T.C.
KASTAMONU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI

CİLT KANSERİNİN SINIFLANDIRILMASINDA DERİN ÖĞRENME MODELLERİNİN PERFORMANSLARININ KARŞILAŞTIRILMASI

ZEYNEP BİLGİN

YÜKSEK LİSANS TEZİ

PROF. DR. KEMAL AKYOL

NİSAN - 2026
KASTAMONU

TEZ ONAYI

Zeynep BİLGİN tarafından hazırlanan "**CİLT KANSERİNİN SINIFLANDIRILMASINDA DERİN ÖĞRENME MODELLERİNİN PERFORMANSLARININ KARŞILAŞTIRILMASI**" adlı tez çalışmasının savunma sınavı **20.04.2026** tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği / oy çokluğu ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Elektrik-Elektronik Mühendisliği Ana Bilim Dalı Yüksek Lisans Tezi** olarak kabul edilmiştir.

Danışman	Prof. Dr. Kemal AKYOL Kastamonu Üniversitesi	.....
Jüri Üyesi	Doç. Dr. Salih GÖRGÜNOĞLU Kastamonu Üniversitesi	.....
Jüri Üyesi	Doç. Dr. Ümit ATİLA Gazi Üniversitesi	.....

Jüri üyeleri tarafından kabul edilmiş olan bu tez Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Enstitü Müdürü Prof. Dr. Selahattin KAYMAKCI .....

TAAHHÜTNAME

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını, bilimsel etiğe uygun olarak kaynak gösterildiğini bildirir ve taahhüt ederim.

Zeynep BİLGİN

ÖZET

YÜKSEK LİSANS TEZİ

CİLT KANSERİNİN SINIFLANDIRILMASINDA DERİN ÖĞRENME MODELLERİNİN PERFORMANSLARININ KARŞILAŞTIRILMASI

ZEYNEP BİLGİN

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANA BİLİM DALI
DANIŞMAN: PROF. DR. KEMAL AKYOL

Bu çalışmanın amacı, Uluslararası Cilt Görüntüleme İş Birliği 2018 veri kümesi kullanılarak dermoskopik cilt lezyonlarının sınıflandırılmasında evrişimsel sinir ağları ve dönüştürücü mimarileri derin öğrenme modellerinin performanslarını karşılaştırmaktır. Çalışma kapsamında EfficientNet-B4, ConvNeXt-Tiny, ViT-B16 ve Swin-T mimarileri değerlendirilmiştir. Veri kümesinden melanom, nevüs, bazal hücreli karsinom, iyi huylu deri lezyonları olmak üzere dört sınıf altında ele alınmıştır ve veriler eğitim, doğrulama ve test kümeleri olarak sırasıyla %70, %10 ve %20 oranında ayrılmıştır. Modellerin performanslarını karşılaştırmak amacıyla iki eğitim senaryosu gerçekleştirilmiştir. Buna göre, eğitim sürecinde sınıf dengesizliğinin etkisini azaltmak amacıyla ağırlıklı rastgele örnekleme yaklaşımı kullanılmıştır. Model performanslarının değerlendirilmesinde Makro-Ortalama Doğruluk, Makro-Ortalama Duyarlılık, Makro-Ortalama Kesinlik ve Makro-Ortalama F1-skoru kullanılmıştır. Deneysel sonuçlar, ağırlıklı rastgele örnekleme tekniğinin özellikle az örnek içeren sınıflar üzerinde model performansını artırdığını göstermiştir. ESA mimarileri arasında ConvNeXt-Tiny mimarisi %95,12 Makro-Ortalama Doğruluk ve %85,51 Makro-Ortalama F1-skoru ile daha başarılı sonuçlar elde ederken, dönüştürücü mimarileri arasında Swin-T mimarisi %97,54 Makro-Ortalama Doğruluk ve %91,08 Makro-Ortalama F1-skoru ile deneysel çalışmalardaki en başarılı model olmuştur. Buna göre, eğitim eğrileri, karışıklık matrisleri ve alıcı işletim karakteristiği incelendiğinde Swin-T mimarisinin daha kararlı bir öğrenme sergilediği ve cilt kanseri sınıflarını daha başarılı şekilde ayırt edebildiği görülmüştür.

ANAHTAR KELİMELER: Dermoskopik Görüntü Sınıflandırma, Cilt Kanseri, Derin Öğrenme, Evrişim Sinir Ağları, Dönüştürücü Mimarileri

Nisan 2026, 79 Sayfa

ABSTRACT

MSC THESIS

COMPARATIVE ANALYSIS OF DEEP LEARNING MODELS FOR SKIN CANCER CLASSIFICATION

ZEYNEP BİLGİN

KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE
DEPARTMENT OF ELECTRICAL AND ELECTRONICS ENGINEERING
SUPERVISOR: PROF. DR. KEMAL AKYOL

The aim of this study is to compare the performance of deep learning models, such as convolutional neural networks and transformer architectures, in the classification of dermoscopic skin lesions using the International Skin Imaging Collaboration 2018 dataset. Within the scope of the study, the EfficientNet-B4, ConvNeXt-Tiny, ViT-B16, and Swin-T architectures were evaluated. The lesions in the dataset were categorized into four classes: melanoma, nevus, basal cell carcinoma, and benign skin lesions, and the data were split into training, validation, and test sets at ratios of 70%, 10%, and 20%, respectively. Two training scenarios were implemented to compare the models' performance. Accordingly, the Weighted Random Sampling approach was used during the training process to mitigate the impact of class imbalance. Macro-Average Accuracy, Macro-Average Sensitivity, Macro-Average Precision, and Macro-Average F1-score were used to evaluate model performance. Experimental results showed that the weighted random sampling technique improved model performance, especially on classes with a few sample. Among ESA architectures, the ConvNeXt-Tiny architecture achieved more successful results with 95,12% Macro-Average Accuracy and 85,51% Macro-Average F1-score, while among transformer architectures, the Swin-T architecture was the most successful model in the experimental studies with 97,54% Macro-Average Accuracy and 91,08% Macro-Average F1-score. Accordingly, when the training curves, confusion matrices, and receiver operating characteristics were examined, it was observed that the Swin-T architecture exhibited more stable learning and was able to distinguish skin cancer classes more successfully.

KEYWORDS: Dermoscopic Image Classification, Skin Cancer, Deep Learning Convolutional Neural Networks, Transformer Architectures

April 2026, 79 Page

TEŞEKKÜR

Bu çalışmanın ortaya çıkmasında yalnızca akademik bir sürecin değil, aynı zamanda sabır, fedakârlık ve inancın da büyük bir payı bulunmaktadır. Zorlu ve zaman zaman yorucu geçen bu yolculukta bana rehberlik eden, bilgi ve deneyimleriyle her aşamada yolumu aydınlatan sevgili danışmanım Prof. Dr. Kemal AKYOL hocama en içten teşekkürlerimi sunarım. Akademik bakış açısını kazanmamda, doğru yönlendirmeleriyle çalışmamın şekillenmesinde ve motivasyonumu kaybettiğim anlarda dahi bana güven aşılamasında emeği çok büyüktür.

Bu süreçte her koşulda yanımda olan, bana güç veren ve anlayışını hiçbir zaman esirgemeyen aileme gönülden teşekkür ederim. Özellikle hayatımın en zor dönemlerinde sabrıyla, sevgisiyle ve desteğiyle bana güç veren eşime ayrı bir parantez açmak isterim. Ayrıca bu yolculuk boyunca moral veren, motivasyonumu canlı tutan ve yanımda olduklarını her zaman hissettiren değerli arkadaşlarıma da içtenlikle teşekkür ederim. Bunun yanında, tüm zorluklara rağmen emek vermeye devam eden, pes etmeyen ve bu süreci kararlılıkla tamamlayan kendime de teşekkür etmek isterim. Çünkü bu çalışma yalnızca akademik bir başarı değil, aynı zamanda sabrın, emeğin ve vazgeçmemenin de bir göstergesi olmuştur. Bugün geldiğim noktada, bu başarının bana inanan, destek olan ve emeği geçen herkesin ortak katkısıyla ortaya çıktığını biliyor ve hepsine sonsuz teşekkürlerimi sunuyorum.

ZEYNEP BİLGİN

Kastamonu, 2026

İÇİNDEKİLER

Sayfa

TEZ ONAYI ..... **ii**
TAAHHÜTNAME ..... **iii**
ÖZET ..... **iv**
ABSTRACT ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİLLER DİZİNİ ..... **ix**
TABLOLAR DİZİNİ ..... **x**
SİMGELER VE KISALTMALAR DİZİNİ ..... **xi**
1. GİRİŞ **1**
1.1 Cilt Kanseri 1
1.2 Cilt Kanseri Nedenleri 2
1.3 Cilt Kanseri Türleri 3
1.3.1 Melanom 3
1.3.2 Bazal Hücreli Karsinom 6
1.3.3 Nevüs 8
1.3.4 İyi Huylu Deri Lezyonu 9
1.4 Teşhis Yöntemleri 9
2. LİTERATÜR TARAMASI **12**
3. MATERYAL ve YÖNTEM **17**
3.1 Veri Kümesi 17
3.2 Veri Ön İşleme 18
3.2.1 Standardizasyon 19
3.2.2 Görüntü Yeniden Boyutlandırma 19
3.2.3 Görüntü Dönüştürme 20
3.2.4 Verilerin Alt Kümelere Ayrılması 20
3.3 Derin Öğrenme 21
3.3.1 Öğrenim Aktarımı 22
3.3.2 Ağırlıklı Rastgele Örnekleme 23
3.3.3 Çapraz Entropi Kayıp Fonksiyonu 24
3.3.4 En İyileme Yöntemleri 24
3.3.4.1 Uyarlanabilir moment tahmini 24
3.3.4.2 Ağırlık azaltmalı uyarlanabilir moment tahmini 25
3.3.5 Öğrenme Oranı 25
3.3.5.1 Kosinüs tabanlı öğrenme oranı 25
3.3.5.2 Başarıma bağlı öğrenme oranı azaltma 25
3.4 Evrişimsel Sinir Ağları 26
3.4.1 EfficientNet-B4 Mimarisi 28
3.4.2 ConvNeXt-Tiny Mimarisi 29
3.5 Dönüştürücü Mimarileri 31
3.5.1 ViT-B16 Mimarisi 33
3.5.2 Swin-T Mimarisi 34
3.6 Performans Değerlendirmesi 36
3.6.1 Karışıklık Matrisi 36

3.6.2 Doğruluk 37
3.6.3 Kesinlik 37
3.6.4 Duyarlılık 38
3.6.5 F1-skoru 38
3.6.6 Alıcı İşletim Karakteristiği 39
4. DENEYSEL ÇALIŞMALAR 40
4.1 Deneysel Ortam 40
4.2 Deneysel Çalışmalar 40
4.2.1 Standardizasyon 40
4.2.2 Görüntü Yeniden Boyutlandırma 41
4.2.3 Görüntü Dönüştürme 41
4.2.4 Veri Ayırma 42
4.3 Derin Öğrenme Modellerinin Eğitimi ve Testi 43
4.3.1 ESA Mimarilerinin Eğitimi Stratejisi 44
4.3.1.1 EfficientNet-B4 mimarisinin eğitimi ve elde edilen sonuçlar 44
4.3.1.2 ContexTiny mimarisinin eğitimi ve elde edilen sonuçlar 50
4.3.2 Dönüştürücü Mimarilerinin Eğitimi Stratejisi 56
4.3.2.1 ViT-B16 mimarisinin eğitimi ve elde edilen sonuçlar 56
4.3.2.2 Swin-T mimarisinin eğitimi ve elde edilen sonuçlar 62
5. TARTIŞMA 68
6. SONUÇ 71
KAYNAKLAR 73
ÖZGEÇMİŞ 79

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1 Seçilmiş ülkelerde yıllara göre melanom insidansındaki değişim 5
Şekil 1.2 Bazal hücreli karsinom alt tiplerinin epidermisteki yerleşimi 7
Şekil 3.1 UCGİB 2018 Veri kümesindeki cilt lezyonu türlerine ait örnek görüntüler 18
Şekil 3.2 Dermoskopik görüntülere uygulanan standardazisyon işlemi 19
Şekil 3.3 Dermoskopik görüntülerin yeniden boyutlandırılması işlemi 20
Şekil 3.4 Dermoskopik görüntüler üzerinde uygulanan görüntü dönüştürme yöntemleri 20
Şekil 3.5 Veri kümesinin eğitim, doğrulama ve test alt kümelerine ayrılması 21
Şekil 3.6 Çok katmanlı yapay sinir ağı yapısı 21
Şekil 3.7 Evrişimsel sinir ağı mimarisinin genel yapısı 27
Şekil 3.8 EfficientNet-B4 Mimarisinin genel mimari yapısı 29
Şekil 3.9 (A) ConvNeXt-Tiny Ağ Yapısı, (B) ConvNeXt Blok Yapısı 30
Şekil 3.10 Dönüştürücü mimarisinin genel yapısı 32
Şekil 3.11 ViT-B16 mimarisinin genel yapısı 34
Şekil 3.12 Swin-T mimarisinin genel yapısı 35
Şekil 3.13 Karışıklık matrisi ve temel sınıflandırma ölçütlerinin gösterimi 37
Şekil 3.14 AİK Eğrisi 39
Şekil 4.1 Senaryo-1'de EfficientNet-B4 mimarisinin doğruluk ve kayıp eğrileri 45
Şekil 4.2 Senaryo-1'de EfficientNet-B4 mimarisinin karışıklık matrisi 46
Şekil 4.3 Senaryo-1'de EfficientNet-B4 mimarisinin AİK eğrileri 46
Şekil 4.4 Senaryo-2'de EfficientNet-B4 mimarisinin doğruluk ve kayıp eğrileri 47
Şekil 4.5 Senaryo-2'de EfficientNet-B4 mimarisinin karışıklık matrisi 48
Şekil 4.6 Senaryo-2'de EfficientNet-B4 mimarisinin AİK eğrileri 49
Şekil 4.7 Senaryo-1'de ConvNeXt-Tiny mimarisinin doğruluk ve kayıp eğrileri 51
Şekil 4.8 Senaryo-1'de ConvNeXt-Tiny mimarisinin karışıklık matrisi 51
Şekil 4.9 Senaryo-1'de ConvNeXt-Tiny mimarisinin AİK eğrileri 52
Şekil 4.10 Senaryo-2'de ConvNeXt-Tiny mimarisinin doğruluk ve kayıp eğrileri 53
Şekil 4.11 Senaryo-2'de ConvNeXt-Tiny mimarisinin karışıklık matrisi 54
Şekil 4.12 Senaryo-2'de ConvNeXt-Tiny mimarisinin AİK eğrileri 55
Şekil 4.13 Senaryo-1'de ViT-B16 mimarisinin doğruluk ve kayıp eğrileri 57
Şekil 4.14 Senaryo-1'de ViT-B16 mimarisinin karışıklık matrisi 58
Şekil 4.15 Senaryo-1'de ViT-B16 mimarisinin AİK eğrileri 58
Şekil 4.16 Senaryo-2'de ViT-B16 mimarisinin doğruluk ve kayıp eğrileri 59
Şekil 4.17 Senaryo-2'de ViT-B16 mimarisinin karışıklık matrisi 60
Şekil 4.18 Senaryo-2'de ViT-B16 mimarisinin AİK eğrileri 61
Şekil 4.19 Senaryo-1'de Swin-T mimarisinin doğruluk ve kayıp eğrileri 63
Şekil 4.20 Senaryo-1'de Swin-T mimarisinin karışıklık matrisi 63
Şekil 4.21 Senaryo-1'de Swin-T mimarisinin AİK eğrileri 64
Şekil 4.22 Senaryo-2'de Swin-T mimarisinin doğruluk ve kayıp eğrileri 65
Şekil 4.23 Senaryo-2'de Swin-T mimarisinin karışıklık matrisi 66
Şekil 4.24 Senaryo-2'de Swin-T mimarisinin AİK eğrileri 67

TABLOLAR DİZİNİ

Sayfa

Tablo 3.1 UCGİB 2018 veri kümesi sınıf dağılımı 18
Tablo 4.1 Modellerde kullanılan görüntü dönüşüm yöntemleri 42
Tablo 4.2 EfficientNet-B4 mimarisinin sınıflandırma sonuçları 50
Tablo 4.3 ConvNeXt-Tiny mimarisinin sınıflandırma performans sonuçları 56
Tablo 4.4 ViT-B16 mimarisinin sınıflandırma performans sonuçları 62
Tablo 4.5 Swin-T mimarisinin sınıflandırma performans sonuçları 67

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

AİK	**:** Alıcı İşletim Karakteristiği
ARÖ	**:** Ağırlıklı Rastgele Örnekleme
BHK	**:** Bazal Hücreli Karsinom
ÇE	**:** Çapraz Entropi
DNA	**:** Deoksiribonükleik Asit
EAA	**:** Eğri Altında Kalan Alan
ESA	**:** Evrişimsel Sinir Ağları
GBÖDL	**:** Güneşe Bağlı Öncül Deri Lezyonu
İHBDKDT	**:** İyi Huylu Bağ Dokusu Kökenli Deri Tümörü
İHDL	**:** İyi Huylu Deri Lezyonu
MEL	**:** Melanom
NV	**:** Nevüs
OKKY	**:** Optimal Kaba Küme Yaklaşımı
OKT	**:** Optik Koherens Tomografi
RKM	**:** Reflektans Konfokal Mikroskop
UBGS	**:** Uluslararası Biyomedikal Görüntüleme Sempozyumu
UCGİB	**:** Uluslararası Cilt Görüntüleme İş Birliği
UV	**:** Ultraviyole Işın
UVB	**:** Ultraviyole B Işını
UVR	**:** Ultraviyole Radyasyon
VL	**:** Vasküler Lezyon

1. GİRİŞ

1.1 Cilt Kanseri

Kanser, her yıl artan yeni vaka ve ölüm sayılarıyla birlikte halk sağlığını tehdit eden en önemli hastalıklardan biri olmaktadır (Raza, 2025). Cilt, dokuda bulunan kök hücreler tarafından sürekli yenilenen ve vücut kaynaklı çevresel stres faktörlerine karşı direnç gösterebilen dinamik bir organdır. Epidermal kök hücreler, dermal hücreler, bağışıklık sistemi hücreleri ve hücre dışı matris arasında kurulan karmaşık bir sinyal ağı, doku bütünlüğü ve fizyolojik dengenin korunmasında kritik bir rol oynamaktadır. Bu hücresel bileşenler arasındaki etkileşimler, epidermisin yenilenme kapasitesini ve fonksiyonel sürekliliğini düzenlemektedir. Ancak söz konusu sinyal yollarında meydana gelen bozulmalar, hücreler arası iletişimin aksamasına, kök hücrelerin farklılaşma süreçlerinin değişmesine ve epidermal kök hücre kimliğinin zayıflamasına yol açabilmektedir. Bu durum, zamanla epidermal bütünlüğün bozulmasına ve doku fonksiyonlarının koordineli bir şekilde sürdürülememesine neden olmaktadır (Ishikawa vd., 2025). Cilt kanseri, klinik belirtilerinin cilt yüzeyinde görsel olarak izlenebilmesi nedeniyle diğer birçok kanser türüne kıyasla daha yüksek erken tanı oranlarına sahiptir.

Cilt kanseri, epidermis ve dermiste yer alan hücrelerin normal büyüme ve bölünme mekanizmalarının bozulması sonucu kontrolsüz çoğalmasıyla gelişen ve lezyonun yapısal özelliklerine bağlı olarak farklı klinik seyirler gösterebilen kötü huylu hastalıkları kapsamaktadır. En sık görülen cilt kanseri tipleri bazal hücreli karsinom, skuamöz hücreli karsinom ve melanomdur. Melanom dışı cilt kanserleri genellikle daha yavaş seyir gösterirken, melanom saldırgan biyolojik özellikleri, erken yayılma eğilimi ve yüksek ölüm oranı nedeniyle en tehlikeli cilt kanseri türü olarak kabul edilmektedir. Bu farklılıklar, cilt kanserlerinin tanı ve tedavi süreçlerinde dikkatli bir klinik değerlendirme gerektirmektedir (Ranjan vd., 2026).

Toplum genelindeki bu hastalığın yayılımı incelendiğinde, cilt kanseri yeni vaka oranındaki artışın yalnızca bireysel biyolojik faktörlerle değil, çevresel ve davranışsal etkenlerle de ilişkili olduğu görülmektedir. Özellikle ultraviyole radyasyonuna

maruziyet, ozon tabakasının incelmesi ve iklim değişikliğine bağlı sıcaklık artışları, toplum genelinde güneş maruziyet süresini artırarak cilt kanseri riskini yükseltmektedir. Ayrıca çevresel kirleticilere maruz kalma da bazı bölgelerde cilt kanseri görülme sıklığını etkileyen önemli bir halk sağlığı faktörü olarak bildirilmektedir (Fabbrocini vd., 2010).

Cilt kanserinde erken teşhis, hastalığın klinik sonucu açısından kritik öneme sahiptir. Ancak klinik değerlendirme çoğunlukla görsel muayeneye dayandığından tanısal doğruluk dermatolog deneyimine bağlı olarak değişkenlik gösterebilmektedir. Özellikle erken evre melanom iyi huylu lezyonlarının oluşumlarla benzer özellikler sergileyebilmesi, tanı sürecini zorlaştırmaktadır. Bu durum, klinik karar sürecini desteklemek amacıyla bilgisayar destekli tanı sistemlerinin ve derin öğrenme tabanlı yaklaşımların geliştirilmesini gerekli kılmaktadır (Govindu vd., 2026).

1.2 Cilt Kanseri Nedenleri

Cilt kanserinin gelişiminde başlıca çevresel risk faktörü ultraviyole (UV) radyasyonuna maruz kalmaktır. UV ışınları, özellikle Ultraviyole B Işını (UVB) dalga boyu aralığı, deri hücrelerinde doğrudan Deoksiribonükleik asit (DNA) hasarına yol açarak genetik değişiklikleri tetikleyebilmekte ve ışığa bağlı kanserleşme sürecini başlatabilmektedir. Ayrıca UV maruziyetinin bağışıklık sistemi üzerinde baskılayıcı etkiler oluşturduğu ve bu durumun kanser gelişimine zemin hazırlayabileceği bildirilmektedir. Uzun süreli ve tekrarlayan UV maruziyeti, hücresel hasarın birikmesine neden olarak cilt kanseri riskini artırmaktadır (Tang vd., 2024).

Cilt kanseri gelişiminde genetik faktörlerin de önemli bir rol oynadığı bilinmektedir. Hücre döngüsü kontrolü, DNA onarımı ve hücresel yaşlanma süreçlerinde görev alan bazı genlerdeki kalıtsal değişiklikler, bireylerin UV kaynaklı hasara karşı duyarlılığını artırabilmektedir. Ailesel melanom öyküsü bulunan bireylerde cilt kanseri görülme riskinin daha yüksek olduğu bilinmektedir. Bu genetik faktörler, çevresel etkenlerle etkileşime girerek hastalığın ortaya çıkışını kolaylaştırmaktadır (Zheng ve Sarin, 2024).

Bireysel fiziksel özelliklerde, cilt kanseri riskini etkileyen faktörler arasında yer almaktadır. Açık ten rengi, mavi veya açık renk gözler, sarı ya da kızıl saç rengi ve yüksek çil yoğunluğu gibi özellikler artmış melanom riski ile ilişkilendirilmiştir (Gandini vd., 2005). Yazarlar tarafından yapılan kapsamlı değerlendirme çalışmasında, açık ten rengine sahip bireylerde hastalık riskinin yaklaşık iki kat arttığı (göreceli risk=2,06), kızıl saçlı bireylerde ise risk artışının daha belirgin olduğu (göreceli risk=3,64) bildirilmiştir. Ayrıca güneşe karşı son derece hassas, kolay yanıp zor bronzlaşan cilt yapısına sahip bireylerde de anlamlı düzeyde risk artışı saptanmıştır (Gandini vd., 2005).

Çevre koşulları ile yaş ve cinsiyet gibi kişisel özellikler, deri kanseri riskinin toplum genelinde farklılık göstermesinde önemli rol oynamaktadır. Özellikle kırsal bölgelerde yaşayan, açık alanda çalışan ve deniz seviyesinden yüksek yerlerde bulunan bireyler, güneş ışığına daha yoğun biçimde maruz kaldıkları için daha yüksek risk altındadır. Bunun yanında erkeklerde, çalışma koşulları ve yaşam alışkanlıklarına bağlı olarak güneş ışınına daha uzun süre maruz kalınması, hastalığın görülme sıklığının kadınlara göre daha yüksek olmasına yol açabilmektedir. Çevresel, kalıtsal ve kişisel etkenlerin birlikte etkisi, deri kanserinin çok nedenli ve karmaşık bir hastalık olarak ortaya çıkmasına neden olmaktadır (Yu vd., 2023).

1.3 Cilt Kanseri Türleri

1.3.1 Melanom

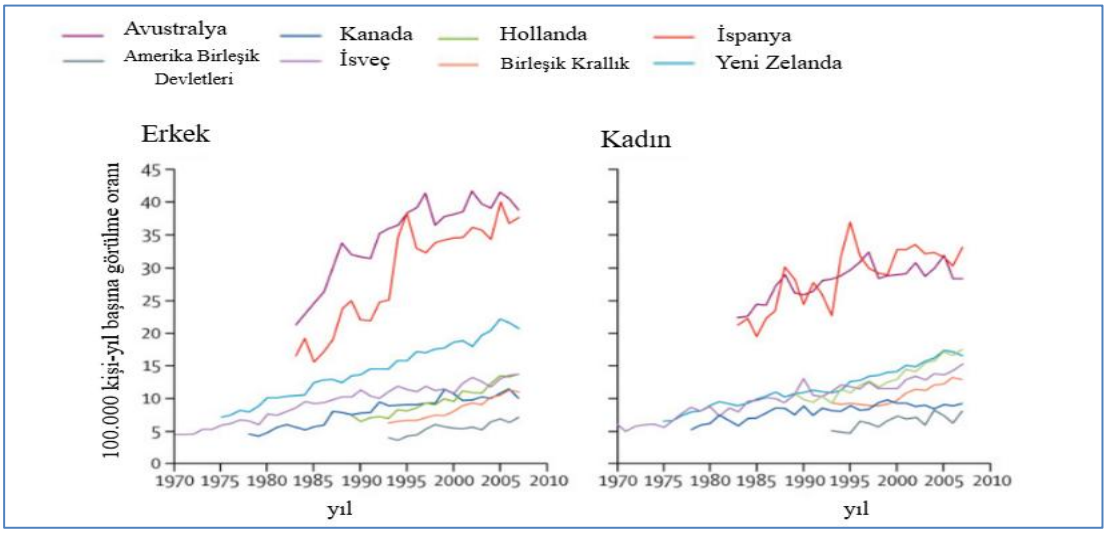
Melanom (MEL), pigment hücrelerinden kaynaklanan kötü huylu bir tümördür. Melanositler, melanin pigmentini üreten hücrelerdir ve çoğunlukla deride bulunurlar. Ancak gözlerde, kulaklarda, ince beyin zarlarında, sindirim sisteminde ve ağız, genital bölge ile sinüslerin iç yüzeyini kaplayan mukozal dokularda bulunabilmektedir (Long vd., 2023).

MEL vakalarının büyük bir bölümü deride gelişmekte olup özellikle beyaz popülasyonda tanıların %90'ından fazlasını oluşturmaktadır. Buna karşılık mukozal ve göz kökenli melanomlar daha nadir görülmekte ve tüm melanom vakalarının yaklaşık %1–5'ini oluşturmaktadır. Melanom, siyah veya kahverengi tenli bireylerde

ve Doğu Asya popülasyonlarında farklı klinik özellikler gösterebilmekte, özellikle akral bölgelerde daha sık ortaya çıkabilmektedir. MEL gelişiminde en önemli çevresel risk faktörlerinden biri Ultraviyole radyasyon (UVR) maruziyetidir. Bununla birlikte, UVR maruziyeti ile doğrudan ilişkili olmayan bazı nadir melanom alt tipleri de bulunmaktadır (Long vd., 2023).

Epidemiyolojik çalışmalar melanom görülme sıklığının özellikle son yıllarda artış gösterdiğini ortaya koymaktadır. Son kırk yılda dünya genelinde özellikle açık ten renkli bireylerde deri melanomu vakalarında belirgin bir artış olduğunu göstermektedir. Amerika Birleşik Devletleri'nde 1970'li yılların başında 100.000 kişi başına yaklaşık 6 olan vaka sayısı 2000'li yılların başında 18'e yükselerek yaklaşık üç kat artış göstermiştir. Orta Avrupa'da ise aynı dönemde vaka oranları 100.000 kişi başına 3–4 vakadan 10–15 vakaya yükselmiş ve benzer bir artış eğilimi gözlenmiştir. En yüksek insidans oranlarının ise 100.000 kişi başına 40–60 vaka ile Avustralya ve Yeni Zelanda'da görüldüğü bildirilmektedir. Buna karşın 1990'lı yıllardan itibaren birçok ülkede melanoma bağlı ölüm oranlarında denge oluşmuş ve tümör derinliğindeki azalmanın erken tanının iyileştiğini gösterdiği belirtilmiştir (Garbe ve Leiter, 2009).

Şekil 1.1'de 1970–2007 yılları arasında bazı ülkelerdeki erkek ve kadın bireylerde melanom görülme sıklığındaki değişim gösterilmektedir. Grafik incelendiğinde, melanom görülme oranlarının yıllar içerisinde genel olarak artış olduğu görülmektedir. Özellikle Avustralya ve Yeni Zelanda'da melanom görülme sıklığının diğer ülkelere göre daha yüksek olduğu dikkat çekmektedir. Bunun yanında erkek bireylerde MEL görülme oranlarının çoğu ülkede kadınlara kıyasla daha yüksek seviyelere ulaştığı görülmektedir. Ayrıca açık tenli popülasyonların yoğun olduğu ülkelerde görülme artışının daha belirgin olduğu anlaşılmaktadır. Bu durum, UV maruziyeti, çevresel faktörler ve yaşam alışkanlıklarının melanom gelişiminde önemli rol oynadığını göstermektedir (Schadendorf vd., 2018).



Şekil 1.1 Seçilmiş ülkelerde yıllara göre melanom insidansındaki değişim (Schadendorf vd., 2018)

Türkiye'de yapılan çalışmalar, birincil deri melanomu tanılarının yıllar içerisinde belirgin artış gösterdiğini ortaya koymaktadır. İstanbul ve Ankara'daki iki farklı merkezde gerçekleştirilen geriye dönük bir çalışmada, 1997–2016 ve 2007–2016 yılları arasında toplam sırasıyla 239 ve 183 birincil deri melanomu tanısı konulduğu bildirilmiştir. Çalışmada yıllık ortalama MEL tanısı sayısının birinci merkezde 11,9 ikinci merkezde ise 18,3 olduğu belirtilmiş; her iki merkezde de MEL tanı sayılarının zaman içerisinde düzenli olarak arttığı gösterilmiştir. Özellikle birinci merkezde ardışık beş yıllık dönemlerde tanı sayılarının 36'dan 83'e, ikinci merkezde ise 51'den 132'ye yükseldiği rapor edilmiştir. Bu bulgular, Türkiye'de MEL görülme sıklığının artış eğiliminde olduğunu göstermektedir (Tas ve Erturk, 2021).

MEL gelişiminde çevresel ve genetik birçok risk faktörünün etkili olduğu bilinmektedir. Özellikle UV radyasyonu maruziyeti, melanom oluşumunda en önemli çevresel risk faktörlerinden biri olarak kabul edilmektedir. Güneş ışını yoğun ve aralıklı şekilde maruz kalma ile özellikle çocukluk döneminde oluşan güneş yanıklarının melanom gelişme riskini artırdığı bildirilmektedir. Bunun yanında solaryum gibi yapay UV kaynaklarına maruz kalmanın da melanom riskini yükselttiği belirtilmektedir. Ayrıca açık ten rengi, açık göz rengi, kızıl veya sarı saç rengi ve çillenme gibi fenotipik özelliklere sahip bireylerde melanom görülme riskinin daha yüksek olduğu ifade edilmektedir. Vücutta fazla sayıda nevüs bulunması ve ailede melanom öyküsünün olması da melanom gelişimi açısından önemli risk faktörleri

arasında yer almaktadır. Bu bulgular, melanom gelişiminin çevresel ve genetik faktörlerin birlikte etkisiyle ortaya çıktığını göstermektedir (Gandini vd., 2005).

Klinik olarak melanomalar genellikle deri lezyonları şeklinde görülmekte olup, lezyonların asimetri, sınır düzensizliği, renk değişkenliği ve çap özellikleri tanı sürecinde önemli klinik göstergeler arasında yer almaktadır. Melanomun erken tanısında yaygın olarak kullanılan ABCD kuralı; lezyonun asimetrik yapıda olması, düzensiz sınırlara sahip olması, birden fazla renk içermesi ve çapının genellikle 6 mm'den büyük olması gibi kriterlerin değerlendirilmesine dayanmaktadır. Daha sonraki çalışmalarda lezyonların zaman içerisindeki değişimlerinin de tanı açısından önemli olduğu gösterilmiş ve bu nedenle değerlendirme ölçütlerine lezyonun büyümesi veya yapısal değişim göstermesi de eklenmiştir. Bu yaklaşım, melanomun erken dönemde tespitinde önemli klinik değerlendirme yöntemlerinden biri olarak kabul edilmektedir (Abbasi vd., 2004).

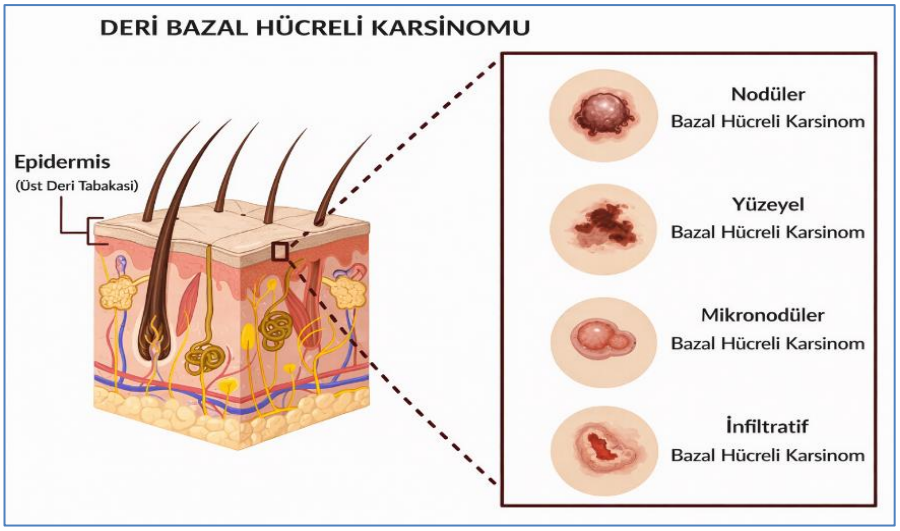
MEL tanısında klinik muayeneye ek olarak dermoskopik inceleme yöntemleri de yaygın şekilde kullanılmaktadır. Dermoskopi, deri yüzeyinin büyütülerek incelenmesine olanak sağlayan ve lezyonun yüzey altındaki pigment yapılarının daha ayrıntılı değerlendirilmesine yardımcı olan bir görüntüleme yöntemidir. Bu yöntem sayesinde pigment ağı, düzensiz yapı dağılımı, renk çeşitliliği ve yapısal asimetri gibi melanom açısından önemli özellikler daha detaylı biçimde analiz edilebilmektedir. Yapılan çalışmalar, dermoskopinin klinik muayeneye kıyasla melanom tanısındaki doğruluğu artırdığını ve özellikle erken evre melanomaların belirlenmesinde önemli katkılar sağladığını göstermektedir (Kittler vd., 2002).

1.3.2 Bazal Hücreli Karsinom

Bazal Hücreli Karsinom (BHK), melanom dışı cilt kanserleri grubunda yer alan ve klinik pratikte yaygın olarak karşılaşılan kötü huylu tümördür. Bu tümör, epidermisin bazal tabakasına benzer görsel ve yapısal özellikleri sergileyen hücrelerden gelişmektedir. Lezyonlar en sık güneşe maruz kalan baş ve boyun bölgelerinde ortaya çıkmakta ve genellikle yavaş büyüme eğilimi göstermektedir. Vücudun farklı bölgelerine yayılma olasılığı düşük olmasına rağmen, tedavi edilmediği durumlarda

çevre dokularda ciddi hasara yol açabilmesi nedeniyle klinik açıdan önem taşımaktadır. BHK'nun doku yapısına göre nodüler, yüzeysel, çevre dokuya yayılan ve mikro nodüler olmak üzere farklı alt tipleri tanımlanmış olup, bu alt tiplerin tümörün klinik davranışı ve tekrar etme riski üzerinde belirleyici rol oynadığı belirtilmektedir (Souto vd., 2022).

Şekil 1.2'de BHK'nun epidermis tabakasındaki gelişimi ve farklı tümörün mikroskop altında görülen yapısal tipi gösterilmektedir. Şeklin sol kısmında derinin epidermis tabakası ve kıl kökleri gibi yapılar şematik olarak verilmiş, BHK'nun epidermisteki bazal hücrelerden kaynaklandığı gösterilmiştir. Sağ tarafta ise BHK'nun farklı alt tipleri olan nodüler, yüzeysel, mikro nodüler ve çevre dokuya yayılım gösteren tiplerin klinik görünümleri sunulmuştur. Nodüler tip genellikle kabarık ve belirgin sınırlı lezyonlar şeklinde görülürken, yüzeysel tip daha yaygın ve yüzeye yakın yapı göstermektedir. Mikro nodüler tip küçük nodüler yapılar içermekte, çevre dokuya yayılım gösteren tip ise çevre dokulara daha düzensiz şekilde yayılım gösterebilmektedir. Bu alt tipler, tümörün klinik davranışı, büyüme biçimi ve tekrar etme riski açısından farklı özellikler göstermektedir.



Şekil 1.2 Bazal hücreli karsinom alt tiplerinin epidermisteki yerleşimi (Souto vd., 2022)

Epidemiyolojik çalışmalar, BHK'nun görülme sıklığının dünya genelinde artış gösterdiğini ve bu artışın ileri yaş, erkek cinsiyet ve yaşam boyu güneş ışığına uzun süreli kalma ile ilişkili olduğunu ortaya koymaktadır (Apalla vd., 2017). Açık tenli bireylerde ve güneşe yoğun biçimde maruz kalan bölgelerde yaşayan topluluklarda

BHK'nun daha sık görülmesi, UV radyasyonunun hastalığın gelişimindeki temel rolünü desteklemektedir.

BHK tedavisinde temel yaklaşım cerrahi çıkarımdır ve bu yöntem günümüzde en güvenilir tedavi seçeneği olarak kabul edilmektedir. Cerrahi uygulamalar, yüksek iyileşme oranları sağlamasının yanı sıra, tümör sınırlarının mikroskobik olarak değerlendirilmesine olanak tanıyarak hastalığın tam olarak ortadan kaldırılmasını mümkün kılmaktadır. Bununla birlikte, yerel olarak ilerlemiş, yineleme gösteren ya da cerrahi müdahalenin uygun olmadığı bazı olgularda farklı tedavi yaklaşımlarına gereksinim duyulmaktadır (Long vd., 2023).

1.3.3 Nevüs

Nevüs (NV), melanositlerin iyi huylu çoğalması sonucu gelişen bir deri lezyonudur. Genellikle simetrik yapı, düzenli sınırlar ve homojen renk dağılımı gibi özellikler göstermekle birlikte, klinik ve dermoskopik açıdan farklı görünümlere sahip olabilmektedir. Bazı NV lezyonları melanom ile benzer pigment yapıları ve renk özellikleri gösterebildiğinden, klinik değerlendirme sürecinde ayırıcı tanı açısından önemli bir yere sahiptir. Dermoskopik incelemelerde pigment ağı, simetri durumu, renk dağılımı ve yapısal özellikler değerlendirilerek NV lezyonlarının MEL'den ayırt edilmesi amaçlanmaktadır. Bu nedenle NV sınıfı, dermoskopik görüntü analizi ve bilgisayar destekli cilt lezyonu sınıflandırma çalışmalarında önemli iyi huylu sınıflardan biri olarak kabul edilmektedir (Cabo ve Lallas, 2018).

Epidemiyolojik çalışmalar, melanositik nevüslerin özellikle çocukluk ve ergenlik döneminde daha belirgin biçimde ortaya çıktığını göstermektedir. NV gelişimi ve sayısındaki artış; açık ten tipi, ultraviyole maruziyeti ve bireysel fenotipik özelliklerle ilişkilendirilmektedir. Ayrıca yüksek nevüs sayısı, pigmente melanositik lezyonların klinik değerlendirilmesinde dikkate alınan önemli özelliklerden biridir (Keskinkaya vd., 2025).

NV'nin dermoskopik değerlendirmesinde, özellikle MEL ile ayırıcı tanı açısından önem taşımaktadır. Dermoskopi, melanositik lezyonların değerlendirilmesinde çıplak göz muayenesine kıyasla daha yüksek tanısal doğruluk sağlayabilmekte; nevüslerin

farklı yapılar göstermesi ise bu sınıfın görüntü tabanlı sınıflandırma çalışmalarında önemli bir iyi huylu referans grup olarak ele alınmasına yol açmaktadır (Kalloniati vd., 2021).

1.3.4 İyi Huylu Deri Lezyonu

İyi Huylu Deri Lezyonu (İHDL), epidermiste gelişen iyi huylu deri oluşumlarını ifade etmektedir. Uluslararası Cilt Görüntüleme İş Birliği (UCGİB) 2018 veri kümesinde bu sınıf içerisinde balmumu görünümlü iyi huylu deri lezyonları, güneş lekeleri ve düz-pullu deri oluşumları yer almaktadır. Bu nedenle İHDL sınıfı yalnızca balmumu görünümlü iyi huylu keratinleşme lezyonu değil, iyi huylu farklı deri lezyonları türlerini içeren birleşik bir sınıf olarak değerlendirilmektedir. Bu lezyonlar genellikle kahverengi veya siyah renkli görülmekte ve bazı durumlarda melanom ile benzer özellikler gösterebilmektedir (Tschandl vd., 2018).

İHDL grubunda yer alan lezyonlar özellikle orta yaş ve ileri yaş bireylerde sık görülmektedir. İyi huylu epidermal deri lezyonları, en yaygın epidermal tümörlerden biri olarak kabul edilmekte ve görülme sıklığı yaşla birlikte artış göstermektedir. Özellikle kronik UV maruziyetine açık bölgelerde daha sık ortaya çıkmaktadır. Güneşe bağlı yaşlılık lekesi gibi lezyonlar da güneş hasarı ile ilişkili iyi huylu renkli deri lezyonları oluşumlar arasında değerlendirilmektedir (Hafner ve Vogt, 2008).

Dermoskopik incelemede beyaz küçük kistik yapılar, siyah nokta benzeri açıklıklar, çatlaklı yüzey yapısı ve beyin kıvrımını andıran görünüm dikkat çekmektedir. Her ne kadar iyi huylu bir lezyon olsa da bazı durumlarda melanom ile benzer görünüm gösterebildiğinden ayırıcı tanı önem taşımaktadır (Noiles ve Vender, 2008).

1.4 Teşhis Yöntemleri

Cilt kanserlerinde tanı süreci, şüpheli lezyonların klinik olarak değerlendirilmesiyle başlamakta ve lezyonların renk, sınır, simetri ile zaman içerisindeki değişim özelliklerinin incelenmesini kapsamaktadır. Klinik muayeneyi takiben kullanılan dermoskopi yöntemi, çıplak gözle görülemeyen pigment yapıları ve damar yapıları değerlendirilmesine olanak tanıyarak tanı doğruluğunu artırmaktadır. Dermoskopinin,

melanomun yanı sıra bazal hücreli ve skuamöz hücreli karsinomların ayırıcı tanısında da önemli katkı sağladığı bildirilmiştir (Tschandl vd., 2018).

Buna ek olarak, Optik Koherens Tomografi (OKT) cilt kanserlerinin teşhisinde kullanılan bir diğer cerrahi müdahale gerektirmeyen tanı yöntemidir. OKT, epidermis ve dermis tabakalarının yüksek çözünürlüklü kesitsel görüntülerini sağlayarak özellikle bazal hücreli karsinom ve aktinik keratoz gibi cilt lezyonların normal deriden ayırt edilmesine katkı sunmaktadır. Dermoskopik görüntüleme ile benzer yapısal bilgi sağlaması sayesinde OKT, biyopsi kararının zor olduğu durumlarda tamamlayıcı bir tanı aracı olarak değerlendirilmektedir. Bu yöntemin, erken evre cilt kanserlerinin saptanmasında ve lezyon sınırlarının belirlenmesinde klinik fayda sağladığı bildirilmektedir (Themstrup ve Jemec, 2016).

Reflektans Konfokal Mikroskop (RKM), deri lezyonlarının deri yüzeyine yakın katmanlarda, girişimsel olmayan şekilde ve anlık olarak incelenmesini sağlayan yüksek çözünürlüklü bir görüntüleme yöntemidir. Bu yöntem, deri dokusundan geri yansıyan ışığın değerlendirilmesine dayanmakta ve lezyonların hücresel ve yapısal özelliklerinin ayrıntılı olarak gözlemlenmesine olanak tanımaktadır. Özellikle MEL tanısında dermoskopi ek olarak kullanıldığında tanı doğruluğunu artırabildiği, iyi huylu ve kötü huylu lezyonların ayırt edilmesinde yardımcı olduğu ve gereksiz cerrahi işlemlerin azaltılmasına katkı sağlayabildiği bildirilmektedir. Bu nedenle RKM, cilt kanserlerinin erken tanısında destekleyici bir görüntüleme yöntemi olarak değerlendirilmektedir (Dinnes vd., 2018).

Geleneksel klinik muayene ve dermoskop yöntemleri, cilt kanserlerinin tanısında yaygın olarak kullanılmakta ve bu yaklaşımların tanısal doğruluğu büyük ölçüde klinisyen deneyimine bağlıdır ve gözlemciler arasında anlamlı değişkenlikler gösterebilmektedir (Tschandl vd., 2018). Özellikle erken evre melanom gibi görsel olarak ayırt edilmesi zor lezyonlarda bu durum tanısal belirsizliklere ve yanlış sınıflandırmalara yol açabilmektedir (Vestergaard vd., 2008). Bu sınırlılıkların aşılması amacıyla, dijital dermoskopik görüntülerin yaygınlaşması ile son yıllarda bu görüntülerin analizinde yapay zekâ ve derin öğrenme tabanlı yöntemler giderek daha fazla araştırılmaktadır (Brinker vd., 2019).

Bu kapsamda, bu tez çalışmasında dermoskopik görüntülerin sınıflandırılmasına yönelik olarak derin öğrenme mimarisi kullanılmış ve farklı model mimarilerinin tanısal performansları karşılaştırmalı olarak incelenmiştir. Çalışmanın deneysel sürecinde kamuya açık olan veri setlerinden UCGİB 2018 veri kümesindeki MEL, NV, BHK ve İHDL olmak üzere dört sınıfa odaklanılmıştır. Bu sınıfların tercih edilmesinin temel nedeni hem iyi huylu hem de kötü huylu deri lezyonlarını içermeleri ve klinik karar destek sistemleri açısından ayırt edilmeleri kritik öneme sahip lezyon tipleri olmalarıdır. Ayrıca diğer sınıflar veri kümesinde oldukça düşük örnek sayısına sahip olması, modelin öğrenme sürecini zorlaştırabilmekte ve genelleme performansını olumsuz etkileyebilmektedir. Diğer sınıflara kıyasla bu dört sınıfın daha yüksek örnek sayısına sahip olması model eğitiminin daha güvenilir şekilde yürütülmesine ve performans değerlendirmelerinin daha sağlıklı yapılmasına olanak sağlamıştır. Bu kapsamda, veri kümesindeki sınıf dengesizliğinin etkisini azaltmak amacıyla ağırlıklı rastgele örnekleme tekniğe başvurulmuş ve böylece derin öğrenme modellerinin farklı sınıflar üzerindeki performanslarının daha objektif olarak değerlendirilmesi sağlanmıştır.

2. LİTERATÜR TARAMASI

Bu bölümde, cilt kanseri ile ilgili çalışmaların karşılaştırılmasında özellikle UCGİB 2018 veri kümesini kullanan çalışmalara yer verilmiştir. Bu kapsamda literatür, Evrişimsel Sinir Ağları (ESA) tabanlı sınıflandırma çalışmaları, başarımı artırmaya yönelik farklı derin öğrenme stratejilerini içeren çalışmalar ve dönüştürücü tabanlı ya da hibrit model yapıları içeren çalışmalar olmak üzere üç temel başlık altında değerlendirilmiştir.

Harangi vd. (2020) çalışmalarında, çok sınıflı deri lezyonu sınıflandırmasını desteklemek amacıyla ESA tabanlı bir yaklaşım önermişlerdir. Çalışmada sınıfların iki ana grupta değerlendirilebilmesinden yararlanılarak ağın bir bölümü ikili sınıflandırma görevine, diğer bölümü ise çok sınıflı sınıflandırma görevine odaklanacak şekilde yapılandırılmıştır. Daha sonra ikili sınıflandırmadan elde edilen güven puanları çok sınıflı sınıflandırma çıktılarının düzenlenmesinde kullanılmıştır. Her iki görev için Google Net, Inception-v3 mimarileri kullanılmış ve yedi sınıflı dengeli veri kümesinde doğruluk metriğinde yaklaşık %7 oranında iyileşme elde etmişlerdir (Harangi vd., 2020).

Mahbod vd. (2020) çalışmalarında, öğrenim aktarımı tabanlı ESA modellerinde görüntü boyutunun sınıflandırma performansı üzerindeki etkisini incelemişlerdir. Çalışmada dermoskopik görüntüler farklı boyutlarda kırpılarak veya yeniden boyutlandırılarak EfficientNetB0, EfficientNetB1 ve SeReNeXt-50 mimarilerinin performansları analiz edilmiştir. Buna göre, yazarlar görüntü kırpma işleminin yeniden boyutlandırmaya göre daha başarılı sonuçlar verdiğini raporlamışlardır. Araştırmacılar ayrıca, farklı ölçeklerde eğitilen çoklu ESA mimarilerinin birleştirildiği çok ölçekli yapının sınıflandırma başarımını artırdığını bildirmişlerdir. Yazarların çalışması, görüntü ön işleme yöntemleri ile çok ölçekli model kullanımının sınıflandırma performansını iyileştirebileceğini göstermektedir (Mahbod vd., 2020).

Thwin ve Park (2024), VGG16, Inception-V3 ve ResNet-50 mimarilerini birleştiren topluluk tabanlı bir deri lezyonu sınıflandırma sistemi geliştirmişlerdir. Önceden eğitilmiş modellerin dermoskopik görüntüler üzerinde ince ayar yöntemiyle yeniden

eğitildiği çalışmada, model çıktıları ağırlıklı ortalama yöntemiyle birleştirilmiştir. Elde edilen bulgular, topluluk yaklaşımının tekil modellere göre daha başarılı sonuçlar verdiğini göstermiştir. Çalışmada, UCGİB 2018 veri kümesinde %91 doğruluk, aşırı örnekleme ile dengelenmiş veri kullanıldığında ise %97 doğruluk elde edildiği bildirilmiştir. Benzer şekilde kamuya açık olan 10.000 eğitim görüntüsü ile insan ve makine karşılaştırması veri kümesinde de özgün veri kümesi üzerinde %90, dengelenmiş veri kümesi üzerinde %96 doğruluk elde edilmiştir. Buna göre, yazarlar, topluluk öğrenmesi ve veri dengeleme işlemlerinin deri lezyonu sınıflandırma performansı üzerinde olumlu etkiler oluşturduğunu belirtmişlerdir (Thwin ve Park, 2024).

Kassani ve Kassani (2019), dermoskopik görüntüler üzerinden cilt lezyonu sınıflandırmasına yönelik karşılaştırmalı bir çalışma gerçekleştirmişlerdir. Yazarlar, çalışmalarında görüntü kalitesini iyileştirmek amacıyla aydınlatma düzeltmesi, karşıtlık artırma ve görüntüdeki istenmeyen yapıların temizlenmesi gibi ön işleme yöntemlerinden yararlanmışlardır. Ayrıca sınıf dengesizliğinin etkisini azaltmak ve aşırı uyumu önlemek amacıyla yatay ve dikey çevirme, rastgele karşıtlık ve rastgele parlaklık gibi veri artırma teknikleri kullanmışlardır. Farklı ESA mimarilerinin karşılaştırıldığı çalışmada, ResNet50 mimarisinin %92,08 doğruluk ve %92,74 Makro F1 ölçümü ile Alex Net, Xception, VGG16 ve VGG19 mimarilerine göre daha başarılı sonuçlar sunduğu bildirilmiştir. Yazarlar, uygun ön işleme ve veri artırma yöntemleri ile birlikte derin ESA mimarilerinin deri lezyonu sınıflandırmasında etkili bir performans sunduğunu rapor etmişlerdir (Kassani ve Kassani, 2019).

Tsai vd. (2023), deri lezyonu sınıflandırmasında sınıf dengesizliği problemini ele alan bir yaklaşım önermişlerdir. Yazarlar, çalışmalarında kötü huylu lezyonlara ait görüntülerin daha sınırlı sayıda olması nedeniyle oluşan veri dengesizliğinin derin öğrenme modellerini baskın sınıflara yöneltebildiğini vurgulamışlardır. Bu sorunu azaltmak amacıyla yazarlar, veri artırma, veri dengeleme ve çoklu model topluluğu temelli bir yöntem geliştirmişlerdir. İlk aşamada üretici çekişmeli ağlar kullanılarak oluşturulan yeni görüntüler sınıflar arasındaki örnek sayısını dengelemek amacıyla kullanılmıştır. Sonraki aşamada ise farklı çözünürlüklerde dengelenmiş verilerle eğitilen derin sinir ağı modellerinin çıktıları birleştirilmiştir. Elde edilen sonuçlara

göre yazarların önerdikleri yöntem, UCGİB 2018 test kümesinde ortalama %82,1 duyarlılık sunmuştur. Buna göre, yazarlar çalışmalarında sınıf dengesizliğini azaltmaya yönelik veri üretimi ve topluluk öğrenmesi stratejilerinin deri lezyonu sınıflandırma performansını artırabileceğini göstermişlerdir (Tsai vd., 2023).

Hosny vd. (2020), UCGİB 2018 veri kümesi üzerinde önceden eğitilmiş AlexNet mimarisi kullanarak yedi sınıflı cilt lezyonu sınıflandırması gerçekleştirmişlerdir. Yazarlar, çalışmalarında bu mimarinin son katmanlarını yeniden düzenlemiş ve %98,70 doğruluk, %95,60 duyarlılık, %99,27 özgüllük ve %95,06 kesinlik değerlerine ulaştıklarını bildirmişlerdir (Hosny vd., 2020).

AbuAlkebash vd. (2025) çalışmalarında, cilt kanserinin çok sınıflı otomatik tespiti ve sınıflandırılması amacıyla evrişimsel ve dönüştürücü tabanlı hibrit modelleri incelemişlerdir. Çalışmada, lezyon bölgesine odaklanmayı sağlamak amacıyla dermoskopik görüntüler YOLOv8 modeli ile ön işleme tabi tutulmuştur. Ayrıca veri artırma yöntemleri kullanılarak veri kümesi dengelenmiş ve sekiz farklı önceden eğitilmiş model üzerinde yeniden eğitim işlemi gerçekleştirilmiştir. Yazarlar, önerdikleri YOLOv8 ve ViT dönüştürücü modele sahip hibrit yaklaşımın en yüksek performansı sunduğunu bildirmişlerdir. Bunun yanında, yazarlar Gradyan Ağırlıklı Sınıf Aktivasyon Haritalama ve Shapley Tabanlı Açıklama yöntemlerini kullanarak modelin karar mekanizması açıklanabilir hale getirmiş ve klinik kullanım açısından güvenilirliğin artırılmasını amaçlamışlardır (AbuAlkebash vd., 2025).

Selvi ve Shalome (2025) çalışmalarında, melanomun erken teşhisinin hayati öneme sahip olduğunu ve görsel incelemeye dayalı tanı süreçlerinin hata riski taşıdığını vurgulamışlardır. Bu doğrultuda araştırmacılar, Optimal Kaba Küme Yaklaşımı (OKKY) kayıp fonksiyonu ile güçlendirilmiş optimize bir ESA modeli önermişlerdir. Önerilen yaklaşımın, gereksiz öznitelikleri eleyerek lezyon sınırlarına daha etkin şekilde odaklandığı ve böylece sınıflandırma doğruluğunu artırdığı bildirilmiştir. Yapılan karşılaştırmalı deneylerde, OKKY tabanlı yaklaşımın LeNet5, AlexNet, VGG16, InceptionV3, ResNet50, Xception ve Inception-ResNetV2 gibi farklı ESA mimarilerine entegre edilmesiyle performansın belirgin şekilde iyileştiği gösterilmiştir. Ayrıca modelin melanomun 1., 2. ve 3. evrelerinde %98–99 doğruluk

değerlerine ulaştığı ve erken teşhis açısından güçlü bir klinik potansiyel sunduğu bildirilmiştir (Selvi ve Shalome, 2025).

Nie vd. (2022) çalışmalarında, dermoskopik görüntülerden cilt lezyonu sınıflandırması için ESA ve dönüştürücü mimarilerini birleştiren hibrit bir derin öğrenme modeli önermişlerdir. Yazarlar en iyi sonuçların hibrit model ile odak kaybı fonksiyonunun birlikte kullanıldığı senaryoda elde edildiğini ve yaklaşık %89,5 genel doğruluk ile %89,09 ağırlıklı Makro F1 skoru elde ettiklerini bildirmişlerdir. Bu bulgular, UCGİB 2018 gibi sınıf dengesizliğinin belirgin olduğu veri kümelerinde yalnızca model mimarisinin değil, aynı zamanda kullanılan kayıp fonksiyonunun da performans üzerinde belirleyici bir etkiye sahip olduğunu göstermektedir (Nie vd., 2022).

Tang vd. (2024) çalışmalarında, UCGİB 2018 veri kümesi üzerinde yedi sınıflı cilt lezyonu sınıflandırması için Swin dönüştürücü ve küresel dikkat mekanizmasına dayalı hafif bir model olan SkinSwinViT yaklaşımını önermişlerdir. Elde edilen bulgulara göre yazarların önerdikleri model, %97,88 doğruluk, %97,55 duyarlılık, %97,83 kesinlik, %99,36 özgüllük ve %97,79 Makro F1 skoru ile oldukça yüksek bir performans sergilemiştir. Bu sonuçlar, Swin dönüştürücü tabanlı hafif mimarilerin UCGİB 2018 gibi çok sınıflı dermoskopik görüntü veri kümelerinde oldukça etkili sonuçlar üretebildiğini göstermektedir (Tang vd., 2024).

Himel vd. (2024) çalışmalarında, cilt kanseri sınıflandırması için dönüştürücü tabanlı bir yaklaşım önermişlerdir. Çalışmada 10.000 eğitim görüntüsü ile insan ve makine karşılaştırması veri kümesi kullanılmış, görüntülere normalizasyon ve veri artırma işlemleri uygulanmıştır. Ayrıca genel amaçlı görüntü bölütleme modeli ile lezyon bölgeleri bölütlenmiş ve sınıflandırma aşamasında farklı önceden eğitilmiş görsel dönüştürücü modeller değerlendirilmiştir. Yazarlar, Google ViT patch-32 modeli ile %96,15 doğruluk elde ettiklerini bildirmişlerdir. Bu bulgular, dönüştürücü tabanlı modellerin cilt kanseri sınıflandırmasında etkili sonuçlar verebildiğini göstermektedir (Himel vd., 2024).

Yang vd. (2023) çalışmalarında, UCGİB 2018 ve UCGİB 2019 veri kümeleri üzerinde dönüştürücü mimarili bir cilt kanseri sınıflandırma yaklaşımı geliştirmişlerdir.

Yazarlar önerdikleri ViTfSCD-L ve ViTfSCD-B modelleri ile sırasıyla %94,1 ve %91,4 genel doğruluk değerleri elde etmişlerdir (Yang vd., 2023).

Li vd. (2025) çalışmalarında, UCGİB 2018 veri kümesi üzerinde çoklu dikkat mekanizmasına sahip dönüştürücü mimarili hibrit bir model olan HyperFusion-Net yaklaşımını tanıtmışlardır. Yazarlar, çalışmalarında %93,24 doğruluk, %92,41 duyarlılık ve %94,15 özgüllük değerlerine ulaştıklarını bildirmişlerdir. Bu sonuçlar, dönüştürücü içeren hibrit yaklaşımların UCGİB 2018 veri kümesi üzerinde yüksek başarı sağlayabildiğini göstermektedir (Li vd., 2025).

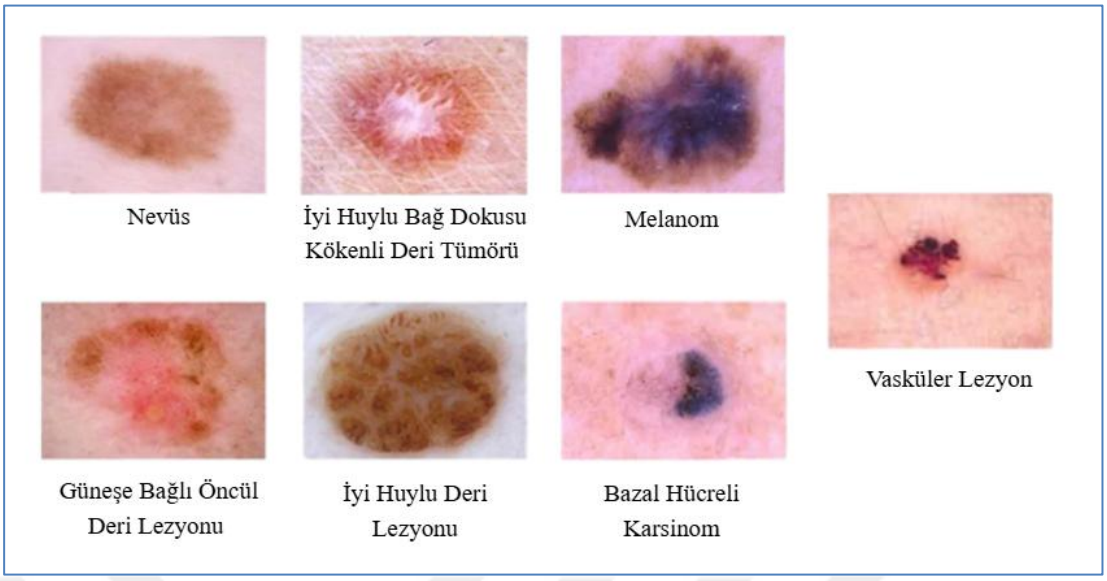
3. MATERYAL ve YÖNTEM

3.1 Veri Kümesi

Cilt kanserinin erken teşhisinin klinik öneminden dolayı tanı yöntemlerinin doğruluğunu ve uygulanabilirliğini artırmaya yönelik araştırmalar son yıllarda hız kazanmıştır. Bu doğrultuda, UCGİB tarafından 2016 ve 2017 yıllarında Uluslararası Biyomedikal Görüntüleme Sempozyumu (UBGS) kapsamında, dermoskopik görüntüler üzerinde MEL tespitine yönelik ilk açık erişimli karşılaştırmalı değerlendirme organizasyonları gerçekleştirilmiştir. Bu girişimler, dermoskopik görüntü analizinde standart veri kümeleri ve ortak değerlendirme ölçütlerinin yaygınlaşmasına önemli katkı sağlamıştır (Guy vd., 2015).

UCGİB 2018 veri kümesi, 2018 yılında Tıbbi Görüntü Hesaplama ve Bilgisayar Destekli Girişimler konferansı kapsamında düzenlenen "Melanom Tespiti için Cilt Lezyonu Analizi" yarışması çerçevesinde oluşturulmuştur. Veri kümesi; lezyon bölütleme, dermoskopik özelliklerin belirlenmesi ve hastalık sınıflandırması olmak üzere üç temel görevi kapsayan geniş ölçekli bir yapı içermektedir. Yarışma sürecinde eğitim ve test amacıyla on binlerce dermoskopik görüntünün araştırmacıların kullanımına açılması UCGİB 2018 veri kümesinin deri lezyonu analizi alanında yaygın olarak kullanılan önemli bir başvuru kaynağı haline gelmesini sağlamıştır (Codella vd., 2019).

Bu veri kümesi, 10.015 dermoskopik görüntüden oluşmakta olup Melanom (MEL), Nevüs (NV), Bazal Hücreli Karsinom (BHK), Güneşe Bağlı Öncül Deri Lezyonu (GBÖDL), İyi Huylu Deri Lezyonu (İHDL), İyi Huylu Bağ Dokusu Kökenli Deri Tümörü (İHBDKDT) ve Vasküler Lezyon (VL) olmak üzere yedi farklı cilt lezyonu sınıfını içermektedir (Codella vd., 2019). Şekil 3.1'de her bir sınıfa ait örnek görseller yer alırken Tablo 3.1'de her bir sınıftaki örnek sayısı özetlenmektedir.



Şekil 3.1 UCGİB 2018 Veri kümesindeki cilt lezyonu türlerine ait örnek görüntüler (ISIC, 2018)

Tablo 3.1 UCGİB 2018 veri kümesi sınıf dağılımı

Sınıf	**Açıklama**	**Görüntü Sayısı**
MEL	Melanom	1.113
NV	Nevüs	6.705
BHK	Bazal Hücreli Karsinom	514
GBÖDL	Güneşe Bağlı Öncül Deri Lezyonu	327
İHDL	İyi Huylu Deri Lezyonları	1.099
İHBDKDT	İyi Huylu Bağ Dokusu Kökenli Deri Tümörü	115
VL	Vasküler Lezyon	142
	Toplam	**10.015**

Tablo 3.1'de görüldüğü üzere, UCGİB 2018 veri kümesinde sınıflar arasında belirgin bir dengesizlik bulunmaktadır. Özellikle NV sınıfı veri kümesinin büyük bir bölümünü oluştururken, İHBDKDT ve VL gibi bazı sınıflar oldukça düşük örnek sayısına sahiptir. Bu dengesiz örnek dağılımı bir derin öğrenme modelinin eğitim sürecinde çoğunluk sınıfa yönelme riskini artırmakta ve sınıflandırma performansını olumsuz etkileyebilmektedir. Bu nedenle, bu tez çalışmasında daha başarılı bir deneysel çalışma gerçekleştirebilmek amacıyla bu veri kümesindeki yedi sınıf arasından MEL, BHK, NV ve İHDL sınıflarının yer aldığı dört sınıflı bir veri kümesi oluşturulmuştur.

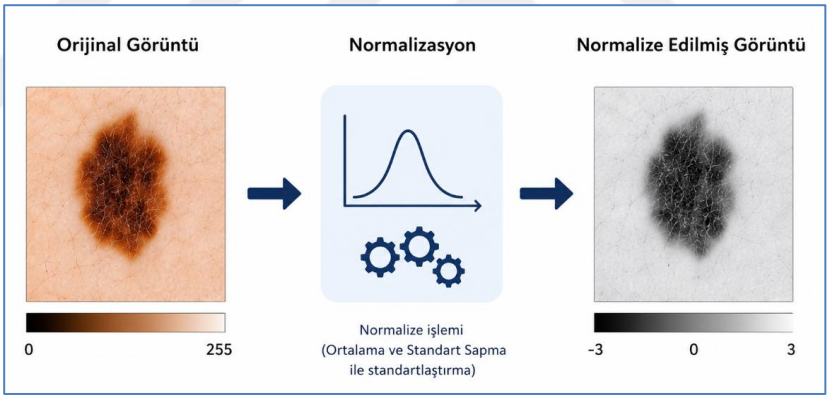
3.2 Veri Ön İşleme

Veri ön işleme, derin öğrenme modelleri tarafından ham verilerin işlenebilir ve daha verimli öğrenilebilir hale getirilmesi amacıyla uygulanan işlemler bütünüdür.

Özellikle görüntü işleme ve derin öğrenme çalışmalarında veri ön işleme adımları, model performansını doğrudan etkileyen önemli süreçler arasında yer almaktadır (Shorten ve Khoshgoftaar, 2019). Bu tez çalışmasında standardizasyon, görüntü yeniden boyutlandırma, görüntü dönüşümleri ve görüntü alt kümelerinin oluşturulması işlemlerinden oluşan veri ön işleme ve hazırlık adımları uygulanmıştır.

3.2.1 Standardizasyon

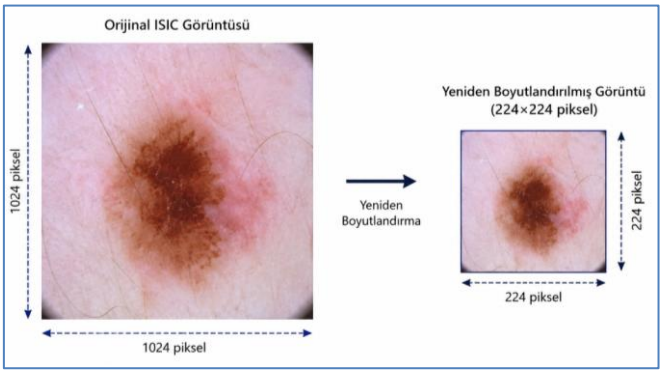
Piksel değerlerinin belirli bir dağılıma dönüştürülerek bir derin öğrenme modelinin eğitimine katkı sağlanması amaçlanır. Bu doğrultuda, Şekil 3.2'de orijinal dermoskopik görüntüsü üzerinde ortalama ve standart sapma değerleri kullanılarak standardizasyon işlemi yer almaktadır. Bu işlem ile görüntüler arasındaki parlaklık ve kontrast farklılıklarının azaltılması, bir derin öğrenme modelinin daha etkili özellikleri öğrenmesi ve eğitim sürecinin kararlılığının artırılması amaçlanmaktadır.



Şekil 3.2 Dermoskopik görüntülere uygulanan standardazisyon işlemi (ISIC, 2018)

3.2.2 Görüntü Yeniden Boyutlandırma

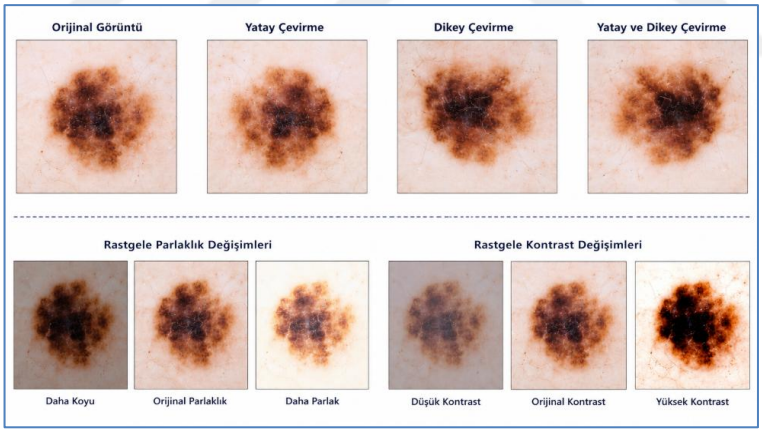
Tüm görüntülerin deneysel çalışmalarda yer verilen herhangi bir model için uygun girdi boyutuna ve çözünürlüğe dönüştürülmesi işlemidir. Şekil 3.3'te, farklı bir çözünürlükteki orijinal UCGİB görüntüsünün derin öğrenme modeli girişine uygun hale getirilmesi amacıyla yeniden boyutlandırılması gösterilmiştir.



Şekil 3.3 Dermoskopik görüntülerin yeniden boyutlandırılması işlemi (ISIC, 2018)

3.2.3 Görüntü Dönüştürme

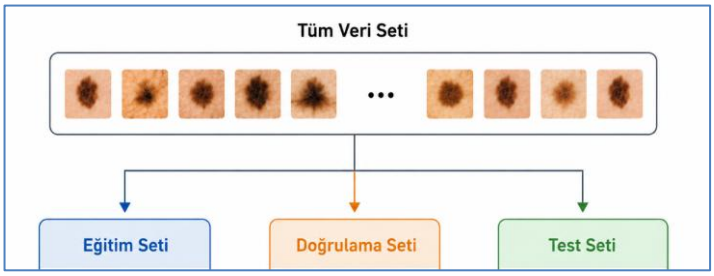
Görüntü dönüştürme, görüntüler üzerinde çeşitli işlemler uygulanarak görüntü çeşitliliğinin artırılmasını sağlayan bir ön işleme yaklaşımıdır. Şekil 3.4'te dermoskopik görüntülere uygulanan görüntü dönüşümleri gösterilmektedir. Bu işlemler, modellerin farklı görüntü koşullarına uyum sağlayabilmesi ve genelleme yeteneğinin geliştirilmesi amacıyla uygulanmıştır.



Şekil 3.4 Dermoskopik görüntüler üzerinde uygulanan görüntü dönüştürme yöntemleri (ISIC, 2018)

3.2.4 Verilerin Alt Kümelere Ayrılması

Veri kümesinin eğitim, doğrulama ve test alt kümelerine ayrılması işlemidir. Şekil 3.5'de dermoskopik görüntülerden oluşan veri kümesinin eğitim, doğrulama ve test alt kümelerine ayrılması gösterilmektedir. Bu işlem sayesinde derin öğrenme modellerinin daha güvenilir, kararlı ve başarılı şekilde eğitilmesi amaçlanmaktadır.

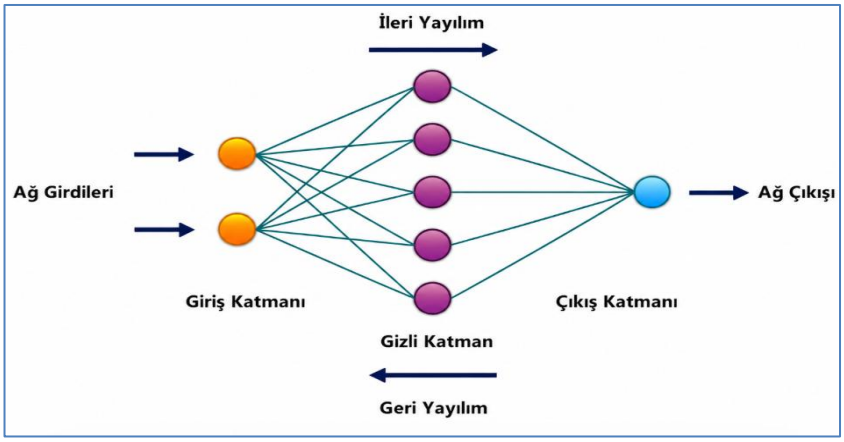


Şekil 3.5 Veri kümesinin eğitim, doğrulama ve test alt kümelerine ayrılması (ISIC, 2018)

3.3 Derin Öğrenme

Yapay sinir ağları, biyolojik sinir sisteminin çalışma prensibinden esinlenerek geliştirilen ve giriş verileri arasındaki ilişkileri matematiksel olarak modelleyebilen hesaplama yapılarıdır. Bu yapılar, sinir hücrelerinin uyarılma ve baskılanma davranışlarının mantıksal bir çerçevede temsil edilmesine dayanmakta olup, bilgi işleme sürecinin sayısal olarak modellenmesine imkan tanımaktadır (McCulloch ve Pitts, 1943).

Şekil 3.6'da çok katmanlı yapay sinir ağı yapısı gösterilmektedir. Bu çok katmanlı sinir ağı yapısı, giriş katmanı, gizli katmanlar ve çıkış katmanından oluşmaktadır. Şekilde ayrıca giriş verilerinin ağ boyunca iletildiği ileri yayılım ve hata bilgisinin geriye aktarılarak ağırlıkların güncellendiği geri yayılım süreçleri gösterilmektedir. Derin öğrenme mimarilerinde de yer alan bu yapı veri içerisindeki karmaşık örüntüleri öğrenmesini sağlayan sınıflandırma katmanı olarak adlandırılır.



Şekil 3.6 Çok katmanlı yapay sinir ağı yapısı (McCulloch ve Pitts, 1943)

Çok katmanlı yapay sinir ağlarına ilişkin çalışmaların temelleri 1960'lı ve 1970'li yıllara kadar uzanmaktadır. Bununla birlikte, derin yapay sinir ağlarının eğitimi uzun yıllar boyunca çeşitli zorluklar nedeniyle sınırlı kalmıştır. Özellikle çok katmanlı ağlarda hata bilgisinin katmanlar boyunca etkin şekilde aktarılmasındaki güçlükler derin modellerinin yaygın olarak kullanılmasının önüne geçmiştir. Ancak büyük veri kümelerinin kullanılabilir hâle gelmesi ve hesaplama gücündeki artışlar sayesinde derin öğrenme yöntemleri yeniden önem kazanmıştır. Günümüzde derin öğrenme modelleri, görüntü işleme, konuşma tanıma ve doğal dil işleme gibi birçok alanda geleneksel makine öğrenmesi yöntemlerine göre üstün performans sergileyerek yapay zekâ araştırmalarının en önemli çalışma alanlarından biri hâline gelmiştir (Schmidhuber, 2015).

Derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla verilerden hiyerarşik temsiller öğrenmeyi amaçlayan bir makine öğrenmesi yaklaşımıdır. Bu yaklaşımda, her bir katman bir önceki katmandan aldığı temsili daha soyut ve ayırt edici bir biçime dönüştürmektedir. Özellikle görüntü verilerinde ilk katmanlar kenar ve köşe gibi düşük seviyeli özellikleri öğrenirken, daha derin katmanlar nesne parçaları ve anlamlı görsel örüntüler gibi yüksek seviyeli temsilleri modelleyebilmektedir. Bu özellik, derin öğrenmenin geleneksel makine öğrenmesi yöntemlerine kıyasla ham veriler üzerinde daha başarılı sonuçlar üretmesini sağlamaktadır (LeCun vd., 2015).

Derin öğrenme yöntemlerinin temel avantajlarından biri, özellik çıkarım sürecinin insan müdahalesi ile olarak tasarlanmasına ihtiyaç duymadan veriye dayalı olarak otomatik biçimde öğrenilebilmesidir. Bu durum, özellikle görüntü ve sinyal işleme gibi yüksek boyutlu veri içeren problemlerde önemli bir üstünlük sağlamaktadır. Geriye yayılım algoritması ve gradyan tabanlı optimizasyon yöntemleri sayesinde ağ parametreleri hata fonksiyonunu en aza indirecek şekilde güncellenmekte ve modelin genelleme yeteneği artırılmaktadır (LeCun vd., 2015).

3.3.1 Öğrenim Aktarımı

Öğrenim aktarımı, farklı görevler veya veri kümeleri arasında bilgi aktarımını sağlayan bir öğrenme yaklaşımı olarak tanımlanır. Araştırmacılar, özellikle hedef veri

kümesinde yeterli etiketli veri bulunmadığı durumlarda öğrenim aktarımının model performansını artırabildiğini ve eğitim maliyetlerini azaltabildiğini belirtmişlerdir (Pan ve Yang, 2010).

İnce ayar yöntemi, önceden eğitilmiş bir modelin hedef veri kümesine uyarlanabilmesi amacıyla yeniden eğitilmesi işlemidir. Bu yaklaşım sayesinde model, daha önce öğrenmiş olduğu genel özellikleri korurken hedef probleme özgü özellikleri de öğrenebilmektedir (Yosinski vd., 2014).

3.3.2 Ağırlıklı Rastgele Örnekleme

Ağırlıklı Rastgele Örnekleme (ARÖ), sınıf dengesizliğinin olduğu veri kümelerinde az temsil edilen sınıfların eğitim sürecinde normal dağılıma kıyasla daha çok seçilmesini sağlayan bir örnekleme yöntemidir. Bu yöntemde her örneğin seçilme olasılığı ait olduğu sınıfın örnek sayısına göre belirlenmekte ve az sayıdaki sınıflara daha yüksek örnekleme ağırlığı verilmektedir. Sonuç olarak eğitim sürecinde sınıflar arasındaki temsil dengesinin artırılması amaçlanmakta ve modelin çoğunluk sınıflara yönelme eğilimi azaltılmaktadır (Efraimidis ve Spirakis, 2006).

Denklem 3.1'de örnekleme ağırlıkları, her sınıftaki örnek sayısının tersi alınarak hesaplanmaktadır.

$$wc = \frac{1}{nc} \tag{3.1}$$

Burada wc, c sınıfına ait örnekleme ağırlığını, nc ise ilgili sınıftaki örnek sayısını göstermektedir. Bu ağırlıklar kullanılarak her bir görüntü için örnekleme ağırlığı atanmakta ve eğitim sırasında örneklerin seçilme olasılıkları belirlenmektedir. Bir görüntüye ait örnekleme ağırlığı Denklem 3.2'de verilmiştir. Burada wi, görüntüye ait örnekleme ağırlığını, yi görüntünün ait olduğu sınıfı ve nyi ise ilgili sınıftaki örnek sayısını ifade etmektedir.

$$wi = \frac{1}{nyi} \tag{3.2}$$

3.3.3 Çapraz Entropi Kayıp Fonksiyonu

Çapraz Entropi (ÇE), çok sınıflı sınıflandırma problemlerinde yaygın olarak kullanılan bir kayıp fonksiyonudur. Bu yöntem, model tarafından tahmin edilen olasılık dağılımı ile gerçek sınıf etiketleri arasındaki farkı ölçmektedir. Kayıp değeri, modelin doğru sınıfa verdiği olasılık arttıkça azalmakta, yanlış sınıflara verdiği olasılık arttıkça yükselmektedir. Bu sayede eğitim sürecinde model parametreleri güncellenerek gerçek sınıf etiketlerine daha yakın tahminler üretilmesi amaçlanmaktadır. ÇE kaybı, derin öğrenme tabanlı görüntü sınıflandırma uygulamalarında etkin ve kararlı sonuçlar sağlaması nedeniyle yaygın olarak tercih edilmektedir (Zhang ve Sabuncu, 2018).

Denklem 3.3'de ÇE formülü verilmiştir. Burada L çapraz entropi kaybını, C sınıf sayısını, yi gerçek sınıf etiketini, $y\hat{i}$ ise model tarafından ilgili sınıf için üretilen olasılık değerini göstermektedir. Kayıp değeri küçüldükçe model tahminlerinin gerçek sınıflara daha yakın olduğu kabul edilmektedir.

$$L = \sum_{i=1}^{C} yi \; log(y\hat{i}) \tag{3.3}$$

3.3.4 En İyileme Yöntemleri

3.3.4.1 Uyarlanabilir moment tahmini

Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation, Adam), derin öğrenme modellerinin eğitiminde yaygın olarak kullanılan bir en iyileme yöntemidir. Bu yöntem, gradyanların birinci momentini ve ikinci momentini birlikte kullanarak her parametre için uyarlanabilir öğrenme oranları oluşturmaktadır. Bu sayede model parametreleri eğitim sürecinde daha kararlı ve hızlı bir şekilde güncellenebilmekte, özellikle büyük veri kümeleri ve yüksek boyutlu parametre uzaylarında etkili sonuçlar elde edilmektedir. Ayrıca bu yöntem, seyrek gradyanlar ve gürültülü optimizasyon problemlerinde başarılı performans göstermesi nedeniyle derin öğrenme uygulamalarında yaygın olarak tercih edilmektedir (Kingma ve Ba, 2014).

3.3.4.2 Ağırlık azaltmalı uyarlanabilir moment tahmini

Ağırlık Azaltmalı Uyarlanabilir Moment Tahmini (Adaptive Moment Estimation with Decoupled Weight Decay, AdamW), Adam optimizasyon algoritmasının geliştirilmiş bir sürümüdür. Bu yöntemde ağırlık azaltma işlemi, parametre güncelleme mekanizmasından ayrılarak bağımsız şekilde uygulanmaktadır. Böylece model parametreleri daha etkili biçimde düzenlileştirilmekte, aşırı öğrenme eğilimi azaltılmakta ve genelleme performansı artırılmaktadır. AdamW en iyileme yöntemi, özellikle derin öğrenme ve dönüştürücü tabanlı modellerde daha kararlı bir eğitim süreci sağlaması ve daha yüksek sınıflandırma başarımı sunması nedeniyle yaygın olarak tercih edilmektedir (Loshchilov ve Hutter, 2017).

3.3.5 Öğrenme Oranı

3.3.5.1 Kosinüs tabanlı öğrenme oranı

Kosinüs tabanlı öğrenme oranı, eğitim sürecinde öğrenme oranını kosinüs fonksiyonuna bağlı olarak kademeli şekilde azaltan bir yöntemdir. Bu yaklaşımda eğitim başlangıcında yüksek öğrenme oranı kullanılırken eğitim ilerledikçe öğrenme oranı düşürülerek model parametrelerinin daha kararlı ve hassas biçimde güncellenmesi sağlanmaktadır (Loshchilov ve Hutter, 2016).

Bu yöntemde, öğrenme oranının hesaplanmasında kullanılan matematiksel ifade Denklem 3.4'te verilmiştir. Burada n_t mevcut öğrenme oranını, n_{max} başlangıç öğrenme oranını, n_{min} minimum öğrenme oranını, T_{tur} mevcut eğitim turu sayısını ve $Tmax$ maksimum toplam eğitim turu sayısını ifade etmektedir.

$$n_t = n_{min} + \frac{1}{2}(n_{max} - n_{min})(1 + \cos\left(\frac{T_{tur}}{T_{max}}\pi\right)) \tag{3.4}$$

3.3.5.2 Başarıma bağlı öğrenme oranı azaltma

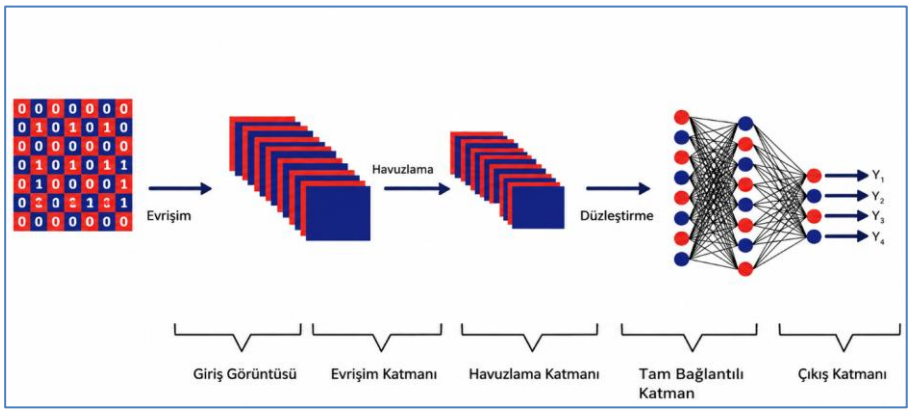
Başarıma bağlı öğrenme oranı azaltma, modelin doğrulama performansını izleyerek öğrenme oranını dinamik olarak ayarlayan bir öğrenme oranı yöntemidir. Bu yaklaşımda, belirlenen performans ölçütünde belirli bir süre boyunca iyileşme

gözlenmediğinde öğrenme oranı otomatik olarak azaltılmaktadır. Böylece eğitim sürecinin ilerleyen aşamalarında parametre güncellemelerinin daha hassas şekilde yapılması sağlanmakta, modelin optimum çözüme daha kararlı biçimde yakınsaması desteklenmektedir. Ayrıca bu yöntem, sabit öğrenme oranı kullanımına kıyasla daha etkili bir eğitim süreci sunarak modelin genelleme performansını artırabilmektedir (Ruder, 2016).

3.4 Evrişimsel Sinir Ağları

Evrişimsel Sinir Ağları (ESA), görüntü verilerinden otomatik özellik çıkarımı yapabilme yeteneği sayesinde derin öğrenme tabanlı görüntü analizi çalışmalarında yaygın olarak tercih edilmektedir. ESA mimarileri, özellikle iki boyutlu görüntülerdeki uzamsal yapıyı ve yerel örüntüleri etkin biçimde öğrenebilme özellikleri sayesinde medikal görüntü analizi alanında önemli başarılar elde etmiştir. Geleneksel makine öğrenmesi yöntemlerinden farklı olarak ESA mimarileri, el yapımı tasarlanmış özelliklere ihtiyaç duymadan, ham piksel verilerinden ayırt edici özellikleri otomatik olarak öğrenebilmektedir. Bu özellik, ESA tabanlı yaklaşımların dermatoloji gibi karmaşık görsel varyasyonların bulunduğu alanlarda yaygın olarak tercih edilmesini sağlamıştır (Litjens vd., 2017).

Şekil 3.7'de ESA mimarisinin genel yapısı gösterilmektedir. Bu mimariler, giriş görüntüsü, evrişim katmanı, havuzlama katmanı, tam bağlantılı katman ve çıkış katmanından oluşmaktadır. Şekilde görüldüğü üzere giriş görüntüsü üzerinde ilk olarak evrişim işlemleri uygulanarak görüntüye ait kenar, doku ve şekil gibi ayırt edici özellikler çıkarılmaktadır. Ardından havuzlama katmanı ile özellik haritalarının boyutu azaltılarak hesaplama yükü düşürülmekte ve önemli özelliklerin korunması sağlanmaktadır. Elde edilen özellikler düzleştirme işlemi sonrasında tam bağlantılı katmanlara aktarılmakta ve son aşamada çıkış katmanında sınıflandırma işlemi gerçekleştirilmektedir.



Şekil 3.7 Evrişimsel sinir ağı mimarisinin genel yapısı (Litjens vd., 2017)

Evirişim katmanları, ESA mimarilerinin temel yapı taşını oluşturmaktadır. Bu katmanlarda, giriş görüntüsü üzerinde küçük boyutlu filtreler kaydırılarak evrişim işlemi uygulanmakta ve farklı özellik haritaları elde edilmektedir. Ağırlık paylaşımı prensibi sayesinde, aynı filtrenin tüm görüntü üzerinde uygulanması sağlanarak parametre sayısı önemli ölçüde azaltılmakta ve modelin genellenebilirliği artırılmaktadır (Litjens vd., 2017). Dermoskopik görüntü analizinde ise bu katmanlar, lezyon sınırları, asimetrik yapılar ve düzensiz pigment dağılımları gibi cilt kanseri açısından önemli görsel özelliklerin otomatik olarak öğrenilmesini sağlamaktadır (Esteva vd., 2017).

Havuzlama katmanı, ESA mimarilerinin evrişim katmanlarından elde edilen özellik haritalarının uzamsal boyutunu azaltmak amacıyla kullanılan temel yapılardan biridir. Bu katman, özellik haritalarındaki en önemli bilgileri korurken genişlik ve yükseklik boyutlarını küçülterek işlem yükünü azaltmakta ve modelin daha kararlı öğrenmesini sağlamaktadır. Havuzlama işlemi sırasında özellik haritası üzerinde belirli boyutlardaki filtreler kaydırılarak ilgili bölgelerdeki özellikler özetlenmektedir. Dermoskopik görüntü analizinde ise havuzlama katmanları, lezyon sınırları, pigment dağılımı ve doku örüntüleri gibi ayırt edici özelliklerin farklı çözünürlük seviyelerinde daha tutarlı temsil edilmesine katkı sağlamaktadır (Esteva vd., 2017).

Tam bağlantılı katmanlar, evrişim ve havuzlama katmanları aracılığıyla çıkarılan yüksek seviyeli özelliklerin sınıflandırma amacıyla birleştirildiği ESA mimarisinin son aşamasını oluşturmaktadır. Bu katmanlarda her nöron bir önceki katmandaki tüm nöronlarla bağlantılı olup elde edilen özellikler doğrusal dönüşümler ve aktivasyon

fonksiyonları aracılığıyla sınıf olasılıklarına dönüştürülmektedir (LeCun vd., 2015). Dermoskopik görüntü analizinde tam bağlantılı katmanlar, lezyonlara ait renk, doku ve şekil özelliklerinin bütüncül biçimde değerlendirilmesini sağlayarak cilt lezyonlarının daha doğru şekilde sınıflandırılmasına katkı sağlamaktadır (Esteva vd., 2017).

Sınıf olasılıklarını hesaplayan aktivasyon fonksiyonu, çok sınıflı sınıflandırma problemlerinde model çıktılarının her bir sınıfı temsilen olasılık değerlerine dönüştürülmesini sağlar. Diğer bir deyişle bu fonksiyon, çıkış katmanındaki her bir sınıfa ait skorları toplamı 1 olacak şekilde olasılık dağılımına dönüştürmektedir. Böylece model, giriş görüntüsünün hangi sınıfa ait olduğunu en yüksek olasılık değerine göre tahmin edebilmektedir (Banerjee vd., 2021).

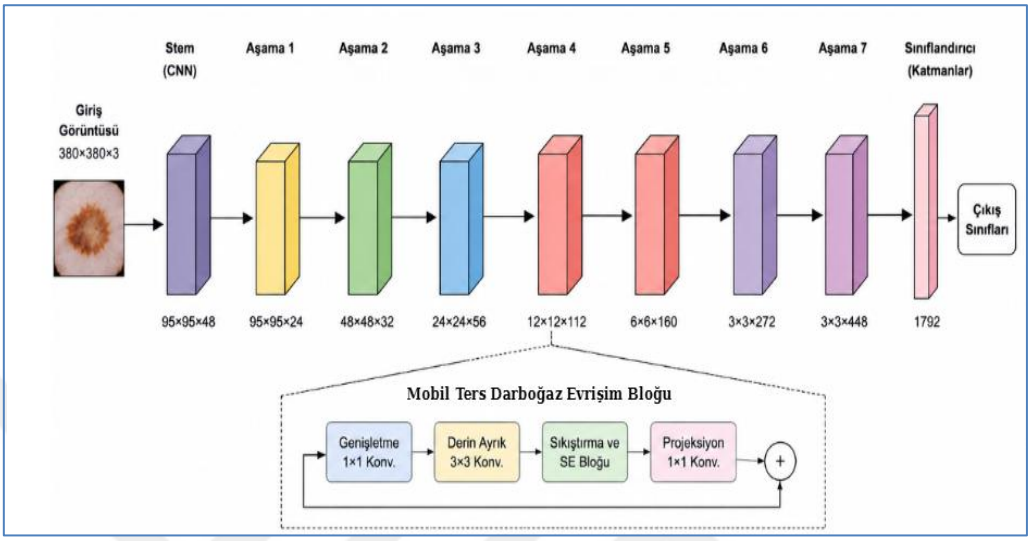
3.4.1 EfficientNet-B4 Mimarisi

EfficientNet mimarisi, ağ derinliği, ağ genişliği ve giriş görüntü çözünürlüğünü birlikte ölçeklendiren bileşik ölçekleme yaklaşımını kullanmaktadır. Bu yaklaşım sayesinde model, daha az parametre kullanmasına rağmen yüksek sınıflandırma performansı sağlayabilmektedir. EfficientNet-B4, doğruluk ile hesaplama maliyeti arasındaki dengeyi iyileştirmek amacıyla geliştirilen ESA bir derin öğrenme mimarisidir (Tan ve Le, 2019).

EfficientNet-B4 mimarisi, dermoskopik görüntülerde lezyon sınırları, pigment dağılımları, renk değişimleri ve doku örüntüleri gibi ayırt edici özelliklerin öğrenilmesinde etkili sonuçlar sunmaktadır. Çok ölçekli özellik çıkarımı gerçekleştirebilmesi sayesinde özellikle düzensiz yapıya sahip cilt lezyonlarının analizinde başarılı performans göstermektedir. Parametre verimliliği ve güçlü genelleme yeteneği nedeniyle cilt lezyonu sınıflandırma çalışmalarında yaygın olarak tercih edilmektedir (Venugopal vd., 2023).

Şekil 3.8'de EfficientNet-B4 mimarisinin genel yapısı gösterilmektedir. Görselde giriş görüntüsünün evrişim katmanlarından geçirilerek farklı mobil ters darboğaz evrişim blokları aracılığıyla çok seviyeli özellik çıkarımının gerçekleştirildiği görülmektedir. Model içerisinde kullanılan sıkıştırma ve uyarım blokları sayesinde kanal tabanlı

dikkat mekanizması desteklenmekte, son aşamada elde edilen özellikler sınıflandırıcı katmanlara aktarılarak görüntünün ait olduğu sınıf tahmin edilmektedir (Tan ve Le, 2019).



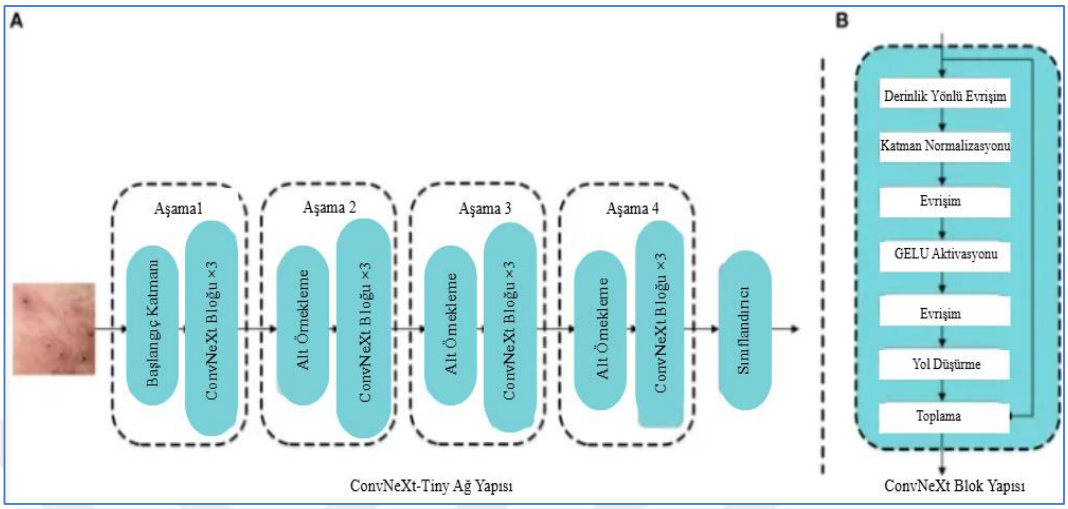
Şekil 3.8 EfficientNet-B4 Mimarisinin genel mimari yapısı (Tan ve Le, 2019)

3.4.2 ConvNeXt-Tiny Mimarisi

ConvNeXt-Tiny, modern dönüştürücü tabanlı tasarım yaklaşımlarını klasik ESA mimarisi ile birleştirmek amacıyla geliştirilen yeni nesil bir evrişimsel sinir ağı mimarisidir. ConvNeXt mimarisi, standart ResNet yapısının modernleştirilmesiyle oluşturulmuş olup büyük çekirdekli evirişimler, katman normalizasyonu ve sadeleştirilmiş blok yapıları kullanmaktadır. Model, tamamen evrişimsel yapısını korumasına rağmen dönüştürücü modelleri ile rekabet edebilecek düzeyde performans sağlayabilmektedir (Liu vd., 2022).

Şekil 3.9'da ConvNeXt-Tiny mimarisinin genel yapısı ve ConvNeXt blok yapısı gösterilmektedir. Görselin sol bölümünde giriş görüntüsünün başlangıç katmanından geçirilerek dört farklı aşamada ConvNeXt blokları ve alt örnekleme işlemleri aracılığıyla çok seviyeli özellik çıkarımının gerçekleştirildiği görülmektedir. Sağ bölümde ise ConvNeXt bloğunun iç yapısı verilmiş olup derinlik yönlü evrişim, katman normalizasyonu, Gauss Hata Doğrusal Birimi (Gaussian Error Linear Unit, GELU) aktivasyonu ve yol düşürme işlemlerinin kullanıldığı gösterilmektedir. Son

aşamada elde edilen özellikler sınıflandırıcı katmana aktarılmakta ve görüntünün ait olduğu sınıf tahmin edilmektedir.



Şekil 3.9 (A) ConvNeXt-Tiny Ağ Yapısı, (B) ConvNeXt Blok Yapısı (Liu vd., 2022)

ConvNeXt-Tiny mimarisinin temel farkı, geleneksel ESA mimarisini modern dönüştürücü tasarım prensiplerine göre yeniden düzenlemesidir. Modelde 7×7 büyük çekirdekli derinlik yönlü evirişimler, GELU aktivasyon fonksiyonu, katman normalizasyonu ve MobileNetV2 gibi mimarilerde kullanılan bir yapı türü olan ters darboğaz yapıları kullanılmaktadır. Ayrıca model, ResNet tabanlı yapılara göre daha sade ve verimli bir blok tasarımı sunmaktadır. Bu yaklaşım sayesinde ConvNeXt mimarisi, yüksek doğruluk sağlarken hesaplama verimliliğini de koruyabilmektedir (Liu vd., 2022).

ConvNeXt-Tiny mimarisi, dermoskopik görüntülerde lezyon sınırları, pigment dağılımları, renk değişimleri ve ince doku örüntülerinin öğrenilmesinde etkili sonuçlar sunmaktadır. Özellikle büyük çekirdekli evrişim yapıları sayesinde görüntü içerisindeki daha geniş bağlamsal ilişkileri öğrenebilmekte ve karmaşık cilt lezyonlarının sınıflandırılmasında başarılı performans gösterebilmektedir. Modelin güçlü özellik öğrenme yeteneği ve yüksek genelleme başarısı dermoskopik görüntü sınıflandırma çalışmalarında etkin biçimde kullanılmasını sağlamaktadır (Liu vd., 2022).

Bununla birlikte, ESA mimarileri yerel uzamsal özelliklerin öğrenilmesinde başarılı olmakla birlikte görüntü genelindeki küresel bağlamsal ilişkileri doğrudan modelleme

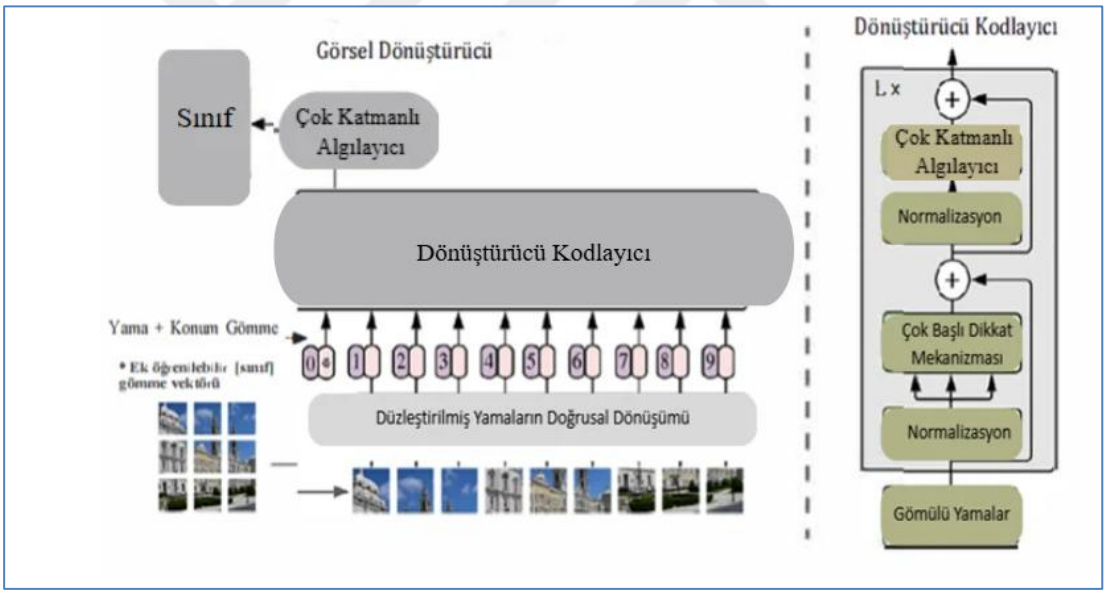
konusunda sınırlılıklar gösterebilmektedir (Liu vd., 2022). Bu sınırlılıkların aşılması amacıyla, dikkat mekanizmalarına dayalı dönüştürücü mimarileri geliştirilmiş olup, bir sonraki bölümde bu yaklaşımlar ayrıntılı olarak ele alınmaktadır.

3.5 Dönüştürücü Mimarileri

ESA mimarileri, görüntü sınıflandırma problemlerinde yerel özellikleri etkin biçimde öğrenmeleri nedeniyle uzun yıllar boyunca bilgisayarlı görme alanında yaygın olarak kullanılmıştır. Ancak bu mimariler, görüntü içerisindeki uzun menzilli bağımlılıkları ve küresel bağlamsal ilişkileri modelleme konusunda bazı kısıtlamalara sahiptir. Özellikle dermoskopik görüntülerde lezyonun tamamına yayılan renk, doku ve yapısal örüntülerin bütüncül biçimde değerlendirilmesi gerekliliği, daha güçlü bağlamsal özellik öğrenimine ihtiyaç duyulmasına neden olmuştur. Bu doğrultuda doğal dil işleme alanında başarılı sonuçlar elde eden dönüştürücü mimarileri, öz-dikkat mekanizması sayesinde görüntü içerisindeki tüm bölgeler arasındaki ilişkileri aynı anda modelleyebilme yeteneği ile bilgisayarlı görme alanına uyarlanmıştır. Dönüştürücü mimarileri, görüntüyü sabit boyutlu yamalara ayırarak bu yamaları bir dizi şeklinde işlemekte ve çok başlı öz-dikkat mekanizması aracılığıyla küresel özellik öğrenimi gerçekleştirmektedir. Bu sayede dönüştürücü tabanlı modeller, görüntü sınıflandırma problemlerinde güçlü bir alternatif yaklaşım olarak öne çıkmaktadır (Dosovitskiy vd., 2020).

Bu mimaride görüntü, belirli boyutlardaki yamalara ayrılarak her bir yama vektör biçiminde temsil edilmektedir. Ancak dönüştürücü yapıda evrişim ve yinelemeli mekanizmalar bulunmadığından görüntüdeki uzamsal konum bilgisi model tarafından doğal olarak korunamamaktadır. Bu nedenle, her bir yama gömme vektörüne görüntü içerisindeki konumunu ifade eden konumsal kodlama vektörleri eklenmektedir. Konumsal kodlamalar ile yama gömme vektörlerinin toplamı dönüştürücü kodlayıcı katmanlarına girdi olarak verilmekte ve böylece modelin görüntüdeki yamaların göreli ve mutlak konumlarına ilişkin bilgileri öğrenmesi sağlanmaktadır. Bu yaklaşım, görüntü içerisindeki uzamsal ilişkilerin korunmasına katkı sağlayarak dönüştürücü mimarinin daha etkili özellik temsilleri oluşturmasına olanak tanımaktadır (Vaswani vd., 2017).

Dönüştürücü mimarisinde öz-dikkat mekanizmasının temsil gücünü artırmak amacıyla çok başlı dikkat yapısı kullanılmaktadır. Bu yapıda, yama temsilleri birden fazla dikkat başlığı altında paralel olarak işlenmekte ve her bir başlık farklı ilişkileri öğrenmektedir. Elde edilen dikkat çıktıları birleştirilerek daha zengin ve kapsamlı bir özellik temsili oluşturulmaktadır (Dosovitskiy vd., 2020). Şekil 3.10'da dönüştürücü mimarisinin genel yapısı gösterilmektedir. Bu yapıda giriş görüntüsü küçük yamalara ayrılarak gömülü yama temsilleri elde edilmekte ve konumsal bilgiler eklenmektedir. Ardından bu temsiller, çok başlı dikkat mekanizması ve çok katmanlı algılayıcı yapılarından oluşan dönüştürücü kodlayıcı bloklarına aktarılmaktadır. Son aşamada elde edilen temsil sınıflandırma katmanına iletilerek görüntünün ait olduğu sınıf tahmin edilmektedir. Bu yapı sayesinde dönüştürücü modelleri, görüntü içerisindeki uzak bölgeler arasındaki ilişkileri etkili şekilde öğrenebilmektedir (Dosovitskiy vd., 2020).



Şekil 3.10 Dönüştürücü mimarisinin genel yapısı (Dosovitskiy vd., 2020)

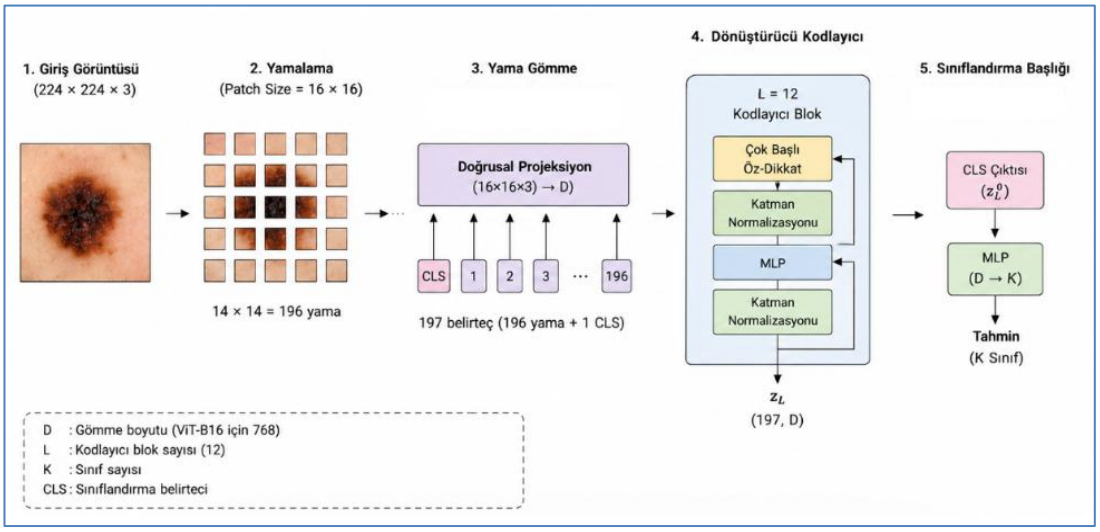
Dönüştürücü mimarisinde girdi temsili, giriş görüntüsünün sabit boyutlu ve örtüşmeyen küçük parçalara ayrılmasıyla oluşturulmaktadır. Elde edilen yamalar düzleştirilmekte ve doğrusal projeksiyon katmanları aracılığıyla gömme vektörlerine dönüştürülmektedir. Bu yaklaşım, görüntülerin dönüştürücü mimarisine uygun biçimde temsil edilmesini sağlamakta ve modelin küresel bağlamsal ilişkileri öğrenmesine olanak tanımaktadır (Dosovitskiy vd., 2020).

3.5.1 ViT-B16 Mimarisi

ViT-B16 mimarisinde giriş görüntüsü öncelikle sabit boyutlu yamalara ayrılmaktadır. Elde edilen her yama düzleştirilerek doğrusal projeksiyon işlemi ile gömme vektörüne dönüştürülmektedir. Daha sonra bu özellik vektörü konumsal bilgi eklenerek dönüştürücü kodlayıcı bloklarına aktarılmaktadır. Kodlayıcı bloklar içerisinde çok başlı öz-dikkat mekanizması, katman normalizasyonu ve çok katmanlı algılayıcı yapıları kullanılmaktadır. Bu yapı sayesinde model, görüntü içerisindeki uzak bölgeler arasındaki ilişkileri öğrenebilmekte ve küresel bağlamsal özellik çıkarımı gerçekleştirebilmektedir (Steiner vd., 2021).

ViT-B16 mimarisinin geleneksel ESA mimarisinden temel farkı, ESA mimarilerinde kullanılan evrişim işlemleri yerine öz-dikkat mekanizmasını kullanmasıdır. Mimari, görüntü içerisindeki uzak bölgeler arasındaki ilişkileri doğrudan öğrenebilmekte ve küresel bağlamsal özellik çıkarımı gerçekleştirebilmektedir. Ayrıca çok başlı dikkat mekanizması sayesinde görüntünün farklı bölgelerine aynı anda odaklanarak güçlü özellik temsilleri oluşturabilmektedir (Dosovitskiy vd., 2020).

Şekil 3.11'de, ViT-B16 mimarisinin genel yapısı gösterilmektedir. Görselde giriş görüntüsünün öncelikle 16×16 boyutlu yamalara ayrıldığı, ardından bu yamaların doğrusal projeksiyon işlemi ile gömme vektörlerine dönüştürüldüğü görülmektedir. Elde edilen yama temsilleri, sınıflandırma belirteci ile birlikte dönüştürücü kodlayıcı bloklarına aktarılmakta ve çok başlı öz-dikkat mekanizması aracılığıyla görüntü içerisindeki ilişkiler öğrenilmektedir. Son aşamada ise elde edilen sınıflandırma belirteci çıktısı çok katmanlı algılayıcı sınıflandırıcı katmanına aktarılmakta ve görüntünün ait olduğu sınıf tahmin edilmektedir.



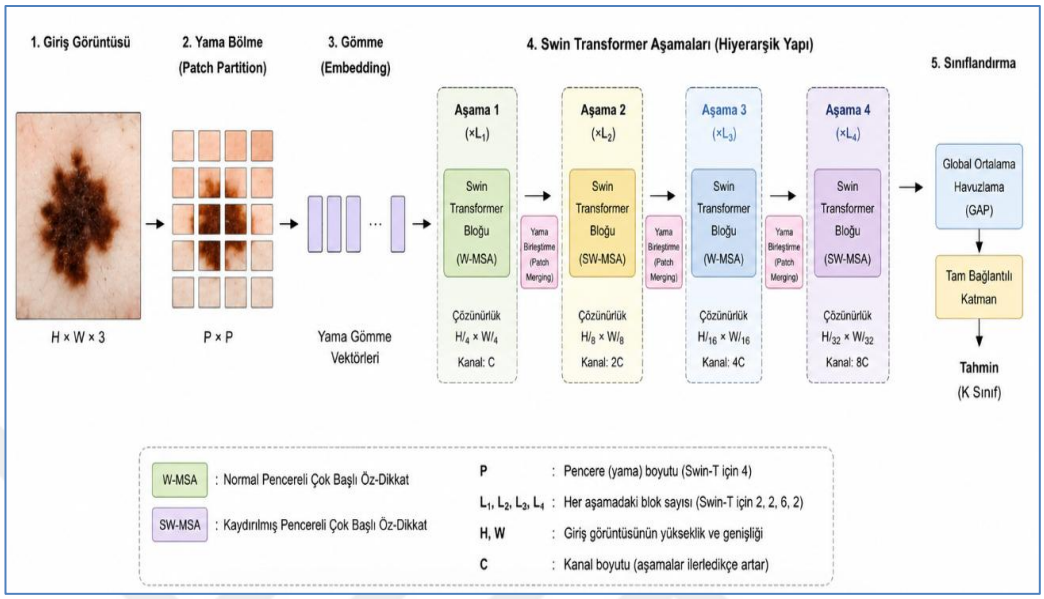
Şekil 3.11 ViT-B16 mimarisinin genel yapısı (Dosovitskiy vd., 2020)

ViT-B16 mimarisi, dermoskopik görüntülerde lezyon sınırları, renk değişimleri, pigment dağılımları ve düzensiz doku örüntülerinin öğrenilmesinde etkili sonuçlar sunmaktadır. Özellikle öz-dikkat mekanizması sayesinde görüntü içerisindeki farklı bölgeler arasındaki ilişkileri bütüncül biçimde değerlendirebilmekte ve MEL gibi karmaşık yapıya sahip cilt lezyonlarının sınıflandırılmasında başarılı performans sağlayabilmektedir. Mimarinin küresel bağlamsal özellik öğrenme yeteneği, dermoskopik görüntü analizinde önemli avantaj oluşturmaktadır (Steiner vd., 2021).

3.5.2 Swin-T Mimarisi

Swin-T mimarisi, görüntü sınıflandırma ve yoğun görüntü işleme görevleri için geliştirilen hiyerarşik bir dönüştürücü modelidir (Liu vd., 2021). Şekil 3.12'de Swin-T mimarisinin genel yapısı gösterilmektedir. Bu mimaride, görüntü sabit boyutlu yamalara ayrılarak işlenmekte ve bu yamalar gömme vektörlerine dönüştürülmektedir. Elde edilen vektörler, hiyerarşik özellik haritaları oluşturan Swin T bloklarına aktarılmaktadır. Bu bloklarda kullanılan pencere tabanlı ve kaydırılmış pencere tabanlı öz-dikkat mekanizmaları, yerel ayrıntılar ile geniş bağlamsal bilgilerin birlikte öğrenilmesini sağlamaktadır. Ayrıca yama birleştirme işlemleri sayesinde çok ölçekli özellik temsilleri oluşturulmakta ve hesaplama maliyeti kontrol altında tutulmaktadır. Bu hiyerarşik yapı, yüksek çözünürlüklü tıbbi görüntülerde hem ince patolojik bulguların hem de genel anatomik bağlamın etkili biçimde analiz edilmesine olanak

tanımaktadır. Son aşamada, elde edilen özellikler sınıflandırma katmanına aktarılmakta ve görüntünün ait olduğu sınıf tahmin edilmektedir (Nour vd., 2025).



Şekil 3.12 Swin-T mimarisinin genel yapısı (Liu vd., 2021)

Swin-T mimarisi, giriş görüntüsünü küçük yamalara ayırarak işlemekte ve farklı aşamalarda yamaları birleştirerek çok seviyeli özellik haritaları oluşturmaktadır. Bu model ile öz-dikkat işlemleri, tüm görüntü yerine yerel pencereler içerisinde gerçekleştirilmektedir. Bu yaklaşım sayesinde model, görüntü boyutuna göre doğrusal hesaplama karmaşıklığı sağlayabilmektedir (Liu vd., 2021).

Swin-T mimarisi, geleneksel dönüştürücü mimarilerinden farklı olarak hiyerarşik özellik çıkarımı ve kaydırılmış pencere dikkat mekanizmasını birlikte kullanmaktadır. Bu yapı sayesinde model hem ince ayrıntıları hem de geniş bağlamsal bilgileri etkili bir şekilde öğrenebilmektedir. Yerel pencereler içerisinde gerçekleştirilen öz dikkat hesaplamaları hesaplama maliyetini azaltırken kaydırılmış pencere yaklaşımı farklı pencereler arasındaki bilgi etkileşimini sağlayarak küresel özelliklerin yakalanmasına katkıda bulunmaktadır. Ayrıca yama birleştirme işlemleri ile çok ölçekli özellik temsilleri oluşturulabilmekte ve böylece yüksek çözünürlüklü tıbbi görüntüler daha verimli şekilde analiz edilebilmektedir. Bu özellikleri nedeniyle Swin-T modeli, tıbbi görüntü sınıflandırma uygulamalarında hem doğruluk hem de hesaplama verimliliği açısından önemli avantajlar sunmaktadır (Nour vd., 2025).

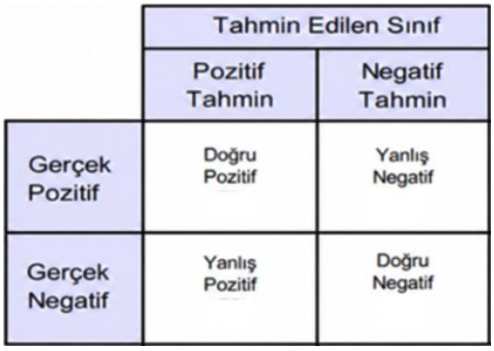
Swin-T mimarisi, dermoskopik görüntülerde lezyon sınırları, pigment dağılımları, renk değişimleri ve düzensiz doku örüntülerinin öğrenilmesinde güçlü bir yapı sunmaktadır. Yerel pencere tabanlı dikkat mekanizması sayesinde lezyonun ince ayrıntıları öğrenilebilirken, kaydırılmış pencere yaklaşımı ile farklı bölgeler arasındaki ilişkiler de etkili biçimde modellenebilmektedir. Bu özellik, özellikle karmaşık yapıya sahip melanom görüntülerinin sınıflandırılmasında modelin başarılı performans göstermesine katkı sağlamaktadır (Liu vd., 2021).

3.6 Performans Değerlendirmesi

Bu çalışmada, derin öğrenme modellerinin sınıflandırma performanslarının kapsamlı olarak değerlendirilebilmesi amacıyla Makro-Ortalama Doğruluk, Makro-Ortalama Kesinlik, Makro-Ortalama Duyarlılık ve Makro-Ortalama F1-skoru metrikleri kullanılmıştır. Bu metrikler, sınıf düzeyindeki doğruluk, kesinlik, duyarlılık ve F1-skoru metriklerini temel alarak hesaplanır. Özellikle sınıf dağılımının dengesiz olduğu veri kümelerinde doğruluk değerine dayalı değerlendirmeler yanıltıcı sonuçlar verebilmekte olup bu tez çalışmasında Makro-Ortalama F1-skoru temel karşılaştırma ölçütü olarak kabul edilmiştir. Buna ek olarak, modellerin sınıflar arasındaki ayırt etme yeteneğinin değerlendirilmesi için AİK eğrilerine de yer verilmiştir.

3.6.1 Karışıklık Matrisi

Karışıklık matrisi, bir makine öğrenmesi modelinin sınıf bazındaki tahmin performansını ayrıntılı olarak gösteren bir değerlendirme aracıdır. Şekil 3.13'de karışıklık matrisi yapısı ve temel sınıflandırma ölçütleri gösterilmektedir. Karışıklık matrisi, bir sınıflandırma mimarisinin gerçek ve tahmin edilen sınıfları arasındaki ilişkiyi değerlendirmek amacıyla kullanılan temel performans analiz yöntemlerinden biridir. Bu matristeki doğru ve yanlış sınıflandırmalar, Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) olmak üzere dört temel öğe üzerinden ifade edilmektedir.



Şekil 3.13 Karışıklık matrisi ve temel sınıflandırma ölçütlerinin gösterimi

Bu matris, her bir sınıf için model tarafından gerçekleştirilen doğru ve yanlış tahminlerin alan uzmanı tarafından değerlendirmesini ve analizini yapma imkânı sunar. Dahası, bu matris üzerinden doğruluk, kesinlik ve duyarlılık gibi performans metrikleri hesaplanabilmektedir.

3.6.2 Doğruluk

Denklem 3.5'de verilen doğruluk metriği, bir makine öğrenmesi modelinin tüm örnekler içerisinden ne kadarını doğru sınıflandırdığına dair oranı sunar. Bu ölçüt, genel performans hakkında temel bir bilgi verse de sınıf dengesizliğinin bulunduğu durumlarda tek başına yeterli değildir.

$$Doğruluk = \frac{DP+DN}{DP+DN+YP+YN} \tag{3.5}$$

Makro-Ortalama Doğruluk metriği, her sınıf için hesaplanan doğruluk değerlerinin aritmetik ortalamasıdır ve Denklem 3.6'da sunulmuştur.

$$Makro - Ortalama\ Doğruluk = \frac{1}{C}\sum_{i=1}^{C} Doğruluk_i \tag{3.6}$$

3.6.3 Kesinlik

Denklem 3.7'de verilen kesinlik metriği, bir makine öğrenmesi modelinin pozitif olarak tahmin ettiği örneklerin ne kadarının gerçekten ilgili sınıfa ait olduğunu göstermektedir. Çok sınıflı problemlerde bu değer her bir sınıf için ayrı ayrı hesaplanmakta ve daha sonra ortalaması alınabilmektedir.

$$Kesinlik = \frac{DP}{DP+YP} \quad (3.7)$$

Makro-Ortalama Kesinlik metriği, her sınıf için hesaplanan kesinlik değerlerinin aritmetik ortalamasıdır ve Denklem 8'de sunulmuştur.

$$Makro - Ortalama\ Kesinlik = \frac{1}{C}\sum_{i=1}^{C} Kesinlik_i \quad (3.8)$$

3.6.4 Duyarlılık

Denklem 3.9'da verilen duyarlılık metriği, bir makine öğrenmesi modelinin gerçek pozitif örneklerin ne kadarını doğru olarak sınıflandırdığını göstermektedir. Özellikle hastalık sınıflandırma problemlerinde önemli bir ölçüttür.

$$Duyarlılık = \frac{\mathrm{DP}}{\mathrm{DP+YN}} \quad (3.9)$$

Makro-Ortalama Duyarlılık metriği, her sınıf için hesaplanan duyarlılık değerlerinin aritmetik ortalamasıdır ve Denklem 3.10'da sunulmuştur.

$$Makro - Ortalama\ Duyarlılık = \frac{1}{C}\sum_{i=1}^{C} Duyarlılık_i \quad (3.10)$$

3.6.5 F1-skoru

Denklem 3.11'de verilen F1-skoru kesinlik ve duyarlılık ölçümlerinin dengeli ortalamasını veren bir ölçüttür. Özellikle sınıf dengesizliğinin bulunduğu problemlerde daha anlamlı sonuçlar sunmaktadır.

$$F1 - skoru = 2\ x\ \frac{Kesinlik\ x\ Duyarlılık}{Kesinlik + Duyarlılık} \quad (3.11)$$

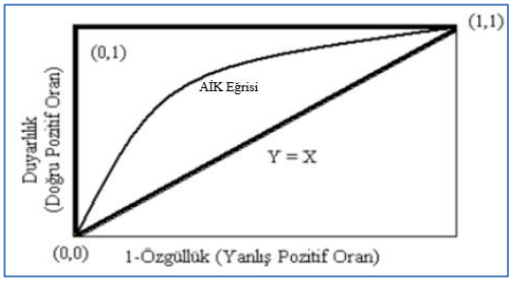
Denklem 3.12'de verilen Makro-Ortalama F1-skoru metriği, her bir sınıf için hesaplanan F1-skorlarının aritmetik ortalamasıdır.

$$Makro - Ortalama\ F1 - skoru = \frac{1}{C}\sum_{i=1}^{C} F1 - skoru_i \quad (3.12)$$

Makro-Ortalama Doğruluk, Makro-Ortalama Kesinlik, Makro-Ortalama Duyarlılık ve Makro-Ortalama F1-skoru metriklerinde yer alan C parametresi veri kümesinde yer alan ve performans değerlendirmesine dâhil edilen toplam sınıf sayısını ifade etmektedir.

3.6.6 Alıcı İşletim Karakteristiği

Alıcı İşletim Karakteristiği (AİK) analizi, sınıflandırma performansının yalnızca tek bir duyarlılık veya özgüllük değeri üzerinden değerlendirilmesinden kaynaklanabilecek sınırlılıkları azaltmak amacıyla kullanılan istatistiksel bir yöntemdir. AİK için Doğru Pozitif Oranı ve Yanlış Pozitif Oranı olmak üzere iki temel ölçüt kullanılır. Bu ölçütlerden Doğru Pozitif Oranı metriği Duyarlılık olarak ta bilinir ve bu metrik daha önce açıklanmıştır. Yanlış Pozitif Oranı metriği (1-Özgüllük) olarak bilinir. Özgüllük, ele alınan sınıf pozitif sınıf olmak üzere negatif sınıftaki örneklerin ne kadarın doğru sınıflandırıldığını ifade eder. AİK eğrisi, farklı karar eşik değerlerinde elde edilen doğru pozitif oranı ile yanlış pozitif oranı arasındaki ilişkiyi grafiksel olarak sunar. Bu eğri sayesinde modelin farklı eşik değerleri altındaki ayırt edicilik performansı kapsamlı bir şekilde değerlendirilebilmektedir (Tomak ve Bek, 2010). Şekil 3.14'te Alıcı İşletim Karakteristiği eğrisinin genel yapısı gösterilmektedir.



Şekil 3.14 AİK Eğrisi (Tomak ve Bek, 2010)

Bir sınıflandırma modelinin ayırt edicilik performansını değerlendirmede kullanılan yaygın yöntem, AİK eğrisi altında kalan alan (EAA) hesaplanır. EAA değeri, modelin farklı sınıfları birbirinden ayırt edebilme yeteneğini tek bir sayısal değer ile ifade eder. EAA değerinin yüksek olması, modelin pozitif ve negatif sınıfları daha başarılı şekilde ayırabildiğini göstermektedir. Bu nedenle EAA, sınıflandırma modellerinin performansını değerlendirmede yaygın olarak kullanılan önemli bir ölçüt olarak kabul edilmektedir (Tomak ve Bek, 2010).

4. DENEYSEL ÇALIŞMALAR

4.1 Deneysel Ortam

Bu çalışmadaki deneyler bulut tabanlı çalışma ortamında gerçekleştirilmiş olup eğitim sürecinde Google Colab altyapısından yararlanılmıştır. ESA modellerinin geliştirilmesinde TensorFlow/Keras, dönüştürücü mimarilerinin geliştirilmesinde ise PyTorch tabanlı kütüphaneler kullanılmıştır. Eğitim sürecinde yüksek parametreli olan bu modellerin eğitiminde NVIDIA A100 grafik işlem birimi kullanılmıştır. Böylece tüm modeller aynı bilgisayar konfigürasyonu üzerinde üretilmiştir.

4.2 Deneysel Çalışmalar

Bu çalışmada kullanılan dermoskopik görüntülerin herhangi bir makine öğrenmesi modelinin eğitimi için uygun hale getirilebilmesi amacıyla öncelikle veri hazırlama ve ön işleme adımlarından geçirilmiştir. İlk olarak UCGİB 2018 veri kümesinden seçilen BHK, İHDL, MEL ve NV sınıflarına ait görüntüler belirlenmiş ve bu sınıflar için sırasıyla BHK:0, İHDL:1, MEL:2 ve NV:3 olacak şekilde kategorik kodlama yapılmıştır.

4.2.1 Standardizasyon

Bu çalışmada kullanılan dermoskopik görüntüler, modellerin giriş veri dağılımlarını standartlaştırmak ve eğitim sürecinin daha kararlı şekilde yürütülmesini sağlamak amacıyla standardize edilmiştir. Tüm modellerde büyük ölçekli bir görüntü veri kümesi üzerinde önceden eğitilmiş ağırlıklar kullanıldığı için standardizasyon işlemleri veri dağılımına uygun şekilde gerçekleştirilmiştir.

EfficientNet-B4 ve ConvNeXt-Tiny mimarilerinin eğitimi için görüntüler üzerinde öncelikle standardizasyon uygulanmıştır. Bu işlemde, görüntülerin kırmızı, yeşil ve mavi renk kanallarına ait ortalama değerler [0,485; 0,456; 0,406] ve standart sapma değerleri [0,229; 0,224; 0,225] olarak kullanılmıştır. Böylece giriş verilerinin dağılımı,

modellerin ön eğitim sırasında öğrendiği veri dağılımı ile uyumlu hâle getirilerek eğitim sürecinin daha kararlı ve etkili şekilde yürütülmesi amaçlanmıştır.

ViT-B16 ve Swin-T mimarisinde ise veri dönüşüm ve standardizasyon işlemleri, kütüphanede yer alan fonksiyonlar ile mimari yapılandırmasına uygun şekilde gerçekleştirilmiştir. Bu doğrultuda, tüm mimarilerde önceden eğitilmiş ağırlıklarla uyumlu giriş veri dağılımı elde edilmiştir.

4.2.2 Görüntü Yeniden Boyutlandırma

Yeniden boyutlandırma işlemi ile farklı boyutlardaki sahip dermoskopik görüntüler aynı uzamsal boyuta dönüştürülmüştür. Buna göre, deneysel çalışmalarda yer alan mimarilerden, EfficientNet-B4 için önerilen boyut 380x380x3 olmakla birlikte diğer modeller için önerilen boyut 224×224x3 olduğu için tüm modeller arasında karşılaştırılabilir bir deney ortamı oluşturmak adına tüm görüntüler 224×224x3 olarak yeniden boyutlandırılmıştır.

4.2.3 Görüntü Dönüştürme

Bu çalışmada ideal bir makine öğrenmesi gereği yatay çevirme ve düşük kontrast gibi görüntü dönüşüm işlemleri yalnızca eğitim veri kümesine uygulanmış, doğrulama ve test veri kümelerinde ise herhangi bir görüntü dönüştürme yöntemine başvurulmamıştır. Görüntü dönüştürme işlemleri sayesinde modellerin eğitim sırasında daha farklı görüntü varyasyonları görmesi sağlanmış, böylece aşırı öğrenme problemi ile başa çıkma ve modelin genelleme performansının artırılması amaçlanmıştır. Buna ek olarak, her model mimarisinin yapısına uygun görüntü dönüşüm yöntemleri tercih edilmiştir. ESA mimarileri ve dönüştürücü mimarileri için uygulanan görüntü dönüşüm işlemleri Tablo 4.1'de gösterilmiştir. Görüntü dönüşüm işlemleri eğitim sürecinde çevrimiçi olarak uygulanmış olup eğitim veri kümesindeki örnek sayısı değiştirilmeden her eğitim turunda görüntülerin farklı varyasyonları modele sunulmuştur.

Tablo 4.1 Modellerde kullanılan görüntü dönüşüm yöntemleri

Model	Model Türü	Uygulanan Görüntü Dönüşüm Yöntemleri
EfficientNet-B4	ESA Mimarileri	%50 yatay çevirme, 10° rastgele döndürme
ConvNeXt-Tiny	ESA Mimarileri	%50 yatay çevirme, %50 dikey çevirme 20° rastgele döndürme, parlaklık, kontrast ve doygunluk değişimi
ViT-B16	Dönüştürücü Mimarileri	%50 yatay çevirme
Swin-T	Dönüştürücü Mimarileri	Timm kütüphanesi üzerinden modele özgü görüntü dönüşümleri

4.2.4 Veri Ayırma

Veri ayırma işleminde sınıflara ait örneklerin eşit oranda yer alması sağlanmıştır. Buna göre, her bir sınıfın veri kümesindeki temsil oranının eğitim, doğrulama ve test kümelerinde korunmasına dikkat edilmiş olup sınıf dağılımındaki dengesizliğin deneysel sonuçlar üzerindeki etkisinin azaltılması amaçlanmıştır.

Çalışmada, UCGİB 2018 veri kümesindeki BHK, İHDL, MEL ve NV olmak üzere dört sınıf değerlendirilmiştir. Bu kapsamda bu dört sınıftaki toplam 9.431 dermoskopik görüntü kullanılmıştır. Veri kümesi %70 eğitim, %10 doğrulama ve %20 test olacak şekilde alt kümelere ayrılmıştır. Bu doğrultuda 6.601 görüntü eğitim, 943 görüntü doğrulama ve 1.887 görüntü ise test veri kümesinde yer almaktadır.

Eğitim veri kümesindeki sınıf dağılımı BHK için 360 görüntü, İHDL için 769 görüntü, MEL için 779 görüntü ve NV için 4.693 görüntü şeklindedir. Bu dağılım, veri kümesinde belirgin bir sınıf dengesizliği bulunduğunu göstermektedir. Bu sınıf dengesizliği sorununu ele almak için eğitim kümesi üzerinde ARÖ tekniğine de ayrıca başvurulmuştur. Buna göre, bu tez çalışmasının devamında dört sınıflı veri kümesinden elde edilen eğitim veri kümesi üzerindeki deneysel çalışmalar Senaryo-1, bu eğitim veri kümesi üzerinde ARÖ tekniğinin uygulanmasını içeren deneysel çalışmalar Senaryo-2 olarak anılacaktır.

4.3 Derin Öğrenme Modellerinin Eğitimi ve Testi

Derin öğrenme modellerinin eğitimi ve testinde adil bir karşılaştırmanın yapılabilmesi amacıyla tüm deneysel çalışmalardaki eğitim, doğrulama ve test bölümlerinin aynı olması sağlanmıştır. Tüm modeller, öğrenim aktarımı yaklaşımı kapsamında büyük ölçekli bir görüntü veri kümesi üzerinde önceden eğitilmiş ağırlıklar ile başlatılmış ve ardından son sınıflandırma katmanları dermoskopik görüntü sınıflandırma probleminde yer alan dört sınıfa uygun şekilde yeniden yapılandırılmıştır. Böylece önceden öğrenilmiş genel görsel özelliklerden yararlanılarak daha kararlı ve etkili bir eğitim süreci oluşturulması amaçlanmıştır.

ESA mimarilerinin eğitiminde Adam ve dönüştürücü mimarilerinin eğitiminde AdamW en iyileme yöntemleri kullanılmıştır. Öğrenme oranının eğitim süreci boyunca etkin bir şekilde yönetilebilmesi amacıyla, ESA model eğitiminde başarıma bağlı öğrenme oranı azaltma yöntemi ve dönüştürücü mimarilerin eğitiminde kosinüs tabanlı öğrenme oranı yönteminden yararlanılmıştır. Model performansının değerlendirilmesinde doğruluk ve kayıp değerlerinin yanı sıra sınıf dengesizliği sorunu olduğu için Makro-Ortalama F1-skoru temel değerlendirme ölçütü olarak tercih edilmiştir. Buna ek olarak, maksimum eğitim tur sayısı 50 olup eğitim sürecinde aşırı öğrenmenin önüne geçebilmek amacıyla erken durdurma tekniği uygulanmıştır. Erken durdurma tekniğinde sabır değeri 6 ve ayrıca Makro-Ortalama F1-skoru için 0,002 değeri minimum iyileşme değeri olarak kabul edilmiştir. Buna göre, bir derin öğrenme modeli üst üste 6 tur boyunca Makro-Ortalama F1-skorunu en az 0,002 değerinde artırmayı başaramaz ise erken durdurma devreye girer ve model eğitimini sonlandırır. Bu doğrultuda, doğrulama veri kümesinde en yüksek Makro-Ortalama F1-skorunun elde edildiği model ağırlıkları kaydedilmiş ve model performansının doğrulanmasında bu ağırlıklar kullanılmıştır. Buna ek olarak, tüm derin öğrenme modelleri için ilgili tablolardaki performans ölçümleri % olarak sunulmuştur. Buna ek olarak, sınıf dengesizliğinin sınıflandırma performansı üzerindeki etkisini incelemek amacıyla her bir model, Senaryo-1 ve Senaryo-2'nin yer aldığı eğitim senaryoları altında ayrı ayrı eğitilmiş ve değerlendirilmiştir.

4.3.1 ESA Mimarilerinin Eğitimi Stratejisi

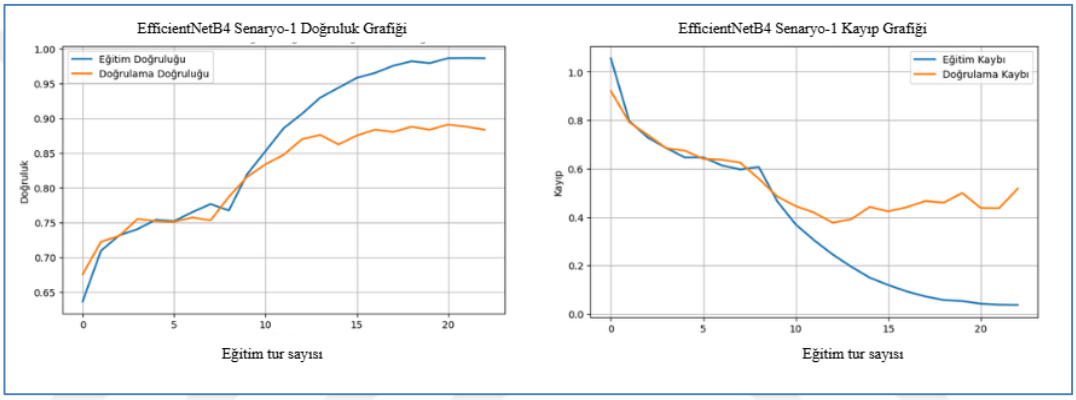
Bu çalışmada ESA mimarileri kapsamında EfficientNet-B4 ve ConvNeXt-Tiny mimarileri değerlendirilmiştir. Modeller, önceden eğitilmiş ağırlıklarla başlatılmış ve çıkış katmanları BHK, İHDL, MEL ve NV sınıflarını tahmin edebilecek şekilde yeniden düzenlenmiştir. Çalışmada toplam 9.431 görüntü kullanılmış, veri kümesi 6.601 eğitim, 943 doğrulama ve 1.887 test görüntüsü olacak şekilde ayrılmıştır. Eğitim veri kümesindeki sınıf dağılımı NV için 4693, MEL için 779, İHDL için 769 ve BHK için 360 görüntü şeklindedir.

EfficientNet-B4 mimarisi ile yeniden boyutlandırma, yatay çevirme ve 10° rastgele döndürme ile gerçekleştirilirken, ConvNeXt-Tiny mimarisi ile de bunlara ek olarak dikey çevirme, 20° rastgele döndürme ve renk tabanlı görüntü dönüşüm işlemleri uygulanmıştır. EfficientNet-B4 mimarisinde mini yığın boyutu 16, ConvNeXt-Tiny mimarisinde ise 32 olarak belirlenmiştir. Bu farklılık, modellerin hesaplama yükleri ve bellek gereksinimlerindeki değişikliklerden kaynaklanmakta olup, mevcut donanım kaynaklarının etkin kullanılması ve eğitim sürecinin kararlı şekilde sürdürülebilmesi amacıyla tercih edilmiştir. Hem Senaryo-1 hem de Senaryo-2 ile elde edilen eğitim veri kümesi üzerinde ESA mimarilerinin eğitimleri gerçekleştirilmiştir. Her iki eğitim senaryosunda da Adam en iyileme yöntemi ve ÇE kayıp fonksiyonu kullanılmıştır. Eğitim sürecinde doğrulama veri kümesi için Makro-Ortalama F1-skoru temel performans ölçütü olarak değerlendirilmiş, erken durdurma yöntemi uygulanmış ve bu doğrultuda en iyi model ağırlıkları kaydedilmiştir.

4.3.1.1 EfficientNet-B4 mimarisinin eğitimi ve elde edilen sonuçlar

Şekil 4.1, EfficientNet-B4 mimarisinin Senaryo-1'deki eğitimine ait doğruluk ve kayıp grafiklerini sunmaktadır. Buna göre, eğitim veri kümesindeki doğruluk eğitim turu boyunca düzenli olarak artmış ve son eğitim turlarında yüksek seviyelere ulaşmıştır. Doğrulama veri kümesi üzerindeki doğruluk da başlangıçta benzer şekilde yükselmiş, ilerleyen eğitim turlarında ise daha sınırlı artış göstererek belirli bir seviyeye ulaşmıştır. Özellikle yaklaşık 8-10. eğitim turları sonrasında model performansında belirgin bir iyileşme gözlenmiştir. Kayıp eğrileri değerlendirildiğinde eğitim kaybının

eğitim turları boyunca sürekli azaldığı görülürken, doğrulama kaybının başlangıçta düşüş göstermesine rağmen ilerleyen eğitim turlarında dalgalı bir yapı sergilediği dikkat çekmektedir. Son eğitim turlarına doğru eğitim veri kümesi üzerindeki kayıp azalmaya devam ederken doğrulama veri kümesi üzerindeki kayıptaki artış, modelde aşırı öğrenme eğiliminin oluştuğunu göstermektedir. Eğitim ve doğrulama eğrileri arasındaki farkın artması bu durumu desteklemekle birlikte doğrulama veri kümesi üzerindeki Makro-Ortalama F1-skorunda üst üste 6 tur boyunca minimum iyileşme sağlanamaması nedeniyle erken durdurma tekniğine dayalı olarak 20. eğitim turunda eğitim süreci sonlanmıştır.



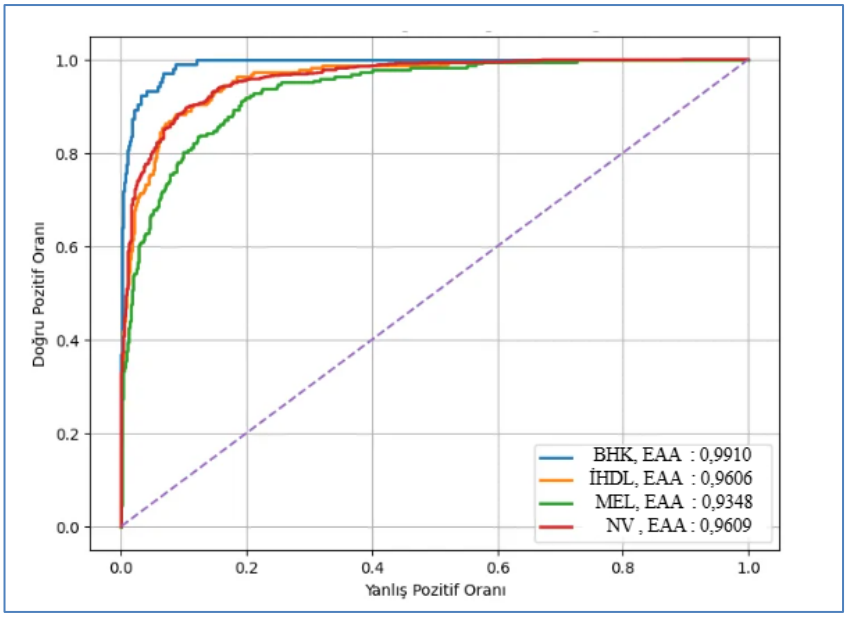
Şekil 4.1 Senaryo-1'de EfficientNet-B4 mimarisinin doğruluk ve kayıp eğrileri

Şekil 4.2, Senaryo-1 çerçevesinde EfficientNet-B4 mimarisinin karışıklık matrisini sunmaktadır. Buna göre, BHK sınıfında yer alan 103 örneğin 81'i doğru sınıflandırılmış ve %78,64 duyarlılık elde edilmiştir. İHDL sınıfında ise 220 örneğin 156'sı doğru tahmin edilerek %70,91 duyarlılık sağlanmıştır. MEL sınıfında 223 örneğin 151'i doğru sınıflandırılmış ve %67,71 duyarlılık elde edilirken özellikle 51 örneğin NV sınıfı olarak tahmin edilmesi dikkat çekmiştir. NV sınıfında ise model yüksek performans sergilemiş ve 1.341 örneğin 1.254'ünü doğru sınıflandırarak %93,51 duyarlılık elde etmiştir.



Şekil 4.2 Senaryo-1'de EfficientNet-B4 mimarisinin karışıklık matrisi

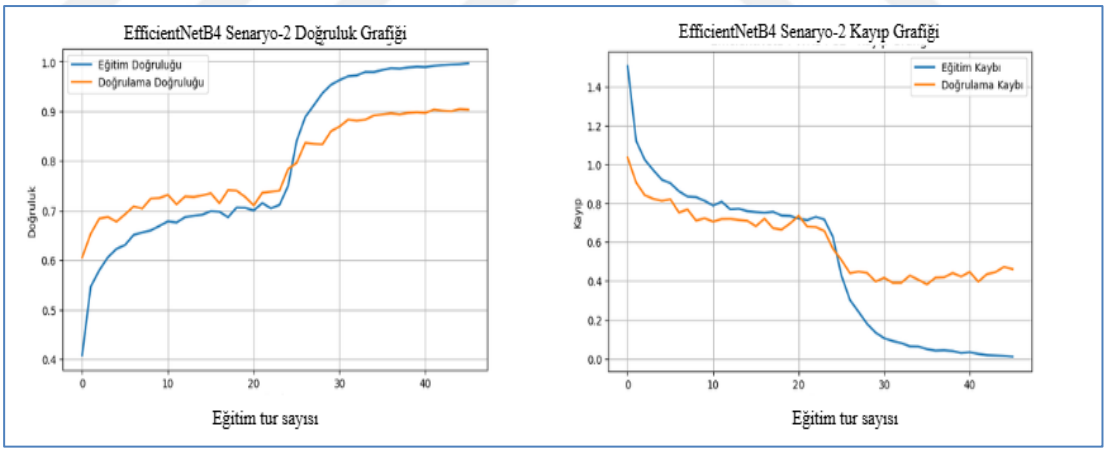
Şekil 4.3, Senaryo-1 çerçevesinde EfficientNet-B4 mimarisinin AİK eğrilerini sunmaktadır. Bu şekildeki eğrilerin genel olarak sol üst köşeye yakın ilerlemesi, modelin düşük yanlış pozitif oranlarında yüksek doğru pozitif oranlarına ulaşabildiğini göstermektedir. Özellikle BHK sınıfında yaklaşık 0,99 EAA değeri elde edilmesi, modelin bu sınıfı oldukça başarılı şekilde ayırt edebildiğini ortaya koymaktadır. İHDL ve NV sınıflarında da yüksek EAA değerleri gözlenirken MEL sınıfında diğer sınıflara kıyasla daha düşük ancak başarılı bir performans elde edilmiştir.



Şekil 4.3 Senaryo-1'de EfficientNet-B4 mimarisinin AİK eğrileri

Şekil 4.4 EfficientNet-B4 mimarisinin Senaryo-2'deki eğitimine ait doğruluk ve kayıp grafiklerini sunmaktadır. Buna göre, modelin eğitim süreci boyunca kararlı ve düzenli

bir öğrenme davranışı sergilediği görülmektedir. Eğitim veri kümesi üzerindeki doğruluk eğitim turu boyunca sürekli artış göstermiş ve son eğitim turlarına doğru yüksek seviyelere ulaşmıştır. Doğrulama veri kümesi üzerindeki doğruluk, başlangıçtan itibaren yükselmiş ancak eğitim doğruluğuna kıyasla biraz düşük seviyede kalmıştır. Özellikle yaklaşık 24-26. eğitim turları sonrasında doğrulama veri kümesi üzerindeki doğrulukta belirgin bir artış gözlenmesi, Senaryo-2 yaklaşımının sınıf dengesizliğinin etkisini azaltarak modelin öğrenme performansına olumlu katkı sağladığını göstermektedir. Kayıp eğrileri değerlendirildiğinde eğitim veri kümesi üzerindeki kaybın eğitim turları boyunca düzenli şekilde azaldığı görülmektedir. Doğrulama veri kümesi üzerindeki kayıpta ise başlangıçta hızlı bir düşüş görülmekte, ilerleyen eğitim turlarında ise bu düşüşte azalma görülmüştür. Sonuç olarak, doğrulama veri kümesi üzerindeki doğruluğun yüksek seviyelerde olması, modelin genelleme performansının başarılı olduğunu ortaya koymaktadır. Buna ek olarak, doğrulama veri kümesi üzerindeki Makro-Ortalama F1-skorunda üst üste 6 tur boyunca minimum iyileşme sağlanamaması nedeniyle erken durdurma tekniğine dayalı olarak 40. eğitim turunda eğitim süreci sonlanmıştır.



Şekil 4.4 Senaryo-2'de EfficientNet-B4 mimarisinin doğruluk ve kayıp eğrileri

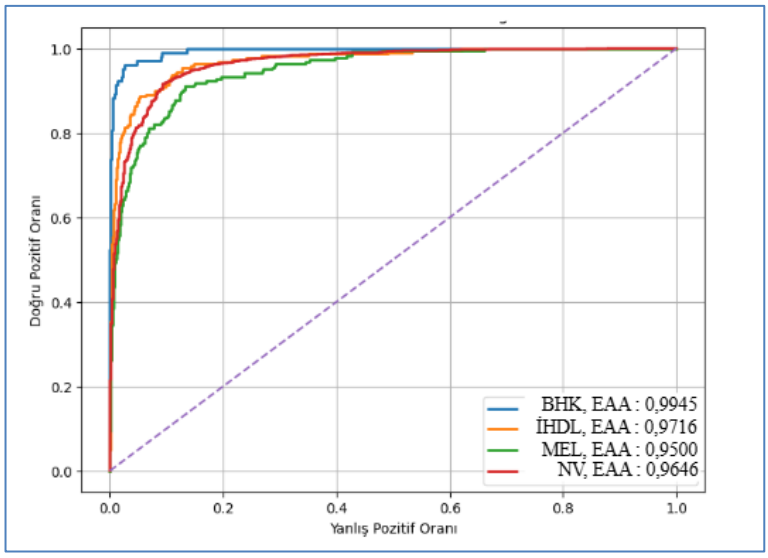
Şekil 4.5, Senaryo-2 çerçevesinde EfficientNet-B4 mimarisinin karışıklık matrisini sunmaktadır. Buna göre, BHK sınıfında yer alan 103 örneğin 90'ı doğru sınıflandırılmış ve %87,38 duyarlılık elde edilmiştir. İHDL sınıfında ise 220 örneğin 171'i doğru tahmin edilerek %77,73 duyarlılık sağlanmıştır. MEL sınıfında 223 örneğin 154'ü doğru sınıflandırılmış ve %69,06 duyarlılık elde edilirken özellikle 55 örneğin NV sınıfı olarak tahmin edilmesi dikkat çekmiştir. NV sınıfında ise model

oldukça yüksek performans göstermiş ve 1.341 örneğin 1.280'ini doğru şekilde sınıflandırarak yaklaşık %95,45 duyarlılık elde etmiştir.



Şekil 4.5 Senaryo-2'de EfficientNet-B4 mimarisinin karışıklık matrisi

Şekil 4.6, Senaryo-2 çerçevesinde EfficientNet-B4 mimarisinin AİK eğrilerini sunmaktadır. Bu eğrilerin genel olarak sol üst köşeye yakın ilerlemesi modelin düşük yanlış pozitif oranlarına ve yüksek doğru pozitif oranlarına ulaşabildiğini göstermektedir. Özellikle BHK sınıfında yaklaşık 0,99 EAA değeri elde edilmesi, modelin bu sınıfı oldukça başarılı şekilde ayırt edebildiğini ortaya koymaktadır. İHDL ve NV sınıflarında da yüksek EAA değerleri gözlenirken MEL sınıfında diğer sınıflara kıyasla daha düşük ancak başarılı bir performans elde edilmiştir. Grafik genel olarak değerlendirildiğinde Senaryo-2 yaklaşımının özellikle İHDL ve MEL sınıflarında ayırt edicilik performansını artırdığı dikkat çekmektedir. Senaryo-1'e kıyasla MEL sınıfına ait eğrinin daha hızlı yükseldiği ve daha yüksek EAA değerine ulaştığı görülmektedir. Bununla birlikte eğrilerin rastgele tahmin doğrusundan belirgin şekilde uzak olması, EfficientNet-B4 mimarisinin oluşturulan dört sınıflı veri kümesinde başarılı ve güvenilir bir sınıflandırma gerçekleştirdiğini göstermektedir. Genel olarak değerlendirildiğinde Senaryo-2 yaklaşımı sınıf dengesizliğinin etkisini azaltarak EfficientNet-B4 mimarisinin genel performansına olumlu katkı sağladığı değerlendirilmektedir.



Şekil 4.6 Senaryo-2'de EfficientNet-B4 mimarisinin AİK eğrileri

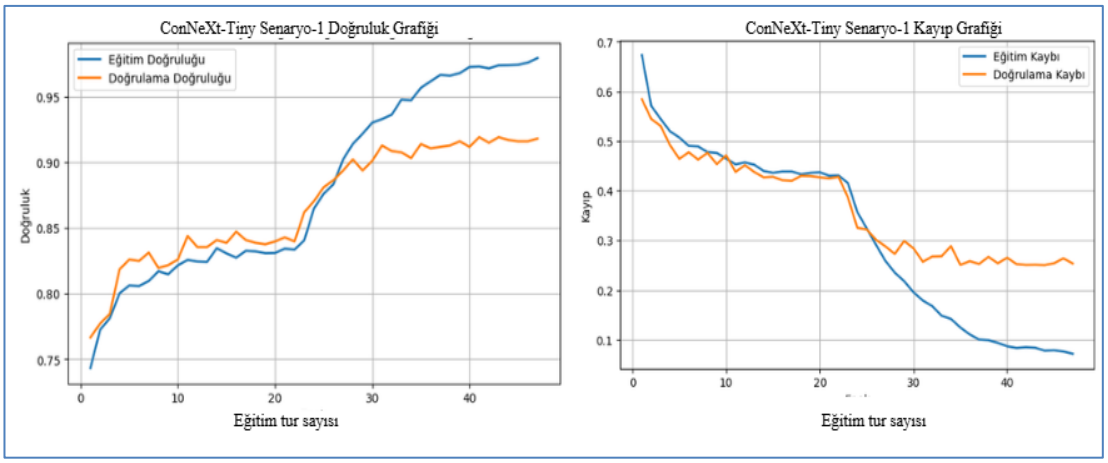
Tablo 4.2 incelendiğinde, Senaryo-2 ile elde edilen veri kümesi üzerindeki EfficientNet-B4 mimarisinin Senaryo-1'e kıyasla daha başarılı sonuçlar sunduğu görülmektedir. Senaryo-1'de Makro-Ortalama Duyarlılık %77,69, Makro-Ortalama Kesinlik %78,21, Makro-Ortalama Doğruluk %94,38 ve Makro-Ortalama F1-skoru %77,91 olarak elde edilirken, Senaryo-2'de bu değerler sırasıyla %82,41, %85,20, %95,71 ve %83,74'e yükselmiştir. Bu durum, Senaryo-2 yaklaşımının sınıf dengesizliğinin etkisini azaltarak model performansına olumlu katkı sağladığını göstermektedir. Sınıf bazında değerlendirildiğinde BHK sınıfında F1-skoru %80,20'den %88,67'ye, İHDL sınıfında %72,73'ten %81,04'e, MEL sınıfında %65,09'dan %70,97'ye ve NV sınıfında %93,61'den %94,29'a yükselmiştir. Özellikle BHK ve İHDL sınıflarında belirgin performans artışı gözlenirken MEL sınıfında da daha dengeli sonuçlar elde edilmiştir. NV sınıfı ise her iki eğitim senaryosunda da en yüksek başarıya sahip sınıf olarak dikkat çekmiştir. Genel olarak değerlendirildiğinde Senaryo-2, EfficientNet-B4 mimarisinin sınıf düzeyindeki doğru sınıflandırma performansını iyileştirerek Senaryo-1'e kıyasla daha başarılı olmasını sağlamıştır.

Tablo 4.2 EfficientNet-B4 mimarisinin sınıflandırma sonuçları

	Sınıf	DP	YN	DN	YP	Duyarlılık	Kesinlik	Doğruluk	F1-skoru
Senaryo-1	BHK	81	22	1.766	18	78,64	81,82	97,88	80,2
	İHDL	156	64	1.614	53	70,91	74,64	93,8	72,73
	MEL	151	72	1.574	90	67,71	62,66	91,41	65,09
	NV	1.254	87	1.632	84	93,51	93,72	94,41	93,61
	Makro-Ortalama					**77,69**	**78,21**	**94,38**	**77,91**
Senaryo-2	BHK	90	13	1.774	10	87,38	90	98,78	88,67
	İHDL	171	49	1.636	31	77,73	84,65	95,76	81,04
	MEL	154	69	1.607	57	69,06	72,99	93,32	70,97
	NV	1.280	61	1.638	94	95,45	93,16	94,96	94,29
	Makro-Ortalama					**82,41**	**85,2**	**95,71**	**83,74**

4.3.1.2 ContexTiny mimarisinin eğitimi ve elde edilen sonuçlar

Şekil 4.7, ConvNeXt-Tiny mimarisin Senaryo-1'deki eğitimine ait doğruluk ve kayıp eğrilerini sunmaktadır. Buna göre, ConvNeXt-Tiny mimarisinin eğitim veri kümesindeki doğruluğu eğitim turu boyunca sürekli artış göstermiş ve son eğitim turlarına doğru oldukça yüksek seviyelere ulaşmıştır. Doğrulama veri kümesi üzerindeki doğruluk, başlangıçtan itibaren artış göstermiş ancak ilerleyen eğitim turlarında daha dengeli bir seyir izlemiştir. Özellikle yaklaşık 24-26. eğitim turları sonrasında model performansında belirgin bir iyileşme meydana geldiği dikkat çekmektedir. Kayıp eğrileri değerlendirildiğinde eğitim veri kümesindeki kaybın eğitim turları boyunca düzenli şekilde azaldığı görülmektedir. Doğrulama kaybı ise başlangıçta eğitim kaybına benzer şekilde düşüş göstermiş ancak ilerleyen eğitim turlarında daha yatay ve hafif dalgalı bir yapı sergilemiştir. Son eğitim turlarına doğru eğitim kaybı azalmaya devam ederken doğrulama kaybının belirli seviyelerde sabitlenmesi, modelde hafif düzeyde aşırı öğrenme eğilimi oluştuğunu göstermektedir. Buna ek olarak, doğrulama veri kümesi üzerindeki Makro-Ortalama F1-skorunda üst üste 6 tur boyunca minimum iyileşme sağlanamaması nedeniyle erken durdurma tekniğine dayalı olarak 40. eğitim turunda eğitim süreci sonlanmıştır.



Şekil 4.7 Senaryo-1'de ConvNeXt-Tiny mimarisinin doğruluk ve kayıp eğrileri

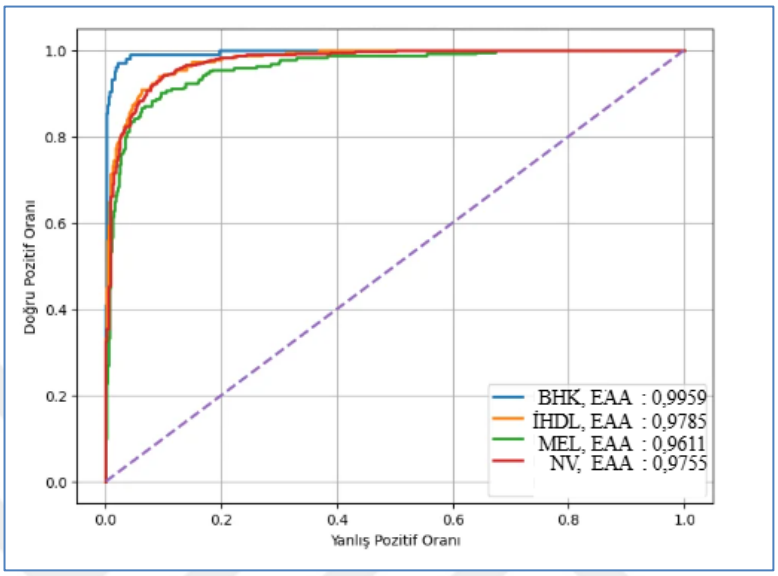
Şekil 4.8, Senaryo-1 çerçevesinde ConvNeXt-Tiny mimarisinin karışıklık matrisini sunmaktadır. Buna göre, BHK sınıfında yer alan 103 örneğin 93'ü doğru sınıflandırılmış ve %90,29 duyarlılık elde edilmiştir. İHDL sınıfında 220 örneğin 168'i doğru tahmin edilerek %76,36 duyarlılık sağlanmıştır. MEL sınıfında ise 223 örneğin 159'u doğru sınıflandırılmış ve %71,30 duyarlılık elde edilirken, özellikle 48 örneğin NV sınıfı olarak tahmin edilmesi dikkat çekmiştir. NV sınıfında model oldukça yüksek performans göstermiş ve 1.341 örneğin 1.299'unu doğru sınıflandırarak %96,87 duyarlılık elde etmiştir.



Şekil 4.8 Senaryo-1'de ConvNeXt-Tiny mimarisinin karışıklık matrisi

Şekil 4.9, Senaryo-1 çerçevesinde ConvNeXt-Tiny mimarisinin AİK eğrilerini sunmaktadır. Bu şekildeki eğrilerin genel olarak sol üst köşeye yakın ilerlemesi, modelin düşük yanlış pozitif oranlarında yüksek doğru pozitif oranlarına ulaşabildiğini göstermektedir. Özellikle BHK sınıfında yaklaşık 0,99 EAA değeri elde edilmesi,

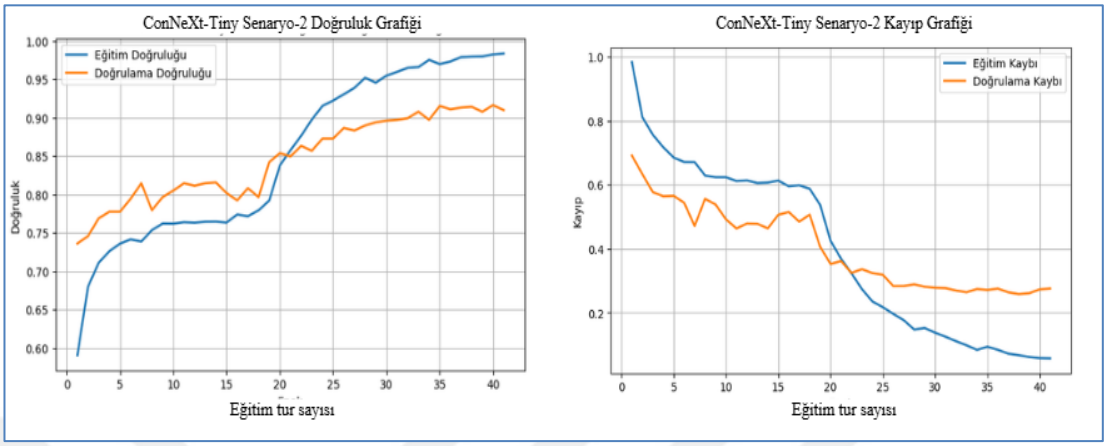
modelin bu sınıfı oldukça başarılı şekilde ayırt edebildiğini ortaya koymaktadır. İHDL ve NV sınıflarında da yüksek EAA değerleri gözlenirken, MEL sınıfında diğer sınıflara kıyasla daha düşük ancak başarılı bir performans elde edilmiştir.



Şekil 4.9 Senaryo-1'de ConvNeXt-Tiny mimarisinin AİK eğrileri

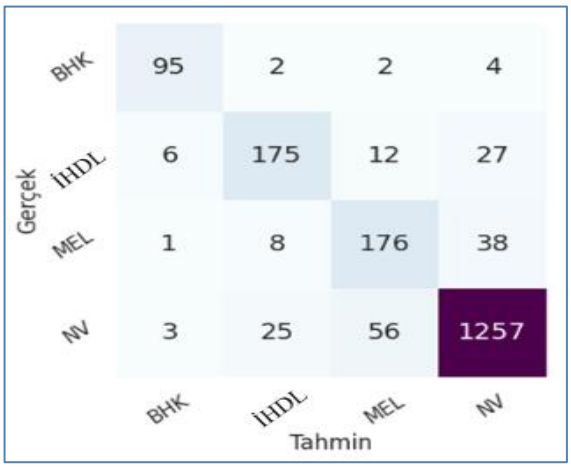
Şekil 4.4 ConvNeXt-Tiny mimarisinin Senaryo-2'deki eğitimine ait doğruluk ve kayıp eğrilerini sunmaktadır. Buna göre, eğitim veri kümesi üzerindeki doğruluk eğitim turları boyunca sürekli artış göstermiş ve son eğitim turlarına doğru oldukça yüksek seviyelere ulaşmıştır. Doğrulama veri kümesi üzerindeki doğruluk da başlangıçtan itibaren artış göstermiş ancak eğitim veri kümesi üzerindeki doğruluğa kıyasla daha dengeli bir seyir izlemiştir. Özellikle yaklaşık 18-20. eğitim turları sonrasında model performansında belirgin bir iyileşme meydana geldiği dikkat çekmektedir. Bu durum Senaryo-2'nin sınıf dengesizliğinin etkisini azaltarak modelin öğrenme sürecine olumlu katkı sağladığını göstermektedir. Kayıp eğrileri değerlendirildiğinde eğitim kaybının eğitim turları boyunca düzenli şekilde azaldığı görülmektedir. Doğrulama veri kümesi üzerindeki doğrulama kaybı ise başlangıçta hızlı bir düşüş göstermiş ancak ilerleyen eğitim turlarında daha yatay ve hafif dalgalı bir yapı sergilemiştir. Son eğitim turlarına doğru eğitim kaybı azalmaya devam ederken doğrulama kaybının belirli seviyelerde sabitlenmesi, modelde hafif düzeyde aşırı öğrenme eğilimi oluştuğunu göstermektedir. Buna rağmen doğrulama veri kümesi üzerindeki doğruluğun yüksek seviyelerde olması, modelin genelleme performansının başarılı olduğunu ortaya koymaktadır. Ayrıca doğrulama veri kümesi üzerindeki Makro-Ortalama F1-skorunda

üst üste 6 tur boyunca minimum iyileşme sağlanamaması nedeniyle erken durdurma tekniğine dayalı olarak 40. eğitim turunda eğitim süreci sonlanmıştır.



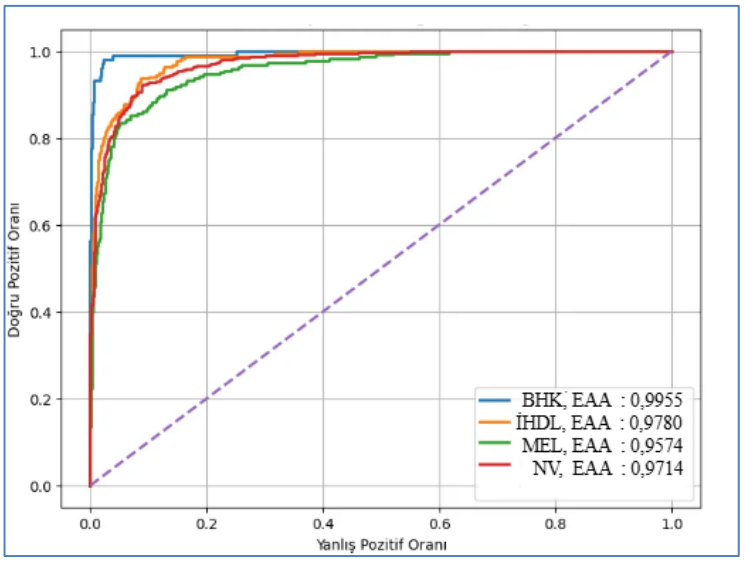
Şekil 4.10 Senaryo-2'de ConvNeXt-Tiny mimarisinin doğruluk ve kayıp eğrileri

Şekil 4.11, Senaryo-2 çerçevesinde ConvNeXt-Tiny mimarisinin karışıklık matrisini sunmaktadır. Buna göre, BHK sınıfında yer alan 103 örneğin 95'i doğru sınıflandırılmış ve %92,23 duyarlılık elde edilmiştir. İHDL sınıfında ise 220 örneğin 175'i doğru tahmin edilerek %79,55 duyarlılık sağlanmıştır. MEL sınıfında 223 örneğin 176'sı doğru sınıflandırılmış ve %78,92 duyarlılık elde edilirken özellikle 38 örneğin NV sınıfı olarak tahmin edilmesi dikkat çekmiştir. NV sınıfında ise model 1.341 örneğin 1.257'sini doğru şekilde sınıflandırmış ve %93,74 duyarlılık elde etmiştir. Karışıklık matrisi genel olarak değerlendirildiğinde Senaryo-2'nin özellikle MEL ve BHK sınıflarında model performansını belirgin şekilde iyileştirdiği görülmektedir. Senaryo-1'e kıyasla MEL sınıfındaki doğru tahmin sayısının arttığı ve NV ile olan karışmaların azaldığı dikkat çekmektedir. Bununla birlikte NV sınıfında bazı örneklerin MEL sınıfı olarak tahmin edilmesi, Senaryo-2'nin azınlık sınıflara daha fazla odaklanmasından kaynaklanabilmektedir. Genel olarak değerlendirildiğinde ConvNeXt-Tiny mimarisinin Senaryo-2'de deneysel çalışmalar için oluşturulan dört sınıflı veri kümesinde başarılı ve dengeli bir sınıflandırma performansı sergilediği değerlendirilmektedir.



Şekil 4.11 Senaryo-2'de ConvNeXt-Tiny mimarisinin karışıklık matrisi

Şekil 4.12, Senaryo-2 çerçevesinde ConvNeXt-Tiny mimarisinin AİK eğrilerini sunmaktadır. Bu eğrilerin genel olarak sol üst köşeye yakın ilerlemesi, modelin düşük yanlış pozitif oranlarında yüksek doğru pozitif oranlarına ulaşabildiğini göstermektedir. Özellikle BHK sınıfında yaklaşık 0,99 EAA değeri elde edilmesi, modelin bu sınıfı oldukça başarılı şekilde ayırt edebildiğini ortaya koymaktadır. İHDL ve MEL sınıflarında da yüksek EAA değerleri elde edilirken, MEL sınıfında diğer sınıflara kıyasla daha düşük ancak başarılı bir performans gözlenmiştir. Bununla birlikte NV sınıfında EAA değerinin çok değişmemiş olması, modelin Senaryo-2'de azınlık sınıflara daha fazla odaklanmasından kaynaklanabilmektedir. Genel olarak değerlendirildiğinde ConvNeXt-Tiny mimarisinin Senaryo-2'de başarılı ve dengeli bir sınıflandırma performansı sergilediği ifade edilebilir.



Şekil 4.12 Senaryo-2'de ConvNeXt-Tiny mimarisinin AİK eğrileri

Tablo 4.3 incelendiğinde, Senaryo-2 ile elde edilen veri kümesi üzerindeki ConvNeXt-Tiny mimarisinin Senaryo-1'e kıyasla daha başarılı sonuçlar sunduğu görülmektedir. Senaryo-1'de Makro-Ortalama Duyarlılık %83,71; Makro-Ortalama Kesinlik %86,62; Makro-Ortalama Doğruluk %95,55 ve Makro-Ortalama F1-skoru %85,03 olarak elde edilirken, Senaryo-2'de bu değerler sırasıyla %86,11; %85,04; %95,12 ve %85,51 olarak hesaplanmıştır. Bu sonuçlar, Senaryo-2 yaklaşımının özellikle duyarlılık ve Makro-Ortalama F1-skoru açısından sınıflandırma performansını iyileştirdiğini göstermektedir. Sınıf bazında değerlendirildiğinde BHK sınıfında Makro-Ortalama F1-skoru %89,00'dan %91,35'e, İHDL sınıfında %80,96'dan %81,40'a, MEL sınıfında %74,82'den %75,05'e ve NV sınıfında %95,34'ten %94,26'ya değişim göstermiştir. Özellikle BHK sınıfında belirgin performans artışı gözlenirken, İHDL ve MEL sınıflarında da daha dengeli sonuçlar elde edilmiştir. NV sınıfı ise her iki eğitim senaryosunda da en yüksek başarıya sahip sınıf olarak dikkat çekmiştir. Genel olarak değerlendirildiğinde Senaryo2'nin ConvNeXt-Tiny mimarisinde sınıflar arasındaki performans dengesini iyileştirerek daha kararlı bir sınıflandırma performansı sağladığı görülmektedir.

Tablo 4.3 ConvNeXt-Tiny mimarisinin sınıflandırma performans sonuçları

	Sınıf	DP	YN	DN	YP	Duyarlılık	Kesinlik	Doğruluk	F1-skoru
Senaryo-1	BHK	93	10	1.771	13	90,29	87,74	98,78	89,00
	İHDL	168	52	1.640	27	76,36	86,15	95,81	80,96
	MEL	159	64	1.621	43	71,30	78,71	94,33	74,82
	NV	1.299	42	461	85	96,87	93,86	93,27	95,34
	Makro-Ortalama					**83,71**	**86,62**	**95,55**	**85,03**
Senaryo-2	BHK	95	8	1.774	10	92,23	90,48	99,05	91,35
	İHDL	175	45	1.632	35	79,55	83,33	95,76	81,40
	MEL	176	47	1.594	70	78,92	71,54	93,80	75,05
	NV	1.257	84	477	69	93,74	94,80	91,89	94,26
	Makro-Ortalama					**86,11**	**85,04**	**95,12**	**85,51**

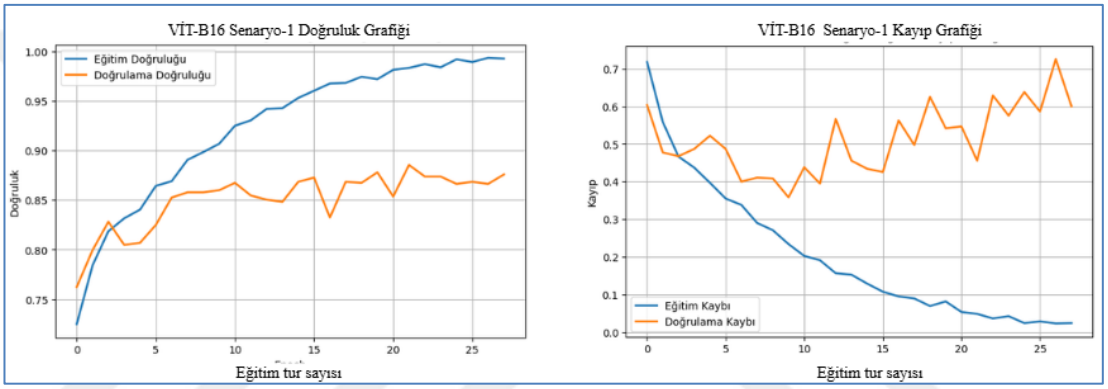
4.3.2 Dönüştürücü Mimarilerinin Eğitimi Stratejisi

Bu çalışmada dönüştürücü mimarileri olarak ViT-B16 ve Swin-T mimarileri kullanılmıştır. Mimarilerin oluşturulmasında *timm* kütüphanesinden yararlanılmış ve büyük ölçekli bir veri kümesi üzerinde önceden eğitilmiş ağırlıklar kullanılmıştır. Her iki model de dört sınıflı sınıflandırma problemine uygun şekilde yeniden düzenlenmiş, giriş görüntü boyutu 224×224x3 olarak belirlenmiştir. Eğitim sürecinde AdamW tabanlı en iyileme yöntemi, kosinüs tabanlı öğrenme oranı ve çapraz entropi kayıp fonksiyonu kullanılmıştır. Ayrıca her bir modelin eğitimi sırasında doğrulama veri kümesinden elde edilen Makro-Ortalama F1-skoru erken durdurma tekniği için izlenecek ölçüt olarak belirlenmiştir.

4.3.2.1 ViT-B16 mimarisinin eğitimi ve elde edilen sonuçlar

Şekil 4.13, ViT-B16 mimarisinin Senaryo-1'deki eğitimine ait doğruluk ve kayıp eğrilerini sunmaktadır. Özellikle, doğrulama veri kümesi üzerindeki doğruluk değeri başlangıçta hızlı bir yükseliş göstermesine rağmen ilerleyen eğitim turlarında dalgalı ve daha yatay bir yapı sergilemiştir. Doğrulama veri kümesi üzerindeki doğruluğun belirli bir seviyeden sonra kararlı kalması, modelin doğrulama verisi üzerinde sınırlı bir iyileşme sağladığını göstermektedir. Kayıp eğrileri değerlendirildiğinde eğitim veri kümesi üzerindeki kaybın düzenli şekilde azaldığı görülürken doğrulama veri kümesindeki kaybın eğitim turları boyunca belirgin dalgalanmalar gösterdiği dikkat

çekmektedir. Özellikle ilerleyen eğitim turlarında doğrulama veri kümesindeki kayıpta artış olması, modelde aşırı öğrenme eğilimi oluştuğunu ortaya koymaktadır. Eğitim ve doğrulama eğrileri arasındaki farkın giderek artması da bu durumu desteklemektedir. Bu sonuçlar, Senaryo-1 yaklaşımının ViT-B16 modelinde azınlık sınıfların öğrenilmesine katkı sağlamasına rağmen modelin genelleme performansının sınırlı düzeyde olduğunu göstermektedir. Ayrıca doğrulama veri kümesindeki Makro-Ortalama F1-skorunda üst üste 6 tur boyunca minimum iyileşme sağlanamaması nedeniyle erken durdurma tekniği gereği model eğitimi 25. eğitim turunda sonlanmıştır.



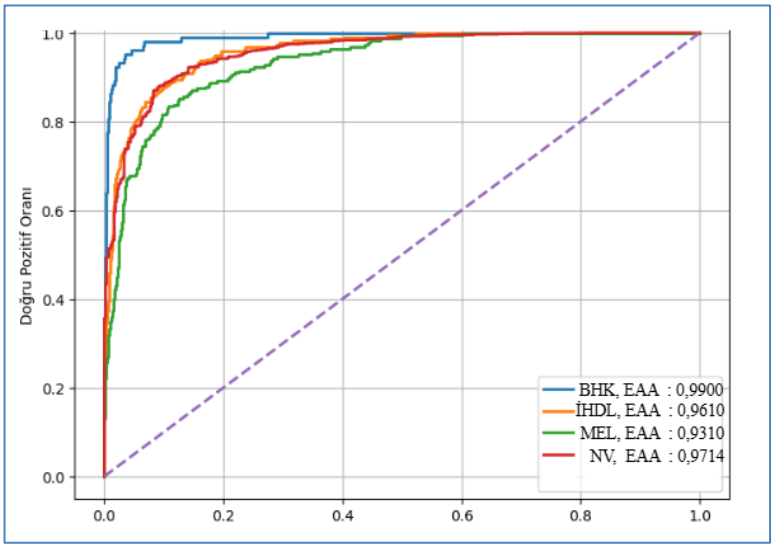
Şekil 4.13 Senaryo-1'de ViT-B16 mimarisinin doğruluk ve kayıp eğrileri

Şekil 4.14, Senaryo-1 çerçevesinde ViT-B16 mimarisinin karışıklık matrisini sunmaktadır. Buna göre, BHK sınıfında yer alan 103 örneğin 86'sı doğru sınıflandırılmış ve %83,5 duyarlılık elde edilirken, İHDL sınıfında 220 örneğin 173'ü doğru tahmin edilerek %78,64 duyarlılık sağlanmıştır. MEL sınıfında 223 örneğin 148'i doğru sınıflandırılmış ve %66,37 duyarlılık elde edilmiş, özellikle 48 örneğin NV sınıfı olarak tahmin edilmesi dikkat çekmiştir. NV sınıfında ise model 1.341 örneğin 1.241'ini doğru şekilde sınıflandırarak %92,54 duyarlılık elde etmiştir. Karışıklık matrisi genel olarak değerlendirildiğinde modelin özellikle NV sınıfında güçlü performans sergilediği, buna karşın MEL sınıfında belirgin düzeyde yanlış negatif tahminlerin bulunduğu görülmektedir. Özellikle MEL sınıfının NV ile karıştırılması, bu sınıfların dermoskopik görüntülerde benzer görsel özellikler taşımasından kaynaklanabilmektedir.



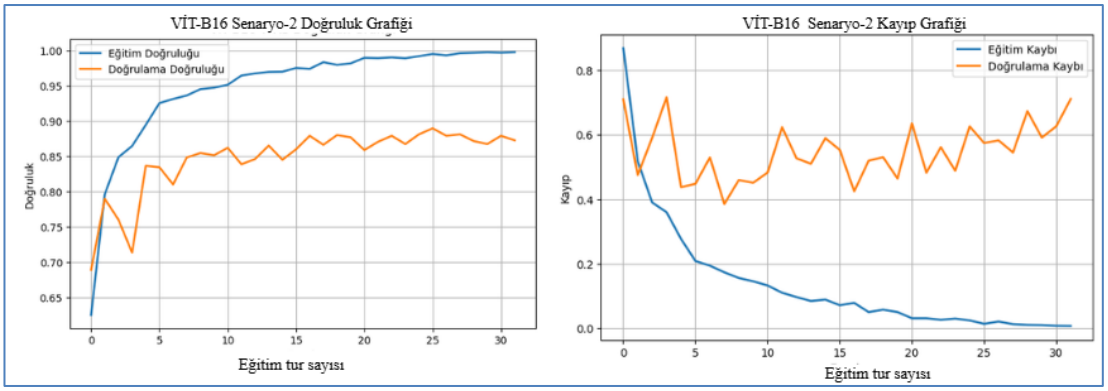
Şekil 4.14 Senaryo-1'de ViT-B16 mimarisinin karışıklık matrisi

Şekil 4.15, Senaryo-1 çerçevesinde ViT-B16 mimarisinin AİK eğrilerini sunmaktadır. Bu şekildeki eğrilerin genel olarak sol üst köşeye yakın ilerlemesi, modelin düşük yanlış pozitif oranlarında yüksek doğru pozitif oranlarına ulaşabildiğini göstermektedir. Özellikle BHK sınıfında yaklaşık 0,99 EAA değeri elde edilmesi, modelin bu sınıfı oldukça başarılı şekilde ayırt edebildiğini ortaya koymaktadır. İHDL ve NV sınıflarında da yüksek EAA değerleri gözlenirken, MEL sınıfında diğer sınıflara kıyasla daha düşük ancak başarılı bir performans elde edilmiştir. Özellikle MEL sınıfına ait eğrinin diğer sınıflara göre daha yavaş yükselmesi, bu sınıfın NV sınıfı ile görsel benzerlik göstermesinden kaynaklanabilmektedir.



Şekil 4.15 Senaryo-1'de ViT-B16 mimarisinin AİK eğrileri

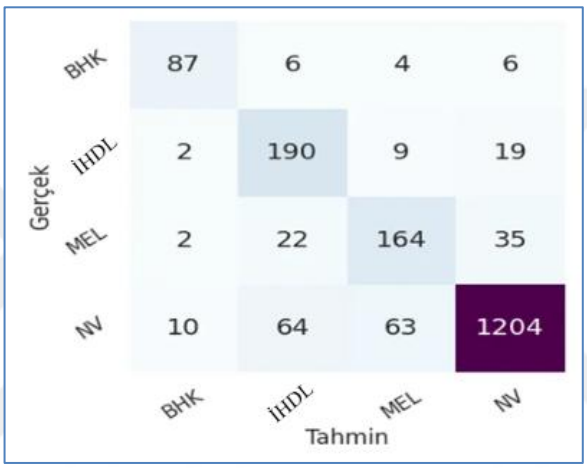
Şekil 4.16, ViT-B16 mimarisinin Senaryo-2'deki eğitimine ait doğruluk ve kayıp eğrilerini sunmaktadır. Buna göre, eğitim veri kümesindeki doğruluğun eğitim turu boyunca sürekli artış gösterdiği ve son eğitim turlarına doğru oldukça yüksek seviyelere ulaştığı görülmektedir. Doğrulama veri kümesindeki doğruluk ise başlangıçta hızlı bir yükseliş göstermesine rağmen ilerleyen eğitim turlarında dalgalı ve daha yatay bir yapı sergilemiştir. Özellikle doğrulama veri kümesindeki doğruluğun belirli bir seviyeden sonra kararlı kalması modelin doğrulama verisi üzerinde sınırlı bir iyileşme sağladığını göstermektedir. Kayıp eğrileri değerlendirildiğinde eğitim veri kümesindeki kaybın düzenli şekilde azaldığı görülürken doğrulama veri kümesindeki kaybın eğitim turları boyunca belirgin dalgalanmalar gösterdiği dikkat çekmektedir. Özellikle ilerleyen eğitim turlarında doğrulama veri kümesindeki kaybın artış eğilimi göstermesinin modelde aşırı öğrenme eğilimi oluştuğunu ortaya koymaktadır. Eğitim ve doğrulama eğrileri arasındaki farkın giderek artması da bu durumu desteklemektedir. Bu sonuçlar, Senaryo-2'nin ViT-B16 modelinde azınlık sınıfların öğrenilmesine katkı sağlamasına rağmen modelin genelleme performansını sınırlı düzeyde etkilediğini göstermektedir. Ayrıca doğrulama veri kümesindeki Makro-Ortalama F1-skorunda üst üste 6 tur boyunca minimum iyileşme sağlanamaması nedeniyle erken durdurma tekniği uygulanmış ve 30. eğitim turunda model eğitim süreci sonlanmıştır.



Şekil 4.16 Senaryo-2'de ViT-B16 mimarisinin doğruluk ve kayıp eğrileri

Şekil 4.17, Senaryo-2 çerçevesinde ViT-B16 mimarisinin karışıklık matrisini sunmaktadır. Buna göre, BHK sınıfında %84,47, İHDL sınıfında %86,36, MEL sınıfında %73,54 ve NV sınıfında %89,78 duyarlılık elde edilmiştir. Özellikle MEL sınıfında bazı örneklerin NV sınıfı olarak tahmin edildiği dikkat çekmektedir.

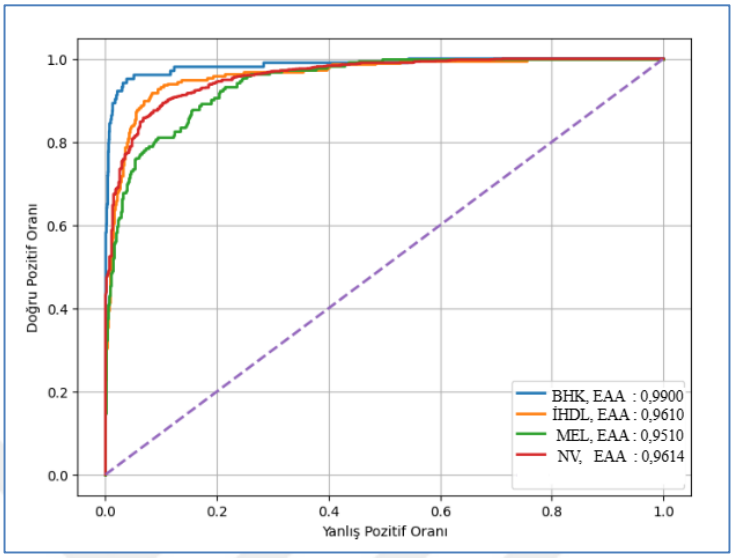
Karışıklık matrisi genel olarak değerlendirildiğinde Senaryo-2'nin özellikle İHDL ve MEL sınıflarında model performansını iyileştirdiği görülmektedir. Senaryo-1'e kıyasla MEL sınıfındaki doğru tahmin sayısının arttığı ve NV ile olan karışmaların azaldığı gözlenmiştir. Bununla birlikte NV sınıfında bazı örneklerin İHDL ve MEL olarak tahmin edilmesi, modelin azınlık sınıflara daha fazla odaklanmasından kaynaklanabilmektedir. Genel olarak değerlendirildiğinde Senaryo-2, ViT-B16 mimarisinde daha dengeli bir sınıflandırma performansı elde edilmesine katkı sağlamıştır.



Şekil 4.17 Senaryo-2'de ViT-B16 mimarisinin karışıklık matrisi

Şekil 4.18, Senaryo-2 çerçevesinde ViT-B16 mimarisinin AİK eğrilerini sunmaktadır. Bu eğrilerin genel olarak sol üst köşeye yakın ilerlemesi, modelin düşük yanlış pozitif oranlarında yüksek doğru pozitif oranlarına ulaşabildiğini göstermektedir. Özellikle BHK sınıfında yaklaşık 0,99 EAA değeri elde edilmesi, modelin bu sınıfı oldukça başarılı şekilde ayırt edebildiğini ortaya koymaktadır. İHDL ve NV sınıflarında yaklaşık 0,96 seviyelerinde yüksek EAA değerleri elde edilirken, MEL sınıfında diğer sınıflara kıyasla daha düşük ancak başarılı bir performans gözlenmiştir. Özellikle MEL sınıfına ait eğrinin diğer sınıflara göre daha yavaş yükselmesi, bu sınıfın dermoskopik görüntülerde NV sınıfı ile benzer görsel özellikler taşımasından kaynaklanabilmektedir. Bununla birlikte Senaryo-2 ile birlikte MEL sınıfına ait eğrinin Senaryo-1'e kıyasla daha hızlı yükseldiği ve daha yüksek ayırt edicilik performansına ulaştığı dikkat çekmektedir. Bu durum Senaryo 2'nin azınlık sınıflara daha fazla odaklanmasına katkı sağladığını göstermektedir. Eğrilerin rastgele tahmin doğrusundan belirgin şekilde uzak olması ise ViT-B16 mimarisinin deneysel

çalışmalar için oluşturulan dört sınıflı veri kümesinde başarılı ve güvenilir bir sınıflandırma gerçekleştirdiğini ortaya koymaktadır.



Şekil 4.18 Senaryo-2'de ViT-B16 mimarisinin AİK eğrileri

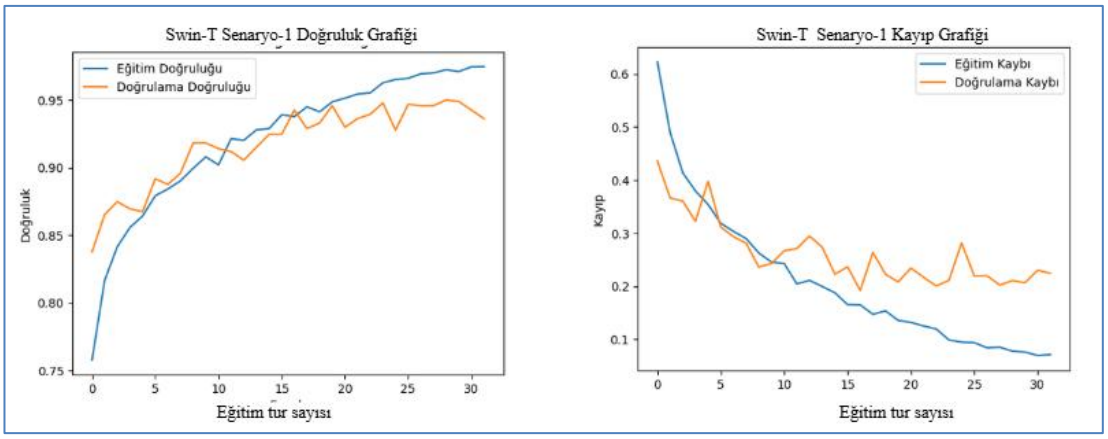
Tablo 4.4 incelendiğinde, Senaryo-2 ile elde edilen veri kümesi üzerindeki ViT-B16 mimarisinin eğitiminin Senaryo-1'e kıyasla daha başarılı sonuçlar sunduğu görülmektedir. Senaryo-1'de Makro-Ortalama Duyarlılık %80,26, Makro-Ortalama Kesinlik %79,61, Makro-Ortalama Doğruluk %94,60 ve Makro-Ortalama F1-skoru %79,84 olarak elde edilirken, Senaryo-2'de bu değerler sırasıyla %83,54; %79,28; %94,57 ve %81,07 olarak gerçekleşmiştir. Sınıf bazında değerlendirildiğinde BHK sınıfında F1-skoru %84,32'den %85,30'a, İHDL sınıfında %73,62'den %75,70'e ve MEL sınıfında %68,36'dan %70,84'e yükselmiştir. NV sınıfında ise F1-skoru %93,06'dan %92,43'e sınırlı düzeyde düşmüştür. Genel olarak değerlendirildiğinde Senaryo-2, ViT-B16 modelinde azınlık sınıfların öğrenilmesine katkı sağlamış ve daha dengeli bir sınıflandırma performansı elde edilmesini desteklemiştir.

Tablo 4.4 ViT-B16 mimarisinin sınıflandırma performans sonuçları

	Sınıf	DP	YN	DN	YP	Duyarlılık	Kesinlik	Doğruluk	F1-skoru
Senaryo-1	BHK	86	17	1.769	15	83,5	85,15	98,30	84,32
	İHDL	173	47	1.590	77	78,64	69,2	93,43	73,62
	MEL	148	75	1.602	62	66,37	70,48	92,74	68,36
	NV	1.241	100	1.617	85	92,54	93,59	93,92	93,06
	Makro-Ortalama					**80,26**	**79,61**	**94,60**	**79,84**
Senaryo-2	BHK	87	16	1.770	14	84,47	86,14	98,41	85,30
	İHDL	190	30	1.575	92	86,36	67,38	93,53	75,70
	MEL	164	59	1.588	76	73,54	68,33	92,85	70,84
	NV	1.204	137	1.630	60	89,78	95,25	93,50	92,43
	Makro-Ortalama					**83,54**	**79,28**	**94,57**	**81,07**

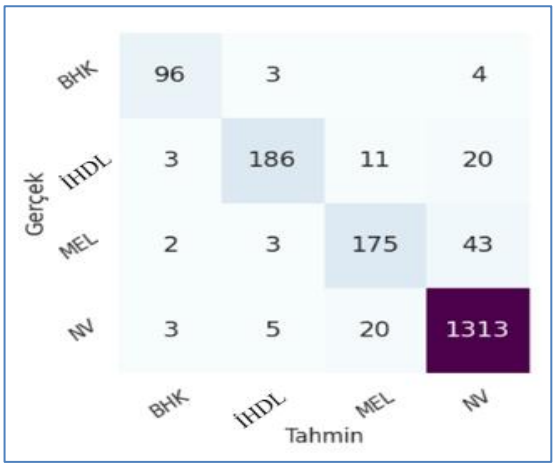
4.3.2.2 Swin-T mimarisinin eğitimi ve elde edilen sonuçlar

Şekil 4.19, Swin-T mimarisinin Senaryo-1 eğitimine ait doğruluk ve kayıp eğrilerini sunmaktadır. Buna göre, eğitim veri kümesi üzerindeki doğruluk eğitim turları boyunca sürekli artış göstermiş ve son eğitim tur sayılarına doğru oldukça yüksek seviyelere ulaşmıştır. Doğrulama veri kümesi üzerindeki doğrulukta eğitim doğruluğuna yakın seviyelerde ilerlemiş ve özellikle yaklaşık 10-15. eğitim turları sonrasında model performansında belirgin bir iyileşme meydana gelmiştir. Kayıp eğrileri değerlendirildiğinde eğitim kaybının eğitim turları boyunca düzenli şekilde azaldığı doğrulama kaybının ise hafif dalgalı ancak genel olarak kararlı bir yapı sergilediği görülmekle birlikte doğrulama veri kümesindeki Makro-Ortalama F1-skorunda üst üste 6 tur boyunca minimum iyileşme sağlanamaması nedeniyle erken durdurma tekniği uygulanmış ve 30. eğitim turunda Swin-T modelinin eğitim süreci sonlanmıştır.



Şekil 4.19 Senaryo-1'de Swin-T mimarisinin doğruluk ve kayıp eğrileri

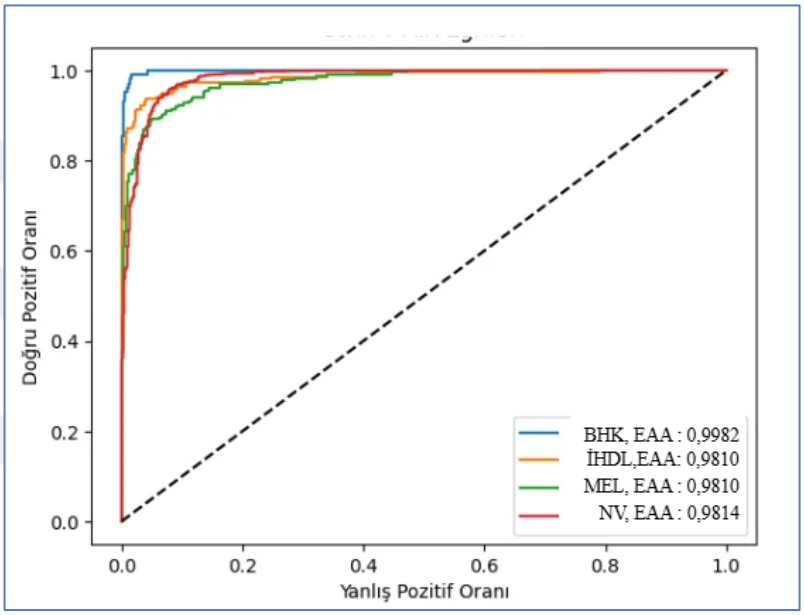
Şekil 4.20, Senaryo-1 çerçevesinde Swin-T mimarisinin karışıklık matrisini sunmaktadır. Buna göre, BHK sınıfında yer alan 103 örneğin 96'sı doğru sınıflandırılmış ve yaklaşık %93,2 duyarlılık elde edilmiştir. İHDL sınıfında ise 220 örneğin 186'sı doğru tahmin edilerek yaklaşık %84,5 duyarlılık sağlanmıştır. MEL sınıfında 223 örneğin 175'i doğru sınıflandırılmış ve yaklaşık %78,5 duyarlılık elde edilirken özellikle 43 örneğin NV sınıfı olarak tahmin edilmesi dikkat çekmiştir. NV sınıfında ise model oldukça yüksek performans göstermiş ve 1.341 örneğin 1.313'ünü doğru sınıflandırarak yaklaşık %97,9 duyarlılık elde etmiştir.



Şekil 4.20 Senaryo-1'de Swin-T mimarisinin karışıklık matrisi

Şekil 4.21, Senaryo-1 çerçevesinde Swin-T mimarisinin AİK eğrilerini sunmaktadır. Bu şekildeki eğrilerin sol üst köşeye çok yakın ilerlemesi, modelin düşük yanlış pozitif oranlarında yüksek doğru pozitif oranlarına ulaşabildiğini göstermektedir. Özellikle BHK sınıfında yaklaşık 1,00 EAA değeri elde edilmesi, modelin bu sınıfı neredeyse

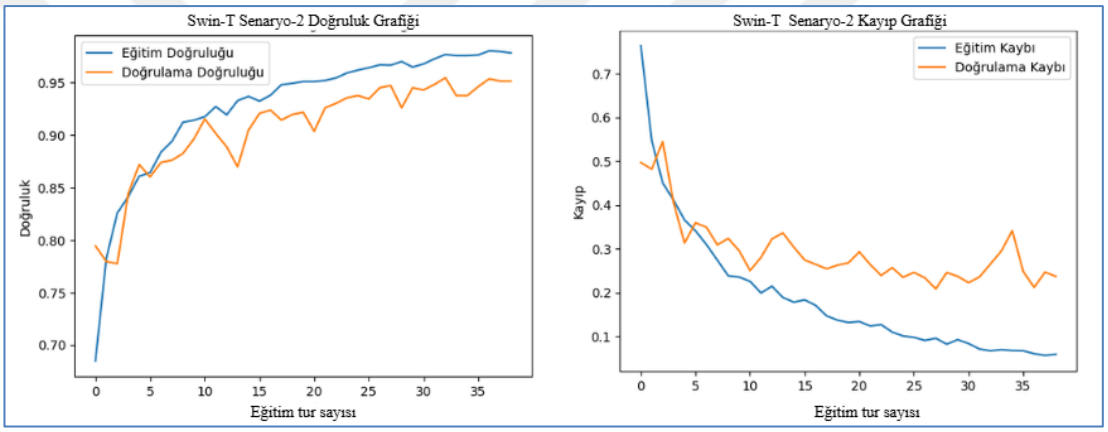
hatasız şekilde ayırt edebildiğini ortaya koymaktadır. İHDL, MEL ve NV sınıflarında da yaklaşık 0,98 seviyelerinde yüksek EAA değerleri elde edilmesi, modelin tüm sınıflarda dengeli ve güçlü bir sınıflandırma performansı sergilediğini göstermektedir. Özellikle MEL sınıfında diğer modellere kıyasla daha yüksek ayırt edicilik performansı elde edilmesi, Swin-T mimarisinin sınıflar arasındaki çok küçük görsel farklılıkları daha başarılı şekilde öğrenebildiğini ve ayırt edebildiğini ortaya koymaktadır.



Şekil 4.21 Senaryo-1'de Swin-T mimarisinin AİK eğrileri

Şekil 4.22, Swin-T mimarisinin Senaryo-2'deki eğitimine ait doğruluk ve kayıp eğrilerini sunmaktadır. Buna göre, eğitim süreci boyunca bu mimarinin kararlı ve düzenli bir öğrenme davranışı sergilediği görülmektedir. Eğitim veri kümesi üzerindeki doğruluk eğitim turları boyunca sürekli artmış ve son eğitim turlarına doğru yüksek seviyelere ulaşmıştır. Doğrulama veri kümesindeki doğruluk, başlangıçtan itibaren yükselmiş ve eğitim doğruluğuna yakın seviyelerde seyretmiştir. Özellikle yaklaşık 8-12. eğitim turları sonrasında model performansında belirgin bir iyileşme gözlenmiştir. Eğitim ve doğrulama veri kümelerindeki doğruluk eğrilerinin birbirine yakın ilerlemesi, modelin başarılı bir genelleme performansı sergilediğini göstermektedir. Kayıp eğrileri değerlendirildiğinde eğitim veri kümesindeki kaybın eğitim turları boyunca düzenli şekilde azaldığı görülürken doğrulama veri kümesindeki kaybın başlangıçta hızlı bir düşüş gösterdiği ve ilerleyen eğitim

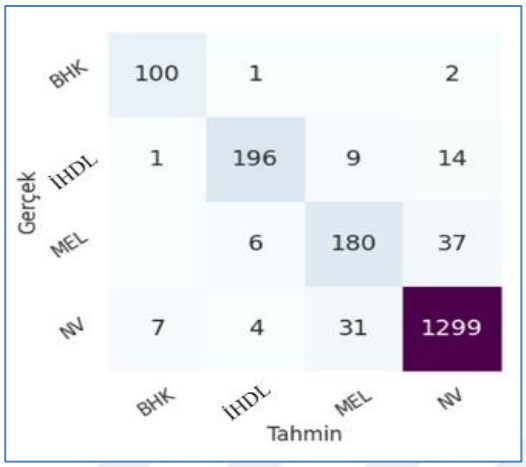
turlarında hafif dalgalı bir yapı sergilediği dikkat çekmektedir. Son eğitim turlarına doğru doğrulama veri kümesindeki kayıptaki küçük dalgalanmalar hafif düzeyde aşırı öğrenme eğilimine işaret etse de doğrulama veri kümesindeki kaybın düşük seviyelerde kalması ve doğrulama veri kümesindeki doğruluğun yüksek düzeyde korunması, modelin güçlü ve dengeli bir öğrenme performansı sergilediğini göstermektedir. Genel olarak değerlendirildiğinde ARÖ tekniğinin Swin-T mimarisinde sınıf dengesizliğinin etkisini azaltarak başarılı bir eğitim süreci sağladığı görülmektedir. Ayrıca doğrulama veri kümesindeki Makro-Ortalama F1-skorunda üst üste 6 tur boyunca minimum iyileşme sağlanamaması nedeniyle erken durdurma tekniği uygulanmış ve 35. eğitim turunda eğitim süreci sonlanmıştır.



Şekil 4.22 Senaryo-2'de Swin-T mimarisinin doğruluk ve kayıp eğrileri

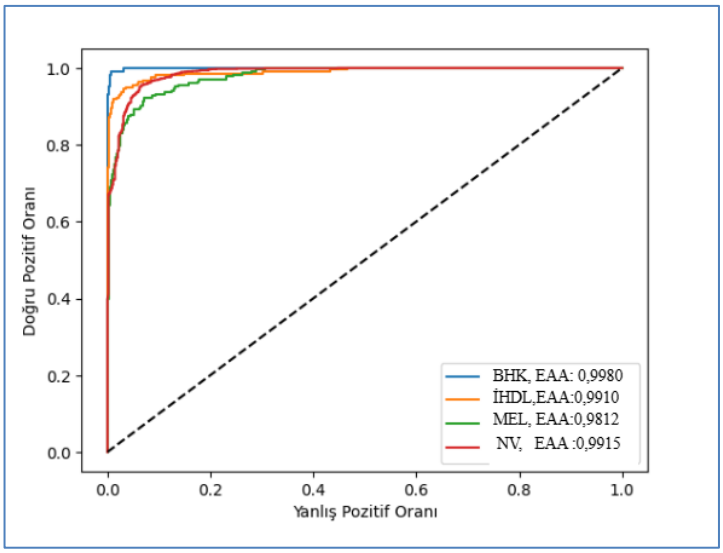
Şekil 4.23, Senaryo-2 çerçevesinde Swin-T mimarisinin karışıklık matrisini sunmaktadır. Buna göre, BHK sınıfında yer alan 103 örneğin 100'ü doğru sınıflandırılmış ve yaklaşık %97,1 duyarlılık elde edilirken, İHDL sınıfında 220 örneğin 196'sı doğru tahmin edilerek yaklaşık %89,1 duyarlılık sağlanmıştır. MEL sınıfında 223 örneğin 180'i doğru sınıflandırılmış ve yaklaşık %80,7 duyarlılık elde edilmiş, özellikle 37 örneğin NV sınıfı olarak tahmin edilmesi dikkat çekmiştir. NV sınıfında ise model 1.341 örneğin 1.299'unu doğru şekilde sınıflandırarak yaklaşık %96,9 duyarlılık elde etmiştir. Karışıklık matrisi genel olarak değerlendirildiğinde Senaryo-2 yaklaşımının özellikle BHK, İHDL ve MEL sınıflarında model performansını belirgin şekilde iyileştirdiği görülmektedir. Senaryo-1'e kıyasla MEL sınıfındaki doğru tahmin sayısının artması ve NV ile olan karışmaların azalması, Senaryo 2'de azınlık sınıfların öğrenilmesine olumlu katkı sağladığını göstermektedir. Genel olarak değerlendirildiğinde Swin-T mimarisinin Senaryo-2'de dört sınıflı veri

kümesi oldukça güçlü, dengeli ve başarılı bir sınıflandırma performansı sergilediği değerlendirilmektedir.



Şekil 4.23 Senaryo-2'de Swin-T mimarisinin karışıklık matrisi

Şekil 4.24, Senaryo-2 çerçevesinde Swin-T mimarisinin AİK eğrilerini sunmaktadır. Bu eğrilerin sol üst köşeye çok yakın ilerlemesi, modelin düşük yanlış pozitif oranlarında yüksek doğru pozitif oranlarına ulaşabildiğini göstermektedir. Özellikle BHK sınıfında yaklaşık 1,00 EAA değeri elde edilmesi, modelin bu sınıfı neredeyse hatasız şekilde ayırt edebildiğini ortaya koymaktadır. İHDL ve NV sınıflarında yaklaşık 0,99, MEL sınıfında ise yaklaşık 0,98 EAA değeri elde edilmesi, modelin tüm sınıflarda dengeli ve güçlü bir sınıflandırma performansı sergilediğini göstermektedir. Özellikle Senaryo-1'e kıyasla MEL ve İHDL sınıflarındaki eğrilerin daha hızlı yükselmesi, Senaryo-2 yaklaşımının azınlık sınıfların öğrenilmesine olumlu katkı sağladığını göstermektedir. Bununla birlikte eğrilerin rastgele tahmin doğrusundan belirgin şekilde uzak olması, Swin-T mimarisinin deneysel çalışmalar için oluşturulan dört sınıflı veri kümesi oldukça başarılı ve güvenilir bir sınıflandırma gerçekleştirdiğini ortaya koymaktadır. Genel olarak değerlendirildiğinde Swin-T mimarisinin hem genel doğruluk hem de sınıf bazlı ayırt edicilik açısından çalışmadaki en başarılı modellerden biri olduğu değerlendirilmektedir.



Şekil 4.24 Senaryo-2'de Swin-T mimarisinin AİK eğrileri

Tablo 4.5 incelendiğinde, Swin-T mimarisinde Senaryo-2'nin Senaryo-1'e kıyasla genel performansı artırdığı görülmektedir. Senaryo-1'de Makro-Ortalama Duyarlılık %88,54, Makro-Ortalama Kesinlik %91,71, Makro-Ortalama Doğruluk %97,40 ve Makro-Ortalama F1-skoru %90,02 olarak elde edilirken, Senaryo-2'de bu değerler sırasıyla %90,94, %91,30, %97,54 ve %91,08 olarak gerçekleşmiştir. Sınıf bazında değerlendirildiğinde BHK sınıfında F1-skoru %92,75'ten %94,79'a, İHDL sınıfında %89,21'den %91,80'e yükselmiştir. MEL sınıfında F1-skoru %81,59'dan %81,27'ye çok sınırlı düzeyde düşse de duyarlılık değeri %78,48'den %80,72'ye çıkmıştır. NV sınıfında ise F1-skoru %96,51'den %96,47'ye çok düşük bir düşüş olmakla birlikte yakın seviyededir denilebilir. Genel olarak değerlendirildiğinde Senaryo-2, Swin-T mimarisinde sınıf dengesizliğinin etkisini azaltarak özellikle azınlık sınıflarda daha dengeli ve güçlü bir sınıflandırma performansı sağlamıştır.

Tablo 4.5 Swin-T mimarisinin sınıflandırma performans sonuçları

	Sınıf	**DP**	**YN**	**DN**	**YP**	**Duyarlılık**	**Kesinlik**	**Doğruluk**	**F1-skoru**
Senaryo-1	BHK	96	7	1.776	8	93,2	92,31	99,21	92,75
	İHDL	186	34	1.656	11	84,55	94,42	97,62	89,21
	MEL	175	48	1.633	31	78,48	84,95	95,81	81,59
	NV	1.313	28	1.725	67	97,91	95,14	96,97	96,51
	Makro-Ortalama					**88,54**	**91,71**	**97,4**	**90,02**
Senaryo-2	BHK	100	3	1.776	8	97,09	92,59	99,42	94,79
	İHDL	196	24	1.656	11	89,09	94,69	98,15	91,8
	MEL	180	43	1.624	40	80,72	81,82	95,6	81,27
	NV	1299	42	1.739	53	96,87	96,08	96,97	96,47
	Makro-Ortalama					**90,94**	**91,3**	**97,54**	**91,08**

5. TARTIŞMA

Bu tez çalışmasında elde edilen bulgular, UCGİB 2018 veri kümesi üzerinde raporlanan literatür çalışmaları ile birlikte değerlendirildiğinde, dermoskopik görüntü sınıflandırma başarısının yalnızca mimarisine değil aynı zamanda veri dengeleme ve eğitim stratejilerine de bağlı olduğu görülmektedir.

Eğitim eğrileri incelendiğinde ViT-B16 mimarisinde doğrulama kaybındaki dalgalanmaların daha belirgin olduğu ve modelin aşırı öğrenmeye daha yatkın bir yapı sergilediği görülürken, Swin-T mimarisinin daha kararlı bir öğrenme davranışı gösterdiği dikkat çekmektedir. Karışıklık matrisleri değerlendirildiğinde her iki modelde de NV sınıfında yüksek başarı elde edilmesine rağmen, ViT-B16 mimarisinde MEL ve İHDL sınıflarında daha fazla sınıf karışıklığı oluştuğu görülmektedir. Swin-T mimarisinde ise özellikle BHK ve İHDL sınıflarında daha yüksek duyarlılık ve F1-skoru değerleri elde edilmiştir.

Bu çalışmada EfficientNet-B4 mimarisi Senaryo-1'de %94,38 Makro-Ortalama Doğruluk ve %77,91 Makro-Ortalama F1-skoru sunarken, Senaryo-2'de Makro-Ortalama Doğruluk %95,71'e ve Makro-Ortalama F1-skoru %83,74'e yükselmiştir. Benzer şekilde ConvNeXt-Tiny mimarisinde Senaryo-2'de Makro-Ortalama F1-skorunun %85,51'e yükseldiği görülmüştür. Elde edilen sonuçlar, literatürde bildirilen görüntü dönüşümü ve dengeleme stratejilerinin ESA mimarileri üzerindeki olumlu etkisini desteklemektedir. Bununla birlikte Senaryo-2 yaklaşımının her ESA mimarilerinde aynı düzeyde iyileşme sağlamadığı tespit edilmiştir.

ViT-B16 mimarisinde Senaryo-1'de %79,84 Makro-Ortalama F1-skoru elde edilirken Senaryo-2'de Makro-Ortalama F1-skoru %81,07'ye yükselmiştir. Swin-T mimarisinde ise Senaryo-1'de %90,02 Makro-Ortalama F1-skoru elde edilmiş, Senaryo-2'de %91,08 Makro-Ortalama F1-skoru olarak gerçekleşmiştir. Bu temel ölçütün yanı sıra diğer metriklerdeki iyileşme ve değişimlerde ilgili tablolarda ayrıca sunulmuştur. Bu sonuçlar, literatürde bildirilen dönüştürücü tabanlı çalışmalar ile uyumlu olup özellikle Swin-T mimarisinin yüksek ayırt edici performans sergilediğini göstermektedir.

Ayrıca AİK eğrileri incelendiğinde Swin-T mimarisinin tüm sınıflarda yaklaşık 0,98–1,00 aralığında AİK değerleri üreterek daha güçlü ayırt edici performans sergilediği belirlenmiştir.

Genel olarak, MEL ve İHDL sınıflarında belirli düzeyde sınıf karışıklıkları devam etmektedir. Buna rağmen Senaryo-2'de duyarlılık ve F1-skoru değerlerini artırarak daha dengeli bir sınıflandırma performansı sağladığı gözlenmiştir. Senaryo-2'de sınıf dengesizliğinin etkisi azalarak hem ESA mimarileri hem de dönüştürücü mimarilerinin performans artışı sağladığı görülmüştür. Bununla birlikte Swin-T mimarisinin, dermoskopik görüntülerdeki renk, doku ve yapısal örüntülerdeki küçük farklılıkları öğrenmede ESA mimarilerine kıyasla daha başarılı olduğu belirlenmiştir. Bunun nedeninin Swin-T mimarisinin görüntüdeki yerel ayrıntıları ve genel yapısal özellikleri birlikte değerlendirebilmesinden kaynaklandığı değerlendirilmektedir.

Bu çalışmanın sınırlılıkları arasında, sınıf dengesizliğinin giderilmesinde yalnızca ARÖ yönteminin kullanılması, değerlendirmelerin tek bir veri seti üzerinde gerçekleştirilmesi ve analizlerin dört cilt lezyonu sınıfı ile sınırlandırılması yer almaktadır. Bu nedenle elde edilen sonuçlar, çalışmanın kapsamı doğrultusunda yorumlanmalıdır.

Literatürde ESA mimarileri ile gerçekleştirilen çalışmalarda doğruluk değerlerinin genel olarak %86–99 aralığında değiştiği raporlanmıştır. Bu çalışmalar, yalnızca model mimarisinin değil, veri seti üzerindeki dengesizliklerin giderilmesi ve uygun eğitim stratejilerinin uygulanmasının da sınıflandırma başarısında önemli rol oynadığı görülmektedir. Özellikle veri dengeleme, öğrenim aktarımı ve topluluk öğrenmesi gibi yaklaşımların ESA mimarilerinin genelleme yeteneğini artırdığı ve sınıflar arasındaki performans farkını azaltabildiği anlaşılmaktadır. Bu durum, cilt lezyonu sınıflandırma problemlerinde model performansının yalnızca ağ mimarisine değil, aynı zamanda veri işleme ve eğitim stratejilerine de önemli ölçüde bağlı olduğunu göstermektedir. Özellikle Harangi vd. dengeli doğruluk yaklaşımı ile %88 doğruluk elde ederken (Harangi vd., 2020), Thwin ve Park aşırı örnekleme yöntemi ile %97 doğruluk bildirmiştir (Thwin ve Park., 2024). Hosny vd. ise öğrenim aktarımı kullanarak %98,7 doğruluk elde etmiştir (Hosny vd., 2020). Bununla birlikte Kassani ve Kassani veri

artırma yöntemlerinin ESA mimarilerinin başarısını artırdığını bildirmişlerdir (Kassani ve Kassani., 2019).

Literatürdeki dönüştürücü mimarilerinin yer aldığı çalışmalarda ise dikkat temelli yapıların dermoskopik görüntü sınıflandırmasında oldukça başarılı sonuçlar üretebildiği görülmektedir. Yang vd. dönüştürücü mimarileri ile %94,1 doğruluk elde ederken (Yang vd., 2023), Tang vd. tanıttıkları SkinSwinViT ile %97,8 doğruluk elde etmişlerdir (Tang vd., 2024). Benzer şekilde Himel vd. (2024), veri dönüşümleri ve segmentasyon destekli ön işleme adımları ile dönüştürücü mimarileri performansının artırılabildiğini göstermiştir. Ayrıca Nie vd. hibrit dönüştürücü mimarilerinde yerel ve küresel özelliklerin birlikte öğrenilebildiğini belirtmiştir (Nie vd., 2022). Ayrıca AbuAlkebash vd. (2025) ve Li vd. (2025) tarafından önerilen hibrit mimarilerde, dikkat mekanizması ile farklı özellik temsillerinin bir araya getirilmesinin performansı artırdığı bildirilmiştir. Literatürde dönüştürücü mimarileri birlikte değerlendirildiğinde, dönüştürücü mimarilerin özellikle uzun menzilli bağımlılıkları modelleyebilme ve görüntünün farklı bölgeleri arasındaki ilişkileri öğrenebilme yetenekleri sayesinde dermoskopik görüntü sınıflandırmasında güçlü bir alternatif oluşturduğu görülmektedir. Bununla birlikte, elde edilen başarıların yalnızca mimari yapıdan değil, veri önişleme adımları, veri dönüşümleri ve veri dengeleme stratejilerinden önemli ölçüde etkilendiği anlaşılmaktadır.

6. SONUÇ

Bu çalışmada, UCGİB 2018 veri kümesindeki dört sınıf üzerinde ESA mimarilerinin ve dönüştürücü mimarilerinin derin öğrenme modellerinin dermoskopik cilt lezyonu sınıflandırma performansları karşılaştırılmıştır. Deneysel çalışmalar kapsamında EfficientNet-B4, ConvNeXt-Tiny, ViT-B16 ve Swin-T mimarileri eğitim, doğrulama ve test olmak üzere aynı veri alt kümeleri ve benzer deneysel koşullar altında değerlendirilmiştir. Elde edilen deneysel sonuçlar, önceden eğitilmiş derin öğrenme modellerinin dermoskopik görüntü sınıflandırmasında yüksek performans sağlayabildiğini göstermiştir. Özellikle sınıf dengesizliğinin bulunduğu veri kümelerinde yalnızca Makro-Ortalama Doğruluk metriğinin yeterli olmadığı, Makro-Ortalama F1-skorunun model performansını değerlendirmede daha anlamlı sonuçlar sunduğu tespit edilmiştir.

Karışıklık matrisleri ve AİK eğrileri incelendiğinde tüm mimarilerin NV sınıfında yüksek başarı elde ettiği görülmüştür. Buna karşılık MEL ve BK sınıflarında belirli düzeyde sınıf karışıklıklarının devam ettiği görülmüştür. Özellikle azınlık sınıflarında Senaryo-2'nin duyarlılık ve Makro-Ortalama F1-skoru değerleri artarak daha dengeli bir sınıflandırma performansı sağladığı gözlenmiştir.

ESA mimarileri incelendiğinde, Senaryo-2'de sınıf dengesizliğinin etkisini azalarak mimari performansını genel olarak iyileştirdiği görülmüştür. EfficientNet-B4 mimarisinde Senaryo-1'de %77,91 Makro-Ortalama F1-skoru elde edilirken, Senaryo-2'de bu değer %83,74'e yükselmiştir. Benzer şekilde ConvNeXt-Tiny mimarisinde Makro-Ortalama F1-skoru %85,03'ten %85,51'e yükselmiştir. Özellikle BHK, İHDL ve MEL sınıflarında Makro-Ortalama Duyarlılık ve Makro-Ortalama F1-skoru değerlerinde artış sağlandığı gözlenmiştir. Bununla birlikte Senaryo-2 yaklaşımının her bir mimaride farklı oranlarda iyileşme sağladığı görülmüştür.

Dönüştürücü mimarileri değerlendirildiğinde ise Swin-T mimarisinin ViT-B16 mimarisine kıyasla daha kararlı bir öğrenme davranışı sergilediği ve daha yüksek sınıflandırma performansı elde ettiği görülmüştür. ViT-B16 mimarisinde Makro-Ortalama F1-skoru Senaryo1'de %79,84 iken Senaryo-2'de %81,07'ye yükselmiştir.

Swin-T mimarisinde ise Senaryo-1'de %90,02 Makro-Ortalama F1-skoru elde edilirken, Senaryo-2'de bu değer %91,08'e ulaşmıştır. Ayrıca Swin-T mimarisi %97,54 Makro-Ortalama doğruluk ölçümü ile çalışmanın en başarılı modeli olmuştur.

Genel olarak değerlendirildiğinde, dönüştürücü mimarilerinin ESA mimarilerine kıyasla daha güçlü özellik öğrenme yeteneğine sahip olduğu ve dermoskopik görüntü sınıflandırmasında daha başarılı sonuçlar üretebildiği sonucuna ulaşılmıştır. Özellikle Swin-T mimarisinin hem Makro-Ortalama Doğruluk hem de Makro-Ortalama F1-skoru açısından diğer mimarilere göre üstün performans gösterdiği belirlenmiştir. Sonuç olarak, uygun veri dengeleme yöntemleri ile desteklenen dönüştürücü mimarilerinin dermoskopik cilt lezyonu sınıflandırmasında güvenilir ve yüksek performanslı bilgisayar destekli tanı uygulamalarının geliştirilmesine katkı sağlayabileceği değerlendirilmektedir. Özellikle Swin-T modelinin elde ettiği sonuçlar, dönüştürücü mimarilerinin yaklaşımların sınıflar arasındaki ince görsel farklılıkların belirlenmesinde etkili olduğunu ortaya koymaktadır. Bu nedenle dönüştürücü mimarilerin dermatolojik görüntü analizi alanında önemli bir potansiyele sahip olduğu değerlendirilmektedir.

Gelecek çalışmalarda farklı görüntü dönüşümleri ve hibrit mimariler ile tanı doğruluğunun daha da artırılabileceği değerlendirilmektedir. Ayrıca farklı veri kümeleri üzerinde gerçekleştirilecek model doğrulama çalışmaları ile modellerin genelleme yeteneklerinin daha kapsamlı şekilde değerlendirilmesi sağlanabilir. Bunun yanında açıklanabilir yapay zekâ yöntemlerinin kullanılması, derin öğrenme modellerinin karar mekanizmalarının daha iyi anlaşılmasına katkı sağlayabilir.

KAYNAKLAR

Abbasi, N. R., Shaw, H. M., Rigel, D. S., Friedman, R. J., McCarthy, W. H., Osman, I., Kopf, A. W., & Polsky, D. (2004). Early Diagnosis of Cutaneous Melanoma: Revisiting the ABCD Criteria. *JAMA*, *292*(22), 2771.

AbuAlkebash, H., Saleh, R. A. A., & Ertunç, H. M. (2025). Automated explainable deep learning framework for multiclass skin cancer detection and classification using hybrid YOLOv8 and vision transformer (ViT). *Biomedical Signal Processing and Control*, *108*, 107934.

Apalla, Z., Nashan, D., Weller, R. B., & Castellsagué, X. (2017). Skin Cancer: Epidemiology, Disease Burden, Pathophysiology, Diagnosis, and Therapeutic Approaches. *Dermatology and Therapy*, *7*(1), 5-19.

Banerjee, K., C., V., Gupta, R., Vyas, K., H., A., & Mishra, B. (2021). Exploring Alternatives to Softmax Function: *Proceedings of the 2nd International Conference on Deep Learning Theory and Applications*, 81-86.

Brinker, T. J., Hekler, A., Enk, A. H., Klode, J., Hauschild, A., Berking, C., Schilling, B., Haferkamp, S., Schadendorf, D., Holland-Letz, T., Utikal, J. S., Von Kalle, C., Ludwig-Peitsch, W., Sirokay, J., Heinzerling, L., Albrecht, M., Baratella, K., Bischof, L., Chorti, E., … Schrüfer, P. (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.

Cabo, H., & Lallas, A. (2018). Nevi. In H. Cabo, A. Lallas (Ed.), *Comprehensive Atlas of Dermatoscopy Cases* (pp. 5-17). Springer International Publishing.

Codella, N., Rotemberg, V., Tschandl, P., Celebi, M. E., Dusza, S., Gutman, D., Helba, B., Kalloo, A., Liopyris, K., Marchetti, M., Kittler, H., & Halpern, A. (2019). *Skin Lesion Analysis Toward Melanoma Detection 2018: A Challenge Hosted by the International Skin Imaging Collaboration (ISIC)* (arXiv:1902.03368).

Dinnes, J., Deeks, J. J., Saleh, D., Chuchu, N., Bayliss, S. E., Patel, L., Davenport, C., Takwoingi, Y., Godfrey, K., Matin, R. N., Patalay, R., Williams, H. C., & Cochrane Skin Cancer Diagnostic Test Accuracy Group. (2018). Reflectance confocal microscopy for diagnosing cutaneous melanoma in adults. *Cochrane Database of Systematic Reviews*.

Dosovitskiy, A., Beyer, L., Kolesnikov, A., Weissenborn, D., Zhai, X., Unterthiner, T., Dehghani, M., Minderer, M., Heigold, G., Gelly, S., Uszkoreit, J., & Houlsby, N. (2020). *An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale* (Versiyon 2). arXiv.

Efraimidis, P. S., & Spirakis, P. G. (2006). Weighted random sampling with a reservoir. *Information Processing Letters*, *97*(5), 181-185.

Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, *542*(7639), 115-118.

Fabbrocini, G., Triassi, M., Mauriello, M. C., Torre, G., Annunziata, M. C., Vita, V. D., Pastore, F., D'Arco, V., & Monfrecola, G. (2010). Epidemiology of Skin Cancer: Role of Some Environmental Factors. *Cancers*, *2*(4), 1980-1989.

Gandini, S., Sera, F., Cattaruzza, M. S., Pasquini, P., Zanetti, R., Masini, C., Boyle, P., & Melchi, C. F. (2005). Meta-analysis of risk factors for cutaneous melanoma: III. Family history, actinic damage and phenotypic factors. *European Journal of Cancer*, *41*(14), 2040-2059.

Garbe, C., & Leiter, U. (2009). Melanoma epidemiology and trends. *Clinics in Dermatology, Melanoma and Pigmented Lesions, Part 1*, *27*(1), 3-9.

Govindu, S., Devi, O. R., Sitharam, M., Koreddi, V., Kumar, M. K., & Sunitha, M. (2026). Cutting-edge CNN-based skin cancer detection with batch normalization and advanced imbalance learning for superior medical image classification. *Biomedical Signal Processing and Control*, *113*, 108929.

Guy, G. P., Machlin, S. R., Ekwueme, D. U., & Yabroff, K. R. (2015). Prevalence and Costs of Skin Cancer Treatment in the U.S., 2002−2006 and 2007−2011. *American Journal of Preventive Medicine*, *48*(2), 183-187.

Hafner, C., & Vogt, T. (2008). Seborrheic keratosis. *JDDG: Journal Der Deutschen Dermatologischen Gesellschaft*, *6*(8), 664-677.

Harangi, B., Baran, A., & Hajdu, A. (2020). Assisted deep learning framework for multi-class skin lesion classification considering a binary classification support. *Biomedical Signal Processing and Control*, *62*, 102041.

Himel, G. M. S., Islam, Md. M., Al-Aff, Kh. A., Karim, S. I., & Sikder, Md. K. U. (2024). Skin Cancer Segmentation and Classification Using Vision Transformer for Automatic Analysis in Dermatoscopy-Based Noninvasive Digital System. *International Journal of Biomedical Imaging*, *2024*, 1-18.

Hosny, K. M., Kassem, M. A., & Fouad, M. M. (2020). Classification of Skin Lesions into Seven Classes Using Transfer Learning with AlexNet. *Journal of Digital Imaging*, *33*(5), 1325-1334.

Hosseinzadeh Kassani, S., & Hosseinzadeh Kassani, P. (2019). A comparative study of deep learning architectures on melanoma detection. *Tissue and Cell*, *58*, 76-83.

International Skin Imaging Collaboration. (2018). *ISIC 2018: Skin lesion analysis toward melanoma detection challenge*. https://challenge.isic-archive.com/landing/2018/, Erişim Tarihi: 12.05.2026

Ishikawa, M., Phung, H. M., Dumrongphuttidecha, T., & Sada, A. (2025). New insights into signaling networks coordinating epidermal stem cell regulation in skin regeneration and aging. *Current Opinion in Cell Biology*, *97*, 102594.

Kalloniati, E., Cavouras, D., Plachouri, K. M., Geropoulou, E., Sakellaropoulos, G., & Georgiou, S. (2021). Clinical, dermoscopic and histological assessment of melanocytic lesions: A comparative study of the accuracy of the diagnostic methods. *Hippokratia*, *25*(4), 156-161.

Keskinkaya, Z., Kaya, Ö., Işık Mermutlu, S., Garipcan Karaemir, H., & Oğuz Kılıç, S. (2025). Clinical and dermoscopic patterns of acquired melanocytic nevi in children and adolescents: A cross-sectional study from Turkey. *Anais Brasileiros de Dermatologia*, *100*(1), 22-30.

Kingma, D. P., & Ba, J. (2014). *Adam: A Method for Stochastic Optimization* (Versiyon 9).

Kittler, H., Pehamberger, H., Wolff, K., & Binder, M. (2002). Diagnostic accuracy of dermoscopy. *The Lancet Oncology*, *3*(3), 159-165.

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436-444.

Li, M., Jiang, Y., Cao, G., Xu, T., & Guo, R. (2025). HyperFusionNet combines vision transformer for early melanoma detection and precise lesion segmentation. *Scientific Reports*, *16*(1), 505.

Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., Van Der Laak, J. A. W. M., Van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. *Medical Image Analysis*, *42*, 60-88.

Liu, Z., Lin, Y., Cao, Y., Hu, H., Wei, Y., Zhang, Z., Lin, S., & Guo, B. (2021). *Swin Transformer: Hierarchical Vision Transformer using Shifted Windows* (Versiyon 2).

Liu, Z., Mao, H., Wu, C.-Y., Feichtenhofer, C., Darrell, T., & Xie, S. (2022). *A ConvNet for the 2020s* (Versiyon 2).

Long, G. V., Swetter, S. M., Menzies, A. M., Gershenwald, J. E., & Scolyer, R. A. (2023). Cutaneous melanoma. *The Lancet*, *402*(10400), 485-502.

Loshchilov, I., & Hutter, F. (2016). *SGDR: Stochastic Gradient Descent with Warm Restarts* (Versiyon 5).

Loshchilov, I., & Hutter, F. (2017). *Decoupled Weight Decay Regularization* (Versiyon 3).

Mahbod, A., Schaefer, G., Wang, C., Dorffner, G., Ecker, R., & Ellinger, I. (2020). Transfer learning using a multi-scale and multi-network ensemble for skin lesion classification. *Computer Methods and Programs in Biomedicine*, *193*, 105475.

McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics, 5*(4), 115-133.

Nie, Y., Sommella, P., Carratù, M., O'Nils, M., & Lundgren, J. (2022). A Deep CNN Transformer Hybrid Model for Skin Lesion Classification of Dermoscopic Images Using Focal Loss. *Diagnostics, 13*(1), 72.

Noiles, K., & Vender, R. (2008). Are All Seborrheic Keratoses Benign? Review of the Typical Lesion and Its Variants. *Journal of Cutaneous Medicine and Surgery, 12*(5), 203-210.

Nour, M. A., Elnokrashy, A. F., & Mabrouk, M. S. (2025). Systematic Review of Swin Transformer Architectures for Medical Image Classification. *2025 Twelfth International Conference on Intelligent Computing and Information Systems (ICICIS)*, 275-280.

Pan, S. J., & Yang, Q. (2010). A Survey on Transfer Learning. *IEEE Transactions on Knowledge and Data Engineering, 22*(10), 1345-1359.

Ranjan, V., Chaurasia, K., & Singh, J. (2026). Enhancing skin cancer classification with Soft Attention and genetic algorithm-optimized ensemble learning. *Image and Vision Computing, 166*, 105848.

Raza, S. A. (2025). Emerging Trends in Global Cancer Epidemiology. *Cancers, 17*(9).

Ruder, S. (2016). An overview of gradient descent optimization algorithms (Version 2). arXiv:1609.04747.

Schadendorf, D., Akkooi, A. C. J. van, Berking, C., Griewank, K. G., Gutzmer, R., Hauschild, A., Stang, A., Roesch, A., & Ugurel, S. (2018). Melanoma. *The Lancet, 392*(10151), 971-984.

Schmidhuber, J. (2015). Deep learning in neural networks: An overview. *Neural Networks, 61*, 85-117.

Selvi S., & Shalome, A. (2025). Melanoma Detection by CNN Model with Optimal Rough Set Approximation-based Similarity Measure Classification. *Procedia Computer Science, 260*, 585-599.

Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data, 6*(1), 60.

Souto, E. B., Da Ana, R., Vieira, V., Fangueiro, J. F., Dias-Ferreira, J., Cano, A., Zielińska, A., Silva, A. M., Staszewski, R., & Karczewski, J. (2022). Non-melanoma skin cancers: Physio-pathology and role of lipid delivery systems in new chemotherapeutic treatments. *Neoplasia, 30*, 100810.

Steiner, A., Kolesnikov, A., Zhai, X., Wightman, R., Uszkoreit, J., & Beyer, L. (2021). *How to train your ViT? Data, Augmentation, and Regularization in Vision Transformers*.

Tan, M., & Le, Q. V. (2019). *EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks*.

Tang, K., Su, J., Chen, R., Huang, R., Dai, M., & Li, Y. (2024). SkinSwinViT: A Lightweight Transformer-Based Method for Multiclass Skin Lesion Classification with Enhanced Generalization Capabilities. *Applied Sciences, 14*(10), 4005.

Tas, F., & Erturk, K. (2021). Trends in the characteristics of skin melanoma in accordance with time intervals: A single Turkish tertiary referral center experience. *Journal of Cancer Research and Therapeutics*, *17*(4), 1119-1122.

Themstrup, L., & Jemec, G. B. E. (2016). Optical Coherence Tomography for Skin Cancer and Actinic Keratosis. In *Imaging in Dermatology* (pp. 59-67). Elsevier.

Thwin, S. M., & Park, H.-S. (2024). Skin Lesion Classification Using a Deep Ensemble Model. *Applied Sciences, 14*(13), 5599.

Tomak, L., & Bek, Y. (2010). İşlem karakteristik eğrisi analizi ve eğri altında kalan alanların karşılaştırılması. *Ondokuz Mayıs Üniversitesi Tıp Dergisi, 27*(2), 58-65.

Tsai, W.-X., Li, Y.-C., & Lin, C. H. (2023). Skin lesion classification based on multi-model ensemble with generated levels-of-detail images. *Biomedical Signal Processing and Control*, *85*, 105068.

Tschandl, P., Rosendahl, C., & Kittler, H. (2018). The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific Data*, *5*(1), 180161.

Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I. (2017). Attention is all you need (Version 7). arXiv:1706.03762.Venugopal, V., Raj, N. I., Nath, M. K., & Stephen, N. (2023). A deep neural network using modified EfficientNet for skin cancer detection in dermoscopic images. *Decision Analytics Journal*, *8*, 100278.

Vestergaard, M. E., Macaskill, P., Holt, P. E., & Menzies, S. W. (2008). Dermoscopy compared with naked eye examination for the diagnosis of primary melanoma: A meta-analysis of studies performed in a clinical setting. British Journal of Dermatology, 159(3), 669-676. Yang, G., Luo, S., & Greer, P. (2023). A Novel Vision Transformer Model for Skin Cancer Classification. *Neural Processing Letters*, *55*(7), 9335-9351.

Yosinski, J., Clune, J., Bengio, Y., & Lipson, H. (2014). How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems*, 27, 3320-3328.

Yu, S.-Y., Hirsch, A., Zaslavsky, O., & Cochrane, B. B. (2023). Risk factors and early prevention of skin cancer in rural older outdoor workers: A scoping review. *Geriatric Nursing*, *54*, 37-45.

Zhang, Z., & Sabuncu, M. R. (2018). *Generalized Cross Entropy Loss for Training Deep Neural Networks with Noisy Labels* (Versiyon 4). arXiv.

Zheng, C., & Sarin, K. Y. (2024). Unveiling the genetic landscape of hereditary melanoma: From susceptibility to surveillance. *Cancer Treatment and Research Communications*, *40*, 100837.