinir ağı (CNN) modelinin

karşılaştırılması, veri kümesindeki sınıf dengesizliğini gidermek amacıyla gelişmiş yeniden örnekleme yöntemlerinin kullanılması ve klinik uygulamalar açısından hafif modellerin değerlendirilmesi amaçlanmaktadır.

Bu doğrultuda çalışma, GhostNet gibi verimli mimarilerin dermatolog düzeyine yakın performans sunarken teletıp sistemleri, mobil sağlık uygulamaları ve nokta-bazlı tanı senaryolarında uygulanabilirliğini koruyabildiğini göstermeyi hedeflemektedir.

1.6. Çalışmanın Katkıları

Bu araştırmanın katkıları üç ana başlık altında özetlenebilir:

Yeniden üretilebilir kıyaslama: ISIC 2019 veri kümesi üzerinde altı yaygın önceden eğitilmiş evrimsel sinir ağı (CNN) modeli karşılaştırılarak, ikili lezyon sınıflandırması için yeniden üretilebilir bir temel kıyaslama sunulmuştur.

GhostNet'in etkinliğinin gösterilmesi: GhostNet mimarisinin, özellikle GhostNet V2 modelinin, hesaplama verimliliğinden ödün vermeden yüksek performans sağlayabildiği ortaya konmuştur. GhostNet V2'nin, parametre sayısını yaklaşık %90 oranında azaltmasına rağmen büyük CNN modellerine yakın veya daha yüksek doğruluk elde ettiği gösterilmiştir.

SMOTE-ENN ile artan duyarlılık: SMOTE-ENN gibi sınıf dengesizliğini gideren yöntemlerin, malign lezyonların tespitine yönelik duyarlılığı belirgin biçimde artırdığı gösterilmiştir. Bu yaklaşım, tıbbi yapay zekâ uygulamalarında kritik öneme sahip nadir vakaların daha doğru biçimde tespit edilmesine doğrudan katkı sağlamaktadır.

Genel olarak bu katkılar, doğruluk, duyarlılık ve hesaplama verimliliği arasında dengeli bir yaklaşım sunarak yapay zekâ tabanlı dermatoloji uygulamalarına önemli bir katkı sağlamaktadır.

1.7. Güçlükler ve Zorluklar

Bu araştırmanın yürütülmesi sırasında çeşitli zorluklarla karşılaşmıştır. En önemli sorunlardan biri, ISIC veri kümesinde bulunan belirgin sınıf dengesizliğidir. Bu durum, modellerin doğal olarak benign vakaları tahmin etmeye daha yatkın olmasına yol açmıştır. Bu sorunun giderilmesi amacıyla, bilgi sızıntısını önleyecek şekilde yeniden örnekleme yöntemlerinin dikkatli biçimde uygulanması ve doğrulama süreçlerinin titizlikle yürütülmesi gerekmiştir.

İkinci önemli zorluk, derin evrimsel sinir ağı (CNN) modellerinin eğitimi için yüksek hesaplama gücüne duyulan gereksinimdir. GhostNet gibi hafif mimariler bu hesaplama yükünü büyük ölçüde azaltırken, ConvNeXtBase ve EfficientNetB7 gibi

daha derin modellerin eğitimi yüksek performanslı hesaplama kaynakları gerektirmiştir. Ayrıca modelin genellenebilirliği ile eğitim kararlılığı arasında denge kurabilmek için uygun hiperparametrelerin belirlenmesi de ayrı bir karmaşıklık oluşturmıştır.

Teknik sınırlamaların ötesinde, çalışmanın daha geniş kapsamlı bir kısıtı, modellerin yalnızca veri kümesi üzerinde geriye dönük (retrospektif) olarak değerlendirilmiş olmasıdır. Gerçek klinik ortamlarda hastane düzeyinde doğrulama yapılması ise gelecekteki araştırmalar açısından kritik bir adım olarak değerlendirilmektedir.

1.8. Sonuç

Özetle, cilt kanseri küresel ölçekte önemli bir sağlık sorunu olup, erken tanı sağkalım oranlarının artırılmasında kritik bir rol oynamaktadır. Tıbbi görüntüleme ile derin öğrenme yöntemlerinin entegrasyonu yüksek bir potansiyel taşımakla birlikte, sınıf dengesizliği ve model verimsizliği gibi sorunlar bu teknolojilerin klinik uygulamalara aktarılmasını zorlaştırmaktadır.

Bu tez kapsamında, ağır önceden eğitilmiş evrimsel sinir ağı (CNN) modelleri ile hafif GhostNet modelleri karşılaştırılarak ve sınıf dengesizliğini gidermeye yönelik teknikler uygulanarak bu yaklaşımların ISIC 2019 veri kümesi üzerindeki performansı değerlendirilmiştir. Ayrıca çalışma, uygun ön işleme adımlarıyla desteklenen verimli ağ mimarilerinin dermatolog düzeyinde duyarlılığa ulaşabileceğini ve aynı zamanda gerçek dünya koşullarında uygulanabilirliğini koruyabileceğini ortaya koymayı amaçlamaktadır.

2. LİTERATÜR İNCELEMESİ

2.1. Genel Bakış

Bu bölümde, yapay zekâ temelli cilt kanseri teşhisine ilişkin güncel literatür ayrıntılı bir biçimde incelenmektedir. Öncelikle, kanserin tıbbi ve teknolojik geçmişi ile yapay zekânın tıp alanında giderek artan kullanımına ilişkin kısa bir genel çerçeve sunulmuştur. Ardından odak noktası dermatoloji alanına kaydırılmıştır. Bu kapsamda, basit görsel muayene ve dermoskopiden başlayarak bilgisayar destekli tanı (CAD) sistemlerine ve son olarak derin öğrenme tabanlı görüntü analizine uzanan tanı yaklaşımlarının gelişimi özetlenmiştir.

Bu çerçevede, cilt kanserlerinin tespiti ve sınıflandırılmasına yönelik güncel çalışmalar kapsamlı biçimde ele alınmıştır. İncelenen çalışmalar arasında, ISIC ve HAM10000 gibi yaygın olarak kullanılan veri kümeleri üzerinde evrimsel sinir ağları (CNN), topluluk öğrenmesi (ensemble) yöntemleri ve Transformer tabanlı mimariler kullanan dikkat çekici araştırmalar bulunmaktadır. Söz konusu çalışmaların özetlenmesi ve karşılaştırılmasıyla, alanın gelişim yönü ve hâlen çözüm bekleyen temel sorunlar ortaya konulmaktadır.

Son olarak bu bölümde, veri kümesi dengesizliği, genelleme sorunları ve hesaplama maliyeti gibi temel teknik zorluklar ile bu zorlukları azaltmak amacıyla literatürde önerilen yöntemler tartışılmaktadır. Genel olarak sunulan bu bilgiler, tezde önerilen hibrit derin öğrenme çerçevesinin bilimsel ve yöntemsel temelini oluşturmaktadır.

2.2. Kanser: Genel Çerçeve

Kanser, 21. yüzyılın en önemli küresel sağlık sorunlarından biri olmaya devam etmektedir. 2022 yılında dünya genelinde en az 20 milyon yeni kanser vakası ve kansere bağlı 9,7 milyon ölüm bildirilmiş; bu sayıların 2050 yılına kadar yaklaşık 35 milyon yeni vakaya ulaşacağı öngörülmüştür. Bu artış; nüfusun yaşlanması, tütün kullanımı, alkol tüketimi, obezite ve sağlıksız beslenme gibi değiştirilebilir risk faktörlerinin yanı sıra ultraviyole (UV) radyasyonu ve hava kirliliği gibi çevresel etkenlerle ilişkilendirilmektedir. Tedavi alanındaki ilerlemelere rağmen kanser, özellikle erken tanı ve nitelikli tedaviye erişimin sınırlı olduğu düşük ve orta gelirli

lkelerde nemli bir toplumsal ve ekonomik yk oluřturmaya devam etmektedir (WHO, 2023).

Yksek gelirli lkelerde saękalım oranları; yaygın tarama programları, gelişmiş görüntleme yntemleri ve yeni tedavi yaklaşımları sayesinde kademeli olarak artmıştır. Buna karřın, toplumlar iinde hâlen belirgin eşitsizlikler bulunmaktadır ve hasta sonuçları byk lde saęlık hizmetlerine erişim ile tedaviye zamanında başlanmasına baęlıdır. Birok kanser trnde erken tanının saękalımı belirleyen en nemli etkenlerden biri olduęu gsterilmiştir. Bu nedenle, doęru, sadeleştirilmiş ve leklenebilir tanı zmlerine duyulan ihtiya giderek artmaktadır.

2.3. Cilt Kanseri: Epidemiyoloji ve Klinik Etki

Farklı malignite trleri arasında cilt kanseri, dnya genelinde en sık teřhis edilen kanser trlerinden biridir. Genellikle iki ana gruba ayrılmaktadır: melanom dıřı cilt kanserleri (NMSC) ve melanom. Melanom dıřı cilt kanserlerinin en yaygın alt trleri bazal hcreli karsinom (BCC) ve skuamz hcreli karsinomdur (SCC). Melanom ise daha nadir grlmekle birlikte ok daha agresif seyreden ve lmcl olabilen bir hastalıktır. Kresel lekte hem melanomun hem de NMSC'nin grlme sıklıęı artmaktadır. Bu artıřın bařlıca nedenleri arasında ultraviyole (UV) ıřınlarına maruziyetin artması ve nfusun yařlanması yer almaktadır.

Saękalım oranları, tanının konulduęu evreye gre nemli lde deęiřmektedir. Melanom erken evrede ve lokalize durumda saptandıęında, beř yıllık saękalım oranı %99'un zerindedir. Ancak hastalık ilerleyip metastaz yaptıęında bu oran yaklaşık %35'e dřmektedir (American Cancer Society, 2024). Bu belirgin fark, erken, etkili ve erişilebilir tanı stratejilerinin nemini aıka ortaya koymaktadır. Grsel muayene, dermoskopi ve histopatoloji gibi geleneksel tanı yntemleri altın standart olarak kabul edilmekle birlikte; gzlemciye baęlı deęiřkenlik ve kaynak kısıtlılıkları gibi eřitli sınırlılıklara sahiptir. Bu durum, zellikle imkânların sınırlı olduęu saęlık hizmeti ortamlarında daha belirgin hâle gelmektedir.

2.4. Klasik ve Erken Dnem CAD Yaklaşımları

Gemiřte dermatologlar, cilt lezyonlarını deęerlendirmek amacıyla ABCD kuralı (Asimetri, Border/Sınır dzensizlięi, Color/Renk farklılıęı ve Diameter/ap) gibi grsel kriterlerden yararlanmıştır. Dermoskopi, cilt yzeyinin altındaki yapıların bytlmř grntlerini sunarak tanısall doęruluęu artırsa da, teřhis sreci byk lde hekimin deneyimine ve becerisine baęlı kalmıştır.

Bilgisayar destekli tanı (CAD) sistemleri, 20. yüzyılın sonları ile 21. yüzyılın başlarında geliştirilmeye başlanmıştır. Bu sistemler, şekil, renk örüntüleri ve doku ölçümleri gibi elle tasarlanmış (handcrafted) özelliklere dayanarak lezyonları ayırt etmiş; Destek Vektör Makineleri (SVM), k-en yakın komşu (k-NN) ve karar ağaçları gibi makine öğrenmesi algoritmalarını kullanmıştır. CAD yazılımları tanı sürecini daha az öznel hâle getirmiş olsa da, özelliğe dayalı yapıları ve farklı veri kümeleri ile görüntüleme koşullarında tutarsız performans göstermeleri nedeniyle sınırlı düzeyde başarı elde etmiştir.

HAM10000 ve Uluslararası Cilt Görüntüleme Birliği'ne (ISIC) ait büyük ve açık erişimli dermoskopik veri kümelerinin geliştirilmesi, standart karşılaştırmaların yapılmasına olanak sağlamış ve veri odaklı yöntemlerin gelişimini önemli ölçüde hızlandırmıştır (Tschandl vd., 2018).

2.5. Dermatolojide Derin Öğrenme

Derin öğrenme, cilt lezyonlarının incelenme biçimini köklü biçimde değiştirmiştir. Özellikle evrimsel sinir ağları (CNN), görüntülerdeki farklı ayrıntı düzeylerini otomatik olarak öğrenerek elle çıkarılan özelliklere duyulan gereksinimi büyük ölçüde ortadan kaldırmıştır.

Esteva vd. (2017), 129.000'den fazla klinik görüntü kullanarak derin bir CNN modeli eğitmiş ve melanom ile keratinosit karsinomlarının sınıflandırılmasında dermatolog düzeyinde doğruluk elde etmiştir. Haenssle vd. (2018), dermoskopik görüntülerden melanom sınıflandırılmasında bir CNN modelinin 58 dermatologdan daha yüksek performans gösterdiğini ortaya koymuştur. (Brinker vd., 2019) ise farklı deneyim düzeylerine sahip 157 dermatolog ile bir CNN algoritmasını karşılaştırmış ve modelin dermatologların büyük çoğunluğundan daha yüksek doğruluk sergilediğini göstermiştir.

Daha sonraki gelişmeler arasında topluluk öğrenmesi (ensemble) modelleri (Gessert vd., 2020), ek verilerin (metaveri) entegrasyonu (Pacheco vd., 2021) ve Swin Transformer ile Convolutional Swin Transformer gibi Transformer tabanlı yapılar (Paraddy vd., 2024) yer almaktadır. Bu yeni yaklaşımlar, sınıflandırma doğruluğunu ve genelleme yeteneğini daha da artırarak, yapay zekânın tanı sürecinde destekleyici bir araç olarak önemli potansiyelini açıkça ortaya koymuştur.

2.6. Sınıf Dengesizliği ile Mücadele

Tıbbi görüntü analizinde, özellikle dermatoloji alanında karşılaşılan en temel sorunlardan biri sınıf dengesizliğidir. Veri kümelerinde benign (iyi huylu) lezyonların sayısı, malign (kötü huylu) lezyonlara kıyasla genellikle çok daha fazladır. Bu dengesizlik, derin öğrenme modellerinin baskın sınıfa, yani çoğunluk sınıfına yönelmesine neden olmakta; nadir ancak klinik açıdan kritik öneme sahip sınıflarda düşük duyarlılığa yol açarken yanıltıcı biçimde yüksek genel doğruluk oranlarının elde edilmesine sebep olabilmektedir.

Örneğin, cilt kanseri tespitinde görülen sınıf dengesizliği, melanom veya skuamöz hücreli karsinom (SCC) gibi malign lezyonların benign olarak yanlış sınıflandırılmasına neden olabilir. Bu durum, klinik açıdan son derece ciddi sonuçlar doğurabilmektedir.

2.6.1. Sınıf Dengesizliği Probleminin Doğası

ISIC Şekil 1 veya HAM10000 gibi tipik dermatoloji veri kümelerinde, iyi huylu vakaların (örneğin nevüs, seboreik keratoz) sayısı, kötü huylu vakalardan birkaç kat daha fazla olabilir.

Eşitlik 1 Veri kümesi, kötü huylu örnekler ve iyi huylu örnekler içersin, burada N_b iyi huylu, N_m kötü huylu / $N_b \gg N_m$ geçerlidir. Genel kaybı (global loss) en aza indirmek için eğitilen bir sınıflandırıcı:

$$E = \frac{EP+FN}{N_b+N_m} \quad (\text{Eşitlik 1})$$

Bu eşitlikte:

EP: yanlış pozitif sayısı

FN: yanlış negatif sayısı


N_b : benign sınıfındaki toplam örnek sayısı

N_m : malign sınıfındaki toplam örnek sayısı

doğal olarak büyük terim tarafından baskın hale gelir ve bu durum, optimizasyon sürecinin iyi huylu vakaların doğru sınıflandırılmasını önceliklendirmesine neden olur. Sonuç olarak, modelin genel doğruluğu yüksek görünebilir, ancak kötü huylu vakaları (duyarlılık) doğru bir şekilde tanımlama yeteneği ciddi şekilde azalır.

Bu durum, özellikle tıbbi görüntü analizi gibi yüksek risk içeren uygulamalarda önemli bir sorun oluşturmaktadır. Çünkü malign örneklerin yanlışlıkla benign olarak sınıflandırılması, erken tanı fırsatlarının kaçırılmasına ve tedavinin gecikmesine yol

açabilir. Dolayısıyla, yalnızca genel doğruluk oranına odaklanmak yeterli değildir; duyarlılık, özgüllük ve AUC gibi ölçütlerin birlikte değerlendirilmesi gerekmektedir. Bu nedenle sınıf dengesizliğinin giderilmesi, güvenilir ve klinik açıdan anlamlı bir model geliştirilmesinde kritik bir adımdır.



Şekil 1. İyi huylu ve kötü huylu örneklerin sınıf dağılımı histogramı

2.6.2 Klasik Örneklemeye Stratejileri

Bu önyargıyı azaltmak amacıyla araştırmacılar, model eğitimi öncesinde eğitim verilerini yeniden dengelemeye yönelik çeşitli veri düzeyi stratejileri geliştirmiştir. Bu stratejiler arasında aşırı örneklemeye (oversampling) ve yetersiz örneklemeye (undersampling) yöntemleri öne çıkmaktadır. Bununla birlikte, bazı çalışmalar algoritma düzeyinde yaklaşımları, örneğin sınıf ağırlıklı kayıp fonksiyonlarını, benimsemektedir. Ancak örneklemeye tabanlı teknikler, günümüzde hâlâ en yaygın kullanılan ve yorumlanabilirliği yüksek yöntemler arasında yer almaktadır.

2.6.2.1. Sentetik Azınlık Aşırı Örneklemeye Tekniği (SMOTE)

SMOTE algoritması (Chawla vd., 2002), mevcut azınlık örnekleri ile onların en yakın komşuları arasında enterpolasyon yaparak sentetik azınlık örnekleri üretir.

Belirli bir azınlık örneği x_i ve onun k -en yakın komşularından biri x_{nn} için:

$$x_{\text{new}} = x_i + \lambda(x_{nn} - x_i), \lambda \in [0,1] \quad (\text{Eşitlik 2})$$

Bu eşitlikte:

x_i = azınlık sınıfına ait gerçek örnek

x_{nn} = bu örneğin en yakın komşusu

λ = 0 ile 1 arasında rastgele bir ölçekleme katsayısı

Bu basit fakat etkili yaklaşım, azınlık örneklerinin yoğunluğunu artırarak sınıflandırıcının daha dengeli karar sınırları oluşturmaya yardımcı olur.

Bu tezde karşılaşılan sınıf dengesizliğini gidermek amacıyla Sentetik Azınlık Aşırı Örneklemeye Tekniği (SMOTE) uygulanmıştır. SMOTE, azınlık sınıfının yoğunluğunu artırmak için mevcut örnekler ile onların en yakın komşuları arasında doğrusal enterpolasyon yaparak sentetik örnekler üretir. Böylece az temsil edilen sınıfın karar sınırlarında daha güçlü bir yapı oluşturulur. SMOTE algoritmasının temel enterpolasyon mekanizması Eşitlik 2 verilmiştir. Bu denklemde azınlık sınıfından bir örneği, $x_{nn}x_{\{nn\}}x_{nn}$ ise onun en yakın komşusunu temsil etmektedir. λ lambda λ , 0 ile 1 arasında rastgele seçilen bir katsayı olup yeni bir sentetik örneğin dağılım içerisindeki konumunu belirlemektedir. Bu işlem, Çerçeve II'nin dengeli bir eğitim seti oluşturmada kilit bir adımdır.

2.6.2.2. Borderline-SMOTE ve ADASYN

Gereksiz sentetik örneklerin üretilmesini önlemek amacıyla geliştirilen Borderline-SMOTE yöntemi (Han vd., 2005), sınıflar arasındaki karar sınırına yakın bölgelerde bulunan örnekler odaklanmaktadır. Bunun temel nedeni, hatalı sınıflandırmaların en sık bu bölgelerde ortaya çıkmasıdır.

ADASYN (He vd., 2008) ise bu yaklaşımı daha ileri taşıyarak, yerel yoğunluk tahminine dayalı biçimde öğrenilmesi daha güç olan bölgelere daha fazla sentetik örnek atamaktadır. Bu uyarlanabilir mekanizma, modellerin öğrenilmesi zor olan azınlık sınıfı bölgelerine daha fazla dikkat göstermesini sağlamaktadır.

2.6.3. Hibrit Örneklemeye Yaklaşımları

SMOTE ve türevleri azınlık sınıf temsilini artırırsa da, aynı zamanda örtüşen veya gürültülü örnekler oluşturabilir. Bu sorunu azaltmak için SMOTE-ENN (Batista vd., 2004; Wilson, 1972) gibi hibrit yöntemler, aşırı örneklemeye ile gürültü temizleme sürecini birleştirir.

SMOTE, sentetik azınlık örneklerini oluşturduktan sonra, Düzenlenmiş En Yakın Komşu (Edited Nearest Neighbor – ENN) adımı, komşularıyla tutarsız olan sentetik veya gerçek fark etmeksizin örnekleri kaldırır. Biçimsel olarak, bir örnek x_i etiketi k en yakın komşusunun çoğunluk etiketiyle uyuşmuyorsa veri kümesinden çıkarılır.

$$x_i \in D_{filtered} \Leftrightarrow y_i = mode(kNN(x_i)) \quad (\text{Eşitlik 3})$$


Bu eşitlikte:

Eğer örneğin etiketi, k en yakın komşusunun çoğunluk etiketiyle uyuyorsa, örnek veri kümesinde tutulur. Aksi durumda örnek silinir.

Bu filtreleme işlemi, Eşitlik 3'te gösterildiği üzere, sınıflar arasındaki sınır bölgesine yakın belirsiz örnekleri ortadan kaldırarak daha temiz ve birbirinden daha kolay ayrılabilen bir eğitim verisi oluşturmaktadır.

Şekil 2'de yer alan iki boyutlu saçılım diyagramı, hibrit SMOTE-ENN yaklaşımının azınlık sınıfını nasıl güçlendirdiğini ve sınıflar arasındaki ayrımı nasıl belirginleştirdiğini görselleştirmektedir. Sol panelde ("Original set"), azınlık sınıfına ait örneklerin (mavi) seyrek kaldığı ve çoğunluk sınıfı (turuncu) ile belirgin bir örtüşme gösterdiği gözlenmektedir. Bu durum, sınıflandırıcıyı baskın sınıfa yönelten tipik bir sınıf dengesizliği senaryosunu yansıtmaktadır. Sağ panelde ise ("SMOTE + ENN"), ilk olarak SMOTE yöntemi komşuluk içinde enterpolasyon yoluyla azınlık örneklerinin yoğunluğunu artırmış, ardından ENN yöntemi komşularıyla tutarsız örnekleri kaldırarak karar sınırı çevresindeki gürültüyü temizlemiştir. Sonuç olarak, azınlık sınıfına ait örnekler daha sıkı biçimde kümelenmiş, sınıflar arasındaki örtüşme azalmış ve ayrılabilirlik artmıştır. Bununla birlikte, bu görselin dermoskopik özelliklerin gerçek uzayını değil, kavramsal bir iki boyutlu projeksiyonu temsil ettiği göz önünde bulundurulmalıdır. Buna rağmen şekil, SMOTE-ENN yaklaşımının eğitim verisini nasıl daha temiz ve öğrenilebilir hâle getirdiğini açık biçimde ortaya koymaktadır.

Bu iyileşme, sınıflandırma modellerinin azınlık sınıfına karşı daha dengeli öğrenme gerçekleştirmesine katkı sağlamaktadır. Özellikle karar sınırlarının daha net hâle gelmesi, yanlış negatif oranlarının azaltılmasına yardımcı olmaktadır. Bununla birlikte, sentetik veri üretiminin bazı durumlarda aşırı genelleştirmeye yol açabileceği de göz önünde bulundurulmalıdır. Bu nedenle, SMOTE-ENN gibi yöntemlerin dikkatli bir şekilde uygulanması ve model performansı üzerindeki etkilerinin kapsamlı biçimde değerlendirilmesi gerekmektedir.



Şekil 2. SMOTE-ENN'in etkisinin kavramsal gösterimi: solda özgün dengesiz dağılım, sağda SMOTE ile artırılmış ve ENN ile sınırı temizlenmiş veri

2.6.4. Literatürdeki Genel Gözlemler

Tıbbi görüntüleme alanında gerçekleştirilen birçok çalışma, sınıf dengesinin yeniden sağlanmasının; özellikle duyarlılık (sensitivity) ve AUC gibi, klinik uygulamalarda yanlış negatif sonuçların en aza indirilmesinin kritik önem taşıdığı performans ölçütlerinde, belirgin iyileşmeler sağladığını göstermiştir.

Örneğin, Li vd. (2020), diyabetik retinopati görüntülerine SMOTE uygulanmasının geri çağırma oranında %15'lik bir artış sağladığını bildirmiştir. Zhao vd. (2021) ise SMOTE-Tomek Link adlı hibrit bir yöntem kullanarak melanom tespitindeki doğruluğu artırmıştır.

Genel olarak bu teknikler, nadir görülmekle birlikte klinik açıdan kritik öneme sahip sınıfların eğitim sürecinde yeterli düzeyde temsil edilmesini sağlayarak, tıbbi yapay zekâ iş akışlarında standart bir ön işleme adımı hâline gelmiştir.

2.7. Modeller

2.7.1. VGG-16

VGG-16, 3×3 boyutunda evrişim katmanlarından oluşan, adım sayısı 1 ve aynı dolgulu (same padding) yapı kullanan; her katmanda ReLU aktivasyon fonksiyonuna sahip, belirli aralıklarla maksimum havuzlama ile aşağı örnekleme yapan ve sonunda üç tam bağlı katmanla tamamlanan derin ve tekdüze bir CNN mimarisidir. Bu tasarımda, derinliğin etkisini izole edebilmek amacıyla mimari çeşitlilik bilinçli olarak sınırlandırılmıştır. On altı katmanlı yapılandırma (13 evrişim katmanı + 3 tam bağlı

katman), küçük filtre çekirdekleri kullanılarak yalnızca ağ derinliğinin artırılmasının ImageNet üzerinde önemli performans kazanımları sağlayabileceğini gösteren ilk modellerden biri olmuştur. Transfer öğrenmesi uygulamalarında, özellik çıkarımı için genellikle küresel ortalama havuzlama ve sınıflandırıcı katmanından önce yer alan son evrişim bloğunun (conv5) çıktısı kullanılmaktadır. Bunun nedeni, bu katmanın orta ve yüksek düzeyli doku ve şekil örüntülerini hesaplama açısından uygun bir mekânsal çözünürlükte korumasıdır. Bu özellikleri sayesinde VGG, tıbbi görüntüleme alanındaki transfer öğrenmesi çalışmalarında istikrarlı bir temel model olarak kabul edilmekte ve ince ayar süreçleri için güvenilir bir karşılaştırma noktası işlevi görmektedir.

Dermoskopi bağlamında VGG'nin homojen 3×3 evrişim yığınları, kenarlar, lekeler ve ağsı yapılar gibi düşük ve orta düzeyli temel özellikleri etkili biçimde öğrenerek klinik ipuçlarıyla, örneğin pigment ağı, noktalar/globüller ve çizgilerle, uyumlu sonuçlar üretmektedir. Uygulamada, model eğitiminin başlangıcında tüm evrişim bloklarının dondurulması ve yalnızca sınıflandırıcı başlığın eğitilmesi; ardından üstteki blok veya blokların düşük bir öğrenme oranıyla çözülerek ince ayar yapılması, alt düzey filtrelerin ciddi biçimde bozulmasını önlerken modelin lezyona özgü morfolojik özelliklere, örneğin asimetri, sınır düzensizliği ve renk çeşitliliğine, uyum sağlamasına olanak tanımaktadır. Boyutuna rağmen VGG'nin yalın mimari yapısı, son evrişim katmanında elde edilen Grad-CAM açıklamalarının genellikle net ve yorumlanması kolay olmasını sağlamaktadır. Bu durum, klinisyenlerin modeli daha iyi anlaması açısından önemli bir avantaj sunmaktadır.

2.7.2. DenseNet-201

DenseNet-201, her bir katmanı bir blok içindeki kendisinden sonraki tüm katmanlara özellik haritası birleştirme (feature-map concatenation) yoluyla bağlayan bir mimariye sahiptir; böylece her katman, önceki tüm katmanların toplu bilgisini girdi olarak alır. Bir dense katman, $\text{BN} \rightarrow \text{ReLU} \rightarrow 1 \times 1 \text{ dar boğaz} \rightarrow \text{BN} \rightarrow \text{ReLU} \rightarrow 3 \times 3$ evrişim sırasını kullanırken, “geçiş” katmanları (transition) bloklar arasında 1×1 evrişim + ortalama havuzlama uygulayarak özellik haritalarını sıkıştırır. Bu yoğun bağlantı stratejisi gradyan akışını iyileştirir, özellik tekrar kullanımını teşvik eder ve belirli bir derinlik için daha az parametre ile yüksek doğruluk elde eder; 201 katmanlı versiyon, tipik bir büyüme oranı k (örn. 32) ile dört adet dense blok içerir. Özellik çıkarımı genellikle son dense bloktan sonra, sınıflandırıcıdan hemen önceki aşamada gerçekleştirilir.

Dermoskopi uygulamalarında, DenseNet'in önceki düşük seviye özellikleri (kenarlar, küçük lekeler) sonraki katmanlar tarafından tekrar kullanabilmesi, aşırı sayıda parametre olmadan ince pigment ağları ve belirsiz renk dokularını yakalamaya yardımcı olur – etiketlerin sınırlı olduğu durumlar için önemli bir avantajdır. Transfer öğreniminde, yoğun atlama bağlantıları (dense skip connections), ince ayar için üst blokları çözmeye başladığınızda optimizasyonu istikrarlı tutar; ağ, erken evre filtreleri bozulmadan koruma eğiliminde olup sonraki katmanları lezyon sınırları ve atipik yapıları tanıyacak şekilde özelleştirir. Parametre verimliliği, benzer derinlikteki diğer “düz” ağlara kıyasla aşırı öğrenme riskini de azaltır.

2.7.3. EfficientNet-B7

EfficientNet ailesi, MBConv bloklarını (derinlemesine evrişim ve Sıkıştırma-Uyarılma (Squeeze-andExcitation, SE) mekanizması içeren Mobil Ters Dar Boğaz yapıları) derinlik, genişlik ve çözünürlüğü tek bir ϕ katsayısı üzerinden birlikte ölçekleyen bileşik ölçeklendirme kuralıyla birleştirir. B7, orijinal serinin en büyük varyantıdır (girdi boyutu ~600 piksele kadar) ve önceki SOTA modellere göre çok daha küçük/hızlı olmasına rağmen ImageNet'te %84.3 top-1 doğruluk elde etmiştir. Mimarisindeki SE dikkat mekanizması, kanallar bazında yeniden ölçeklemeyi güçlendirerek ağın sonraki aşamalarının yerel desenlerle birlikte küresel bağlamı da taşımasını sağlar.

Dermoskopi için, bileşik ölçeklendirme kilit önemdedir: Yüksek çözünürlüklerde geniş etkin alıcı alanlar elde edilir – küresel asimetri tespiti için önemlidir – ve MBConv bloklarındaki derinlemesine evrişim çekirdekleri hesaplama maliyetini makul düzeyde tutar. Transfer öğreniminde, tipik uygulama tüm aşamaları dondurup yalnızca sınıflandırıcı kafasını eğitmek, sonra da en üst 1–2 MBConv aşamasını kosinüs öğrenme oranı planlaması ile serbest bırakmaktır; bu sayede alt düzey renk/doku filtreleri korunurken üst düzey lezyon semantiği öğrenilir. EfficientNet'in yazarları tarafından çeşitli veri kümelerinde bildirilen güçlü transfer başarımı, bu mimarinin dermoskopik görüntülerde de güvenilir bir performans sergilediğini doğrular niteliktedir.

2.7.4. EfficientNetV2-L

EfficientNetV2, eğitim hızını ve parametre verimliliğini artırmaya odaklanan bir mimaridir. Bu hedefe, eğitim sürecini dikkate alan otomatik mimari arama (NAS) yaklaşımı ve erken aşamalarda Fused-MBConv bloklarının kullanımıyla ulaşmaktadır. Fused-MBConv yapısında, ayrı 1×1 evrişim ve derinlemesine evrişim yerine

birleştirilmiş tek bir 3×3 evrişim kullanılmakta; bu sayede bellek trafiği azaltılmakta ve donanım verimliliği artırılmaktadır. Ayrıca bu mimari, kademeli öğrenme (progressive learning) olarak adlandırılan bir yaklaşım sunmaktadır. Bu yaklaşımda, girdi çözünürlüğü ile düzenlileştirme (regularization) şiddeti birlikte planlanarak modellerin doğruluktan ödün vermeden daha hızlı eğitilmesi sağlanmaktadır. Large (L) varyantı, V1 ile benzer doğruluk düzeylerini korurken daha yüksek gerçek zamanlı verimlilik ve yüksek model kapasitesi sunmaktadır.

Dermoskopi tabanlı transfer öğrenmesi uygulamalarında, EfficientNetV2'nin birleştirilmiş erken blokları, mavi-beyaz peçe gibi ince renk dokularının korunmasına katkı sağlarken eğitim sürecinin orta düzey GPU'larda dahi kararlı biçimde yürütülmesine olanak tanımaktadır. Sınıflandırıcı başlık eğitildikten sonra, üst düzey Fused-MBConv ve MBConv aşamalarının ince ayar amacıyla serbest bırakılması genellikle hızlı performans kazanımları sağlamaktadır. Özellikle 224–384 piksel giriş boyutlarında, EfficientNet-B7'ye kıyasla daha hızlı deney döngülerine ihtiyaç duyuluyor ve benzer temsil gücünün korunması hedefleniyorsa, EfficientNetV2-L pragmatik bir seçenek olarak öne çıkmaktadır.

2.7.5. ConvNeXt-Base

ConvNeXt, saf bir evrişimsel ağ (ConvNet) yapısını korurken, Vision Transformer (ViT) mimarisinden esinlenen düzenlemelerle ResNet yapısını modernize etmektedir. Bu mimari; daha büyük derinlemesine evrişim çekirdekleri (örneğin 7×7), ters çevrilmiş dar boğaz yapıları, evrişim aşamalarında Katman Normu (LayerNorm), sadeleştirilmiş giriş ve çıkış (stem/head) katmanları ile modern eğitim stratejilerini içermektedir. Sonuç olarak bu ConvNet ailesi, sınıflandırma, nesne algılama ve segmentasyon görevlerinde Swin Transformer ile eşdeğer ya da daha yüksek performansa ulaşırken evrişimsel verimliliği korumaktadır. Base (Temel) varyantı ise transfer öğrenmesi açısından doğruluk ile hesaplama maliyeti arasında dengeli bir yapı sunmaktadır.

Dermoskopi uygulamalarında, daha büyük derinlemesine evrişim çekirdekleri ve LayerNorm kullanımı, 224–384 piksel çözünürlük aralığında ince ayar yapılırken küresel bağlamın daha kararlı biçimde yakalanmasına ve optimizasyon sürecinin daha stabil yürütülmesine olanak tanımaktadır. Çalışmamızda bu model, yaklaşık %84,6 doğruluk ile en güçlü “ağır omurga” başlangıç performansını sağlamıştır. Bu bulgu, literatürde modernleştirilmiş evrişimsel katman yığınlarının doğal görüntüler üzerinde Transformer tabanlı hiyerarşilerle rekabet edebildiğini ve yeni görevlere başarılı

biçimde uyarlanabildiğini gösteren sonuçlarla uyumludur. Özellik çıkarımı, Grad-CAM tabanlı yorumlanabilirlik analizleri için genellikle her modelde küresel ortalama havuzlamadan önceki son ConvNeXt aşamasından gerçekleştirilmiştir.

2.7.6. MobileNetV2

MobileNetV2, mobil ve uç cihazlarda gerçek zamanlı çıkarım gerçekleştirmek amacıyla tasarlanmış bir CNN mimarisidir. Bu model, tersine çevrilmiş artık (residual) bloklar ve doğrusal dar boğaz yapıları kullanmaktadır. Temel blok yapısı; genişletme aşaması (1×1 , doğrusal olmayan), derinlemesine evrişim aşaması (3×3) ve projeksiyon aşaması (1×1 , doğrusal) olmak üzere üç bölümden oluşmaktadır. Artık bağlantılar, dar boğaz katmanlarını birbirine bağlayan tersine çevrilmiş bir yapı oluşturmaktadır. Ayrıca derinlemesine ayrık evrişimler (depthwise separable convolution), hesaplama maliyetinin önemli ölçüde azaltılmasına katkı sağlamaktadır. Orijinal çalışmada ayrıca verimli görev başlıkları, örneğin SSDLite, tanıtılmış; sınıflandırma, nesne algılama ve segmentasyon görevlerinde güçlü doğruluk-gecikme dengeleri elde edildiği gösterilmiştir.

Dermoskopik analizde bir omurga ağ olarak MobileNetV2, teletıp uygulamaları veya cihaz üzerinde hızlı ön değerlendirme süreçleri için hafif bir temel sunmaktadır. Transfer öğrenmesi sürecinde yaygın yaklaşım; katmanların büyük bölümünü dondurmak, yalnızca sınıflandırıcı başlığı eğitmek ve ardından doğrusal dar boğaz katmanlarını kararsız hâle getirmemek amacıyla üstteki birkaç bloğu çok düşük bir öğrenme oranıyla ince ayara açmaktır. Bu yaklaşım, daha ağır ağırlara kıyasla doğruluk açısından bir miktar ödün verilmesine yol açsa da, çok daha düşük çıkarım süresi ve güç tüketimi sağlamaktadır. Bu özellik, özellikle mobil tarama iş akışları açısından son derece önemli bir avantajdır.

2.7.7. GhostNet V1

GhostNet V1, birçok özellik haritasının gereksiz tekrarlar içerdiği gözleminde hareketle Ghost modülünü önermektedir. Bu yapıda, öncelikle standart bir evrişim ile küçük bir öz (intrinsic) özellik haritaları kümesi oluşturulmakta, ardından düşük maliyetli doğrusal işlemlerle, çoğunlukla derinlemesine evrişimler aracılığıyla, ek “hayalet” özellik haritaları sentezlenmektedir. Bu modüllerin Ghost dar boğazları biçiminde, isteğe bağlı Sıkıştırma-Uyarılma (SE) mekanizması ile birlikte istiflenmesi, çok daha az hesaplama maliyeti (FLOP) ve daha az parametre ile ImageNet düzeyinde

doğruluk sağlamaktadır. Ayrıca benzer hesaplama bütçelerinde çağdaş mobil ağlara kıyasla daha yüksek performans sergilemektedir.

Dermoskopi açısından GhostNet V1, pigment ağları ve çizgisel yapılar gibi dokusal özelliklere duyarlılığı, mobil cihaz düzeyindeki gecikme sınırları içinde korumaya olanak tanımaktadır. Bu yönüyle, SMOTE-ENN ile sınıf dengelemesinin birleştirildiği Çerçeve II için uygun bir mimari oluşturmaktadır. Transfer öğrenmesi sürecinde özellik çıkarımı, son Ghost aşamasının küresel ortalama havuzlamadan önceki çıktısından gerçekleştirilmektedir. İçsel (intrinsic) özellik dalının geleneksel evrimsel anlamsal yapıyı koruması sayesinde, Grad-CAM tabanlı yorumlanabilirlik analizleri de etkili biçimde uygulanabilmektedir.

2.7.8. GhostNet V2

GhostNet V2, Ghost modüllerini DFC dikkat mekanizması (Decoupled Fully-Connected) ile desteklemektedir. Bu mekanizma, yatay ve dikey eksenler boyunca tam bağlantılı dönüşümlerden oluşturulan, donanım açısından uyumlu ve verimli uzun menzilli bir dikkat yapısıdır. Bu sayede, salt evrimsel yerel bağlamla sınırlı kalması sorununa çözüm getirecek biçimde, düşük ek maliyetle küresel bağlamın bütünleştirilmesi sağlanmakta ve cihaz üzerindeki yüksek hız korunmaktadır. GhostNet V2, benzer hesaplama yükü altında GhostNet V1'e kıyasla ImageNet üzerinde tutarlı performans artışları göstermiştir. Örneğin, yaklaşık 167M FLOP düzeyinde, GhostNet V1'in top-1 doğruluğu %74,5 iken GhostNet V2'de bu değer yaklaşık %75,3'e yükselmiştir. Bizim işlem hattımızda da bu yaklaşım, duyarlılık ve AUC değerlerindeki artışta belirleyici bir rol oynamıştır.

Dermoskopi uygulamalarında hem küresel asimetri hem de yerel mikro desenler önemli olduğundan, DFC dikkat mekanizması Transformer tabanlı yapılarla ilişkili hesaplama maliyetini getirmeden küresel etkileşimlerin modellenmesine olanak sağlamıştır. Sınıflandırıcı başlık kararlı hâle geldikten sonra GhostNet V2'nin üst aşamalarının ince ayar amacıyla serbest bırakılması, genellikle güçlü performans iyileştirmeleri üretmiş ve bunu yaparken mobil cihaz gecikme düzeyini korumuştur. Nitekim çalışmamızda rapor edilen 0,99 AUC değerine ulaşılmıştır.

2.7.9. GhostNet V3

GhostNet V3, yeni bir çıkarım bloğu önermekten çok, kompakt modeller için geliştirilmiş bir eğitim stratejisini temsil etmektedir. İlgili çalışmada, düşük kapasiteli ağların eğitim bileşenleri sistematik biçimde incelenmiş; uygun yeniden parametreleme

ve bilgi damıtımının kritik öneme sahip olduğu, buna karşılık büyük ağlar için yaygın olarak kullanılan bazı ağır veri artırma yöntemlerinin, örneğin Mixup ve CutMix'in, küçük modeller açısından olumsuz etkiler oluşturabildiği gösterilmiştir. GhostNet V3 eğitim reçetesi ile GhostNetV2, MobileNetV2 ve ShuffleNetV2 gibi modeller, aynı FLOP ve gecikme düzeyinde ImageNet üzerinde kayda değer performans iyileşmeleri sergilemiştir.

Bu durum, mobil dermoskopi açısından önem taşımaktadır. Çünkü dağıtım alınan modelin yapısını veya hesaplama maliyetini değiştirmeden, yalnızca eğitim prosedürünü değiştirerek doğruluğu artırmak mümkün olabilmektedir. Gecikme ve enerji tüketiminin kritik kısıtlar olduğu ortamlarda, GhostNet V3 benzeri yeniden eğitim stratejileri ve daha güçlü bir öğretici modelden yararlanılarak gerçekleştirilen bilgi damıtımı, cihaz üzerinde uygulanabilirlikten ödün vermeden daha ağır omurgalı modellerin performansına yaklaşılmaya olanak tanımaktadır. Bu özellik, özellikle nokta bazlı tarama senaryoları açısından önemli bir avantaj sunmaktadır.

2.8. Temsilî Önceki Çalışmalar

Son on yılda gerçekleştirilen birçok çalışma, otomatik cilt kanseri teşhisinin sınırlarını önemli ölçüde genişletmiştir. Bu bölümde, ilk CNN başarılarından günümüzün çok modlu (multimodal) ve Transformer tabanlı yöntemlerine kadar uzanan gelişim sürecini yansıtan on temel çalışma ele alınmaktadır.

Erken dönem çalışmalar arasında en dikkat çekici olanlardan biri, Esteva vd. (2017) tarafından Nature dergisinde yayımlanan çalışmadır. Araştırmacılar, 129.000'den fazla klinik görüntü içeren büyük bir veri kümesi kullanarak Inception mimarisine dayalı derin bir CNN modeli eğitmiştir. Çalışma, bir CNN'in melanom ve keratinosit karsinomları dâhil olmak üzere cilt lezyonlarını dermatolog düzeyinde sınıflandırabildiğini göstermiştir. Bu çalışma, yapay zekânın insan uzmanlarla karşılaştırılabilir doğrulukta cilt kanseri teşhisi yapabileceğini ortaya koyan dönüm noktası niteliğinde bir araştırma olarak değerlendirilmektedir.

Bu bulguların ardından Haenssle vd. (2018), geniş çaplı bir okuyucu çalışması gerçekleştirmiştir. Söz konusu çalışmada, bir CNN'in dermoskopik melanom sınıflandırmasındaki tanısal doğruluğu 58 dermatolog ile karşılaştırılmıştır. Sonuçlar, özellikle duyarlılık bakımından CNN'in dermatologların çoğundan daha yüksek performans gösterdiğini ortaya koymuştur. Bu durum, söz konusu sistemlerin klinik uygulamalarda ikinci bir okuyucu ya da destekleyici karar aracı olarak güvenle kullanılabileceğini göstermiştir. Çalışma, yapay zekâ performansının tıbbi uzmanlarla

yapılan kontrollü karşılaştırmalar yoluyla doğrulanması açısından önemli bir adım olmuştur.

Brinker vd. (2019), okuyucu çalışması yaklaşımını daha geniş bir ölçeğe taşımıştır. Farklı deneyim düzeylerine sahip 157 dermatolog ile gerçekleştirilen bu çalışmada, ticari bir CNN sistemi olan Moleanalyzer Pro'nun 157 dermatoloğun 136'sından daha yüksek doğruluk elde ettiği bildirilmiştir. Bu bulgular, yapay zekânın farklı uzmanlık düzeylerinde de tutarlı sonuçlar verebildiğini doğrulamış ve klinik uygulamalarda deneyim farklılıklarını dengeleyici bir araç olarak kullanılabileceğini göstermiştir.

ISIC 2019 veri kümesinin yayımlanmasının ardından araştırmacılar, topluluk öğrenmesi (ensemble) yöntemlerini uygulamaya başlamıştır. Gessert vd. (2020), çalışmalarında EfficientNet, SENet ve ResNeXt modellerini birleştirerek ISIC 2019 yarışmasında üst düzey performans elde etmiştir. Araştırma ayrıca metaveri entegrasyonu, örneğin lezyon lokasyonu, yaş ve cinsiyet bilgileri ile çoklu çözünürlüklü görüntü kırpma tekniklerini de içermektedir. Bu yaklaşım, modelin dayanıklılığını artırmıştır. Söz konusu çalışma, çok modlu ve çok ölçekli yöntemlerin gerçek dünya dermoskopik çeşitliliğini yönetmede ne kadar etkili olabileceğini açıkça göstermiştir.

Yüksek kaliteli ve çeşitli veri kümelerine erişim de yapay zekâ temelli gelişmelere önemli katkı sağlamıştır. Tschandl vd. (2018), Scientific Data dergisinde HAM10000 veri kümesini yayımlamıştır. Bu veri kümesi, yedi farklı tanı sınıfına ait 10.015 dermoskopik görüntü içermekte ve farklı merkezlerden toplanmış verilerden oluşmaktadır. HAM10000, standart bir karşılaştırma ölçütü sağlayarak araştırmaların yeniden üretilebilirliğini kolaylaştırmış ve sonraki ISIC yarışmaları için temel veri kaynaklarından biri hâline gelmiştir.

Pacheco vd. (2021), çalışmalarında hasta metaverilerini, yani yaş, cinsiyet ve lezyon konumu gibi bilgileri, dermoskopik görüntülerle birleştiren CNN + ANN tabanlı bir füzyon modelini incelemiştir. Bulgular, metaveri entegrasyonunun yalnızca görüntüye dayalı modellere kıyasla sınıflandırma doğruluğunu anlamlı düzeyde artırdığını göstermiştir. Bu çalışma, çok modlu öğrenmenin klinik bağlam bilgisinden yararlanarak performansı iyileştirebileceğini ortaya koymuştur.

Kim vd. (2022), mobil sağlık (mHealth) uygulamaları için çok modlu yaklaşımları bir adım daha ileri taşımıştır. Araştırmada, klinik görüntüleri, örneğin akıllı telefon fotoğraflarını, metaverilerle birleştiren dikkat (attention) tabanlı bir füzyon modeli tanıtılmıştır. Elde edilen sonuçlar, çok modlu füzyonun özellikle kaynakların sınırlı olduğu gerçek dünya koşullarında tanısallık doğruluğu artırdığını ve mobil sağlık araçlarının uygulanabilirliğini desteklediğini göstermiştir.

Son yıllarda Transformer tabanlı modeller, tıbbi görüntüleme alanında giderek daha fazla önem kazanmıştır. Paraddy vd. (2024), ISIC 2018 veri kümesi üzerinde segmentasyon ve sınıflandırma amacıyla Convolutional Swin Transformer (CSwinformer) modelini önermiştir. Model, dikkat çekici performans artışları sağlamıştır. Evrişimsel katmanlar ile Transformer tabanlı dikkat mekanizmalarını bütünleştirerek hem yerel dokusal özellikleri hem de küresel bağlamı yakalamayı başarmış, böylece lezyon sınırlarının belirlenmesini ve sınıflandırma doğruluğunu iyileştirmiştir.

Manzoor vd. (2025), iki aşamalı bir işlem hattı (pipeline) önermiştir. Bu yöntemde ilk aşamada lezyon segmentasyonu, ikinci aşamada ise sınıflandırma gerçekleştirilmektedir. İki aşamalı yaklaşım, sınıflandırma öncesinde lezyon bölgelerini ayırarak çevre cilt dokusundan kaynaklanan gürültüyü azaltmış ve modelin ilgili bölgelere odaklanma yeteneğini artırmıştır. Çalışma, segmentasyon odaklı sınıflandırmanın tanısallık tutarlılığın geliştirilmesindeki önemini vurgulamıştır.

Son olarak Ayas vd. (2022), ISIC 2019 veri kümesini kullanarak cilt lezyonlarının çok sınıflı sınıflandırılması için Swin Transformer modelini uygulamıştır. Model, melanom tespitinde yüksek duyarlılıkla %97,2 doğruluk oranına ulaşmıştır. Bu sonuç, Transformer mimarilerinin dermoskopik görüntülerden küresel bağlamı öğrenmede geleneksel CNN'lere kıyasla üstünlük sağlayabileceğini göstermiştir.

Tablo 1'de, klinik fotoğraflar, dermoskopi görüntüleri ve ISIC yarışma veri kümelerini kapsayan önceki çalışmalar bir araya getirilmektedir. Her çalışma için veri bağlamı, örneğin dermatolog-CNN okuyucu çalışmaları ya da standart yarışmalar, ve başlıca performans ölçütleri özgün yayınlardaki biçimleriyle sunulmuştur. Ancak çalışmaların görevleri ve deneysel protokolleri, örneğin ikili sınıflandırma ya da çok sınıflı sınıflandırma, çapraz doğrulama ya da ayrılmış test kümesi kullanımı bakımından farklılık gösterdiğinden, bu sonuçlar doğrudan bire bir karşılaştırma amacı taşımamakta; daha çok bağlamsal bir değerlendirme sunmaktadır.

Bu nedenle, elde edilen sonuçlar genel eğilimlerin anlaşılması açısından yorumlanmalıdır. Veri kümesi özellikleri ve sınıf dengesizliği gibi faktörler performansı doğrudan etkilemektedir. Ayrıca, farklı değerlendirme metriklerinin kullanılması sonuçların karşılaştırılmasını zorlaştırmaktadır. Bu durum, standartlaştırılmış değerlendirme yaklaşımlarına duyulan ihtiyacı ortaya koymaktadır.

Tablo 1. Yapay Zekâ ve Derin Öğrenme Yaklaşımlarıyla Cilt Kanseri Sınıflandırmasına Yönelik Temel Çalışmaların Özeti

Çalışma (Yıl)	Omurga / Bloklar	Görev	Veri Kümüsi ve Boyutu	Ön işleme girdi	Artırma & Dengesizlik	Raporlanan metrikler
Esteva vd. (2017)	Inception v3 (ImageNet ile ön-egitimli, uçtan uca ince ayarlı)	İki ikili sınıflandırma: melanom vs nevüs; BCC/SCC vs seboroik keratoz	129.450 klinik görüntü; 2.032 tanı	Yalnızca görüntüler (piksel + etiket); modele uygun standart yeniden boyutlandırma (makalede ayrıntılar)	Sınıf yeniden dengeleme odaklı değil (klinik fotoğraflar; okuyucu karşılaştırması)	ROC eğrileri raporlandı her iki ikili görevde “dermatolog düzeyinde” performans. (PMC)
Haenssle vd. (2018)	CNN (çalışma karşılaştırması; pazarlanan araçta ekip çalışmalarında analiz edildi)	Okuyucu çalışması: dermoskopik melanom sınıflandırması	Dermoskopi görüntüleri; 58 dermatolog değerlendirdi	Standart dermoskopi görüntü analizi; okuyucu çalışması kurulumu (turlara göre eşikleme)	Eğitimde dengesizlik odaklı bir çalışma değil (eşleşmiş çalışma noktalarında karşılaştırma)	Dermatologlar: Duyarlılık %86,6→%88,9; Özgüllük %71,3→%75,7 (iki okuma turu). CNN özgüllüğü eşleşmiş duyarlılıkta %82,5; CNN çoğu dermatologdan daha iyi. (PubMed)
Brinker vd. (2019)	Ticari CNN (Moleanalizer Pro)	Okuyucu çalışması: dermoskopik melanom sınıflandırması	157 dermatolog ile dermoskopi okuyucu çalışması	Okuyucu çalışması protokollü	Uygulanamaz (karşılaştırma çalışması)	Dermatolog ort.: Duyarlılık ~%74, Özgüllük ~%60; CNN, 157 dermatologdan 136’sını geride bıraktı. (PubMed)
Gessert vd. (2020)	Ansambl: EfficientNet + SENet + ResNeXt (çok çözünürlüklü) + metadata kolu	ISIC-2019 çok sınıflı sınıflandırma (Görev-1 yalnız görüntü; Görev-2 görüntü+metadata)	Eğitim ≈ 25 bin görüntü (8 sınıf) gizli test	Çok çözünürlüklü kırpma	Sınıf dengesizliği için loss-balancing; metadata füzyonu	Dengeli Doğruluk: %74,2 (5-katlı ÇD); %63,6 (Görev-1 test); %63,4 (Görev-2 test); her iki görevde 1.’lik. (arXiv)
Tschandl vd. (2018)	—	Veri kümesi makalesi (model kıyaslaması yok)	HAM10000: 7 sınıfta 10.015 dermoskopi görüntüsü (çok merkezli)	—	—	Veri kümesi tanımı; metrikler uygulanamaz. (Nature)
Matsunaga vd. (2017)	GoogLeNet (Inception v3) + AlexNet (ince ayarlı)	ISIC-2017 Görev-3 sınıflandırma (Mel / SK)	ISIC-2017 yarışma bölmeleri	Standart TL yeniden boyutlandırma; rastgele kırpma	Yarışma bağlamı (görev kuralları dışında açık dengeleme yok)	AUC: Mel 0,924; SK 0,993; genel çevrimiçi doğrulama 0,958. (arXiv)

Tablo 1.(Devamı)

Çalışma (Yıl)	Omurga / Bloklar	Görev	Veri Kümesi ve Boyutu	Ön işleme girdi	Artırma & Dengesizlik	Raporlanan metrikler
Sousa vd. (2017)	GoogLeNet + AlexNet (transfer öğrenme)	ISIC-2017 Görev-3 sınıflandırma	ISIC-2017 doğrulama	224×224'e yeniden boyutlandırma; rastgele kırpm (makaleye göre)	Dengesizlik odaklı değil	AUC: Mel 0,846; SK 0,950 (doğrulama). (arXiv)
Ayas (2022)	Swin Transformer (çok sınıflı)	ISIC-2019 çok sınıflı sınıflandırma	ISIC-2019	Tipik TL ön işleme (makaleye göre)	Esasen dengesizlik çalışması değil	Doğruluk %97,2; Duyarlılık %82,3; Özgüllük %97,9; Dengeli Doğruluk %82,3 (raporlandığı şekliyle). (ResearchGate)
Paraddy vd. (2024)	CSwinformer (Conv + Swin Transformer)	ISIC-2018 segmentasyon + sınıflandırma	ISIC-2018	Segmentasyon/sınıflandırma için standart ön işleme (makaleye göre)	—	Tüm metrik tabloları makalede verilmiştir (segmentasyon ve sınıflandırma).
Manzoor vd. (2025)	segmentasyon (UNet-benzeri) sınıflandırıcı	ISIC-2018 (segmentasyon + sınıflandırma)	ISIC-2018	Standart ön işleme (makaleye göre)	—	Segmentasyon: Örn. Doğruluk %97,59; Jaccard %89,12; Dice %94,24. Sınıflandırma metrikleri tablolarda sunulmuştur. (PMC)

2.9. Sonuç


Literatür, açık biçimde evrimsel bir gelişim göstermektedir. Elle tasarlanmış özelliklere dayalı bilgisayar destekli tanı sistemlerinden, dermatologlardan daha yüksek performans sergileyen CNN modellerine; oradan da topluluk öğrenmesi yaklaşımlarına, metaveri füzyonuna ve Transformer tabanlı hibrit yapılara uzanan bir ilerleme söz konusudur. Ancak bu gelişmelere rağmen, veri kümesi dengesizliği hâlen önemli bir sorun olmaya devam etmektedir. Buna ek olarak, hafif mimariler klinik ortamlarda uygulanabilirlik açısından giderek daha kritik bir konuma gelmektedir.

Tüm bu unsurlar birlikte değerlendirildiğinde, bu tezde ağır CNN modelleri ile GhostNet gibi hafif mimarilerin, uygun yeniden örnekleme teknikleriyle birlikte ele alınmasının klinik güvenilirliği en üst düzeye çıkarma açısından güçlü bir araştırma zemini sunduğu görülmektedir.

3. MATERYAL VE YÖNTEMLER

3.1. Genel Bakış

Bu bölüm, dermoskopik görüntülerden cilt lezyonlarının otomatik sınıflandırılması için derin öğrenme modellerinin oluşturulması ve doğrulanmasında kullanılan yöntemleri açıklamaktadır. Çalışmanın hedeflerine ulaşmak için iki kavramsal çerçeve kullanılmıştır:



Şekil 3. Çerçeve I ve Çerçeve II için Birleştirilmiş Veri Akış Diyagramı

1. İlk yaklaşım: Derin öğrenmede standart bir yöntem olan transfer öğrenme ile önceden eğitilmiş evrimsel sinir ağı (CNN) modellerinden oluşan bir setin değerlendirilmesine odaklanmıştır.

2. İkinci yaklaşım: GhostNet modellerini, veri dengesizliğini azaltmaya yönelik bir mekanizma (SMOTEENN) ile entegre eden, hafif ve verimli bir yaklaşım önermiştir.

Bu iki yöntem, model yapılandırması ve veri dengeleme stratejileri açısından farklılık gösterse de aynı veri kümesini, ön işleme adımlarını ve performans ölçütlerini paylaşarak birbirleriyle tutarlı bir deneysel platform sunmaktadır.

3.2. Veri Kümesi ve Hazırlık

3.2.1. Veri Seti Açıklaması


Bu çalışmada, dermatolojik görüntü analizi alanında yaygın olarak kullanılan herkese açık ISIC veri kümesi kullanılmıştır. Veri kümesi, uzman dermatologlar tarafından konulmuş tanılara göre etiketlenmiş çeşitli dermoskopik görüntüler içermektedir. ISIC 2019 Challenge veri kümesi, cilt kanseri araştırmalarında en kapsamlı veri kümelerinden biri olarak kabul edilmektedir. International Skin Imaging Collaboration (ISIC) tarafından 2019 ISIC Challenge kapsamında yayımlanan bu veri kümesi, sekiz farklı tanı sınıfına ayrılmış toplam 25.331 dermoskopik görüntüden oluşmaktadır. Bunların 15.991'i benign, 9.340'ı ise malign olarak sınıflandırılmıştır. Veri kümesi, otomatik melanom tespiti desteklemek amacıyla oluşturulmuş olup, yapay zekâ modellerinin genellenabilirliğini artırmak için farklı lezyon tiplerini kapsamaktadır.

ISIC 2019 veri kümesindeki sekiz tanısal sınıf şu şekildedir: malign kategoride melanom (MEL), skuamöz hücreli karsinom (SCC), bazal hücreli karsinom (BCC) ve aktinik keratoz (AK); benign kategoride ise benign keratoz benzeri lezyonlar (BKL), dermatofibrom (DF), melanositik nevüs (NV) ve vasküler lezyonlar (VASC) yer almaktadır. Şekil 3'te bir malign ve bir benign görüntüye ait örnek gösterilmektedir. Bu çalışmada, ISIC 2019'un özgün 25.331 görüntüsü; 20.264 eğitim, 5.067 doğrulama ve test verisi olacak şekilde bölümlendirilmiştir.

ISIC 2019 veri kümesi, derin öğrenme ve bilgisayar destekli tanı araştırmalarında yaygın olarak kullanılmakta olup, yapay zekâ temelli dermatolojik uygulamaların geliştirilmesi açısından değerli bir kaynak sunmaktadır. Bu çalışmada, görüntüler benign ve malign kategorilerine göre yeniden düzenlenerek ikili sınıflandırma görevine uygun bir veri kümesi oluşturulmuştur. ISIC veri kümesi, yüksek kaliteli anotasyonları

ve cilt kanseri tespitine yönelik derin öğrenme modellerinin geliştirilmesine elverişli yapısı nedeniyle tercih edilmiştir.

Şekil 4'te, ISIC 2019 dermoskopik veri kümesinden seçilen temsili bir malign ve bir benign örnek yan yana gösterilmektedir. Görüntüler, veri kümesinin kimliksizleştirilmiş yayımlama protokolüne uygun olarak sağlanmış ve standart ön işleme hattı kapsamında yeniden boyutlandırılıp normalize edilmiştir. Bu çalışmada, klinik tarama senaryosunu yansıtmak amacıyla ISIC'in sekiz tanı sınıfı benign ve malign olmak üzere iki ana grupta birleştirilmiştir.



Şekil 4. ISIC 2019 dermoskopik veri kümesinden temsili örnekler

3.2.2. Veri Seti Bölünmesi

Bu çalışmada veri bölünmesi, split-first yaklaşımı esas alınarak ve sınıf dağılımı korunacak şekilde (stratified) gerçekleştirilmiştir. Görüntüler, benign (0) ve malign (1) etiketlerine göre iki aşamalı olarak ayrılmıştır. İlk aşamada verinin %11,5'i test kümesi olarak ayrılmış, kalan veri içinden ise %8,5'lik bölüm doğrulama kümesi için seçilmiştir. Böylece yaklaşık olarak %80 eğitim, %8,5 doğrulama ve %11,5 test oranlarına sahip bir veri bölünmesi elde edilmiştir.

Her iki aşamada da train_test_split yöntemi kullanılmıştır. Doğrulama ve test kümelerine herhangi bir dengeleme ya da yeniden örnekleme işlemi uygulanmamış, bu kümeler yalnızca nihai model değerlendirmesi amacıyla kullanılmıştır. Bölünme, görüntü düzeyinde (image-level) yapıldığından hasta ya da lezyon kimliğine dayalı bir gruplama gerçekleştirilmemiştir. Bu nedenle, aynı hastaya veya lezyona ait birden fazla görüntünün farklı veri kümelerine düşmesi teorik olarak mümkündür ve bu durum veri sızıntısı (data leakage) riski doğurmaktadır. Söz konusu sınırlılık tez kapsamında açıkça belirtilmiş olup, gelecekte yapılacak çalışmalarda hasta düzeyinde (patient-level) veri bölünmesi ile daha sağlam bir doğrulama sürecinin planlandığı ifade edilmiştir.

3.2.3. Ön İşlem Adımları

Tüm görüntüler 224×224 piksel boyutuna yeniden ölçeklendirilmiş ve ImageNet veri kümesinin ortalama ile standart sapma değerleri kullanılarak normalize edilmiştir. Eğitim verilerine yalnızca standart veri artırma işlemleri, yani yatay çevirme, küçük açısız döndürmeler ve hafif renk değişimleri uygulanmıştır. Doğrulama ve test alt kümelerine ise yalnızca deterministik yeniden boyutlandırma ve normalizasyon adımları uygulanmıştır. Bu ön işleme adımları, her iki metodolojik çerçevede de aynı tutulmuştur. Böylece farklı modelleme stratejilerinin etkilerini izole etmek ve karşılaştırmalı sonuçların güvenilirliğini sağlamak mümkün olmuştur.

Tablo 2’de, tüm deneylerde kullanılan kesin deneysel kurulum özetlenmektedir. ISIC 2019 veri kümesindeki sekiz tanı sınıfı benign ve malign olmak üzere iki grupta birleştirilmiş, görüntüler 224×224 boyutuna yeniden ölçeklendirilmiş ve standart biçimde normalize edilmiştir. Eğitim aşamasında, dermoskopik görüntülere uygun hafif veri artırma işlemleri kullanılmıştır. Sınıf dengesizliği, bilgi sızıntısını önlemek amacıyla yalnızca eğitim alt kümesinde, GhostNet V2’nin dondurulmuş gömme (embedding) uzayında uygulanan SMOTE-ENN yöntemi ile giderilmiştir. Doğrulama ve test kümelerine herhangi bir müdahalede bulunulmamıştır. Optimizasyon süreci, AdamW algoritması ve kosinüs öğrenme oranı planlayıcısı kullanılarak yürütülmüş; kayıp fonksiyonu olarak Binary Cross Entropy with Logits (BCEWithLogitsLoss) tercih edilmiş ve doğrulama doğruluğuna göre erken durdurma uygulanmıştır. Bu tercihler, tıbbi görüntülemelerde transfer öğrenmesi ve dengesiz sınıflandırma alanlarında yerleşik en iyi uygulamalarla uyumludur.

Tablo 2. Metodoloji Ayrıntıları (Veri Bölünmesi, Hiperparametreler)

Öge	Değer
Veri seti	ISIC 2019 (25.331 dermoskopik görüntü, 8 sınıf → benign vs malign olarak ikili sınıflandırmaya indirgenmiştir)
Malign sınıflar	MEL, SCC, BCC, AK
Benign sınıflar	NV, BKL, DF, VASC
Görüntü boyutu	224×224 piksel
Normalizasyon	Ortalama = [0.5, 0.5, 0.5], Std = [0.5, 0.5, 0.5]
Dengeleme yöntemi	Yalnızca Çerçeve II için: Eğitim kümesi gömüleri üzerinde SMOTE-ENN /Çerçeve I için SMOTE-ENN uygulanmamıştır.
Optimizasyon yöntemi	AdamW (LR = $1e-4$, weight decay = $1e-4$)
Öğrenme oranı planlayıcı	Cosine Annealing LR
Kayıp fonksiyonu	Logit’li İkili Çapraz Entropi (BCEWithLogitsLoss)
Epok sayısı	35

Table 2.(Devamı)

Öge	Değer
Batch boyutu	32
Erken durdurma	En iyi kontrol noktası doğrulama doğruluğuna (validation accuracy) göre kaydedilmiştir (best checkpoint).

3.3. Çerçeve I: Önceden Eğitilmiş CNN'lerle Transfer Öğrenme

3.3.1. Genel Bakış

İlk metodolojik yaklaşım, güncel önceden eğitilmiş CNN mimarilerini kullanarak güvenilir bir temel model (baseline) oluşturmayı amaçlamaktadır. Transfer öğrenmesi, ImageNet gibi büyük ölçekli veri kümelerinden öğrenilen görsel temsillerin tıbbi görüntü analizi alanına aktarılmasına ve bu alana uyarlanmasına olanak tanımaktadır. Bu yaklaşım, özellikle etiketli veri miktarının sınırlı olduğu durumlarda önemli avantajlar sağlamaktadır.

Şekil 6, önerilen hibrit yaklaşımın bütünleşik iş akışını göstermektedir. Şeklin sol tarafındaki akış, transfer öğrenmesi ile önceden eğitilmiş CNN omurgalarının kullanımına dayanan Çerçeve I' i; sağ tarafındaki akış ise dondurulmuş GhostNet kodlayıcı, SMOTE-ENN ile dengeleme ve ince ayar sürecini içeren Çerçeve II'yi temsil etmektedir. Her iki veri akışı da sonraki bölümlerde ayrıntılı olarak açıklanacaktır.

Çerçeve I' de (Şekil 4' te gösterildiği üzere), ISIC 2019 veri kümesindeki dermoskopik görüntüler, aydınlatma ve ölçek tutarlılığını sağlamak amacıyla ön işleme tabi tutulmuştur. Ardından özellik çıkarımı; sırasıyla VGG16, DenseNet-201, EfficientNet-B7, EfficientNetV2-L, ConvNeXt-Base ve MobileNetV2 olmak üzere altı farklı önceden eğitilmiş CNN omurgası kullanılarak gerçekleştirilmiştir.

Önceden eğitilmiş CNN tabanlı modellerin temel gücü, giriş görüntülerinden ayırt edici özellikleri evrişim (convolution) katmanları aracılığıyla çıkarabilmesinden gelir. Bu tezde kullanılan VGG16, DenseNet201, EfficientNet, Mobilenet ve ConvNeXtBase gibi tüm modeller, ilk aşamada lezyon görüntülerini çok kanallı özellik haritalarına dönüştürmektedir. Tipik bir evrişim katmanında, filtre çekirdeği belirli bir bölgede kaydırılarak yerel doku bilgilerini toplar ve yeni bir özellik haritası üretir. Bu sürecin matematiksel formülasyonu eşitlik 4da detaylandırılmıştır. Denklemden W filtre çekirdeğini, X giriş özellik haritasını ve F ise çıkarılan yeni özellik haritasını temsil etmektedir. Bu işlem, hem Çerçeve I' deki ağır CNN modellerinin hem de Çerçeve II' deki GhostNet mimarisinin temel yapı taşını oluşturmaktadır.

$$F_{i,j,k} = \sum_{m=1}^M \sum_{u=1}^h \sum_{v=1}^w W_{u,v,m,k} X_{i+u,j+v,m} + b_k \quad (\text{Eşitlik 4})$$

Bu eşitlikte:

W = evrişim çekirdeği (kernel)

X = giriş özellik haritası (feature map)

F = çıkarılan özellik haritası

b_k = filtreye ait bias terimi

h, w = filtre boyutları

M = giriş kanal sayısı

Bu ağların her biri daha önce ImageNet üzerinde eğitildiğinden, evrişim katmanları kenarlar, renkler ve dokular gibi genel düşük ve orta düzey temsilleri yakalayabilen filtreler içermektedir. Eğitimin başlangıç aşamasında, bu evrişim katmanları genel özellik uzayını korumak amacıyla dondurulmuş; yalnızca yeni sınıflandırma başlığı, yani tam bağlı katmanlar ve bunları izleyen sigmoid biriminden oluşan yapı, lezyon veri kümesi üzerinde eğitilmiştir. Sınıflandırıcı kararlı hâle geldikten sonra, üst evrişim blokları ince ayar için çözülmüş ve böylece modellerin pigment ağı düzensizlikleri, renk çeşitliliği ve lezyon asimetrisi gibi alana özgü özelliklere uyum sağlaması mümkün hâle getirilmiştir. Bu iki aşamalı strateji, yani önce özellik çıkarımı, ardından ince ayar uygulanması, sınırlı dermoskopi verisi üzerinde aşırı uyum riskini azaltmış ve milyonlarca doğal görüntüden öğrenilmiş ön bilginin kullanılmasına olanak tanımıştır. Optimizasyon sürecinde, kosinüs azaltımlı öğrenme oranı planlaması ile AdamW optimizasyonu ve ikili çapraz entropi kaybı kullanılarak kararlı bir yakınsama elde edilmiştir. Elde edilen temel model güçlü bir doğruluk düzeyine ulaşmış olsa da, ConvNeXt-Base için yaklaşık %84,6 doğruluk, hesaplama maliyeti yüksek kalmıştır. Bu durum, hafif GhostNet türevlerine dayanan ikinci çerçevenin geliştirilmesi için motivasyon oluşturmıştır.

Dermoskopik tanıda özellik çıkarımının temel amacı, her görüntüyü malign ve benign lezyonları birbirinden ayırt edebilen, aynı zamanda klinik açıdan yorumlanabilirliğini koruyan, kompakt ve bilgilendirici bir temsile dönüştürmektir. Transfer öğrenmesi kapsamında, önceden eğitilmiş bir CNN; kenarlar, dokular ve şekiller gibi genel görsel ilkeleri zaten kodlamaktadır. Özellik çıkarımı, bu temsillerin ya olduğu gibi dondurularak yeniden kullanılmasını ya da üst katmanların kısmen ince ayarlanarak dermoskopik yapılara, örneğin pigment ağı, noktalar/globüller, çizgiler ve mavi-beyaz örtü gibi özelliklere, uyum sağlamasını mümkün kılmaktadır. Literatürde, ImageNet üzerinde önceden eğitilmiş CNN özelliklerinin güçlü ve genellenebilir betimleyiciler sunduğu ve tıbbi görüntüleme dâhil birçok görevde etkili biçimde

yeniden kullanılabilirdiği gösterilmiştir. Bu durum, önceden eğitilmiş omurgaların kullanılması ve sonrasında ince ayar uygulanması yönündeki tercihimizin temel gerekçesini oluşturmaktadır.

Omurgalar (Backbones). Derin özellikler, ImageNet ağırlıklarıyla başlatılmış VGG16, EfficientNet-B7, EfficientNetV2-L, DenseNet-201, ConvNeXt-Base ve MobileNetV2 olmak üzere altı farklı CNN ailesinden çıkarılmıştır. Bu aileler, klasik, ölçeklenebilir ve mobil verimli tasarım uzaylarını kapsamaktadır. Örneğin, EfficientNet'in bileşik ölçekleme yaklaşımı, ConvNeXt'in modernleştirilmiş ConvNet blokları ve MobileNetV2'nin tersine çevrilmiş artık yapıları bu çeşitliliği yansıtmaktadır. Böylece alıcı alan (receptive field), derinlik/genişlik ve dermoskopik doku-yapı ile ilişkili indüktif önyargılar bakımından çeşitlilik sağlanmıştır.

Özellik çıkarım katmanı. Her model için özellikler, küresel ortalama havuzlama ve sınıflandırıcı katmanından hemen önceki son evrişim aşamasının aktivasyonlarından elde edilmiştir. Bu temsiller, mekânsal olarak birikmiş doku ve şekil bilgisini korurken aynı zamanda kompakt bir yapı sunmaktadır. İnce ayar uygulandığında yalnızca üst bloklar çözülmüş; böylece düşük düzeyli kenar ve doku filtreleri kararlı kalırken, göreve özgü ayrımların üst katmanlarda öğrenilmesi sağlanmıştır.

Klinik geçerliliğin doğrulanması. Çıkarılan özelliklerin klinik açıdan anlamlı yapılara odaklandığını doğrulamak amacıyla, son evrişim katmanı üzerinde Grad-CAM ısı haritaları hesaplanmıştır. Bu haritalar, sınıf skoruna en fazla katkı sağlayan bölgeleri yerleştirerek atipik pigment ağları, çizgi/pseudopod yapıları, noktalar/globüller ve mavi-beyaz örtü gibi tanısal değeri yüksek dermoskopik yapıların model tarafından dikkate alındığını göstermektedir.

Eğitim sürecinde öğrenilen özellik çıkarımı. Bu çalışmada özellik çıkarımı, elle tasarlanmış bağımsız bir aşama olarak değil, önceden eğitilmiş CNN'lerin içinde öğrenilen bir süreç olarak ele alınmıştır. Başlangıçta, ImageNet üzerinde ön eğitimden geçirilmiş omurgalar dondurulmuş; böylece genel görsel filtrelerin sabit özellik çıkarıcılar gibi davranması sağlanırken yeni eklenen sınıflandırma başlığı eğitilmiştir. İlk yakınsama sağlandıktan sonra, üst evrişim bloklarının bir bölümü kısmen çözülmüş ve uçtan uca ince ayar gerçekleştirilmiştir. Bu sayede ağın içsel özellik hiyerarşisi, pigment ağı düzensizlikleri, noktalar/globüller ve çizgiler gibi dermoskopik yapılara uyum sağlayabilmiştir. Sonuç olarak sınıflandırmada kullanılan özellikler, doğrudan omurganın ürettiği aktivasyonlardan oluşmakta ve ince ayar süreciyle kademeli olarak cilt kanseri tanıma görevine özgü hâle gelmektedir. Bu tasarım, başlangıçta kararlılığı

koruyarak aşırı uyumu azaltmakta ve sınıflandırıcı başlık dengelendikten sonra göreve özgü temsil öğrenimini etkinleştirmektedir.

3.3.2. Model Seçimi ve Adaptasyonu

Bu çalışmada altı farklı CNN mimarisi incelenmiştir: VGG16, EfficientNet-B7, EfficientNetV2-L, DenseNet-201, ConvNeXt-Base ve MobileNetV2. Tüm modeller, ImageNet üzerinde önceden eğitilmiş ağırlıklarla başlatılmıştır. Genel görsel temsilleri korumak amacıyla, başlangıç eğitim aşamasında özellik çıkarım katmanları dondurulmuştur. Son katmandaki tam bağlı yapı ise ikili sınıflandırma görevine uyarlanmış özel bir sınıflandırma başlığı (classification head) ile değiştirilmiştir. Bu başlık; yoğun katmanlar, aktivasyon fonksiyonları ve düzenleştirme bileşenleri içerecek şekilde, genelleme yeteneğini artırmak ve aşırı öğrenmeyi azaltmak amacıyla tasarlanmıştır.

Özellik çıkarımı (eğitim sürecinde öğrenilir). Bu çerçevede özellik çıkarımı, elle tasarlanmış bağımsız bir adım değildir; eğitim süreci sırasında önceden eğitilmiş CNN'lerin içinde gerçekleşmektedir. Başlangıçta, ImageNet üzerinde ön eğitim almış omurgalar (backbone) dondurulmakta; böylece genel görsel filtreler sabit özellik çıkarıcılar gibi görev yaparken yeni eklenen sınıflandırma başlığı eğitilmektedir. İlk yakınsama sağlandıktan sonra, üst evrişim bloklarının bir bölümü kısmen çözülmekte ve uçtan uca ince ayar gerçekleştirilmektedir. Bu sayede ağ, içsel özellik hiyerarşisini pigment ağı, noktalar/globüller ve çizgiler gibi dermoskopik yapılara uyarlayabilmektedir. Böylece sınıflandırmada kullanılan “özellikler”, omurga tarafından üretilen aktivasyonlardan oluşmakta ve ince ayar süreciyle giderek cilt kanseri tanısına özgü hâle gelmektedir. Bu tasarım, başlangıçta eğitimin kararlılığını korumakta, aşırı uyumu azaltmakta ve sınıflandırma başlığının dengelenmesinin ardından göreve özgü temsil öğrenimini mümkün kılmaktadır.

Tablo 3, çalışmada değerlendirilen altı önceden eğitilmiş omurganın model boyutunu (parametre sayısı, M) ve hesaplama maliyetini (FLOP, G) karşılaştırmalı olarak sunmaktadır. Görüldüğü üzere, VGG16 en yüksek parametre sayısına sahip klasik bir mimaridir (138,4M). Buna karşılık MobileNetV2, yalnızca 3,5M parametre ve 0,3G FLOP ile açık ara en hafif seçenektir. EfficientNet-B7 ve EfficientNetV2-L, bileşik ve modern ölçekleme stratejileri sayesinde yüksek temsil gücü sunarken, sırasıyla yaklaşık 37G ve 53G FLOP düzeyindeki hesaplama maliyetleri nedeniyle daha yüksek çıkarım yükü oluşturmaktadır. DenseNet-201, bağlantı paylaşımı sayesinde 20M parametre ile görece kompakt kalırken, 4,3G FLOP düzeyinde makul bir hesaplama

gereksinimi göstermektedir. ConvNeXt-Base ise modernleştirilmiş evrişim bloklarıyla 87M parametre ve 16,9G FLOP düzeyinde bir denge sunmaktadır. Bu karşılaştırma, mimari seçimin doğruluk-verimlilik ödünleşimini doğrudan etkilediğini ve özellikle gerçek zamanlı ya da mobil kullanım hedeflendiğinde FLOP ve parametre bütçesinin kritik bir tasarım kısıtı olduğunu vurgulamaktadır. Verilen değerler, 224×224 giriş boyutu varsayımı altında raporlanan tipik sonuçlara karşılık gelmektedir.

Tablo 3. Önceden Eğitilmiş Omurgaların Hesaplama Karmaşıklığı (Parametre ve FLOP'lar)

Model	Params (M)	FLOPs (G)
VGG16	138.4	15.5
EfficientNet-B7	66	37
EfficientNetV2-L	120–121	53
DenseNet201	20.0	4.3
ConvNeXt-Base	87	16.9
MobileNetV2	3.5	0.3

3.3.3. Eğitim Konfigürasyonu

Başlangıçta model kararlı bir yakınsamaya ulaştıktan sonra, üst evrişim bloklarının kısmen serbest bırakılmasına (unfreezing) olanak tanıyan bir ince ayar aşaması uygulanmıştır. Eğitim optimizasyonu, dinamik öğrenme oranı planlamasına sahip adaptif algoritmalar (örn. AdamW, uygun durumda momentumlu SGD varyantları) kullanılarak gerçekleştirilmiştir. Batch boyutu, öğrenme oranı ve epok sayısı gibi hiperparametreler, deneysel olarak ayarlanarak kararlılık ve en yüksek doğruluk elde edilmiştir. İkili çapraz entropi (binary cross-entropy) kayıp fonksiyonu, sınıflandırma hatasını en aza indirmek için kullanılmıştır. İkili sınıflandırma problemlerinde modelin optimize edilmesinde en sık kullanılan fonksiyonlardan biri Binary Cross-Entropy (BCE) kaybıdır. Bu çalışma kapsamında da hem Çerçeve I hem de Çerçeve II için model parametreleri, BCE fonksiyonunu minimize edecek şekilde güncellenmiştir. BCE, modelin ürettiği tahminin gerçek etiket ile ne kadar uyumlu olduğunu ölçer ve hatalı tahminlerde modeli daha fazla cezalandırır. Bu fonksiyonun matematiksel ifadesi Eşitlik 5te verilmiştir. Burada y , gerçek sınıf etiketini (0 veya 1) temsil ederken; $\hat{y}$, modelin sigmoid çıkış fonksiyonundan elde edilen tahmin olasılığını göstermektedir. Kayıp değeri küçüldükçe modelin tahmin performansı artmakta, bu durum özellikle klinik görüntü sınıflandırmasında duyarlılığı yükseltmektedir.

$$\mathcal{L} = -y \log(\hat{y}) + (1 - y) \log(1 - \hat{y}) \quad (\text{Eşitlik 5})$$

Bu eşitlikte:

y = gerçek etiket (0/1)

$y^{\wedge}$ = modelin tahmini (sigmoid çıkışı)

3.3.4. Değerlendirme Ölçütleri

Modelin performansı, Doğruluk (Accuracy), Duyarlılık (Sensitivity/Recall), Özgüllük (Specificity) ve AUC (Eğri Altındaki Alan) ölçütleriyle değerlendirilmiştir. Ayrıca, yanlış pozitif (False Positive) ve yanlış negatif (False Negative) sonuçları görselleştirmek amacıyla bir karışıklık matrisi (confusion matrix) oluşturulmuş böylece modelin klinik açıdan yorumlanabilirliği artırılmıştır.

3.3.5. Sonuçların Özeti

Tüm önceden eğitilmiş modeller arasında ConvNeXt-Base, en yüksek doğruluk (%84,63) ve duyarlılık (%78) değerlerine ulaşarak güçlü bir temel performans ortaya koymuştur. EfficientNet-B7 (%82,33 doğruluk) ve DenseNet-201 (%80,44 doğruluk) gibi diğer modeller de rekabetçi performans sergilemiş, ancak duyarlılık açısından bir miktar daha düşük kalmıştır. Buna karşılık MobileNetV2, hesaplama açısından verimli olmasına rağmen en düşük tanısal doğruluk oranına (%77,17) sahip olmuştur. Bu sonuçlar, sonraki metodolojik iyileştirmeler için önemli bir başlangıç noktası sağlamıştır.

EfficientNet'in yüksek doğruluk düzeyine ulaşması, derinlik, genişlik ve giriş çözünürlüğünün birlikte artırılmasına dayanan bileşik ölçekleme yaklaşımı ile MBConv ve SE bloklarının birleşik kullanımına bağlanabilir. Bu yapı, dondurma, kısmi çözme ve ince ayar aşamalarından oluşan eğitim akışında, küresel lezyon asimetrisini ve ince dermoskopik ayrıntıları, örneğin küçük noktalar/globüller ile retiküler doku örüntülerini, eş zamanlı olarak yakalayabilmekte ve aşırı öğrenmeyi sınırlayabilmektedir. Uygulamada bu mimari, transfer öğrenmesi açısından güçlü bir yanlılık-varyans dengesi sunmaktadır. Alt katmanlar kararlı renk ve kenar filtrelerini korurken, üst katmanlar lezyona özgü ipuçlarına verimli biçimde uyum sağlamak ve benzer özgüllük düzeylerinde daha fazla malign vakanın doğru sınıflandırılmasına katkıda bulunmaktadır.

Bununla birlikte, bu çerçevede elde edilen performans düzeyi, daha hafif ve daha verimli mimariler için güçlü bir karşılaştırma zemini oluşturmuştur. Özellikle duyarlılık ve AUC gibi klinik açıdan kritik ölçütlerde daha ileri iyileştirmelerin mümkün olduğu görülmüştür. Bu nedenle, sonraki aşamada hem hesaplama maliyetini azaltan hem de

malign lezyonların tespit başarısını artıran alternatif mimarilere yönelmek yöntemsel açıdan gerekli hâle gelmiştir.

3.4. Çerçeve II: Hafif Mimari (GhostNet) + SMOTE-ENN

3.4.1. Genel Bakış

Temel çerçeve üzerine inşa edilen ikinci metodoloji, kaynakları sınırlı cihazlarda çalışabilecek, ancak aynı derecede doğru ve verimli bir model tasarlamayı amaçlamıştır.

Bunu başarmak için, hafif yapısı ve düşük hesaplama maliyeti nedeniyle GhostNet ailesi (V1, V2, V3) kullanılmış; ayrıca SMOTE-ENN yöntemi, sınıf dengesizliğini gidermek ve malign lezyonlara karşı duyarlılığı artırmak amacıyla entegre edilmiştir.

Şekil 3'ta gösterilen ikinci çerçeve II, tanısal doğruluğu artırırken hesaplama verimliliğini korumak amacıyla GhostNet ailesini (V1-V3) SMOTE-ENN hibrit dengeleme stratejisiyle bütünleştiren, optimize edilmiş ve hafif bir yöntemi sunmaktadır. Aynı ISIC-2019 dermoskopik veri kümesiyle başlanarak, tüm görüntüler tutarlılığı sağlamak ve gürültüyü azaltmak için standart ön işlem adımlarından yeniden boyutlandırma, normalizasyon ve artırma geçirilmiştir. Dengelemeyi doğrudan piksel düzeyinde uygulamak yerine, önce dondurulmuş bir GhostNet kodlayıcı kullanılarak derin özellik gömüleri çıkarılmış, böylece her görüntü temel görsel ve dokusal özellikleri yakalayan kompakt sayısal temsillere dönüştürülmüştür. Bu gömüler, azınlık sınıfı için komşu örnekler arasında enterpolasyon yaparak yeni özellik vektörleri üreten SMOTE ile sentetik aşırı örnekleme için kullanılmış ve sınıf dengesizliği telafi edilmiştir. Veri kümesini daha da rafine etmek üzere, karar sınırları yakınındaki gürültülü veya belirsiz örnekleri kaldırmak için Edited Nearest Neighbor (ENN) filtrelemesi uygulanmış; bunun sonucunda benign ve malign sınıflar için daha temiz ve daha ayrılabilir bir dağılım elde edilmiştir. Dengelenmiş veri kümesi, AdamW çözücüsü, cosine-annealing öğrenme oranı planlayıcısı ve ikili çapraz entropi kaybı kullanılarak aynı hiperparametrelerle GhostNet modellerinin eğitimi için kullanılmıştır. Üç varyant arasında GhostNet V2, doğruluk ile hesaplama maliyeti arasında en etkili dengeyi kurarak %95 doğruluk, %94 duyarlılık ve 0.99 AUC değerlerine ulaşmıştır. Bu iş akışı, gömü uzayında dengelemenin hafif mimarilerle birleştirildiğinde, teledermatoloji ve mobil tanı sistemlerinde gerçek zamanlı dağıtımı mümkün kılarken dermatolog düzeyinde sınıflandırma performansı sağlayabildiğini göstermektedir.

Özellik Çıkarımı İkinci çerçevede, özellik çıkarımı el yapımı (hand-engineered) ayrı bir adım değil, önceden eğitilmiş omurga içinde uçtan uca öğrenilen bir süreç olarak kalır; ancak omurga sınıfı, mobil gecikme ve parametre bütçesi hedeflerini karşılamak için verimli GhostNet varyantlarıyla sınırlandırılmıştır. Genel transfer öğrenimi yaklaşımında olduğu gibi, ImageNet üzerinde önceden eğitilmiş CNN’lerin erken katmanlarda zengin, genel görsel ilkeleri (kenarlar, renk lekeleri, dokular) ve ileri katmanlarda giderek daha göreve özgü soyutlamaları kodlamasından yararlanırız. Eğitimde, GhostNet omurgası dondurularak başlatılır; böylece filtreleri kararlı, genel amaçlı özellik çıkarıcılar gibi görev yaparken, yeni eklenen sınıflandırma başlığı yakınsamaya kadar eğitilir. Bu istikrardan sonra, üst GhostNet blokları kısmen çözülür ve uçtan uca ince ayar (fine-tuning) uygulanır; bu sayede iç temsil, dermoskopik morfolojiye (pigment ağı düzensizlikleri, noktalar/kürecikler, çizgiler/pseudopodlar, mavi-beyaz örtü) alt düzeydeki sağlam filtreleri bozmadan özelleşir. Böylece eğitim dinamikleri, özellik çıkarımını modelin içinde gerçekleştirir: “özellikler”, genel havuzlamadan hemen önceki son evrişim aşamasının aktivasyonlarıdır; bu aktivasyonlar mekânsal olarak birikmiş doku-şekil bilgisini korurken kompakt kalır. Öğrenilen özelliklerin klinik açıdan anlamlı yapılara odaklandığını doğrulamak için, son evrişim katmanında Grad-CAM hesaplarız; ortaya çıkan haritalar, malign/benign skora en çok katkı yapan bölgeleri yerleştirir ve karar verici ipuçlarının arka plan/hair artefaktları yerine lezyon üzerinde bulunduğunu görsel olarak kanıtlar. Bu dondur → kısmen çöz rejimi, aktarılabilirlik literatürüyle uyumludur: alt katmanlar geniş ölçüde yeniden kullanılabilir, üst katmanlar ise ılımlı bir uyarlamadan fayda görür; Grad-CAM ise CNN’lerde olgu düzeyinde modelden bağımsız yorumlanabilirliğin standart yöntemidir.

SMOTE ile Aşırı Örnekleme (yalnızca eğitimde; dondurulmuş özellik uzayında) Malign/benign dengesizliğini bilgi sızıntısı olmadan düzeltmek için, tek seferlik tabakalı bölmeden sonra yalnızca eğitim dilimi üzerinde aşırı örnekleme uygularız. Önemle, klasik SMOTE görüntü değil, özellik uzayında vektörler sentezler: her azınlık örneği için, k en yakın azınlık komşusuna doğru çizgi parçaları boyunca enterpolasyon yaparak azınlık karar bölgesini genişletiriz. Uygulamamızda, her eğitim görüntüsü için dondurulmuş omurgadan tek bir gömme (sondan bir önceki katman aktivasyonu) hesaplarız ve SMOTE’u bu sabit gömme uzayında çalıştırırız; bu tercih, komşuluk geometrisini stabil tutar (özellik uzayı henüz değişmiyordur) ve aşırı örnekleme prosedürünü iyi tanımlı kılar. SMOTE çıktısı piksel değil vektör olduğundan, her sentetik vektörü eğitim zamanında aynı uzaydaki en yakın gerçek azınlık görüntü kimlik(ler)ine (top-K komşu) eşleyerek gerçekleriz. DataLoader, bu gerçek görüntüleri

fazladan örnekler ve her çekimde taze stokastik artırmalar (yansıtma, döndürme, ölçekleme, hafif renk oynatma) uygular Şekil 5ta gösterdi gibi. Omurga başta dondurulmuş, sonra kısmen çözölmüş bu artırılmış piksellerden anlık özellik çıkarır; bu nedenle sentetik ögeler için ayrı bir özellik çıkarım geçişi yoktur ve hiçbir zaman bir üreteçle piksel “icat etmeyiz”. Özetle, SMOTE temsil uzayında nerede daha fazla kapsama gerektiğini söyler; biz de bunu gerçek lezyonları daha sık (çeşitli artırılmış görünümlemlerle) örnekleyerek gerçekleştiririz; böylece eğitim yığınları, SMOTE’un geometrik niyetini orijinal görüntü dağılımına sadık kalarak yaklaşıkklar. Bu prosedür, özgün SMOTE formülasyonu ve imbalanced-learn kılavuzuyla uyumludur ve yalnızca eğitim, sızıntısız bir protokole bağlı kalır.



Şekil 5. Çalışmada kullanılan temel veri artırma (augmentation) işlemlerinin örnek görüntüleri

ENN filtreleme (dengelenmiş kümede sınır temizleme; yalnızca eğitim aşamasında). Tek başına uygulanan aşırı örnekleme, sınıf sınırına yakın bölgelerde belirsiz örneklerin oluşmasına yol açabilmektedir. Bu nedenle, aşırı örnekleme adımının ardından, yine yalnızca eğitim kümesinde ve aynı dondurulmuş gömme uzayında Düzenlenmiş En Yakın Komşular (Edited Nearest Neighbors, ENN) yöntemi uygulanmıştır. ENN, etiketi yerel komşularının çoğunluk etiketiyle uyuşmayan sentetik

veya gerçek örnekleri veri kümesinden çıkararak sınır bölgesindeki ya da hatalı etiketlenmiş örnekleri budamakta ve öğrenme öncesinde sınıf kümelerini daha sıkı hâle getirmektedir.

ENN uygulamasının ardından temizlenmiş ve sınıf dengesi iyileştirilmiş bir eğitim indeksi elde edilmektedir. SMOTE adımı olduğu gibi, eklenen her “sentetik” vektör eğitim sırasında en yakın gerçek azınlık sınıfı görüntü kimlikleri üzerinden gerçeğe bağlanmaktadır. Böylece optimizasyon süreci daima gerçek piksel verileri üzerinde yürütülmekte; her yinelemede uygulanan yeni veri artırma işlemleri sayesinde ağın farklı görünüm varyasyonlarını görmesi sağlanmakta ve özellikler omurga tarafından çevrim içi olarak üretilmektedir. Birlikte kullanıldığında SMOTE ve ENN, hem literatürde hem de imbalanced-learn kütüphanesinde yerleşik bir yaklaşım olarak kabul edilmektedir. Bu bağlamda SMOTE azınlık sınıfının temsil alanını genişletirken, ENN gürültülü örtüşmeleri temizlemekte; böylece sonraki ince ayar aşaması için daha keskin ve öğrenilebilir bir karar sınırı elde edilmektedir.

3.4.2. Sınıf Dengesizliğinin Giderilmesi

Bu tezde sınıf dengesizliği, iki farklı deneysel çerçeve üzerinden ele alınmıştır. Çerçeve I’de, yani ağır ve klasik CNN omurgalarına dayanan yapıda, eğitim süreci veri kümesinin özgün sınıf dağılımı korunarak yürütülmüş; SMOTE veya SMOTE-ENN gibi yeniden örnekleme yöntemleri kullanılmamıştır. Buna karşılık Çerçeve II’de, yani GhostNet tabanlı hafif mimarilerde, sınıf dengesizliğinin model duyarlılığı üzerindeki etkisini azaltmak amacıyla yalnızca eğitim kümesine uygulanmak üzere SMOTE-ENN yaklaşımı benimsenmiştir. Bu yaklaşım, doğrulama ve test kümelerine herhangi bir müdahalede bulunmadan eğitim örneklerinin temsilini dengelemeyi amaçlamaktadır. Böylece Çerçeve I ile Çerçeve II, kendi tasarım hedeflerine uygun biçimde, özellikle performans ile hesaplama maliyeti dengesi açısından karşılaştırılabilir.

Eğitim veri kümesi başlangıçta belirgin bir sınıf dengesizliği göstermiştir: 12.791 benign ve 7.472 malignant örnek. Bu çalışmada sınıf dengesizliğini gidermek amacıyla SMOTE-ENN yalnızca eğitim kümesine uygulanmış; doğrulama ve test kümelerine hiçbir müdahalede bulunulmamıştır. SMOTE-ENN yöntemi, ham görüntü yani piksel uzayında değil, önceden eğitilmiş GhostNetV2 modelinin dondurulmuş özellik çıkarıcısından elde edilen gömme (embedding) ya da özellik vektörleri üzerinde uygulanmıştır. SMOTE ile yeniden örneklenen vektörler, görüntü uzayında karşılık bulmalarını sağlamak amacıyla eğitim kümesindeki en yakın gerçek örneklerle k-en yakın komşu (k-NN) yöntemi kullanılarak eşleştirilmiştir. Böylece sentetik piksel

üretimi yapılmadan, eğitim verisi yeniden örnekleme ve veri artırma işlemleri yoluyla dengelenmiştir.

3.4.3. Ağ Mimarisi

GhostNet V1, “Ghost modülleri” olarak adlandırılan yapılar kullanarak öz (intrinsic) özellik haritalarından düşük maliyetli doğrusal işlemler yoluyla ek özellik haritaları üretmektedir.

GhostNet V2, Decoupled Fully Connected (DFC) dikkat mekanizmasını kullanarak daha güçlü özellik temsilleri sunmakta ve bunu en düşük gecikme süresini koruyarak gerçekleştirmektedir.

GhostNet V3 ise yeniden parametreleştirme (re-parameterization) ve bilgi damıtımı (knowledge distillation) yöntemleriyle eğitim verimliliğini artırmakta, ancak çıkarım (inference) mimarisinde herhangi bir değişiklik yapmamaktadır.

Bu tasarımlar, parametre sayısını ve FLOP değerlerini önemli ölçüde azaltırken temsil gücünü yüksek düzeyde korumaktadır.

Tablo 4, aynı genişlikteki üç GhostNet sürümünü karşılaştırmaktadır. Buna göre GhostNet V1 en küçük ve en hızlı sürümken, GhostNet V2 ve GhostNet V3 biraz daha fazla parametre ve FLOP içermekte, buna bağlı olarak gecikme süresi de sınırlı düzeyde artmaktadır. GhostNet V2 ile GhostNet V3’ün çıkarım mimarisi aynıdır; çünkü GhostNet V3 esas olarak eğitim stratejisini değiştirmektedir. Bu nedenle hesaplama maliyeti ve gecikme değerleri pratikte aynı kabul edilebilir. Bununla birlikte, gerçek gecikme süresinin kullanılan cihaza ve çalışma zamanı ortamına bağlı olarak değişebileceği unutulmamalıdır.

Tablo 4 ayrıca, üç GhostNet sürümünün hesaplama yükünü ve cihaz üzerindeki mobil gecikme sürelerini karşılaştırmalı olarak özetlemektedir. GhostNet V1, 5,2M parametre ve 141M FLOP ile en kompakt seçenek olup yaklaşık 12,65 ms gecikme sunmaktadır. GhostNet V2 ve GhostNet V3 ise mimari iyileştirmeler, örneğin daha güçlü dikkat ve DFC bileşenleri sayesinde, 6,1M parametre ve 167M FLOP düzeyine ulaşmakta; buna karşın gecikme süresini yalnızca sınırlı biçimde artırarak yaklaşık 14,69 ms düzeyinde tutmaktadır. Bu değerler, GhostNet ailesinin temel ödünleşimini açıkça göstermektedir: GhostNet V1 en düşük model boyutunu ve gecikmeyi hedeflerken, GhostNet V2 ve GhostNet V3 hafif bir hesaplama artışı karşılığında daha güçlü temsil kapasitesi sunmakta ve yine de mobil ya da gerçek zamanlı çıkarım bütçeleri içinde kalmaktadır.

Tablo 4. GhostNet modellerinin hesaplama profili ve çalışma gecikmesi

Model	Params (M)	FLOPs (M)	Raporlanan Mobil Gecikme (ms)
GhostNet V1 1.0×	5.2	141	12.65
GhostNet V2 1.0×	6.1	167	14.69
GhostNet V3 1.0×	6.1	167	14.69

3.4.4. Eğitim Süreci

Karşılaştırma amacıyla GhostNet'in üç versiyonu da aynı hiperparametrelerle eğitilmiştir:

- Optimizasyon algoritması: AdamW (öğrenme oranı = $1e-4$, ağırlık bozunumu = $1e-4$)
- Öğrenme oranı planlayıcısı: Cosine Annealing Learning Rate
- Batch (yığın) boyutu: 32
- Epok sayısı: 35 (erken durdurma: art arda 3 epok boyunca iyileşme olmadığında)
- Kayıp fonksiyonu: Binary Cross-Entropy with Logits

Veri artırma (augmentation) işlemleri, deneylerin tekrarlanabilirliğini sağlamak amacıyla ilk metodolojik çerçeveye aynı şekilde uygulanmıştır.

Her modelin ortalama eğitim süresi, tek bir GPU iş istasyonunda yaklaşık altı saat olarak kaydedilmiştir.

3.4.5. Değerlendirme Metrikleri ve Sonuçlar

Performans, Birinci Çerçeve'de (Framework I) kullanılan aynı metrikler üzerinden değerlendirilmiştir. GhostNet V2, %95 doğruluk, %94 duyarlılık (sensitivity) ve 0,99 AUC değeri elde ederek hem selefleri olan V1 ve V3'ten hem de ConvNeXt-Base karşılaştırma modelinden daha iyi sonuçlar vermiştir. Bu bulgular, uygun dengesizlik giderme yöntemleriyle birleştirildiğinde verimli ve mobil uyumlu mimarilerin, tanısal doğruluk açısından ağır CNN modelleriyle rekabet edebildiğini, hatta bazı durumlarda onları aşabildiğini açıkça göstermiştir.

GhostNet V2'nin üstün performansı üç temel bileşenin birleşimine dayanmaktadır. İlk olarak, V2'de yer alan DFC (Decoupled Fully-Connected) dikkat modülü, evrişimin yerel pencere sınırlamasını aşarak uzun menzilli bağımlılıkları donanım dostu bir maliyetle yakalayabilmektedir. Böylece dermoskopide kritik öneme sahip olan lezyonun küresel asimetrisi ve sınır geometrisi gibi ipuçları, yerel doku örüntüleriyle aynı blok içinde bütünleştirilebilmektedir. Bu durum, V1'e kıyasla benzer FLOP bütçesi altında daha güçlü bir temsil kapasitesi ve daha tutarlı bir duyarlılık-özgüllük dengesi sağlamaktadır.

İkinci olarak, dengeleme adımı dondurulmuş gömme (embedding) uzayında SMOTE-ENN ile gerçekleştirildiğinden, eğitim kümesindeki azınlık sınıfına ait malign örneklerin temsil alanı genişletilmiş ve sınır bölgesindeki gürültü ENN ile ayıklanmıştır. GhostNet V2'nin geniş bağlamı yakalama kapasitesi, daha temiz ve daha ayrılabilir hâle getirilen bu dağılım üzerinde özellikle etkili olmuştur. Son olarak, V2'nin hafif mimarisi, yani daha az parametre ve düşük gecikme özelliği, eşit eğitim bütçesi altında aşırı öğrenme riskini sınırlandırmış ve dondurma, kısmi çözme ve ince ayardan oluşan eğitim akışında daha kararlı bir yakınsama sağlamıştır. Bu üç etken birlikte değerlendirildiğinde, GhostNet V2'nin %95 doğruluk, %94 duyarlılık ve 0,99 AUC düzeyine ulaşması açıklanabilmektedir.

3.5. Karşılaştırmalı Özet ve Tartışma

Her iki metodoloji de aynı veri kümesi, ön işleme adımları ve değerlendirme standartları temel alınarak kurgulanmış; böylece yöntemsel tutarlılık sağlanmıştır. İlk çerçeve, geleneksel CNN tabanlı transfer öğrenmesi yaklaşımını kullanarak temel bir performans karşılaştırması sunmuş ve ağ derinliği ile mimari tasarımın tanısallık doğruluk üzerindeki etkisini ortaya koymuştur. Buna karşılık ikinci çerçeve, verimlilik, denge ve duyarlılık açısından optimize edilmiş; böylece stratejik model tasarımı ile veri dengeleme tekniklerinin, hesaplama maliyetini artırmadan önemli iyileşmeler sağlayabildiği gösterilmiştir.

Her iki metodolojik yaklaşım birlikte değerlendirildiğinde, mimari verimlilik ile veri kümesi iyileştirme stratejilerinin güvenilir yapay zekâ tabanlı cilt kanseri teşhisinde nasıl tamamlayıcı roller üstlendiği kapsamlı biçimde ortaya konulmaktadır.

4. SONUÇ VE DEĞERLENDİRME

4.1. Önceden Eğitilmiş CNN Çerçevesinin Sonuçları

4.1.1. Kantitatif Performans

Tablo 5, önceki bölümlerde ayrıntılı olarak açıklanan tam işlem hattı kapsamında değerlendirilen altı önceden eğitilmiş omurganın toplu performansını sunmaktadır. Bu işlem hattı; veri bölme, standart ön işleme adımları (yeniden boyutlandırma ve normalizasyon), kontrollü veri artırma, dondurulmuş özellik çıkarıcılarla sınıflandırma başlığının eğitilmesi ve ardından kısmi ince ayar aşamalarını içermektedir. Tüm metrikler, mimariler arasında adil bir karşılaştırma sağlamak amacıyla ayrılmış test kümesi üzerinde hesaplanmıştır.

Görüldüğü üzere doğruluk, duyarlılık, özgüllük, kesinlik, F1 skoru ve AUC değerleri birlikte değerlendirildiğinde, her modelin performans profili daha kapsamlı biçimde tanımlanabilmektedir. Böylece yalnızca genel doğruluk değil, aynı zamanda klinik açıdan kritik öneme sahip olan kaçırılmış malign olguların azaltılması, yani duyarlılık, ile yanlış alarmların sınırlandırılması, yani özgüllük, arasındaki denge de değerlendirilebilmektedir.

Tablo 5. Altı önceden eğitilmiş CNN modelinin nicel performansını özetlemektedir


Model	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	Kesinlik (%)	F1-Skoru	AUC
VGG16	80.01	72.0	85.2	77.4	0.75	0.87
DenseNet201	80.44	73.2	86.4	77.9	0.76	0.88
EfficientNetB7	82.33	75.0	88.1	79.5	0.77	0.90
EfficientNetV2-L	83.61	76.0	89.2	80.3	0.78	0.91
ConvNeXtBase	84.63	78.0	90.3	81.5	0.79	0.92
MobileNet	77.17	65.0	84.6	72.2	0.69	0.85

ConvNeXt-Base, incelenen modeller arasında en yüksek doğruluk (%84,63) ve duyarlılık (%78) değerlerine ulaşarak diğer modellerden daha üstün bir performans sergilemiştir. Bu sonuç, modelin ince dermoskopik dokuları yakalama konusundaki güçlü kapasitesini ortaya koymaktadır. DenseNet-201 ve EfficientNet-B7 modelleri de kapasite ile verimlilik arasındaki denge bakımından başarılı performans göstermiş ve ConvNeXt-Base'i yakından takip etmiştir. Buna karşılık MobileNetV2'nin görece düşük performansı, göreve özgü dengeleme uygulanmadan kullanılan aşırı hafif modellerin karmaşık lezyon örüntülerini yeterince öğrenemediğini ve bu durumun

yetersiz öğrenmeye (underfitting) yol açabildiğini göstermiştir. Genel olarak elde edilen bulgular, daha derin ve iyi düzenlenmiş CNN mimarilerinin cilt lezyonu analizi açısından hâlen güçlü bir temel oluşturduğunu doğrulamaktadır.

Şekil 6, tüm modellerin 0,85–0,92 aralığında AUC değerleri elde ederek güçlü bir ayırt edicilik sergilediğini göstermektedir. ConvNeXt-Base’in ROC eğrisi, hemen her yanlış pozitif oranında diğer modellerin üzerinde seyrederek daha yüksek gerçek pozitif oranını koruduğunu ortaya koymaktadır. Buna karşın VGG16 ve MobileNetV2’nin ROC eğrileri daha sıkı bir profil göstermiştir. Bu durum, malign lezyonların tespitinde daha düşük duyarlılığa işaret etmektedir. Eğriler arasındaki belirgin ayrışma, transfer öğrenmesi ile eğitilen modern CNN modellerinin sınırlı dermoskopik veri üzerinde dahi iyi bir genelleme yeteneği sergileyebildiğini göstermektedir.


Şekil 6, ConvNeXtBase, en yüksek AUC (0.92) değerine ulaşırken, onu EfficientNet V2-L (0.91) takip etmiştir.



Şekil 6. Altı önceden eğitilmiş CNN modelinin ROC eğrilerini karşılaştırmaktadır

Şekil 7’de görüldüğü üzere, ConvNeXt-Base modeli hem benign hem de malign görüntülerin büyük çoğunluğunu doğru sınıflandırmış ve yalnızca sınırlı sayıda yanlış negatif üretmiştir. Bu görsel bulgu, Tablo 5’te sunulan nicel sonuçları desteklemekte ve modelin görece dengeli performansını ortaya koymaktadır.

Bununla birlikte, karışıklık matrisindeki köşegen dışı hücrelerde görülen yanlış sınıflandırmaların bir kısmı, bazı malign lezyonların görsel özellikler bakımından benign nevüslerle hâlen örtüşebildiğini göstermektedir. Bu durum, dermoskopik tanıda süregelen temel zorluklardan biri olarak değerlendirilmektedir.



Şekil 7. (ISIC 2019) test seti üzerinde ConvNeXtBase modelinin sınıflandırma sonuçlarını gösteren karışıklık matrisi (confusion matrix)

4.2. Hafif GhostNet + SMOTE-ENN Yaklaşımının Sonuçları

4.2.1. Kantitatif Performans

Tablo 6, GhostNet V2 modelinin %95,0 doğruluk, %93,9 duyarlılık, %95,3 özgüllük, F1 skoru = 0,94 ve AUC = 0,99 değerleriyle en güçlü genel performansı sergilediğini ve malign–benign ayrımında neredeyse kusursuz bir ayırt edicilik düzeyine ulaştığını göstermektedir. Bu çalışmadaki kurulumda GhostNet V2’nin üstünlüğü, mimari dengesine dayanmaktadır. Ghost modülleri, düşük maliyetli doğrusal işlemlerle zengin özellik haritaları üreterek hesaplama yükünü düşük tutarken, Ayrık Tam Bağlantılı (Decoupled Fully-Connected, DFC) dikkat bileşeni, ağır Transformer tabanlı dikkat bloklarının oluşturduğu gecikmeye benzer bir yük getirmeden küresel bağlamın toplanmasını güçlendirmektedir. Bu birleşim, uygulanan eğitim rejimiyle, yani dondurma, kısmi çözme ve ince ayar ile birlikte AdamW ve kosinüs öğrenme oranı planlayıcısı kullanımıyla, uyumlu biçimde çalışarak optimizasyonun daha kararlı hâle gelmesini sağlamış ve farklı eşik değerleri boyunca daha iyi kalibrasyon sunmuştur. Yüksek AUC değerinin temel nedenlerinden biri de bu durumdur. Klinik açıdan değerlendirildiğinde, %93,9 duyarlılık değeri, ağır ConvNeXt-Base karşılaştırma modeline kıyasla çok daha az malign olgunun gözden kaçırılması anlamına gelmektedir. Buna karşılık %95,3 özgüllük, yanlış alarmların artmasını önlemektedir. Bu durum, doğru uygulanan sınıf dengesizliği düzeltmesinin sağladığı değerli bir ödünleşim olarak değerlendirilebilir.

Karşılaştırma amacıyla incelendiğinde, GhostNet V1 aynı Ghost modüllerini paylaşmasına rağmen DFC mekanizmasının sağladığı güçlü küresel etkileşimlerden

yoksundur. Bu nedenle, 15 epokluk eğitim bütçesi altında yaklaşık %91 doğruluk düzeyinde kalmıştır. GhostNet V3 ise eğitim sürecinde avantaj sağlayabilecek yeniden parametreleştirme ve bilgi damıtımı gibi teknikler içermektedir. Ancak bu çalışmada kullanılan sabit ve görece kısa eğitim programı ile ikili sınıflandırma hedefi altında, söz konusu avantajların etkisi sınırlı kalmıştır. Bu nedenle, parametre ve FLOP değerleri benzer olmasına rağmen GhostNet V3, GhostNet V2'nin gerisinde kalmıştır. Genel olarak değerlendirildiğinde, GhostNet V2'nin dermoskopik morfoloji açısından, özellikle pigment ağı, noktalar/globüller ve çizgiler gibi yapılar bakımından, kapasite, dikkat mekanizması ve verimlilik arasında en uygun dengeyi sağladığı görülmektedir. Ayrıca model, gömme uzayında uygulanan SMOTE-ENN yaklaşımıyla da özellikle uyumlu bir performans göstermiştir. SMOTE azınlık sınıfının temsil alanını genişletmiş, ENN ise sınır bölgesindeki gürültüyü temizlemiştir. GhostNet V2'nin dikkat mekanizması da bu daha temiz geometrik yapıdan yararlanarak sınıfları daha kesin biçimde ayırabilmiştir.

Tablo 6. Çerçeve II (GhostNet) test sonuçları

Model	Doğruluk (%)	Duyarlılık (%)	Özgüllük (%)	Kesinlik (%)	F1-Skoru	AUC
GhostNet V1	91.0	91.2	90.8	90.9	0.91	0.97
GhostNet V2	95.0	93.9	95.3	94.6	0.94	0.99
GhostNet V3	91.3	90.7	91.8	91.0	0.91	0.97

4.2.2. Karşılaştırmalı Değerlendirme

En iyi geleneksel model ile optimize edilmiş hafif modelin performans metrikleri karşılaştırılmıştır. Bu karşılaştırmaya ait sonuçlar Tablo 7'de sunulmuştur.


Tablo 7. En iyi ağır omurga (ConvNeXt-Base; Çerçeve I) ile en iyi hafif modelin (GhostNet-V2; Çerçeve II) ISIC-2019 (ikili) üzerindeki doğrudan karşılaştırması

Metrik	En İyi Ağır CNN (ConvNeXtBase)	En İyi Hafif Model (GhostNet V2)	Görelî Kazanç
Doğruluk	84.63 %	95.0 %	+10.37 pp
Duyarlılık	78 %	93.9 %	+15.9 pp
Özgüllük	90.3 %	95.3 %	+5.0 pp
AUC	0.92	0.99	+0.07

Tablo 7, en iyi geleneksel model ile en iyi hafif model arasındaki doğrudan karşılaştırmayı özetlemektedir. Sonuçlar, ağır ConvNeXt-Base mimarisinden optimize edilmiş GhostNet V2 modeline geçişle birlikte doğruluk ve duyarlılıkta önemli artışlar yaşandığını göstermektedir. Özellikle duyarlılıktaki %15,9'luk artış klinik açıdan büyük


önem taşımaktadır; çünkü bu artış, malign vakaların gözden kaçırılma olasılığının azaldığını göstermektedir. Daha küçük model boyutuna rağmen GhostNet V2, daha yüksek kesinlik ve daha hızlı çıkarım sağlayarak mimari verimlilik ile uygun veri dengeleme stratejilerinin, tanısal kaliteden ödün vermeden birlikte sağlanabileceğini ortaya koymuştur.

Şekil 8, doğru pozitif örneklerin sayısına kıyasla düşük bir yanlış negatif sayısı (FN = 87) göstererek, klinik açıdan kritik olan malign lezyonların saptanmasında güçlü bir performansa işaret etmektedir. Yanlış pozitif sayısının da sınırlı düzeyde kalması (FP = 71), modelin yüksek özgüllüğünü desteklemektedir. Bu bulgular, Çerçeve II kapsamında raporlanan kesinlik, F1 skoru ve AUC metrikleriyle uyumludur.



Şekil 8. ISIC 2019 test seti üzerinde ChostNet V2 modelinin sınıflandırma sonuçlarını gösteren karışıklık matrisi (confusion matrix)


Şekil 9, eşik değerleri boyunca modellerin ayırt ediciliğini karşılaştırır. GhostNet-V2 eğrisi, özellikle düşük yanlış-pozitif bölgede diğerlerini tutarlı biçimde aşarak malign/benign ayrımında üstünlük gösterir ve Çerçeve II’de raporlanan en iyi test metriklerini destekler.



Şekil 9. Test kümesinde GhostNet V1–V3 modellerinin ROC eğrilerinin karşılaştırılması

Temsili örnekler, Şekil 10’da doğru pozitif, yanlış pozitif ve yanlış negatif durumlar için gösterilmiştir. Her bir lezyon için özgün dermoskopik görüntü, Grad-CAM görselleştirmesi ile birlikte sunulmaktadır. Vurgulanan bölgeler, model kararını en fazla etkileyen görüntü alanlarını göstermektedir. Malign olgularda dikkat, genellikle asimetri, sınır düzensizlikleri ve pigmentasyon örüntüleri gibi yapılar üzerinde yoğunlaşmaktadır. Bu görselleştirmeler, ağların arka plan artefaktları yerine klinik açıdan anlamlı lezyon bölgelerine dayandığını göstererek yorumlanabilirliği artırmaktadır.

Erken tanı açısından en kritik grubun malign örnekler olması nedeniyle, görsel incelemede bu örnekler öncelik verilmiştir. Bununla birlikte, modelin sınıflar genelindeki davranışını ortaya koymak amacıyla benign örnekler de yer verilmiştir. Yanlış pozitif örneklerde dikkat haritalarının çoğunlukla lezyonun pigment yoğunluğu yüksek veya yapısal olarak düzensiz bölgelerinde toplandığı gözlenmiştir. Yanlış negatif örneklerde ise modelin bazı ince malign ipuçlarını yeterince ayırt edemediği, özellikle benign görünümlü alanlarla örtüşen örneklerde hata yapabildiği anlaşılmaktadır. Bu bulgular, modelin karar mekanizmasının görsel olarak izlenebilir olduğunu ve güçlü yönleri kadar hata eğilimlerinin de açıklanabildiğini göstermektedir. Dolayısıyla Grad-CAM tabanlı değerlendirme, yalnızca yorumlanabilirliği artırmakla kalmayıp modelin klinik güvenilirliğinin tartışılmasına da katkı sağlamaktadır.



Şekil 10. Grad-CAM’li temsili dermoskopi olguları: DP, YP ve YN (malign odak düzensiz yapılarda)

4.3. Sonuç

Bu bölümde, önceden eğitilmiş CNN modelleri ile optimize edilmiş hafif GhostNet modellerine dayanan iki farklı metodolojik yaklaşımın deneysel sonuçları sunulmuş ve karşılaştırılmıştır. Her iki yöntem de, ikili cilt lezyonu sınıflandırması amacıyla ISIC 2019 dermoskopik görüntü veri kümesi üzerinde uygulanmıştır. VGG16, EfficientNet-B7, EfficientNetV2-L, DenseNet-201, MobileNetV2 ve ConvNeXt-Base olmak üzere altı önceden eğitilmiş CNN modelinin karşılaştırmalı analizi, ConvNeXt-Base modelinin %84,63 genel doğruluk ve %78 duyarlılık ile en yüksek performansı gösterdiğini ortaya koymuştur. Bu sonuç, söz konusu modelin malign ve benign lezyonları ayırt etmede diğer modellere göre daha üstün bir performans sergilediğini göstermektedir.

Bununla birlikte, elde edilen bulgular, bu derin modellerin yüksek performanslarına rağmen hesaplama açısından yoğun kaynak gerektirdiğini ve bu nedenle gerçek zamanlı tanısal uygulamalarda sınırlı pratiklik sunduğunu da göstermektedir. Özellikle çıkarım süresi ve bellek kullanımı, kaynakların sınırlı olduğu ortamlarda kurulum ve ölçeklenebilirlik açısından önemli kısıtlar oluşturmaktadır.

Bu sınırlılıkları aşmak amacıyla tasarlanan GhostNet tabanlı işlem hattı (V1, V2 ve V3 sürümleri), özellikle GhostNet V2 varyantında anlamlı kazanımlar sağlamıştır.

GhostNet V2 modeli; %95 doğruluk, %94 geri çağırma, %94 F1 skoru ve 0,99 AUC değerlerine ulaşmıştır. Bu ölçütler, modelin üstün ayırt edicilik gücünü ortaya koymakta; özellikle malign lezyonlara karşı yüksek duyarlılığı korurken düşük yanlış pozitif oranlarını sürdürebildiğini göstermektedir. Karışıklık matrisleri ve ROC eğrisi analizleriyle doğrulanan bu dengeli performans, lezyon sınıfları arasında güvenilir bir karar sınırının oluştuğunu göstermekte ve önerilen yaklaşımın klinik açıdan sağlamlığını desteklemektedir.

Genel olarak bulgular, hafif ağların uygun biçimde optimize edilip SMOTE-ENN gibi gelişmiş yeniden örnekleme stratejileriyle birleştirildiğinde, yalnızca ağır CNN modelleriyle rekabet etmekle kalmayıp tanısal doğruluk ve hesaplama verimliliği açısından onları aşabildiğini göstermektedir. Bu durum, özellikle çıkarım hızı ve enerji verimliliğinin kritik önem taşıdığı teledermatoloji uygulamaları ile kaynak kısıtlı klinik ortamlarda pratik kullanım için güçlü bir temel oluşturmaktadır.

5. TARTIŞMA

5.1. Genel Bakış

Bu bölümde, Bölüm 4’te sunulan nicel ve nitel bulgular yorumlanmakta ve bu bulgular yapay zekâ destekli dermatoloji alanındaki genel eğilimler çerçevesinde değerlendirilmektedir.

Gerek geleneksel önceden eğitilmiş CNN modellerinden gerekse optimize edilmiş hafif GhostNet ailesinden elde edilen sonuçlar, uygun veri dengeleme ve optimizasyon stratejileri uygulandığında, modern derin öğrenme yaklaşımlarının dermoskopik görüntü sınıflandırmasında dermatolog düzeyinde doğruluğa ulaşabildiğini göstermektedir.

5.2. Önceden Eğitilmiş CNN Sonuçlarının Yorumlanması

Altı önceden eğitilmiş CNN modelinin, yani VGG16, DenseNet-201, EfficientNet-B7, EfficientNetV2-L, ConvNeXt-Base ve MobileNetV2’nin değerlendirildiği temel çerçeve, yakın tarihli derin öğrenme çalışmalarında bildirilen performans eğilimleriyle, örneğin Ranjan vd. (2023) ile Ayas vd. (2022) tarafından sunulan bulgularla, tutarlı sonuçlar ortaya koymuştur.

Daha derin ve daha iyi düzenlenmiş mimariler, özellikle ConvNeXt-Base, daha hafif CNN modellerine kıyasla daha yüksek duyarlılık (%78) ve daha düşük kayıp değeri (loss = 0,3515) üretmiştir. Bu durum, hiyerarşik özellik çıkarımı ile Transformer esintili tasarımın güçlü lezyon tanıma performansına katkıda bulunduğunu doğrulamaktadır.

Yanlış pozitif sonuçlar çoğunlukla, skuamöz hücreli karsinom (SCC) ile görsel benzerlik gösteren benign keratoz benzeri lezyonlar arasında gözlenmiştir. Bu bulgu, ISIC veri kümelerinde sınıflar arası belirsizliklere ilişkin önceki raporlarla örtüşmektedir.

ConvNeXt-Base, bu model grubu içinde en yüksek doğruluğa ulaşmış olsa da, yüksek parametre sayısı ve uzun çıkarım süresi, nokta bazlı klinik uygulamadaki kullanılabilirliğini sınırlamaktadır. Bu kısıtlamalar, daha hafif ve klinik açıdan daha uygulanabilir bir mimarinin araştırılmasını teşvik etmiştir.

5.3. GhostNet + SMOTE-ENN Sonuçlarının Yorumlanması

İkinci metodolojik yaklaşım, veri kümesinin dengelenmesi ile hafif bir mimarinin birlikte kullanılmasının tanısallıkta güvenilirliği önemli ölçüde artırabileceğini göstermiştir.

GhostNet V2 modeli, parametre sayısını yaklaşık 6 milyona düşürmesine rağmen %95 doğruluk, %94 geri çağırma ve 0,99 AUC değerlerine ulaşmıştır.

Bu başarının temelinde iki ana unsur bulunmaktadır. Birincisi, Ghost modülleri ek özellik haritalarını verimli biçimde üretmek amacıyla doğrusal dönüşümleri yeniden kullanmaktadır. İkincisi, Ayrık Tam Bağlantılı (Decoupled Fully Connected, DFC) dikkat mekanizması, önemli bir hesaplama yükü oluşturmadan küresel bağlamın daha etkili biçimde yakalanmasını sağlamaktadır.

Eğitim sürecinde uygulanan SMOTE-ENN yöntemi, sınıflandırıcının malign lezyonları tanıma yeteneğini daha da güçlendirmiştir. Bu yaklaşım, azınlık sınıfına ait örnekleri sentetik olarak artırıp gürültülü örnekleri filtreleyerek veri kümesini dengelemiş ve sınıf dağılımını yaklaşık 10.883'e karşı 10.883 düzeyine getirmiştir. Bunun sonucunda yanlış negatif oranları azalmıştır.

Karışıklık matrisi analizi de bu avantajı doğrulamıştır. Toplam 1.424 malign vakanın yalnızca 87'si gözden kaçırılmıştır. Buna karşılık, ConvNeXt-Base temel modelinde bu sayının yaklaşık 300 olduğu görülmüştür. Bu iyileşme, melanomların gözden kaçırılma riskini azaltarak doğrudan klinik güvenliğe katkı sağlamaktadır.

5.4. Önceki Çalışmalarla Karşılaştırma

ISIC 2019 veri kümesi üzerinde gerçekleştirilen güncel çalışmalarla karşılaştırıldığında, bu tezde elde edilen sonuçların rekabetçi, hatta bazı açılardan üstün bir performans sergilediği görülmektedir. Ayas vd. (2022), çok sınıflı görevler için Swin Transformer kullanarak %97,2 doğruluk bildirmiş; Ranjan vd. (2023) ise daha küçük ve dengelenmiş veri kümelerinde MobileNet ve ResNet50V2 tabanlı birleşik modellerle %84 doğruluk elde etmiştir.

Bununla birlikte, söz konusu çalışmaların bir bölümü daha az belirsizlik içeren çok sınıflı senaryolara odaklanmış ya da veri dengesini manuel biçimde sağlamıştır. Bu tezde ise klinik açıdan daha zorlayıcı olan ikili sınıflandırma problemi ele alınmış ve karşılaştırılabilir doğruluk düzeyleri çok daha düşük hesaplama yükü ile elde edilmiştir. GhostNet V2'nin %95 doğruluk ve 0,99 AUC değeri, ikili cilt lezyonu sınıflandırması açısından performans ile verimlilik arasında son teknoloji düzeyinde bir denge sunduğunu göstermektedir.

5.5. Klinik Çıkarımlar

GhostNet V2'nin hızlı, görüntü başına 30 ms'nin altında, ve doğru teşhis sunabilme yeteneği, mobil ve teletıp uygulamaları, özellikle teledermatoloji platformları, kapsamında kullanılmasını mümkün kılmaktadır. Bu tür sistemler, uzman eksikliğinin bulunduğu düşük kaynaklı bölgelerde erken taramayı destekleyebilir ve klinik kararın yerini almadan bir karar destek aracı olarak işlev görebilir.

Dermatolojide yüksek duyarlılık büyük önem taşımaktadır; çünkü yanlış negatif bir sonuç, melanom tedavisinde gecikmeye yol açabilmektedir. Bu çalışmada elde edilen sonuçlar, yapay zekâ destekli ön değerlendirme sistemlerinin bu riski önemli ölçüde azaltabileceğini göstermektedir. Ayrıca modelin düşük yanlış pozitif oranı (%4,7), gereksiz biyopsilerin ve hasta kaygısının azaltılmasına yardımcı olarak klinik iş akışlarının optimize edilmesine katkı sağlamaktadır.

5.6. Sınırlamalar

Güçlü sonuçlara rağmen, çalışmanın bazı sınırlılıkları bulunmaktadır. İlk olarak, kullanılan veri kümesi yalnızca dermoskopik görüntülerle sınırlıdır ve hasta yaşı, cinsiyeti ya da lezyon yerleşimi gibi klinik metaverileri içermemektedir. Oysa bu tür ek bilgilerin tanısal doğruluğu artırabildiği bilinmektedir.

İkinci olarak, ikili sınıflandırma yaklaşımı, gerçek dünyada birden fazla lezyon tipinin birlikte değerlendirildiği tanı sürecini belirli ölçüde basitleştirmektedir. Üçüncü olarak, SMOTE-ENN yöntemi sınıf dengesizliğini azaltmasına rağmen, gömme uzayının sınıf sınırlarını tam olarak yansıtmadığı durumlarda sentetik örneklerden kaynaklanan bir önyargı oluşturabilmektedir.

Son olarak, tüm deneyler tek bir veri kümesi bölünmesi üzerinde gerçekleştirilmiştir. Bu nedenle, modelin klinik genellenebilirliğini doğrulamak amacıyla kurumlar arası doğrulama ve ileriye dönük (prospektif) testler gereklidir.

5.7. Gelecek Çalışmalar

Gelecekte yapılacak araştırmaların, mevcut sınırlılıkları gidermeye yönelik olarak birkaç temel alana odaklanması gerekmektedir. İlk olarak, klinik bilgiler ve metaveri özellikleri entegre edilerek çok modlu tanı modelleri geliştirilebilir. İkinci olarak, farklı hastaneler ve popülasyonlar üzerinde doğrulama çalışmaları genişletilerek farklı cilt tonları arasında adaletin değerlendirilmesi sağlanabilir. Üçüncü olarak, Grad-CAM veya Katman Bazlı İlgililik Yayılımı (Layer-wise Relevance Propagation) gibi açıklanabilir yapay zekâ araçlarının kullanımıyla klinik güven ve şeffaflık artırılabilir.

Buna ek olarak, ADASYN veya Borderline-SMOTE gibi alternatif veri dengeleme stratejileri, SMOTE-ENN yöntemi ile karşılaştırılarak duyarlılık ve kesinlik üzerindeki etkileri nicel olarak değerlendirilebilir. Son olarak, GhostNet V2'nin gerçek zamanlı mobil uygulamalara entegre edilmesi ve ileriye dönük klinik çalışmalarda test edilmesi, modelin tanısallık etkinliğini ve klinik iş akışındaki pratik verimliliğini daha kapsamlı biçimde ortaya koyacaktır.

5.8. Genel Değerlendirme

Özetle, bu tartışma GhostNet V2 gibi verimli ve hafif mimarilerin, ConvNeXt-Base gibi ağır CNN modellerine kıyasla daha yüksek doğruluk ve duyarlılık sunabildiğini göstermektedir. Bu durum, hesaplama açısından uygulanabilirlik ile klinik güvenilirlik arasındaki boşluğun azaltılabileceğini ortaya koymaktadır.

Elde edilen bulgular, tıbbi yapay zekâ tasarımında bir paradigma değişimine işaret etmektedir. Buna göre, yalnızca daha büyük modeller geliştirmek yerine, tanısallık güvenliği koruyan, optimize edilmiş ve erişilebilir çözümler üretmek giderek daha fazla önem kazanmaktadır.

İleriye dönük ek doğrulama çalışmaları ve klinik uygulamalara entegrasyon ile birlikte, önerilen bu yaklaşımın gelecek nesil cilt kanseri tarama sistemleri için sağlam bir temel oluşturma potansiyeline sahip olduğu değerlendirilmektedir.

6. SINIRLILIKLAR VE GELECEK ÇALIŞMALAR

6.1. Genel Bakış

Bu tez, cilt lezyonlarını otomatik yöntemlerle sınıflandırmak amacıyla doğru, hızlı ve klinik olarak uygulanabilir bir yapay zekâ modeli geliştirmeyi hedeflemiştir. Derin öğrenme mimarilerinin sınıf dengesizliğini giderme teknikleriyle birleştirilmesi yoluyla, kötü huylu (malign) lezyonlara yönelik duyarlılığı artırırken hesaplama hızından ödün vermeme problemine odaklanılmıştır. Bu kapsamda, ISIC 2019 dermoskopik veri kümesi üzerinde iki farklı metodolojik yaklaşım izlenmiştir:

VGG16, DenseNet-201, EfficientNet-B7, EfficientNetV2-L, ConvNeXt-Base ve MobileNetV2 olmak üzere yaygın olarak kullanılan altı önceden eğitilmiş CNN modeline dayanan transfer öğrenmesi tabanlı bir karşılaştırma yaklaşımı,

GhostNet V1–V3 mimarileri ve SMOTE-ENN tabanlı dengelenmiş veri üretimine dayanan optimize edilmiş hafif bir işlem hattı.

Her iki yaklaşım da aynı ön işleme, veri artırma ve değerlendirme çerçevesi içinde eğitilmiş; böylece yöntemler arasında doğrudan karşılaştırma yapılması mümkün hâle getirilmiştir.

6.2. Önemli Bulguların Özeti

6.2.1. Transfer Öğrenimi Temel Modeli

Önceden eğitilmiş CNN modelleri güçlü bir tanısal performans sergilemiş, bu modeller arasında ConvNeXt-Base en başarılı model olarak öne çıkmıştır (doğruluk = %84,63, duyarlılık = %78, AUC = 0,92). Modelin başarısı, lezyon yapılarının bağlamsal farkındalığını artıran Transformer esintili evrişim bloklarına bağlanmaktadır. Buna karşın, yüksek hesaplama maliyeti ve yavaş çıkarım süresi, modelin gerçek zamanlı ya da mobil uygulamalardaki kullanılabilirliğini sınırlamıştır.

6.2.2. Hafif GhostNet + SMOTE-ENN İşlem Hattı

Ağır omurga yapılarının GhostNet mimarileriyle değiştirilmesi ve sınıf dengesizliğinin SMOTE-ENN yöntemiyle giderilmesi, performansta belirgin iyileşmeler sağlamıştır. GhostNet V2, %95 doğruluk, %93,9 duyarlılık ve 0,99 AUC değerlerine ulaşarak önceki tüm CNN modellerini geride bırakmış, aynı zamanda parametre sayısını yaklaşık %90 oranında azaltmıştır. Dengelenmiş veri kümesi ile

dikkat mekanizması destekli mimari, kötü huylu vakaların yakalanma oranını önemli ölçüde artırırken yanlış pozitif sayısını da düşük düzeyde tutmuştur. Görüntü başına 30 milisaniyenin altındaki çıkarım süresi, modelin gerçek zamanlı uygulamalara uygunluğunu göstermiş ve bu yaklaşımı teletıp, özellikle teledermatoloji, ile nokta bazlı tanı sistemleri açısından güçlü bir aday hâline getirmiştir.

6.3. Bilimsel ve Klinik Katkılar

Dermatoloji için yapay zekâda yöntemsel gelişim: Bu çalışma, hafif mimariler ile gömme uzayında yeniden örnekleme tekniklerinin dikkatli biçimde birleştirilmesi sayesinde, sınırlı donanım kaynakları üzerinde dahi dermatolog düzeyinde doğruluğa ulaşılabileceğini göstermektedir.

İkili lezyon sınıflandırması için ampirik kıyaslama: Altı temel CNN modelinin aynı koşullar altında tek bir çerçevede değerlendirilmesi, gelecekteki tıbbi yapay zekâ araştırmaları için yeniden üretilebilir bir referans noktası sunmaktadır.

Klinik iş akışları üzerindeki pratik etki: GhostNet V2'nin yüksek verimliliği, modelin el tipi cihazlarda veya bulut bağlantılı sistemlerde kullanılmasına olanak tanımakta; hızlı ön tarama desteği sağlayarak tanısız gecikmenin azaltılmasına katkıda bulunmaktadır.

Etik ve açıklanabilir yapay zekâ için çerçeve: Karışıklık matrisi ve ROC analizleri aracılığıyla şeffaflığın korunması, bu çalışmayı güvenilir tıbbi yapay zekâ için gelişen standartlarla uyumlu hâle getirmektedir.

6.4. Sınırlamalar

Umut verici sonuçlara rağmen, çalışmanın bazı sınırlılıkları devam etmektedir. Veri kümesi yalnızca dermoskopik görüntülerden oluşmakta olup hasta yaşı, cinsiyeti veya lezyon yerleşimi gibi eşlik eden klinik metaverileri içermemektedir. Bu durum, bağlamsal öğrenmenin kapsamını sınırlandırmaktadır. Ayrıca ikili sınıflandırma düzeni, gerçek dünyadaki klinik çeşitliliği basitleştirmektedir. Eğitim sürecinde kullanılan sentetik dengeleme yaklaşımı da popülasyon heterojenliğini tam olarak yansıtamayabilir. Bunun yanı sıra, donanım koşullarının ve veri kümesinin görece homojen yapısı dış geçerliliği sınırlamaktadır. Bu nedenle, daha geniş kapsamlı ve çok merkezli doğrulama çalışmalarına ihtiyaç vardır.

6.5. Gelecek Çalışmalar İçin Öneriler

Çok modlu entegrasyon: Dermoskopik görüntülerin klinik ve histopatolojik verilerle birleştirilmesi yoluyla tanısal karar doğruluğunun en üst düzeye çıkarılması hedeflenebilir.

Kurumsal çapraz doğrulama: Modelin, birden fazla hastaneden ve farklı cilt tonu dağılımlarına sahip veri kümeleri üzerinde çapraz doğrulanması, adaletin ve dayanıklılığın değerlendirilmesine katkı sağlayacaktır.

Açıklanabilirlik ve kullanıcı güveni: Karar verme sürecini görünür kılmak ve hekimlerin sistemi benimsemesini kolaylaştırmak amacıyla Grad-CAM, LRP veya SHAP gibi yorumlanabilirlik araçları sisteme entegre edilebilir.

Karşılaştırmalı dengeleme çalışmaları: ADASYN ve Borderline-SMOTE gibi diğer yeniden örnekleme yöntemleri, SMOTE-ENN ile karşılaştırılarak duyarlılık yönetimi üzerindeki etkileri ayrıntılı biçimde incelenebilir.

Gerçek zamanlı uygulama ve klinik çalışmalar: GhostNet V2'nin Android veya web tabanlı tanı araçlarına entegre edilmesiyle, iş akışı verimliliği ve hasta sonuçları açısından pilot klinik çalışmalar yürütülebilir.

Yeni nesil mimarilerin incelenmesi: Verimlilikten ödün vermeden küresel bağlamdan yararlanmak amacıyla işlem hattı, Vision Transformer (ViT), ConvNeXt-Transformer hibritleri ve GhostFormer varyantlarını kapsayacak şekilde genişletilebilir.

6.6. Son Değerlendirmeler

Bu araştırma, tıbbi yapay zekâda verimlilik ile doğruluğun birbirine zıt kavramlar olmadığını ortaya koymaktadır. Model tasarımı, veri ön işleme ve değerlendirme süreçleri arasında kurulan bilinçli denge sayesinde, bu tez hem bilimsel açıdan sağlam hem de klinik açıdan uygulanabilir bir çerçeve sunmaktadır.

Yüksek performanslı hesaplama ile erişilebilirliği bir araya getiren bu çalışma, ölçeklenebilir ve gerçek zamanlı tanı sistemlerinin geliştirilmesine zemin hazırlamakta; aynı zamanda erken cilt kanseri tespitini küresel ölçekte dönüştürme potansiyeli taşıyan bir yaklaşım önermektedir.

KAYNAKÇA

- Abayomi-Alli, O., Damasevicius, R., Misri, S. ve Maskeliunas, R. (2021). Malignant skin melanoma detection using image augmentation by oversampling in nonlinear lower-dimensional embedding manifold. *Turkish Journal of Electrical Engineering and Computer Sciences*, 2600-2614. <https://doi.org/10.3906/elk-2101-133>.
- Ali, S., Han, Y. ve Khan, M. (2022). Hybrid deep learning model for multiclass skin lesion classification. *Computers in Biology and Medicine*, 146, 105603. <https://doi.org/10.1016/j.compbiomed.2022.105603>.
- American Cancer Society. (2024). *Cancer facts and figures 2024*. Erişim adresi: <https://www.cancer.org/research/cancer-facts-statistics.html>.
- Ayas, S. (2022). Skin lesion classification based on Swin Transformer architecture. Proceedings of the 14th International Conference on Machine Learning and Computing (ICMLC 2022), (ss. 298-303). ACM.
- Batista, G. E., Prati, R. C. ve Monard, M. C. (2004). A study of the behavior of several methods for balancing machine learning training data. *SIGKDD Explorations Newsletter*, 6(1), 20-29. <https://doi.org/10.1145/1007730.1007735>.
- Brinker, T. J., Hekler, A., Enk, A. H., Berking, C., Haferkamp, S., Hauschild, A., ... Utikal, J. S. (2019). Deep learning outperformed 136 of 157 dermatologists in a head-to-head dermoscopic melanoma image classification task. *European Journal of Cancer*, 113, 47-54. <https://doi.org/10.1016/j.ejca.2019.04.001>.
- Chawla, N. V., Bowyer, K. W., Hall, L. O. ve Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, 16, 321-357. <https://doi.org/10.1613/jair.953>.
- Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T. ve Houslsby, N. (2020). An image is worth 16x16 words: Transformers for image recognition at scale. arXiv preprint arXiv:2010.11929.
- Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M. ve Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542(7639), 115-118. <https://doi.org/10.1038/nature21056>.
- Gessert, N., Sentker, T., Madesta, F., Schmitz, R., Knip, H., Baltruschat, I. ve Schlaefer, A. (2020). Skin lesion classification using ensembles of deep neural

- networks and transfer learning. *Medical Image Analysis*, 61, 101600. <https://doi.org/10.1016/j.media.2020.101600>.
- Haenssle, H. A., Fink, C., Schneiderbauer, R., Toberer, F., Buhl, T., Blum, A. ve Leser, U. (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. <https://doi.org/10.1093/annonc/mdy166>.
- Han, K., Wang, Y., Tian, Q., Guo, J., Xu, C. ve Xu, C. (2020). GhostNet: More features from cheap operations. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR 2020) , (ss. 438-447) .IEEE.
- He, H., Bai, Y., Garcia, E. A. ve Li, S. (2008). ADASYN: Adaptive synthetic sampling approach for imbalanced learning. IEEE International Joint Conference on Neural Networks (IJCNN 2008), (ss. 1322-1328). <https://doi.org/10.1109/IJCNN.2008.4633969>.
- Huang, G., Liu, Z., van der Maaten, L. ve Weinberger, K. Q. (2017). Densely connected convolutional networks. IEEE Conference on Computer Vision and Pattern Recognition (CVPR), (ss. 4700-4708) https://openaccess.thecvf.com/content_cvpr_2017/papers/Huang_Densely_Connected_Convolutional_CVPR_2017_paper.pdf.
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T. ve Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- Howard, A., Sandler, M., Chu, G., Chen, L.-C., Chen, B., Tan, M. ve Adam, H. (2019). Searching for MobileNetV3. Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV 2019), (ss. 1314-1324). <https://doi.org/10.1109/ICCV.2019.00140>.
- Kassem, M. A., Hosny, K. M., Damaševičius, R. ve Eltoukhy, M. M. (2020). Skin lesion classification using Gaussian mixture model and deep neural network. *IEEE Access*, 8, 162122-162133. <https://doi.org/10.1109/ACCESS.2020.3019950>.
- Kim, J., Kim, M., Roh, J. ve Lee, S. (2022). Multimodal fusion network for mobile skin-lesion classification integrating image and metadata. *IEEE Journal of Biomedical and Health Informatics*, 26(4), 1608-1618. <https://doi.org/10.1109/JBHI.2022.3141554>.

- Kumari, A. ve Subbarao, R. (2022). Performance analysis of hybrid SMOTE–ENN oversampling for imbalanced medical data. *Computers & Electrical Engineering*, 99, 107792. <https://doi.org/10.1016/j.compeleceng.2022.107792>.
- Liu, Z., Hao, Z., Han, K., Tang, Y. ve Wang, Y. (2024). GhostNet V3: Exploring the training strategies for compact models. arXiv preprint arXiv:2404.11202. <https://arxiv.org/abs/2404.11202>.
- Manzoor, M., Lee, H. ve Kim, D. (2025). Dual-stage hybrid network for robust skin lesion segmentation and classification. *Applied Sciences*, 15(2), 823. <https://doi.org/10.3390/app15020823>.
- Pacheco, A. G., Lima, G. R., Salomão, A. S., Krohling, R. A. ve da Costa, J. F. (2021). Skin lesion classification based on deep learning and metadata fusion. *Journal of Medical Internet Research*, 23(4), e22934. <https://doi.org/10.2196/22934>.
- Pang, B., Ding, H. ve Zhang, X. (2024). GA-UNet: Ghost Attention U-Net for lightweight skin lesion segmentation. *Medical Image Analysis*, 92, 103013. <https://doi.org/10.1016/j.media.2024.103013>.
- Ranjan, V., Kaur, M. ve Sharma, S. (2023). Comparative evaluation of deep-learning architectures for melanoma detection. *Biomedical Signal Processing and Control*, 82, 104560. <https://doi.org/10.1016/j.bspc.2022.104560>.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. ve Chen, L.-C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), (ss. 4510-4520). https://openaccess.thecvf.com/content_cvpr_2018/papers/Sandler_MobileNetV2_Inverted_Residuals_CVPR_2018_paper.pdf.
- Simonyan, K. ve Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. International Conference on Learning Representations (ICLR), (ss. 1309-1316). <https://arxiv.org/abs/1409.1556>.
- Tan, M. ve Le, Q. V. (2019). EfficientNet: Rethinking model scaling for convolutional neural networks. Proceedings of the 36th International Conference on Machine Learning (ICML 2019), (ss. 6105-6114).
- Tan, M. ve Le, Q. V. (2021). EfficientNetV2: Smaller models and faster training. International Conference on Machine Learning (ICML), (ss. 10096-10106).
- Tang, Y., Han, K., Wang, Y., Xu, C. ve Xu, C. (2022). GhostNet V2: Enhance cheap operation with long-range attention. arXiv preprint arXiv:2206.14227. <https://arxiv.org/abs/2206.14227>.

- Thompson, J., Evans, P. ve Kim, J. (2023). Clinical and dermoscopic diagnosis of skin cancer: A practical overview. *Journal of the American Academy of Dermatology*, 88(3), 451-463. <https://doi.org/10.1016/j.jaad.2022.09.015>.
- Tschandl, P., Rosendahl, C. ve Kittler, H. (2018). The HAM10000 dataset: A large collection of multi-source dermoscopic images of common pigmented skin lesions. *Scientific Data*, 5, 180161. <https://doi.org/10.1038/sdata.2018.161>.
- Wilson, D. L. (1972). Asymptotic properties of nearest neighbor rules using edited data. *IEEE Transactions on Systems, Man, and Cybernetics*, 2(3), 408-421. <https://doi.org/10.1109/TSMC.1972.4309137>.
- World Health Organization. (2023). *Cancer statistics and global burden 2023*. <https://www.who.int/news/item/04-02-2023-global-cancer-statistics>. Eriřim 20 Haziran 2025.

ÖZGEÇMİŞ

Heba ALMASANI, lise öğrenimini tamamladıktan sonra lisans eğitimini Taiz Üniversitesi Bilgi Teknolojileri Mühendisliği Bölümünde tamamlamıştır. Lisans eğitiminin ardından yapay zekâ alanına yönelmiş ve yüksek lisans eğitimine Gümüşhane Üniversitesi Yapay Zekâ ve Akıllı Sistemler Bölümünde devam etmiştir. Yüksek lisans sürecinde özellikle tıbbi görüntüleme ve derin öğrenme alanlarında çalışmalar yapmış, cilt kanseri sınıflandırmasına yönelik yapay zekâ tabanlı modeller geliştirmiştir. Ayrıca sağlık ve medikal danışmanlık alanında profesyonel olarak çalışmaktadır.

Yayınlar:

Almasani, H., ve Türe, H. (2025). A deep learning approach powered by GhostNet for skin cancer classification

Almasani, H., ve Türe, H. (2025). Improving Skin Lesion Classification with Pretrained Deep Learning Models