



**T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI**

YÜKSEK LİSANS TEZİ

**DİYABETİK AYAK ÜLSERLERİNİN
YAPAY ZEKA İLE TESPİTİ**

MURAT ÖZDAŞ

**Temmuz-2025
BATMAN**

T.C.
BATMAN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİ TEKNOLOJİLERİ ANA BİLİM DALI

YÜKSEK LİSANS TEZİ

DİYABETİK AYAK ÜLSERLERİNİN
YAPAY ZEKA İLE TESPİTİ

MURAT ÖZDAŞ

Danışman
Doç. Dr. Yılmaz KAYA

Diğer Jüri Yeleri

Doç. Dr. Cüneyt ÖZDEMİR

Doç. Dr. Abdulkерim ÖZTEKİN

Temmuz-2025
BATMAN

TEZ KABUL VE ONAYI

Murat ÖZDAŞ tarafından hazırlanan “Diyabetik ayak ülserlerinin yapay zeka ile tespiti” adlı tez çalışması 09/07/2025 tarihinde aşağıdaki jüri tarafından oy birliği ile Batman Üniversitesi Lisansüstü Eğitim Enstitüsü Bilgi Teknolojileri Ana Bilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Doç. Dr. Cüneyt ÖZDEMİR

.....

Danışman

Doç. Dr. Yılmaz KAYA

.....

Üye

Doç. Dr. Abdulkerim ÖZTEKİN

.....

Yukarıdaki sonucu onaylarım.

Dr. Öğr. Üyesi Ömer Murat ÖTER
Lisansüstü Eğitim Enstitüsü Müdürü

ETİK BEYANI

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını beyan eder, aksinin ortaya çıkması durumunda her türlü yasal sorumluluğu kabullendiğimi bildiririm.

ETHICAL DECLARATION

I declare that all the information in this thesis has been obtained within the framework of ethical behavior and academic rules, and that the source of any statements and information that do not belong to me in this study prepared in accordance with the thesis writing rules has been fully cited, and I declare that I accept all kinds of legal responsibility in case of any contrary situation.

Murat ÖZDAŞ
09.07.2025

ÖZET

YÜKSEK LİSANS TEZİ

DİYABETİK AYAK ÜLSERLERİNİN YAPAY ZEKA İLE TESPİTİ

Murat ÖZDAŞ

Batman Üniversitesi Lisansüstü Eğitim Enstitüsü

Bilgi Teknolojileri Ana Bilim Dalı

Danışman: Doç. Dr. Yılmaz KAYA

2025, 67 Sayfa

Diyabetik ayak ülseri (DAU), diyabet hastalarında enfeksiyon, uzuv kaybı ve mortalite oranlarını artıran ciddi bir sağlık sorunudur. Erken teşhis edilmediğinde hasta yaşam kalitesini düşürmekte ve sağlık sistemine önemli bir yük getirmektedir. Bu çalışmada, DAU'nun doğru ve erken tespiti amacıyla derin öğrenme tabanlı sınıflandırma modelleri değerlendirilmiştir. Kaggle platformundan temin edilen, uzman doktorlarca etiketlenmiş DFU görüntüleri; RegNetY-400MF, RegNetY-800MF, EfficientNet-B0 ve EfficientNet-B1 olmak üzere dört farklı evrimsel sinir ağı (CNN) mimarisi ile analiz edilmiştir. Transfer öğrenme ve veri çoğaltma yöntemleriyle model eğitimi iyileştirilmiş; kontrast artırma ve gürültü giderme gibi ön işleme adımları ile sınıflandırma başarımları artırılmıştır.

Analiz sonuçları, EfficientNet-B1 ve RegNetY-800MF modellerinin yüksek doğruluk, düşük kayıp ve güçlü genelleme yetenekleri ile öne çıktığını göstermiştir. EfficientNet-B1 modeli %99'un üzerinde doğruluk ile en başarılı sonuçları sunarken; RegNetY-800MF modeli ise hem eğitim hem test verilerinde istikrarlı bir performans sergilemiştir. RegNetY-400MF modeli eğitimde yüksek başarı elde etmesine rağmen test aşamasında dalgalanmalar yaşamıştır. EfficientNet-B0 modeli ise kompakt yapısı sayesinde düşük kaynaklı sistemlerde uygun bir alternatif olarak değerlendirilmiştir.

Tartışma bölümünde, tüm modellerin duyarlılık oranlarının %100'e yakın olduğu ve ülserli vakaların atlanmadığı belirlenmiştir. ROC eğrileri ve AUC değerleri bakımından EfficientNet-B1 ve RegNetY-800MF modelleri, klinik uygulamalarda kullanılacak güvenilir yapılar olarak öne çıkmıştır. Özgüllük oranlarının da yüksek bulunması, yanlış pozitif oranını minimize eden bir yapı sunmuştur. Sonuç olarak, bu tez çalışması, DAU tanısında yapay zekâ destekli çözümlerin hem akademik araştırmalarda hem de klinik pratikte uygulanabilirliğini ortaya koymuştur.

Anahtar Kelimeler: Yapay Zeka, Derin Öğrenme, Tıbbi Görüntüleme, Evrimsel Sinir Ağları, Sınıflandırma Modelleri, Diyabetik Ayak Ülseri, RegNet, EfficientNet

ABSTRACT

MASTER THESIS

DETECTION OF DIABETIC FOOT ULCERS USING ARTIFICIAL INTELLIGENCE

Murat ÖZDAŞ

Batman University Graduate Education Institute

Department of Information Technologies

Advisor: Assoc. Prof. Dr. Yılmaz KAYA

2025, 67 Pages

Diabetic foot ulcer (DFU) is a severe health complication in diabetic patients that significantly increases the risk of infection, limb loss, and mortality. If not diagnosed early, it substantially reduces patient quality of life and imposes a considerable burden on healthcare systems. In this study, deep learning-based classification models were evaluated for the accurate and early detection of DFU. DFU images, labeled by expert physicians and obtained from the Kaggle platform, were analyzed using four different convolutional neural network (CNN) architectures: RegNetY-400MF, RegNetY-800MF, EfficientNet-B0, and EfficientNet-B1. The training process was enhanced through transfer learning and data augmentation techniques, while image preprocessing steps such as contrast enhancement and noise reduction further improved classification performance.

The analysis results demonstrated that EfficientNet-B1 and RegNetY-800MF outperformed the others, exhibiting high accuracy, low loss, and strong generalization capabilities. The EfficientNet-B1 model achieved the highest results with an accuracy exceeding 99%, whereas RegNetY-800MF also showed consistent performance on both training and testing datasets. Although the RegNetY-400MF model achieved high success during training, it exhibited fluctuations during testing. In contrast, the EfficientNet-B0 model, with its more compact architecture, was evaluated as a suitable alternative for systems with limited computational resources.

The discussion section revealed that all models achieved sensitivity rates close to 100%, ensuring that no ulcerated cases were missed. In terms of ROC curves and AUC values, EfficientNet-B1 and RegNetY-800MF stood out as reliable structures potentially applicable in clinical settings. Moreover, the high specificity rates indicated a minimized false positive ratio. In conclusion, this thesis demonstrates that artificial intelligence-assisted solutions for DFU diagnosis are applicable in both academic research and clinical practice.

Keywords: Artificial Intelligence, Deep Learning, Medical Imaging, Convolutional Neural Networks, Classification Models, Diabetic Foot Ulcer, RegNet, EfficientNet

ÖN SÖZ

Bu tez çalışması, yalnızca akademik bir çabanın değil; aynı zamanda kalbimde taşıdığım bir vefanın ve sorumluluğun ürünüdür. Çok sevdiğim anneannemin, yıllarca ağır şeker hastalığıyla verdiği mücadeleye yakından tanıklık ettim. Onun hastalıkla geçen zorlu günleri ve ardından yaşanan kayıp, bu çalışmanın manevi ilham kaynağı oldu. Diyabetin bireyler ve toplum üzerindeki etkisini derinden hisseden biri olarak, bu tezi hazırlarken sadece bilimsel bir katkı değil, aynı zamanda bu hastalığa karşı duyduğum vicdani sorumluluğu da ortaya koymak istedim.

Diyabetin yaygınlığı gün geçtikçe artarken, onun neden olduğu komplikasyonların – özellikle diyabetik ayak ülserlerinin – erken teşhisinde yapay zekâ temelli yöntemlerin taşıdığı potansiyelin farkındayım. Bu çalışmada, derin öğrenme mimarileri aracılığıyla erken ve doğru tanıya katkı sunmak hedeflenmiştir.

Tez sürecinde bana her anlamda destek olan, bilgi birikimini ve tecrübelerini esirgemeyen değerli danışmanım Doç. Dr. Yılmaz KAYA'ya, yalnızca bu çalışmadaki rehberliğiyle değil, lisans eğitimimden bu yana bana yol gösteren duruşuyla da gönülden teşekkür ederim.

Tıp alanında teknik ve bilimsel desteklerini sunarak katkı sağlayan sevgili kardeşim, Dicle Üniversitesi Tıp Fakültesi Enfeksiyon Hastalıkları Asistanı Dr. Ömer ÖZDAŞ'a da özel olarak teşekkür ederim.

Bu süreci benimle birlikte göğüsleyen, her anımda yanımda olan sevgili eşime ve çocuklarıma da en derin sevgimle teşekkür ediyorum. Onların sabrı, sevgisi ve desteği olmadan bu yolculuk eksik kalırdı.

Bu çalışmanın, yapay zekânın tıbbi uygulamalardaki rolünü güçlendirmesi ve diyabetle mücadelede umut verici adımların atılmasına katkı sağlaması en içten dileğimdir.

Murat ÖZDAŞ
BATMAN-2025

İÇİNDEKİLER

ÖZET	V
ABSTRACT.....	VI
ÖN SÖZ	VII
İÇİNDEKİLER	VIII
ŞEKİLLER LİSTESİ	XI
1. GİRİŞ	1
1.1. Amaç	2
1.2. Kapsamı	3
1.3. Sınırlılıklar	5
2. KAYNAK ARAŞTIRMASI	1
3. MATERYAL VE YÖNTEM.....	14
3.1. Materyal	14
3.2. Metod	15
3.2.1. Yapay Zeka	15
3.2.2. Derin öğrenme	17
3.2.3. Yapay sinir ağları (Artificial Neural Networks - ANN)	18
3.2.4. Evrimsel sinir ağları (CNN)	20
3.2.4.1. CNN yapısı ve temel katmanlar	21
3.2.4.2. Evrim katmanı	21
3.2.4.3. Havuzlama katmanı	22
3.2.4.4. Tam bağlantı katmanı	23
3.2.4.5. Aktivasyon fonksiyonları	24
3.2.5. Transfer öğrenme	25
3.2.6. RegNet nedir?	26
3.2.6.1. RegNetY-400MF modeli ve özellikleri	29
3.2.6.2. RegNetY-800MF modeli ve özellikleri	31
3.2.7. EfficientNet-B0 modeli.....	33
3.2.8. EfficientNet-B1 modeli.....	35
3.2.9. Karmaşıklık matrisi ve performans metrikleri.....	36
3.2.9.1. Karmaşıklık matrisi.....	36
3.2.9.2. Performans Metrikleri.....	37
4. BULGULAR.....	40
5. SONUÇLAR VE ÖNERİLER	56
5.1. Derin Öğrenme Modellerinin Klinik Performansı Üzerine Tartışma	56
5.3. Veri Dağılımı, Eğitim-Test Oranları ve Klinik Uygulamalar Açısından Sonuçların Yorumlanması	59
5.4. Çalışmanın Eksiklikleri.....	60
5.5. Gelecek Çalışmalar İçin Öneriler	61

6. KAYNAKLAR	63
---------------------------	-----------



ÇİZELGELER/TABLolar LİSTESİ

Tablo 3.1. Performans Metrik Tablosu	36
Tablo 4.1. Performans Değerleri (%70-30 Eğitim-test seti)	53
Tablo 4.2. Farklı Eğitim-test oranları için Regnet800 modelin performansı	55



ŞEKİLLER LİSTESİ

Şekil 3.1. Veri setinden örnek görüntüler	15
Şekil 3.2. Alan Turing	16
Şekil 3.3. YZ, MÖ ve DÖ'nün Mantıksal Yapısı	17
Şekil 3.4. Biyolojik Sinir Hücresi Yapısı	19
Şekil 3.5. Yapay Sinir Hücresi Yapısı	19
Şekil 3.6. ESA'nın Temel Yapısı	20
Şekil 3.7. Evrişim Katmanı Çalışma Prensibi	22
Şekil 3.8. a)Maksimum Havuzlama b) Ortalama Havuzlama	22
Şekil 3.9. Tam Bağlantı Katmanı	24
Şekil 3.10. En sık kullanılan aktivasyon fonksiyonları	25
Şekil 3.11.RegNet Modelinin Mimari Yapısı	28
Şekil 3.12. RegNetY-400MF modelinin mimari yapısının şematik gösterimi	28
Şekil 3.13. RegNetY-800MF modelinin mimari yapısının şematik gösterimi	33
Şekil 3.14.EfficientNet Modeli	34
Şekil 3.15. EfficientNetB1 Topolojisi	36
Şekil 3.16. Karmaşıklık Matrisi Örneği	37
Şekil 3.17. Precision, Recall, and F1 Score Örneği	39
Şekil 3.18. ROC Eğrisi ve ROC-AUC Grafiği	39
Şekil 4.1. Modellere ait performans grafikleri	42
Şekil 4.2. Modellere ait yitim fonksiyonları	45
Şekil 4.3. Model performanslarına ait karışıklık matrisleri	48
Şekil 4.4. ROC eğrileri	50

SİMGELER VE KISALTMALAR

YZ	Yapay Zekâ
MÖ	Makine Öğrenmesi
DÖ	Derin Öğrenme
CNN	Convolutional Neural Network (Evrşimsel Sinir Ağı)
DAU	Diyabetik Ayak Ülseri
DFU	Diabetic Foot Ulcer (Diyabetik Ayak Ülseri)
ROI	Region of Interest (İlgili Bölge)
XAI	Explainable Artificial Intelligence (Açıklanabilir Yapay Zekâ)
AUC	Area Under Curve
F1 Skoru	Harmonik ortalama (kesinlik ve duyarlılığın ortalaması)
SGD	Stokastik Gradyan İniş
ReLU	Rectified Linear Unit (Aktivasyon Fonksiyonu)
Adam	Adaptive Moment Estimation (Optimizasyon algoritması)
TPU/GPU	Tensor/Graphical Processing Unit (İşlemciler)
IoU	Intersection over Union (Kesişim-Birleşim Oranı)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
RMSE	Root Mean Square Error (Karekök Ortalama Hata)
MCC	Matthews Correlation Coefficient
Grad-CAM	Gradient-weighted Class Activation Mapping

1.GİRİŞ

Diyabetik ayak ülserleri (DAU), diyabet hastalarında yaygın olarak görülen, kronik ve potansiyel olarak ciddi komplikasyonlara yol açabilen deri lezyonlarıdır (Ganesan ve Orgill, 2024). Diyabetin uzun dönemli etkileri arasında yer alan bu ülserler, ilerleyen evrelerde hastanede yatış, uzuv kaybı ve hatta ölüm gibi ciddi sonuçlara neden olabilir (Manjunath ve ark., 2025). Ünsal (2023) tarafından yapılan bir çalışmada, DAU gelişiminde kan dolaşımının bozulmasının ve sinir hasarının kritik rol oynadığı vurgulanmıştır.

DAU'lar genellikle periferik sinir hasarı (diyabetik nöropati) ve yetersiz kan akışı (iskemi) nedeniyle ortaya çıkmaktadır (Araújo ve ark., 2024). Sinir hasarı, hastaların ayaklarındaki ağrıyı ve basınç değişikliklerini hissetmelerini engelleyerek yara oluşumu riskini artırır (Kolachi ve ark., 2025). Aynı zamanda damar hastalıkları nedeniyle ayaktaki kan dolaşımının azalması, yaraların iyileşmesini zorlaştırır ve enfeksiyon riskini yüksek seviyelere çıkarır (Dayan, 2022). DAU'lar, hastaların günlük yaşam aktivitelerini ciddi şekilde kısıtlayan ve yürümeyi zorlaştıran bir durum olup, fiziksel hareket kısıtlamalarının yanı sıra psikolojik ve ekonomik etkileriyle de dikkat çekmektedir (Almufadi ve Alhasson, 2024). Hastalar, uzun süre hastanede kalmak zorunda kalabilir, ayak veya bacak amputasyonlarına maruz kalabilir ve hatta ölüm riskiyle karşı karşıya kalabilirler (Dhar, 2024).Diyabetik ayak ülserleri, yatkınlık ve belirtileri açısından periferik arter hastalığı (PAH) ve bası yaraları gibi hastalıklara benzerlik göstermektedir. Ancak DAU'lar, diyabete bağlı metabolik bozukluklarla daha yakından ilişkili olup, enfeksiyon riski ve iyileşme süreci açısından farklılıklar gösterir (Athira ve ark., 2024).

DAU tespiti, genellikle klinik muayene ve yara doku analiziyle gerçekleştirilmektedir. Doktorlar, yaranın büyüklüğünü, derinliğini, etkilenen doku tipini ve var olan enfeksiyon belirtilerini inceleyerek tanı koymaktadır (Kolachi ve ark., 2025). Bununla birlikte, bu geleneksel yöntemler subjektif olabilir ve farklı klinisyenler arasında değişkenlik gösterebilir.Tedavi süreci ise yaranın temizlenmesi, enfeksiyonun kontrol altına alınması, uygun yara bakımı ve kan akışını iyileştirici yaklaşımları içermektedir (Dhar, 2024). Antibiyotik tedavisi, basınç düzeyini azaltan ayakkabı veya tabanlıklar ve hiperbarik oksijen terapisi gibi yöntemler sıklıkla kullanılmaktadır (Araújo ve ark., 2024).

Ancak ileri vakalarda amputasyon gibi radikal tedavi yaklaşımlarına başvurulabilmektedir. Son yıllarda, DAU'ların tespitinde ve analizinde bilgisayarlı görüntü işleme ve derin öğrenme tekniklerinin kullanımı yaygınlaşmıştır. Yapay zeka destekli sistemler, ayak yaralarının görüntülerini analiz ederek DAU'ların erken tespit edilmesini ve hastalığın seyrinin izlenmesini sağlayabilir (Athira ve ark., 2024). Evrişimli sinir ağları (CNN) tabanlı modeller, yara dokusunu analiz ederek yaranın boyutu, derinliği ve enfeksiyon seviyesi gibi faktörleri belirleyebilir (Almufadi ve Alhasson, 2024). RegNet gibi yeni nesil derin öğrenme modelleri, geleneksel CNN modellerine göre daha yüksek hassasiyet sunmakta ve segmentasyon yöntemleri ile yara bölgesinin daha doğru belirlenmesini sağlamaktadır (Dhar, 2024).

Derin öğrenme tabanlı DAU tespit ve analiz çalışmaları, klinik karar alma süreçlerini iyileştirerek hastalara erken ve doğru tedavi uygulanmasını mümkün kılmaktadır (Manjunath ve ark., 2025). Bu tez çalışmasında, RegNet ve EfficientNet derin öğrenme modellerinin DAU tespitinde kullanımı incelenecek ve bu yöntemlerin klinik faydaları detaylandırılacaktır. Yapay zeka destekli yaklaşımların diyabetik ayak ülseri tedavisinde ve takibinde sunduğu avantajlar, bu çalışmanın odak noktasını oluşturmaktadır.

1.1. Amaç

Bu tez çalışmasının amacı, diyabetik ayak ülserlerinin RegNet ve EfficientNet modelleri kullanılarak otomatik teşhis edilmesi ve sınıflandırılmasıdır. RegNet ve EfficientNet modellerinin bu alanda sunduğu avantajlar, mevcut literatürdeki diğer CNN tabanlı yaklaşımlar ile kıyaslanarak daha derinlemesine değerlendirilecektir. Bu çalışma, derin öğrenme algoritmalarının medikal görüntü işleme alanındaki etkisini göstermek ve yeni yöntemlerin geliştirilmesine katkıda bulunmayı hedeflemektedir. Öncelikli olarak, CNN tabanlı modellerin diyabetik ayak ülserlerini yüksek doğrulukla tespit etme kapasitesi değerlendirilecektir. Literatürde yer alan bulgular, CNN modellerinin bu tür görüntülerin analizi konusunda diğer makine öğrenmesi tekniklerinden daha üstün performans gösterdiğini kanıtlamaktadır. Özellikle RegNet ve EfficientNet gibi derin CNN mimarileri, daha karmaşık ve çok katmanlı yapıları sayesinde daha yüksek doğruluk oranlarına ulaşmaktadır (Dhar, 2024). Transfer öğrenimi, bu tezde önemli bir strateji olarak kullanılacaktır. Bu yaklaşım, önceden eğitilmiş modellerin mevcut veri seti üzerinde yeniden eğitilmesi yoluyla daha hızlı ve etkin sonuçlar elde etmeyi

sağlamaktadır (Ganesan ve Orgill, 2024). Transfer öğrenimi, veri setinin sınırlı olduğu durumlarda model performansını artırmanın yanı sıra, eğitim süresini de önemli ölçüde kısaltmaktadır. Özellikle medikal görüntüleme alanında transfer öğrenimi, sıfırdan eğitim almaktan çok daha pratik ve etkili bir çözüm olarak değerlendirilmektedir.

Görüntü ön işleme tekniklerinin model performansı üzerindeki etkisi de bu çalışmanın önemli bir parçasını oluşturacaktır. Kontrast artırma, keskinleştirme ve gürültü azaltma gibi teknikler, görüntülerin kalitesini artırarak modelin daha doğru tahminlerde bulunmasını sağlamaktadır (Kolachi ve ark., 2025). Bu tür tekniklerin kullanımı, özellikle düşük kaliteli görüntüler üzerinde yapılan çalışmalarda belirgin bir iyileşme sağlamaktadır. Veri çoğaltma (data augmentation) teknikleri, bu çalışmada modelin genelleme kapasitesini artırmak amacıyla kullanılacaktır. Sınırlı veri setleri üzerinde çalışan modellerin aşırı öğrenme (overfitting) sorunu yaşama olasılığı yüksektir. Veri çoğaltma teknikleri, görüntüleri döndürme, ölçekleme ve yansıtma gibi işlemlerle çeşitlendirilerek modelin daha geniş bir veri yelpazesi üzerinde eğitilmesini sağlamaktadır (Araújo ve ark., 2024).

Daha büyük veri setleriyle çalışmanın modelin genelleme yeteneği üzerinde olumlu bir etkisi olduğu bilinmektedir (Manjunath ve ark., 2025). Bu çalışmada, farklı boyutlardaki veri setleri üzerinde yapılan deneylerle bu hipotez test edilecektir. Büyük veri setleri, modelin farklı varyasyonlardaki görüntüler üzerinde daha doğru tahminlerde bulunmasına olanak tanımaktadır (Dhar, 2024). Son olarak, CNN modellerinin diğer tıbbi görüntüleme alanlarında kullanılabilirliği değerlendirilecektir. Bu çalışma, yalnızca diyabetik ayak ülserlerinin teşhisiyle sınırlı kalmayıp, benzer medikal görüntüleme problemleri için de geliştirilebilir bir yaklaşım sunmayı hedeflemektedir. Elde edilen sonuçlar, sağlık sisteminde daha geniş çaplı otomatik teşhis sistemlerinin geliştirilmesine katkı sağlayabilir.

Bu tez çalışmasının temel amacı, diyabetik ayak ülserlerinin teşhisinde yeni ve etkili bir yaklaşım sunmak, klinik uygulamalarda kullanılabilecek yenilikçi çözümler geliştirmek ve literatürdeki boşlukları dolduracak bulgular elde etmektir. Çalışmanın sonuçları, hem akademik hem de klinik açıdan önemli katkılar sağlayacaktır.

1.2. Kapsamı

Bu tez çalışması, diyabetik ayak ülserlerinin erken teşhisi ve sınıflandırılması için RegNet ve EfficientNet tabanlı evrişimli sinir ağı (CNN) modellerinin kullanılmasını kapsamaktadır. Araştırmanın temel odağı, bu modellerin doğruluk oranlarını artırmak ve klinik uygulamalarda kullanılabilirliğini incelemektir. Bu bağlamda, hem mevcut literatür taraması hem de deneysel çalışmalarla desteklenen kapsamlı bir yaklaşım benimsenmiştir.

Çalışmada kullanılan veri seti, Kaggle platformunda erişilebilen diabetic foot ulcer (DFU) veri setidir (<https://www.kaggle.com/datasets/laithjj/diabetic-foot-ulcer-dfu>). Bu veri seti, Irak'ın Nasiriyah kentinde bulunan Nasiriyah Hastanesi Diyabet Merkezi'nde, ilgili etik kurul onayı ve hastalardan alınan yazılı onam doğrultusunda oluşturulmuştur. Toplamda 754 adet renkli ayak görüntüsünden oluşan bu veri seti, hem DAU içeren hem de sağlıklı cilt dokularını barındıran yüksek çözünürlüklü görüntüleri içermektedir. Görüntüler, Samsung Galaxy Note 8 ve iPad cihazları kullanılarak çeşitli açılar ve ışık koşullarında çekilmiş, ardından kimlik bilgileri gizlenerek anonimleştirilmiştir (Alzubaidi ve ark., 2020).

Görüntü ön işleme teknikleri, bu çalışmanın önemli bir parçasını oluşturmaktadır. Görüntülerin kontrastının artırılması, gürültülerin giderilmesi ve keskinleştirme gibi işlemler, modellerin daha doğru tahminlerde bulunmasını sağlamaktadır (Kolachi ve ark., 2025). Bu tür ön işlemler, veri setindeki düşük kaliteli görüntülerin olumsuz etkilerini azaltmakta ve modelin genel başarısını artırmaktadır. Optimizasyon algoritmaları ve düzenleme teknikleri de araştırmanın kapsamı dahilindedir. Stokastik Gradyan İnişi (SGD) ve Adam optimizasyon algoritmaları, model eğitimi sırasında kullanılacak ve performans farkları analiz edilecektir. Ayrıca, dropout gibi düzenleme teknikleri, aşırı öğrenmenin önlenmesi için uygulanacaktır (Athira ve ark., 2024). Bu tekniklerin etkileri, model doğruluğu ve eğitim süresi üzerindeki katkıları açısından değerlendirilecektir.

Araştırmanın önemli bir başka boyutu ise, transfer öğrenme stratejilerinin etkinliğini değerlendirmektir. Transfer öğrenme, önceden eğitilmiş modellerin mevcut veri seti üzerinde yeniden eğitilmesi yoluyla daha hızlı ve etkili sonuçlar elde edilmesini sağlamaktadır (Ganesan ve Orgill, 2024). Bu strateji, sınırlı veri setlerine sahip medikal görüntüleme çalışmalarında büyük avantajlar sunmaktadır. Son olarak, bu tez çalışmasının sonuçları, yalnızca akademik alanda değil, aynı zamanda klinik uygulamalarda da kullanılabilirliği hedeflemektedir. Elde edilen bulgular, diyabetik ayak ülserlerinin erken teşhisinde yenilikçi çözümler sunarak hasta bakımını iyileştirme potansiyeline sahiptir. Araştırmanın kapsamı, bilimsel literatüre önemli katkılar sunmayı

ve klinik karar destek sistemlerinin geliştirilmesine yardımcı olmayı amaçlamaktadır. Bu bağlamda, hem teorik hem de uygulamalı düzeyde geniş bir çerçeve sunulmaktadır.

1.3. Sınırlılıklar

Bu çalışmada kullanılan veri seti, derin öğrenme modelleri için önemli olan görsel çeşitlilik, etiket doğruluğu ve sınıf dengesi açısından bazı sınırlılıklar taşımaktadır. Öncelikle, veri seti yalnızca Irak'ın güneyinde yer alan Nasiriyah Hastanesi Diyabet Merkezi'nden toplanan 754 ayak görüntüsüne dayanmaktadır ve bu tek merkezli yapı, farklı coğrafi bölgelerden ya da etnik kökenlerden gelen hastaların cilt özelliklerini yeterince yansıtmadığı için modelin genelleme kapasitesini sınırlayabilir (Alzubaidi ve ark., 2020). Ayrıca görüntülerin Samsung Galaxy Note 8 ve iPad gibi kişisel mobil cihazlarla farklı açılarda ve ışık koşullarında çekilmesi, veri standardizasyonunu zorlaştırmakta ve modele aktarılacak görüntü varyasyonlarını artırmaktadır. Etiketleme işlemlerinin yalnızca tek bir uzman tarafından gerçekleştirilmiş olması, etiketleme sürecinde öznelliğe ve olası uzman önyargılarına neden olabilecek bir başka sınırlılık olarak karşımıza çıkmaktadır. Veri setinde oluşturulan yamaların sınıf dağılımı da homojen değildir; 1609 yamanın 1067'si ülserli, 542'si sağlıklı cilt örneklerinden oluşmaktadır. Bu dengesizlik, modelin eğitim sürecinde sınıflar arasında önyargı geliştirmesine ve az temsil edilen sınıfta daha düşük performans göstermesine neden olabilir. Ek olarak, kullanılan sınıflandırma sadece iki etiketle (normal ve anormal) sınırlı kalmakta; ülserin farklı evreleri, doku derinliği, enfeksiyon durumu gibi klinik açıdan kritik farklılıklar dikkate alınmamaktadır. Bu durum, modelin klinik doğruluk açısından sınırlı bilgiyle karar vermesine yol açabilir. Görüntü çoğaltma (data augmentation) teknikleri ile veri seti genişletilmiş olsa da, döndürme, parlaklık artırımı ve çevirme gibi işlemler, gerçek dünyadaki patolojik varyasyonları tam olarak temsil edememektedir. Ayrıca, görüntülerin temiz, pansumansız ve kontrollü ortamlarda çekilmiş olması, gerçek klinik senaryolarda karşılaşılan kanamalı, ödemli veya enfekte vakaları yeterince kapsayamamaktadır. Son olarak, veri setinin sınırlı yapısı nedeniyle oluşturulan modelin gerçek zamanlı tıbbi uygulamalarda, özellikle düşük kaynaklı klinik ortamlarda uygulanabilirliği hâlâ soru işaretidir. Bu sınırlamalara rağmen, çalışmanın sunduğu katkılar ve önerilen çözümler, diyabetik ayak ülserlerinin teşhisinde yeni yaklaşımlar geliştirilmesine önemli bir temel oluşturmaktadır.

2. KAYNAK ARAŞTIRMASI

DAÜ, diyabet hastalarında yaygın olarak görülen ve tedavi edilmediği takdirde alt ekstremité amputasyonlarına neden olabilen ciddi komplikasyonlardır. Dünya Sağlık Örgütü verilerine göre, diyabetin küresel yaygınlığı giderek artmakta ve bu durum DAÜ görülme sıklığını da paralel şekilde yükseltmektedir. Bu alanda gerçekleştirilen bilimsel çalışmalar, erken tanı ve müdahalenin hem hasta sağlığı hem de sağlık sisteminin ekonomik yükü açısından kritik önem taşıdığını ortaya koymaktadır . Bu konuyla ilgili yapılan çalışmalar aşağıda sıralanmıştır.

Ahzan ve arkadaşlarının yaptığı çalışmada, DAÜ enfeksiyon ve iskemi sınıflarının otomatik tanınması amacıyla farklı derin öğrenme tabanlı CNN mimarilerinin performansları değerlendirilmiştir. Çalışmada DFU2020 veri seti kullanılmıştır; bu veri seti enfeksiyon ve iskemi sınıflarını içermekte olup, başlangıçta 1459 görüntüden oluşmuş, çeşitli veri artırma yöntemleri (döndürme, yansıtma, ölçekleme, gürültü ekleme, kesme gibi) uygulanarak iskemik vakalar için 4935, enfekte vakalar için ise 2945 örneğe çıkarılmıştır. Kullanılan modeller arasında AlexNet, VGG16, VGG19, GoogLeNet, ResNet50, ResNet101, MobileNet, SqueezeNet ve DenseNet bulunmaktadır; tüm bu modeller transfer öğrenme yaklaşımıyla ImageNet üzerinde önceden eğitilmiş ağırlıklar kullanılarak fine-tune edilmiştir. Elde edilen sonuçlara göre, ResNet50 modeli en iyi performansı göstermiştir; iskemik sınıflamada %99,49 doğruluk, %99,59 hassasiyet, %99,39 özgüllük, %99,39 kesinlik, %99,49 F1 skoru, %99,96 AUC ve %98,99 MCC değerleri elde edilmiştir. Enfeksiyon sınıflamasında ise ResNet50 modeli %84,76 doğruluk, %89,80 hassasiyet, %85,71 özgüllük, %83,27 kesinlik, %85,00 F1 skoru, %94,16 AUC ve %75,57 MCC değerlerine ulaşmıştır. Sonuç olarak, çalışmada ResNet50 modelinin iskemik vakaların tanınmasında son derece yüksek bir başarı sağladığı, enfeksiyon vakalarında ise verilerin daha az ve dengesiz olması nedeniyle nispeten daha düşük doğruluk elde edildiği belirtilmiş ve gelecek çalışmalarda daha dengeli ve büyük veri setlerinin kullanımının enfeksiyon sınıflamasındaki başarıyı artırabileceği vurgulanmıştır (Ahsan ve ark., 2023).

Bir diğer çalışmada Bansal ve Vidyarthi, DAÜ tespitinde derin öğrenme modellerinin açıklanabilirliğini artırmak amacıyla DFU_XAI adlı bir çerçeve geliştirilmiştir. Çalışmada, DAÜ görüntülerinden oluşan bir veri seti kullanılmıştır; bu

veri seti Nasiriye Hastanesi'nden toplanmış, 1055 yama (patch) görüntüsünden oluşmakta ve çeşitli veri artırma teknikleri (döndürme, kontrast artırma vb.) ile 3200 görüntüye çıkarılmıştır. Veri seti, SMOTE yöntemiyle dengelenmiştir. Kullanılan modeller arasında Xception, DenseNet121, ResNet50, InceptionV3 ve MobileNetV2 bulunmaktadır; bu modeller transfer öğrenme yöntemiyle, özellikle ImageNet üzerinde önceden eğitilmiş ağırlıklar kullanılarak yeniden eğitilmiştir. ResNet50 modeli, diğerlerinden üstün performans göstermiş ve %98,8 doğruluk, %99,2 kesinlik, %97,6 duyarlılık, %98,4 F1 skoru ve %98,5 AUC değerleri elde etmiştir. DFU_XAI çerçevesinde açıklanabilirlik için SHAP, LIME ve Grad-CAM teknikleri entegre edilmiş, böylece modellerin karar verme süreçleri görsel olarak açıklanmıştır. Sonuç olarak, ResNet50 tabanlı DFU_XAI modeli, diyabetik ayak ülserlerinin doğru, şeffaf ve güvenilir şekilde tespit edilmesini sağlamış; geliştirilen açıklanabilirlik mekanizmaları sayesinde klinik karar destek sistemleri için önemli bir katkı sunmuştur (Bansal ve Vidyarthi, 2024).

Khandakar ve arkadaşlarının yaptığı çalışmada, diyabetik ayak komplikasyonlarının şiddetinin termal görüntüler (termogramlar) kullanılarak sınıflandırılması hedeflenmiştir. Çalışmada, Meksika'nın Puebla şehrindeki dört farklı sağlık kurumundan 2012-2014 yılları arasında toplanmış ve kamuya açık olarak yayımlanmış 167 ayak çifti termogramından oluşan bir veri seti kullanılmıştır; veri seti diyabetik ve sağlıklı bireylerin yaş, cinsiyet, boy ve kilo gibi demografik bilgilerini de içermektedir. Veri seti üzerindeki termal görüntülerden özellikler çıkarılmış, boyut indirgeme için Temel Bileşenler Analizi (PCA) uygulanmış ve k-means kümeleme algoritması ile yeni, uzman hekimler tarafından doğrulanan “hafif”, “orta” ve “şiddetli” olmak üzere üç yeni şiddet seviyesi etiketi oluşturulmuştur. Makine öğrenmesi yöntemleri (XGBoost, Random Forest, vb.) ve derin öğrenme yaklaşımları (VGG19, ResNet, DenseNet gibi transfer öğrenme tabanlı CNN modelleri) farklı görüntü iyileştirme teknikleri (AHE, gamma düzeltme) kullanılarak test edilmiştir. En iyi sonuçlar, VGG19 modeli kullanılarak AHE ile iyileştirilmiş görüntülerde %95,08 doğruluk, %95,08 kesinlik, %95,09 duyarlılık, %95,08 F1 skoru ve %97,2 özgüllük elde edilerek kaydedilmiştir; klasik makine öğrenmesi yöntemlerinden oluşturulan stacking sınıflandırıcı ise %94,47 doğruluk ile benzer bir performans göstermiştir. Sonuç olarak, çalışma, termogramlar üzerinde makine öğrenmesi ve derin öğrenme tekniklerinin etkin şekilde kullanılarak diyabetik ayak komplikasyonlarının şiddet seviyelerinin güvenilir bir şekilde sınıflandırılabilceğini göstermiş, böylece erken teşhis ve müdahaleye önemli katkılar sağlayabileceği ortaya konmuştur (Khandakar ve ark., 2022).

Karthik ve arkadaşlarının yaptığı çalışmada, DAÜ sınıflandırması için Swin Transformer ve Verimli Çok Ölçekli Dikkat Sürücülü Ağ (EMADN) tabanlı çift izli bir derin öğrenme modeli geliştirilmiştir. Kullanılan veri seti, DFUC-2021 veri seti olup 5955 etiketli DFU görüntüsünden oluşmaktadır; veri seti eğitim, doğrulama ve test için bölünmüş, sınıf dengesizliğini azaltmak amacıyla enfeksiyon ve iskemi sınıflarına yönelik veri artırma yöntemleri uygulanmıştır. Modelde, küresel özellikleri yakalamak için Swin Transformer ve yerel detayları çıkarmak için EMADN kullanılmış, her iki izdeki özellikler birleştirilerek Shuffle Attention mekanizmasıyla optimize edilmiştir; ayrıca Grad-CAM yöntemi kullanılarak modelin karar verme süreçleri açıklanabilir hâle getirilmiştir. Elde edilen sonuçlara göre, önerilen model %78,79 doğruluk, %81 kesinlik, %79 duyarlılık ve %80 makro F1 skoru ile DFUC-2021 veri setinde üstün bir performans göstermiştir; ayrıca DAÜ veri setinde %99 doğruluk ve PAD-UFES-20 veri setinde %90 doğruluk elde edilerek modelin genellenebilirliği de kanıtlanmıştır. Sonuç olarak, Swin Transformer ve özel geliştirilmiş EMADN'nin birleşimiyle oluşturulan bu açıklanabilir derin öğrenme mimarisi, hem yüksek sınıflandırma başarımı hem de karar mekanizmalarının görselleştirilebilir olması sayesinde klinik uygulamalarda DAÜ teşhisi için güvenilir bir destek sunabileceğini ortaya koymuştur (Karthik ve ark., 2025).

Amin ve arkadaşlarının yaptığı çalışmada, DAÜ sınıflandırılması ve lokalizasyonu için birleştirilmiş bir derin öğrenme tabanlı yaklaşım geliştirilmiştir. Çalışmada, DFU-Part (B) veri seti kullanılmıştır; bu set enfeksiyon ve iskemik lezyonlardan oluşmakta, veri artırma yöntemleriyle denge sağlanarak genişletilmiştir. Sınıflandırma için sıfırdan eğitilmiş 16 katmanlı bir CNN modeli geliştirilmiş, yerel özellikleri yakalamak için 5x5 filtreler, ReLU aktivasyon fonksiyonları ve batch-normalizasyon katmanları kullanılmıştır. Elde edilen derin özellikler çeşitli makine öğrenmesi sınıflayıcıları (Naive Bayes, Decision Tree, Ensemble, Softmax, KNN) ile test edilmiş, iskemik sınıflandırmada Naive Bayes ile %97,9, enfeksiyon sınıflandırmasında Decision Tree ile %99,6 doğruluk oranı elde edilmiştir. Lokalizasyon aşamasında ise ShuffleNet temelli geliştirilen YOLOv2-DFU modeli kullanılmış, enfekte bölgelerin tespiti için Grad-CAM yöntemiyle açıklanabilirlik sağlanmıştır. YOLOv2-DFU modeli, iskemik bölgeler için %98, enfeksiyon bölgeleri için %97 ortalama IOU skorlarına ulaşmış, iskemik sınıflamada %95 ortalama hassasiyet ve %0,1 hata oranı ile mevcut yöntemlere kıyasla daha üstün performans göstermiştir. Sonuç olarak, önerilen bütünleşik yöntem hem sınıflandırma hem de lokalizasyon görevlerinde yüksek doğruluk ve

güvenilirlik sağlamış, DAÜ tespitinde klinik uygulamalar için etkili ve açıklanabilir bir çözüm sunmuştur (Amin ve ark., 2020) .

Wu ve arkadaşlarının yaptığı çalışmada, Çin'in güneydoğusundaki bir sahil bölgesindeki DAÜ'den izole edilen patojenlerin dağılımı ve antibiyotik duyarlılık sonuçları analiz edilerek klinik antibiyotik seçiminde yol gösterilmesi amaçlanmıştır. Çalışmada, 2018-2023 yılları arasında Xiamen Üçüncü Hastanesi'nde diyabetik ayak nedeniyle yatan 212 hastanın yara sekresyonlarından mikrobiyolojik kültür ve antibiyotik duyarlılık testleri yapılmıştır. Sonuçlara göre, hastaların %76,9'unda patojen kültürü pozitif bulunmuş, toplamda 207 patojenik bakteri izole edilmiştir; bunların %57'si Gram-negatif (G-), %36,23'ü Gram-pozitif (G+) bakteri ve %6,76'sı mantarlardır. En sık izole edilen bakteriler Staphylococcus aureus, Klebsiella pneumoniae ve Pseudomonas aeruginosa olmuştur. Gram-pozitif bakteriler vankomisin, linezolid, tigesiklin ve rifampisine yüksek duyarlılık gösterirken, penisilin ve eritromisine karşı dirençli bulunmuştur. Gram-negatif bakterilerde ise en etkili antibiyotikler ertapenem, imipenem ve amikasin olurken, penisilin ve birinci nesil sefalosporinlere karşı yüksek direnç saptanmıştır. Wagner ülser derecesi arttıkça G- bakterilerin oranı artarken, G+ bakterilerin oranı azalmış ve karışık enfeksiyon sıklığı belirgin şekilde artmıştır. Sonuç olarak, enfeksiyonun şiddeti arttıkça tedavi zorlaşmakta ve amputasyon riski artmaktadır; bu nedenle, lokal koşullara uygun patojen dağılım haritası ve direnç profiline göre antibiyotik seçiminin yapılması, direnç gelişimini önlemek ve hasta sonuçlarını iyileştirmek açısından kritik öneme sahiptir (Wu ve ark., 2024).

Mayya ve arkadaşlarının yaptığı çalışmada, DAÜ tanısında kullanılan makine öğrenmesi uygulamaları, RGB görüntüler ve termal görüntüler gibi çok modlu veriler temel alınarak kapsamlı bir şekilde incelenmiştir. Çalışmada doğrudan yeni bir veri seti oluşturulmamış, mevcut literatür taraması yapılmıştır; incelenen çalışmalarda genellikle DFUC2020, DFUC2021 ve Plantar Thermogram gibi kamuya açık veri setleri kullanılmıştır. Yöntem olarak klasik görüntü işleme tekniklerinden başlayarak derin öğrenme modellerine, özellikle CNN, ResNet, MobileNet, EfficientNet gibi yapılarla geliştirilmiş klinik karar destek sistemlerine (CDSS) odaklanılmıştır. Literatürdeki yöntemler RGB görüntülere ve termal görüntülere dayalı olarak iki grupta sınıflandırılmış; termal görüntülerde ResNet50v2, MobileNetV2+ShuffleNet gibi modellerle %100 doğruluk elde edilirken, RGB görüntülerde EfficientNet, Ensemble CNN ve Faster R-CNN gibi modellerle iskemik ve enfekte DAÜ tespitinde F1 skorlarının %97'lere ulaştığı rapor edilmiştir. Çalışma sonucunda, ikili sınıflandırma görevlerinde

yüksek başarılar elde edildiği, ancak çok sınıflı sınıflandırma, açıklanabilirlik ve veri dengesizliği gibi alanlarda önemli geliştirme gereksinimleri olduğu vurgulanmış; gelecekte daha dengeli ve çok modlu veri setlerine dayalı, açıklanabilir yapay zekâ destekli sistemlerin geliştirilmesinin DAÜ tanısında klinik kullanıma geçişi hızlandırabileceği ifade edilmiştir (Mayya ve ark., 2023).

Khosa ve arkadaşlarının yaptığı çalışmada, DAÜ tanısı için çok seviyeli termal görüntü verileri kullanılarak makine öğrenmesi ve derin öğrenme yaklaşımları ile otomatik tanı sistemleri geliştirilmiştir. Çalışmada, Puebla (Meksika) bölgesinden 2012–2014 yılları arasında toplanan ve 122 diyabetik, 45 sağlıklı bireyden elde edilen toplam 334 plantar termogramdan oluşan halka açık bir veri seti kullanılmıştır; veri artırma yöntemleriyle veri seti genişletilmiş ve denge sağlanmıştır. Makine öğrenmesi yöntemleri olarak SVM, Random Forest, XGBoost, Naive Bayes, AdaBoost, kNN ve Bagging algoritmaları kullanılırken, derin öğrenmede ResNet50, DenseNet121 ve özel geliştirilmiş hafif bir CNN modeli kullanılmıştır. Özellik çıkarımı için HOG, Gabor, GLCM ve LBP gibi tekniklerden yararlanılmıştır. Sayısal sonuçlara göre, makine öğrenmesi yöntemleri arasında en iyi doğruluk %85,6 ile XGBoost yöntemi kullanılarak tam görüntü seviyesinde elde edilmiştir. Özel geliştirilen CNN modeli ise derin öğrenme yöntemleri arasında en üstün performansı göstermiş; tam görüntü seviyesinde %97,1 doğruluk, %97 duyarlılık, %95,8 özgüllük ve %0,976 AUC değeri elde etmiştir. Yama seviyesinde ve görüntü-yama birleşik veri seviyesinde de benzer şekilde özel model üstün sonuçlar vermiştir. Sonuç olarak, önerilen özel CNN modeli hem termal görüntüler üzerinde yüksek doğruluk sağlamış hem de yanlış negatif oranını azaltarak klinik kullanım açısından güvenilir bir ikinci görüş sistemi olabileceği ortaya konmuştur; ayrıca kırsal bölgelerde uzman erişiminin sınırlı olduğu durumlarda etkili bir destek aracı olarak kullanılabileceği belirtilmiştir (Khosa ve ark., 2023).

Avinash ve arkadaşlarının yaptığı çalışmada, DAÜ enfeksiyonlarının otomatik olarak tespiti amacıyla geliştirilmiş, geliştirilmiş CNN-SVM (I-CNN-SVM) tabanlı yeni bir yöntem sunulmuştur. Çalışmada özel bir DFU görüntü veri seti kullanılmış, görüntüler üzerinde gürültü giderme (diffusion filtering) ve RGB'den HSI renk uzayına dönüşüm gibi ön işleme adımları uygulanmıştır. Görüntüler, OSTU eşikleme yöntemiyle segmente edilmiş ve histogram tabanlı özellik çıkarımı yapılmıştır. Model eğitimi aşamasında geleneksel CNN ve CNN-SVM yöntemleriyle karşılaştırmalı analizler yapılmış, önerilen I-CNN-SVM modeli özellikle %98,5 doğruluk, %98,5 kesinlik, %98,5 duyarlılık ve %98,0 F1 skoru ile en yüksek başarıyı göstermiştir. Geliştirilen sistemde CNN mimarisi,

yedi katmanlı bir ağ yapısıyla özellik çıkarımı sağlarken, son katmanda SVM sınıflayıcı kullanılmıştır. Ayrıca, ROC eğrisi analizleri, doğruluk ve kayıp grafiklerinde I-CNN-SVM yaklaşımının diğer modellere göre daha kararlı ve yüksek performans sunduğu gösterilmiştir. Sonuç olarak, çalışma, enfekte DFU lezyonlarının doğru şekilde tanımlanmasında klasik CNN tabanlı yaklaşımlara kıyasla üstün sonuçlar elde etmiş ve DFU teşhisinde klinik kullanıma uygun, hızlı ve hassas bir destek sistemi geliştirilmesine katkı sağlamıştır (Avinash ve ark., 2023).

Bir diğer çalışmada Almufadi ve Alhasson, DAÜ enfeksiyon ve iskemik durumlarının sınıflandırılması amacıyla, çeşitli önceden eğitilmiş CNN modelleri (EfficientNetB0, DenseNet121, ResNet101, VGG16, InceptionV3, MobileNetV2 ve InceptionResNetV2) kullanılarak bir makine öğrenmesi temelli sınıflandırma sistemi geliştirilmiştir. Çalışmada DFU-Part (B) veri seti kullanılmış; başlangıçta 1249 iskemik, 210 non-iskemik, 628 enfekte ve 831 non-enfekte görüntüden oluşan veri seti, doğal veri artırma yöntemleri ve klasik dönüşüm teknikleri (döndürme, yatay ve dikey çevirme) ile genişletilmiştir. Önerilen sistemde, CNN modellerinin sonuna özel olarak tasarlanan bir "head model" eklenmiş; bu model dropout, batch normalization ve düzenleme (L1, L2) katmanları içermektedir. Modellerin çıktıları ayrıca LazyPredict kütüphanesi kullanılarak farklı makine öğrenmesi sınıflayıcılarına (Logistic Regression, AdaBoost, XGBoost, KNN gibi) verilmiş ve performans artışı sağlanmıştır. Elde edilen sonuçlara göre EfficientNetB0 modeli, önerilen başlık modeli ve Logistic Regression sınıflayıcı kombinasyonu ile iskemik sınıflamada %96,7 doğruluk, %96,7 kesinlik, %96,8 duyarlılık, %96,7 özgüllük, %96,7 F1 skoru ve %96,7 AUC değerine ulaşmıştır; enfeksiyon sınıflamasında ise EfficientNetB0 modeli ve AdaBoost sınıflayıcı kombinasyonu ile %92,7 doğruluk, %93,4 kesinlik, %91,9 duyarlılık, %93,6 özgüllük, %92,7 F1 skoru ve %92,7 AUC elde edilmiştir. Sonuç olarak, önerilen yaklaşım, önceki çalışmalara kıyasla diyabetik ayak ülseri sınıflamasında daha yüksek doğruluk sağlamış, aşırı öğrenme (overfitting) problemini azaltarak modellerin genel performansını ve genellenebilirliğini önemli ölçüde iyileştirmiştir (Almufadi ve Alhasson, 2024).

Bir diğer çalışmada Arumuga Maria Devi ve Hepzibai, DAÜ klinik değerlendirilmesi ve sınıflandırılması için hiperspektral görüntü işleme tabanlı, Gri Kurt Optimizasyonu (GWO) ile optimize edilmiş Konvolüsyonel Sinir Ağı (CNN) tabanlı yeni bir yöntem geliştirilmiştir. Çalışmada DFUC2020 veri seti kullanılmış, toplam 4000 görüntüden oluşan veri seti eğitim (2000 görüntü) ve test (2000 görüntü) setlerine ayrılmıştır; hiperspektral görüntüler üzerinde gürültü giderme için kademeli bulanık filtre

uygulanmış, ardından NPDE (Nonlinear Partial Differential Equation) tabanlı segmentasyon yöntemiyle ülser bölgeleri belirlenmiştir. Özellik çıkarımı için Local Binary Pattern (LBP) kullanılmış, ardından GWO algoritması ile özellik optimizasyonu sağlanarak CNN mimarisine giriş yapılmıştır. Önerilen GWO-CNN modelinde üç aşamalı optimizasyon ve eğitim süreci uygulanmış, 300 epoch boyunca model eğitilmiş ve %98,5 doğruluk, %99 duyarlılık, %97,1 kesinlik ve %1,4 hata oranı elde edilmiştir. Ayrıca model, geleneksel CNN ve KNN gibi yöntemlerle karşılaştırıldığında hem doğruluk hem de hata oranı açısından üstün performans göstermiş, eğitim ve doğrulama kayıplarında önemli azalmalar gözlemlenmiştir. Sonuç olarak, önerilen GWO-CNN modeli, diyabetik ayak ülseri sınıflandırmasında yüksek doğruluk, düşük hata oranı ve hızlı cevap süresi sağlayarak klinik uygulamalar için etkili ve güvenilir bir tanı destek aracı olabileceğini göstermiştir (Arumuga Maria Devi ve Hepzibai, 2023).

Dhar yaptığı çalışmada, DAÜ yara alanı ve yara dokularının otomatik segmentasyonu amacıyla derin öğrenme tabanlı iki farklı yöntem geliştirilmiştir. Kullanılan veri setleri, Chronic Wound Dataset, FUSeg Challenge 2021 Dataset ve Wound Tissue Dataset olmak üzere üç ayrı kaynaktan elde edilmiştir; Chronic Wound Dataset 1010 görüntü içerirken, FUSeg Challenge veri seti 1210 görüntüden oluşmaktadır ve Wound Tissue Dataset'te 110 etiketli ve 600 etiketsiz görüntü kullanılmıştır. Yara alanı segmentasyonu için EfficientNet-b7 tabanlı bir encoder-decoder mimarisi olan FUSegNet geliştirilmiş, bu modelde geliştirilmiş bir paralel sıkıştırma ve uyarım (P-scSE) modülü entegre edilmiştir; FUSegNet, Chronic Wound Dataset üzerinde %92,70 Dice skoru ve FUSeg Challenge veri setinde %89,23 Dice skoru ile en iyi sonuçları elde etmiştir. Yara dokusu segmentasyonu için ise fibrin, granülasyon ve kallus dokularını tespit etmek amacıyla, MiT-b3 Transformer tabanlı bir yarı denetimli öğrenme (semi-supervised learning) modeli geliştirilmiş, denetimli aşamada %84,89 Dice skoru elde edilmiş ve pseudo-labeling yöntemiyle yapılan yarı denetimli eğitim sonrası Dice skoru %87,64'e yükselmiştir. Sonuç olarak, bu iki önerilen yaklaşım hem yara alanı hem de doku segmentasyonunda mevcut yöntemlere kıyasla daha yüksek doğruluk sağlamış ve diyabetik ayak yaralarının tedavi sürecinde daha etkili klinik karar destek sistemleri geliştirilmesine katkı sunmuştur (Dhar, 2024).

Khali ve arkadaşlarının yaptığı çalışmada, diyabetik ayak yaralarının (DAY) aşınma kaynaklı ve iskemik tiplerinin kamera ile çekilmiş görüntüler üzerinden sınıflandırılması amacıyla Vgg-19 temelli özellik çıkarımı ve altı katmanlı CNN mimarisi ile desteklenen yeni bir derin öğrenme modeli geliştirilmiştir. Çalışmada iki farklı açık

erişimli veri seti kullanılmış ve başlangıçta 1413 aşınma (AFS) ve 1413 iskemik (DAY) örneği olmak üzere toplam 2826 görüntü toplanmış, veri artırma teknikleri (döndürme, zoomlama, çevirme vb.) uygulanarak veri seti 8478 görüntüye çıkarılmıştır. Görüntülerde gürültü giderme ve UNet++ kullanılarak segmentasyon yapılmış, ardından önerilen model eğitilmiştir. Modelde, Vgg-19 ile çıkarılan özellikler altı katmanlı CNN ağına verilerek sınıflandırma gerçekleştirilmiştir. Elde edilen sonuçlara göre, UNet++ destekli önerilen model %99,05 doğruluk, %98,99 kesinlik, %99,01 duyarlılık, %99,04 F1 skoru, %0,9801 MCC ve %0,9967 AUC değeri elde etmiştir. Ayrıca InceptionV3 (%95,52 doğruluk) ve MobileNet (%96,73 doğruluk) gibi önceden eğitilmiş modellerle karşılaştırıldığında önerilen modelin anlamlı derecede daha yüksek performans gösterdiği, istatistiksel analizlerde (ANOVA, Friedman ve Wilcoxon testleri) bu farkın anlamlı olduğu saptanmıştır. Sonuç olarak, geliştirilen derin öğrenme tabanlı modelin diyabetik ayak ülserlerinin otomatik ve doğru sınıflandırılmasında mevcut yöntemlere kıyasla daha üstün performans sergileyerek klinik uygulamalarda etkili bir destek aracı olabileceği ortaya konmuştur (Khalil ve ark., 2023).

Haryanto ve arkadaşlarının yaptığı çalışmada, diyabetik ayak ülserlerindeki enfeksiyonların şiddet seviyelerini sınıflandırmak amacıyla makine öğrenmesi yaklaşımıyla, özellikle Destek Vektör Makineleri (SVM) kullanılarak bir model geliştirilmiştir. Çalışmada, Endonezya'daki PKU Muhammadiyah Klinik Kitamura'dan toplanan 90 adet yara görüntüsünden oluşan bir veri seti kullanılmış, bu veri seti hafif, orta ve şiddetli enfeksiyon olmak üzere üç kategoriye ayrılmıştır. Görüntüler üzerinde segmentasyon ve Gray Level Co-occurrence Matrix (GLCM) temelli özellik çıkarımı yapılmış, homojenlik, kontrast, korelasyon ve enerji gibi istatistiksel özellikler elde edilmiştir; çıkarılan bu özellikler normalize edilerek SVM modeline giriş verilmiştir. Sınıflandırma sonuçlarına göre model genel olarak %71,4 doğruluk sağlamış; orta şiddetteki enfeksiyonlar için %100 kesinlik, duyarlılık ve F1 skoru ile mükemmel performans sergilerken, hafif enfeksiyonlar için %50 kesinlik, %100 duyarlılık ve %0,67 F1 skoru, şiddetli enfeksiyonlar için ise %100 kesinlik, %67 duyarlılık ve %0,80 F1 skoru elde edilmiştir. Sonuçlar, modelin orta seviye enfeksiyonları çok iyi tespit ettiğini, ancak hafif ve şiddetli vakalarda karışıklık yaşadığını göstermiştir. Gelecek çalışmalar için hiperparametre ayarlarının iyileştirilmesi, eğitim veri setinin büyütülmesi ve SMOTE veya ADASYN gibi veri artırma yöntemlerinin kullanılması önerilmiştir; buna rağmen, bu çalışma yapay zekâ teknolojisinin diyabetik ayak enfeksiyonlarının hızlı ve etkili

tanısında klinik uygulamalara değerli katkılar sunabileceğini göstermiştir (Haryanto ve ark., 2024).

Bir diğer çalışmada Arumuga Maria Devi ve Hepzibai, DAÜ görüntülerinin sınıflandırılması için, hiperspektral görüntü işleme kullanılarak geliştirilen hibrit bir derin öğrenme ve makine öğrenmesi modeli (CNN-SVM) önerilmiştir. Kullanılan veri seti, internet üzerinden toplanan ve manuel olarak dört sınıfa (normal ayak, yüksek riskli ayak, ülserli ayak ve enfekte ayak) ayrılan DFUC 2020 veri setinden oluşturulmuş, toplam 4000 görüntüden oluşmuş ve RGB formatından hiperspektral formata dönüştürülmüştür. Modelde, ön işleme aşamasında adaptif medyan filtre uygulanmış, ardından IFCM-PSO (Geliştirilmiş Bulanık C-Ortalamalar ve Parçacık Sürü Optimizasyonu) algoritması ile segmentasyon yapılmış, GLCM (Gray Level Co-occurrence Matrix) kullanılarak kontrast, enerji, korelasyon, homojenlik ve entropi gibi özellikler çıkarılmış ve nihayetinde CNN-SVM hibrit modeli ile sınıflandırma gerçekleştirilmiştir. Sayısal sonuçlara göre, önerilen hibrit model, dört sınıf için %98 doğruluk, %98 hassasiyet, %98 duyarlılık ve %98 F1 skoru elde ederek mevcut yöntemlere göre daha üstün bir performans sergilemiştir; örneğin DFUNet %92, DFU_QUTNet+SVM %94 doğruluk sağlamışken, önerilen model %98 doğruluğa ulaşmıştır. Sonuç olarak, önerilen hibrit CNN-SVM yaklaşımı, diyabetik ayak ülserlerinin farklı şiddet derecelerinin yüksek doğrulukla tespit edilmesini sağlamış, overfitting problemini azaltmış ve klinik uygulamalarda DFU tanısı için etkili bir destek sistemi sunabileceği ortaya koyulmuştur (Arumuga Maria Devi ve Hepzibai, 2024).

Athira ve arkadaşlarının yaptığı çalışmada, DAÜ erken teşhisi ve aşamalarının sınıflandırılması amacıyla EfficientNet, InceptionResNet-v2, Stacked Sparse Autoencoder (SSAE) ve Sparrow Search Optimization (SSO) algoritmalarının birleşiminden oluşan hibrit bir derin öğrenme modeli geliştirilmiştir. Çalışmada DFUC 2020 veri seti kullanılmış; 4000 görüntüden oluşan bu setin 2000'i eğitim, 2000'i test ve 200'ü doğrulama (sanity check) için ayrılmıştır; görüntüler ön işleme aşamalarından geçirilmiş, veri artırma teknikleri ve normalizasyon uygulanmıştır. Modelde, EfficientNet ve InceptionResNet-v2 ile çok ölçekli özellik çıkarımı yapılmış, SSAE ile bu özellikler detaylandırılmış ve SSO ile optimize edilmiştir; ardından, dikkat mekanizması (attention mechanism) kullanılarak özellikler birleştirilmiş ve sınıflandırma işlemleri gerçekleştirilmiştir. Elde edilen sayısal sonuçlara göre, önerilen hibrit model %99,49 doğruluk, %99,49 kesinlik, %99,3 duyarlılık ve %99,4 F1 skoru ile mevcut yöntemlerden daha yüksek performans göstermiştir; karşılaştırmalı olarak AlexNet %91,1, VGG16

%96,2, DFUNet+KNN %92,5, DFUNet+SVM %96,5 doğruluk sağlamıştır. Sonuç olarak, bu çalışma EfficientNet ve InceptionResNet-v2 tabanlı hibrit modelin DAÜ sınıflandırmasında mevcut yöntemlere kıyasla yaklaşık %2 daha fazla doğruluk sağladığını, böylece diyabetik ayak ülserlerinin erken teşhisi ve yönetimi için güçlü, etkili ve optimize edilmiş bir klinik destek aracı sunduğunu göstermiştir (Athira ve ark.,2024).

Gudivaka ve arkadaşlarının yaptığı bu çalışmada, DAÜ sınıflandırılması için gelişmiş bir makine öğrenmesi yöntemi önerilmiş ve klasik yöntemlere kıyasla daha doğru ve etkili sonuçlar elde edilmesi hedeflenmiştir. Kullanılan veri seti, DFUC2020 veri seti olup, farklı şiddet derecelerine sahip DAÜ görüntülerini içermekte ve veri artırma teknikleri ile zenginleştirilmiştir; veri seti içerisinde hem yapılandırılmış hem de yapılandırılmamış görüntüler yer almaktadır. Modelde, pekiştirmeli öğrenme algoritması (Reinforcement Learning), Compositional Pattern-Producing Networks (CPPN), Destek Vektör Makineleri (SVM) ve Hiyerarşik Kümeleme yöntemleri birleştirilmiş; ayrıca ResNet50, AlexNet, VGG16 ve GoogLeNet gibi derin öğrenme modelleri de değerlendirilmiştir. Bulunan sayısal sonuçlara göre, önerilen yöntem iskemik ülserlerin sınıflandırılmasında %99,49 doğruluk oranına ulaşmış, genel sınıflandırma doğruluğu ise %93,75 seviyesine kadar çıkmıştır; ayrıca kümeleme analizlerinde %78,45'e varan performans artışı sağlanmıştır. Sonuç olarak, çalışmada geliştirilen ileri düzey makine öğrenmesi yaklaşımı, DAÜ sınıflandırmasında hem yüksek doğruluk hem de hızlı ve güvenilir tanı potansiyeli sunmuş, bu sayede klinik ortamlarda diyabetik ayak hastalıklarının daha erken teşhis ve müdahalesine önemli katkılar sağlayabileceği ortaya konmuştur (Gudivaka ve ark., 2025).

Das ve arkadaşlarının yaptığı bu çalışmada, DAÜ iskemik durumunun otomatik tanınması amacıyla, inception, residual ve dense modüllerinin birleşiminden oluşan hibrit yapılı bir konvolüsyonel sinir ağı modeli (HCNNet) geliştirilmiştir. Kullanılan veri seti, 210 iskemik ve 1249 iskemik olmayan tam ayak görüntüsünden çıkarılan toplam 1666 bölge-of-ilgi (ROI) görüntüsünden oluşmakta olup, doğal veri artırma yöntemleriyle 9870 görüntüye çıkarılmış ve deneylerde bu artırılmış set kullanılmıştır. Modelde, giriş görüntüleri başlangıçta 3×3 evrişim katmanından geçirilmiş, ardından hibrit bloklardan oluşan bir mimari içinde her blok sonrası Squeeze-and-Excitation (SE) blokları ve geçiş katmanları yerleştirilmiştir; böylece hem lokal hem de global özellik çıkarımı gerçekleştirilmiş ve özelliklerin kanal bazlı yeniden kalibrasyonu sağlanmıştır. Elde edilen sonuçlara göre, önerilen HCNNet modeli SGD optimizasyon algoritması ve 1e-2 öğrenme oranı ile eğitildiğinde %98,8 doğruluk, %99,4 hassasiyet, %98,2 özgüllük,

%98,8 F1 skoru ve %0,999 AUC değerlerine ulaşmıştır; bu performans, literatürdeki Ensemble CNN ve ResKNet gibi yöntemlerden daha üstün bulunmuştur. Sonuç olarak, geliştirilen HCNNet modeli, diyabetik ayak ülserlerinde iskemi tespitinde hem doğruluk hem de genelleme açısından mevcut yöntemlerin üzerinde bir başarı göstermiş, ayrıca gelecekte enfeksiyon tespiti gibi ileri aşamalara yönelik geliştirmelerin GAN tabanlı veri artırma gibi yöntemlerle daha da desteklenebileceği vurgulanmıştır (Das ve ark., 2024).

Fadhel ve arkadaşlarının yaptığı bu çalışmada, DAÜ normal ve anormal sınıflara ayrılarak gerçek zamanlı sınıflandırılması amacıyla, derin öğrenme modelleri ile donanım hızlandırıcıları (GPU ve FPGA) kullanılarak geliştirilmiş bir sistem önerilmiştir. Kullanılan veri seti, Irak'ın Nasiriyah Hastanesi'nde toplanmış ve kamuya açık hale getirilmiş 754 ayak görüntüsünden oluşmakta olup, görüntüler çeşitli açılardan ve ışık koşullarında çekilmiş, 224x224 piksel boyutunda ROI (bölge-of- ilgi) yaması oluşturularak etiketlenmiştir. Çalışmada, DFU_FNet ve DFU_TFNet adlı iki farklı CNN modeli geliştirilmiştir; DFU_FNet daha basit bir yapıya sahipken, DFU_TFNet derin transfer öğrenme kullanarak büyük miktarda benzer veriyle ön eğitim yapılmış ve daha yüksek genel performans hedeflenmiştir. Sayısal sonuçlara göre, DFU_TFNet (Cycle#3) modeli %99,81 doğruluk, %99,38 kesinlik, %99,76 duyarlılık ve %99,25 F1 skoru ile üstün başarı elde etmiş, AlexNet, VGG16, GoogleNet gibi önceki derin öğrenme modellerini geride bırakmıştır; FPGA platformunda düşük enerji tüketimi (9.16W) ile GPU'ya kıyasla daha verimli çalışmıştır. Sonuç olarak, DFU_TFNet modeli, DAÜ sınıflandırmasında hem yüksek doğruluk hem de düşük enerji tüketimi ile gerçek zamanlı uygulamalara uygun bir çözüm sunmuş, gelecekte giyilebilir akıllı cihazlara entegre edilerek hasta takibinde kullanılabileceği önerilmiştir (Fadhel ve ark., 2024).

Mishra ve arkadaşları tarafından yapılan bu çalışmada, DAÜ iskemik ve enfekte bölgelerin tanınması amacıyla, art arda yerleştirilen özgün artık (residual) bloklardan oluşan yeni bir derin evrimsel sinir ağı (ResKNet) geliştirilmiştir. Kullanılan veri seti, Manchester Metropolitan Üniversitesi tarafından oluşturulan ve iskemik ile enfekte DAÜ görüntülerinden oluşan, erişimi kısıtlı bir veri setidir; veri setinde 1459 tam ayak görüntüsünden çıkarılan 9870 iskemik ve 4890 enfekte/normal etiketli yama (patch) görüntüleri yer almaktadır. Model, dört ile on arasında değişen sayıda residual blok içeren varyantlarla denenmiş; Res4Net modeli (4 blok) iskemik tespitinde en iyi performansı göstermiş (%97,8 doğruluk, %97,8 F1 skoru, AUC 0,9968), Res7Net modeli (7 blok) ise enfeksiyon tespitinde en iyi sonucu vermiştir (%80 doğruluk, %79,8 F1 skoru, AUC 0,8890). Ayrıca Res4Net, Matthews korelasyon katsayısında (MCC) %95,6 gibi yüksek

bir değere ulaşmıştır. Sonuç olarak, ResKNet mimarisi ile daha az derin ağların iskemik tespitinde yeterli olduğu, ancak enfeksiyon gibi daha zor görevlerde orta derinlikte ağların daha iyi performans gösterdiği belirlenmiş; geliştirilen model, mevcut literatürdeki yöntemlere kıyasla hem iskemik hem de enfekte DAÜ tespitinde üstün sonuçlar elde etmiş ve klinik uygulamalarda erken tanı ve müdahale süreçlerine değerli bir katkı sağlayabileceği ortaya konulmuştur (Mishra ve ark., 2022).

Arnia ve arkadaşlarının yaptığı bu çalışmada, DAÜ plantar termogram görüntüleri üzerinden doğru bir şekilde sınıflandırılması amacıyla, önceden eğitilmiş CNN modellerinden çıkarılan özelliklerin Extreme Learning Machine (ELM) algoritması ile birleştirildiği bir yöntem geliştirilmiştir. Kullanılan veri seti, Hernandez-Contreras ve arkadaşları tarafından oluşturulan Plantar Thermogram veri seti olup, 334 görüntüden (122 diyabetik, 45 sağlıklı birey) oluşmaktadır; veri seti dengelenmek amacıyla her sınıftan 55 görüntü seçilmiş ve ön işleme adımları uygulanmıştır. Özellik çıkarımı için ResNet101, DenseNet201, MobileNetv2, EfficientNetB0, InceptionResNetv2 ve NasNet Mobile gibi önceden eğitilmiş CNN modelleri kullanılmış, sınıflandırma ise ELM ile gerçekleştirilmiştir; bu yapı, düşük örneklemlili veri setlerinde veri artırmaya ihtiyaç duymadan yüksek performans sağlamak için tercih edilmiştir. Elde edilen sayısal sonuçlara göre, CNN-ELM (özellikle MobileNetv2 tabanlı) %83,34 doğruluk, %66,67 duyarlılık ve %100 özgüllük ile en iyi performansı göstermiştir; bu sonuçlar ResNet101 (%73,34 doğruluk), MobileNetv2 (%80 doğruluk) ve EfficientNetB0 (%80 doğruluk) gibi klasik CNN modellerinin performansını aşmıştır. Sonuç olarak, bu çalışma, CNN tabanlı özellik çıkarımı ile ELM sınıflayıcısının birleşiminin, küçük ve dengesiz veri setlerinde yüksek doğrulukla DAÜ sınıflandırması yapabildiğini göstermiş; düşük model parametresi, hızlı öğrenme süresi ve yüksek özgüllük değerleri ile özellikle gerçek zamanlı ve mobil uygulamalar için umut vaat eden bir yöntem olduğu ortaya konmuştur (Arnia ve ark., 2024).

Wang ve arkadaşlarının yaptığı bu çalışmada, DAÜ görüntülerinde yara dokularının (granülasyon, fibrin ve kallus) segmentasyonu amacıyla yeni bir derin öğrenme tabanlı yöntem geliştirilmiş ve DFUTissue adında 110 etiketli, 600 etiketsiz görüntüden oluşan bir veri seti oluşturulmuştur. Kullanılan model, encoder kısmında Mix Transformer (MiT-b3) ve decoder kısmında CNN katmanları içeren hibrit bir mimari olup, her decoder aşamasında Parallel spatial and channel squeeze-and-excitation (P-scSE) modülü entegre edilmiştir; model ayrıca hem denetimli öğrenme (SL) hem de yarı denetimli öğrenme (SSL) aşamaları içermektedir. Sayısal sonuçlara göre, denetimli

öğrenme aşamasında önerilen model, SegFormer-b3, U-Net ve DeepLabV3+ gibi yöntemlerden daha iyi performans göstererek %84,89 Dice benzerlik katsayısı (DSC) elde etmiş; yarı denetimli aşamada SSL yöntemiyle DSC %87,64'e çıkarılmıştır. Ayrıca, Chronic Wound veri setinde yara bölgesi segmentasyonu yapılarak %92,99 DSC ile mevcut FUSegNet ve SegFormer modellerinden daha yüksek başarı sağlanmıştır. Sonuç olarak, bu çalışma, DFU görüntülerinde yara dokusu segmentasyonu için derin öğrenme ve yarı denetimli öğrenmenin etkili şekilde birleştirilebileceğini göstererek hem yeni bir açık veri seti sunmuş hem de düşük veri ortamlarında yüksek doğruluk elde edilebileceğini kanıtlamıştır; gelecekte daha fazla etiketli veriyle performansın artırılabilir ve yöntemin genişletilebileceği belirtilmiştir (Wang ve ark., 2024).



3. MATERYAL VE YÖNTEM

3.1. Materyal

Diabetic Foot Ulcer (DFU) veri seti, Kaggle üzerinde Laith Sabah Alzubaidi tarafından paylaşılmış olup, DAÜ'lerin otomatik olarak tespiti ve sınıflandırılması amacıyla hazırlanmıştır. Veri seti, özellikle derin öğrenme modelleri ile tıbbi görüntü analizi yapmak isteyen araştırmacılar için önemli bir kaynak niteliği taşımaktadır. Görüntüler, 2017-2019 yılları arasında veri seti, Irak'ın güneyinde bulunan Nasıriye Hastanesi'nin diyabet merkezinden toplanmıştır. Uzman doktorlar tarafından etiketlenmiş olan bu görüntüler, normal (sağlıklı) ve anormal (ülserli) olarak iki kategoriye ayrılmıştır.

Veri seti dört ana klasörden oluşmaktadır: Orijinal tam boyutlu ayak görüntüleri, bu görüntülerden kırılarak oluşturulmuş 224x224 piksel boyutundaki yama (patch) görüntüleri, tıbbi uzmanlar tarafından sağlanan etiketler (ground truth) ve çeşitli veri artırma teknikleriyle oluşturulmuş genişletilmiş (augmented) görüntüler. Toplamda 754 hastaya ait görüntülerden üretilmiş 1.188 yama bulunmaktadır. Bunların 645'si ülserli bölgeyi temsil ederken, 543'si sağlıklı bölgeleri temsil etmektedir. Bu denge, sınıflandırma modellerinin gerçek klinik senaryolarda eğitimine olanak tanımaktadır. Bu veri seti, özellikle CNN, ResNet, Inception gibi derin öğrenme modelleri ile sınıflandırma çalışmalarında sıkça kullanılmaktadır. Ayrıca transfer öğrenme (transfer learning) yöntemleriyle önceden eğitilmiş modellerin bu özel veriye uyarlanması da mümkündür. Açıklanabilir yapay zeka (XAI) uygulamaları da bu veri setiyle test edilerek, modelin hangi bölgelere dikkat ettiğini Grad-CAM veya LIME gibi tekniklerle görselleştirmek mümkündür. Ayrıca bu veri seti, mobil sağlık uygulamaları veya düşük kaynaklı klinik ortamlar için geliştirilecek yapay zeka tabanlı teşhis sistemleri açısından da büyük potansiyel taşır.

Sonuç olarak DFU veri seti, diyabetik ayak ülseri gibi önemli bir sağlık problemi üzerine çalışan araştırmacılar için yüksek kaliteli, etiketli ve çeşitli klinik durumları temsil eden görüntüler içeren kapsamlı bir kaynaktır. Tıbbi yapay zeka, bilgisayarlı görü ve klinik destek sistemleri alanındaki akademik yayınlarda sıklıkla referans alınmakta ve

ileride yapılacak klinik uygulamalar için zemin oluşturmaktadır. Veri setinde örnek görüntüler Şekil 3.1’de verilmiştir.




Şekil 3.1. Veri setinden örnek görüntüler

3.2. Metod

3.2.1. Yapay Zeka

Yapay zekâ (YZ), insan zekâsına özgü bilişsel işlevlerin bilgisayar sistemleri tarafından taklit edilmesi sürecini ifade eder. İlk olarak 1950 yılında Alan Turing’in “makinelere düşünebilir mi?” sorusunu ortaya attığı ünlü makalesiyle kavramsallaşan yapay zekâ, yıllar içinde çok yönlü ve karmaşık bir araştırma alanı hâline gelmiştir (Turing, 1950). Bu alandaki sistemler, çevreden veri toplayabilen, bu verileri işleyebilen, görüntüler çıkartabilen ve sonuçlara göre eylemde bulunabilen algoritmalarla oluşur




Şekil 3.2. Alan Turing

YZ'nin akademik bir alan olarak kuruluşu ise 1956 yılında John McCarthy ve arkadaşlarının Dartmouth Konferansı'nda bu terimi ilk kez kullanmasıyla gerçekleşmiştir (Russell ve Norvig, 2021). 1950'li ve 60'lı yıllarda sembolik yapay zekâ çalışmaları ön plandayken, bilgi temelli sistemler geliştirilmeye çalışılmış, ancak sınırlı işlem gücü ve veri eksikliği nedeniyle bu sistemler çoğunlukla dar kapsamlı kalmıştır. 1970'li yıllarda bu nedenle “YZ kışı” olarak adlandırılan bir duraklama dönemi yaşanmıştır (Crevier, 1993).

1990'ların ortasından itibaren ise veri miktarındaki artış, işlemci gücündeki gelişmeler ve özellikle makine öğrenmesi algoritmalarının güç kazanmasıyla YZ yeniden ilgi görmeye başlamıştır. Makine öğrenmesi, yapay zekânın önemli bir alt dalı olarak, sistemlerin deneyimden öğrenmesini ve performansını zamanla iyileştirmesini sağlar. Denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme gibi alt yöntemlerle, makineler büyük veri kümeleri üzerinde istatistiksel örüntüler keşfederek geleceğe yönelik tahminlerde bulunabilir (Jordan & Mitchell, 2015). Makine öğrenmesinin daha karmaşık örüntüleri tanıma yeteneği ise derin öğrenme yöntemleriyle mümkün olmuştur. Derin öğrenme, çok katmanlı yapay sinir ağları aracılığıyla verilerden daha soyut temsiller öğrenebilen sistemlerin geliştirilmesini sağlar (Goodfellow ve ark., 2016). Derin öğrenme özellikle görüntü işleme, ses tanıma ve doğal dil işleme gibi karmaşık görevlerde yüksek başarı göstermiştir. Bu başarıda temel rol oynayan yapılardan biri ise yapay sinir ağlarıdır. İnsan beynindeki nöron yapısından esinlenerek geliştirilen bu ağlar, giriş verilerini işleyerek ağırlıklandırılmış bağlantılar üzerinden çıktı üretir. Sinir ağları,

özellikle derin katmanlara sahip olduğunda öğrenme sürecinde çok katmanlı temsil gücünü artırarak veri içindeki karmaşık yapıları çözümleyebilir.

YZ'nin gelişimi sadece teknik başarılarla sınırlı kalmamış, aynı zamanda sosyal ve etik tartışmaları da beraberinde getirmiştir. Özellikle karar süreçlerinde algoritmaların şeffaflığı, veri mahremiyeti ve önyargı sorunu gibi meseleler, günümüzdeki YZ uygulamalarının sürdürülebilirliği açısından kritik önemdedir (Floridi ve ark., 2018). Tüm bu gelişmeler ışığında, yapay zekâ sadece bir teknoloji değil; aynı zamanda toplumsal yapıyı, iş gücü dağılımını ve bireysel yaşam biçimlerini yeniden şekillendiren bir dönüşüm aracı hâline gelmiştir.



Şekil 3.3. YZ, MÖ ve DÖ'nün mantıksal yapısı


3.2.2. Derin öğrenme

Derin öğrenme (deep learning), yapay zekâ ve makine öğrenmesinin alt dallarından biri olarak, çok katmanlı yapay sinir ağları aracılığıyla verilerden yüksek düzeyde soyut temsiller öğrenmeyi amaçlayan bir yaklaşımdır. İnsan beyninin çalışma biçiminden esinlenerek geliştirilen bu yöntem, özellikle büyük veri kümeleri üzerinde yüksek doğruluk oranlarıyla çalışabilme kapasitesi sayesinde günümüzün en güçlü yapay zekâ tekniklerinden biri hâline gelmiştir (Goodfellow ve ark., 2016). Derin öğrenmenin ortaya çıkışı, yapay sinir ağlarının geliştirilmesine dayanır. 1943'te McCulloch ve Pitts'in sinir hücresi modellemesi ile temelleri atılan sinir ağları, 1980'lerde geri yayılım (backpropagation) algoritması sayesinde daha karmaşık problemler üzerinde eğitilebilir

hâle gelmiştir (LeCun ve ark., 2015). Ancak sınırlı hesaplama gücü ve yetersiz veri nedeniyle uzun süre sınırlı kullanım alanı bulmuştur. 2000’li yılların başında grafik işlem birimlerinin (GPU) yaygınlaşması, büyük veri setlerinin erişilebilir hâle gelmesi ve daha etkili optimizasyon yöntemlerinin geliştirilmesiyle birlikte, derin öğrenme teknikleri hızla gelişmiş ve uygulama alanı genişlemiştir. Derin öğrenme modelleri, birden fazla katmandan oluşan yapay sinir ağları kullanarak, girdilerden yüksek seviyeli özellikleri otomatik olarak öğrenir. Bu öğrenme süreci, manuel olarak özellik mühendisliği gerektiren klasik makine öğrenmesi yöntemlerinden farklı olarak, veriden anlamlı örüntüleri doğrudan çıkarma kapasitesine sahiptir. Örneğin bir görüntü sınıflandırma probleminde, derin öğrenme modeli düşük katmanlarda kenar ve doku gibi temel özellikleri; üst katmanlarda ise nesne parçaları veya bütünsel yapıları öğrenebilir (Krizhevsky ve ark., 2012). Günümüzde derin öğrenme, çok çeşitli alanlarda kullanılmaktadır. Görüntü tanıma ve nesne tespiti, doğal dil işleme (NLP), konuşma tanıma, makine çevirisi, biyomedikal teşhis, otonom araçlar ve öneri sistemleri bu alanlardan sadece birkaçıdır. Özellikle CNN, görüntü işleme; tekrarlayan sinir ağları (RNN) ve Transformer tabanlı modeller ise zaman serisi ve dil verileri üzerinde büyük başarılarla ulaşmıştır (Vaswani ve ark., 2017). Derin öğrenmenin başarısına rağmen, bazı sınırlılıkları da mevcuttur. Büyük miktarda etiketli veriye ve yüksek işlem gücüne ihtiyaç duyması, aşırı öğrenmeye (overfitting) yatkınlığı ve modelin karar verme sürecinin genellikle “kara kutu” niteliğinde olması, bu yöntemin şeffaflık ve açıklanabilirlik açısından eleştirilmesine neden olmaktadır (Lipton, 2018). Bu nedenle, açıklanabilir yapay zekâ (XAI) ve etik YZ uygulamaları gibi yeni alanlar da derin öğrenme ile birlikte önem kazanmaktadır.


3.2.3. Yapay sinir ağları (Artificial Neural Networks - ANN)

Yapay Sinir Ağları (YSA), insan beynindeki nöronların çalışma prensibinden esinlenerek geliştirilmiş hesaplama modelleridir. Bu yapay sistemler, biyolojik sinir sistemlerinden farklı olarak sayısal verileri işleyerek öğrenme, genelleme, sınıflandırma ve tahmin yapma gibi görevleri gerçekleştirebilir. YSA’lar, özellikle büyük veri kümeleriyle çalışabilme ve karmaşık örüntüleri tanıyabilme özellikleri sayesinde görüntü işleme, doğal dil işleme, ses tanıma, finansal modelleme ve sağlık alanlarında yaygın bir şekilde kullanılmaktadır (Goodfellow ve ark., 2016).



Şekil 3.4. Biyolojik sinir hücresi yapısı(Öztemel, 2012)

Bir yapay sinir ağı temel olarak girdi katmanını (input layer), gizli katmanlar (hidden layers) ve çıktı katmanından (output layer) oluşur. Girdi katmanındaki nöronlar, ham verileri alır ve bu veriler ağırlıklı bağlantılar aracılığıyla gizli katmanlara aktarılır. Gizli katmanlar, bu veriler üzerinde matematiksel işlemler gerçekleştirerek belirli örüntüleri tanımaya çalışır. Her bir nöronun çıkışı, aktivasyon fonksiyonları aracılığıyla hesaplanır ve bir sonraki katmana aktarılır (Haykin, 2009).



Şekil 3.5. Yapay sinir hücresi yapısı(Öztürk ve ark., 2018)

Aktivasyon fonksiyonları, ağın doğrusal olmayan ilişkileri öğrenmesini sağlar. En yaygın kullanılan aktivasyon fonksiyonları arasında Sigmoid, Tanh ve özellikle derin öğrenme uygulamalarında ReLU (Rectified Linear Unit) yer alır. ReLU fonksiyonu, negatif değerleri sıfıra çekerken pozitif değerleri olduğu gibi geçirdiği için derin ağlarda eğitim sürecini hızlandırma avantajı sunar (Nair ve Hinton, 2010).


YSA'ların eğitilmesinde kullanılan en temel algoritmalarından biri geri yayılım (backpropagation) algoritmasıdır. Bu algoritma, tahmin edilen değer ile gerçek değer arasındaki hata miktarını hesaplayarak ağırlıkları bu hataya göre günceller. Bu süreç, gradyan iniş algoritması (gradient descent) ile birlikte çalışarak hata fonksiyonunun minimize edilmesini sağlar (Rumelhart ve ark., 1986).Günümüzde kullanılan daha gelişmiş sinir ağı türleri arasında Derin Sinir Ağları (Deep Neural Networks - DNN), Evrimsel Sinir Ağları, CNN ve Tekrarlayan Sinir Ağları (RNN) yer almaktadır. Bu ağlar, klasik YSA yapısının ötesinde çok katmanlı ve özelleşmiş mimariler sunar. Özellikle CNN'ler, görüntü işleme ve sınıflandırma alanlarında; RNN'ler ise sıralı veri, yani zaman serileri ve dil işleme gibi alanlarda yüksek başarı elde etmektedir (LeCun ve ark., 2015).YSA'ların başarısı, veri miktarı ve kalitesiyle doğrudan ilişkilidir. Büyük veri setleri üzerinde öğrenen bu ağlar, yeterli eğitim sağlandığında insan uzmanlara yakın ya da onları aşan performanslar sergileyebilmektedir. Ancak, aşırı öğrenme (overfitting), ağ derinliği arttıkça yaşanan hesaplama yükü gibi zorluklar da barındırmaktadır. Bu tür problemlerle başa çıkmak için dropout, erken durdurma (early stopping) ve veri artırımı (data augmentation) gibi teknikler uygulanmaktadır (Srivastava ve ark., 2014).

3.2.4. Evrimsel sinir ağları (CNN)

CNN'ler özellikle görüntü işleme alanında çığır açan başarılar elde etmiş olan derin öğrenme mimarilerindendir. İnsan beynindeki görsel korteksin işleyiş biçiminden esinlenerek geliştirilmiş bu yapılar, görüntüleri pikseller düzeyinde tanıyarak sınıflandırma, nesne tanıma, segmentasyon ve tespitite olağanüstü performanslar sergilemektedir (LeCun ve ark., 2015). Yapay Sinir Ağları (ANN) geleneksel olarak çok katmanlı algılayıcılar (MLP) ile tanınmakla birlikte, CNN'ler uzaysal ve zamansal ilişkileri göz önüne alarak daha yüksek doğruluk oranlarına ulaşabilmektedir. CNN mimarisinin gücü, otomatik olarak özellik çıkarımı yapabilme kapasitesinden gelmektedir. El ile özellik mühendisliği gerektirmeden, veriden anlamlı desenleri kendi kendine öğrenebilmesi bu ağları özellikle değerli kılmaktadır.

3.2.4.1. CNN yapısı ve temel katmanlar

Evrişimsel Sinir Ağları(ESA), katmanlı bir mimariye sahiptir. Bu mimari, her katmanda farklı bir işlevi yerine getirerek veriyi giderek daha anlamlı temsillere dönüştürür. Aşağıdaki şekil, tipik bir CNN modelinin temel katmanlarını özetlemektedir:




Şekil 3.6. ESA'nın temel yapısı

3.2.4.2. Evrişim katmanı

Evrişim Katmanı (Convolutional Layer), Evrişimsel Sinir Ağlarının temel bileşeni olarak giriş görüntüsü üzerinde küçük boyutlu filtrelerin (çekirdeklerin) kaydırılması yoluyla özellik çıkarımı yapan yapıdır. Bu katman, görüntünün her bir bölgesinde belirli desenleri tanıyarak ilgili özellikleri öğrenmeye yarar. Görselde örneklenen şekilde, 5x5 boyutundaki bir görüntü üzerinde 3x3 boyutunda bir filtre uygulanmaktadır. Bu filtre, görüntü üzerinde soldan sağa ve yukarıdan aşağıya doğru birer piksel adım (stride = 1) ile kaydırılarak her konumda çarpım ve toplama işlemi yapılır. Her 3x3 bölge, filtredeki karşılık gelen değerlerle çarpılıp toplanarak, çıktı matrisinde tek bir hücreye karşılık gelir. Örneğin ilk adımda, görüntünün sol üst köşesindeki 3x3 bölge ile filtre elemanlarının noktasal çarpımı sonucu 6 değeri elde edilir. Aynı işlem diğer bölgeler için de tekrar edilerek 3x3 boyutunda bir çıktı matrisi (özellik haritası) oluşturulur. Bu işlem sırasında filtredeki pozitif ve negatif değerler, görüntüdeki kenar, yön, kontrast gibi özellikleri öne çıkaracak şekilde belirlenmiştir. Örnek olarak gösterilen filtre, özellikle dikey kenarları tespit etmeye yöneliktir. Bu nedenle, özellik haritasında bazı hücrelerde pozitif,

bazılarında negatif değerler ortaya çıkar; bu durum, görüntünün hangi bölgelerinde belirli desenlerin bulunduğunu gösterir. Bu mekanizma sayesinde model, filtreleri eğitim sürecinde optimize ederek görüntülerdeki yapısal bilgileri otomatik şekilde öğrenir. Evrişim katmanı bu yönüyle, klasik görüntü işleme tekniklerinde manuel olarak tanımlanan kenar algılayıcılarının yerini alır ve sistemin daha karmaşık ve soyut bilgileri öğrenmesini sağlar. Görseldeki örnek, evrişim işleminin matematiksel temelini görsel biçimde özetleyerek, CNN mimarilerinin nasıl çalıştığını somut şekilde ortaya koymaktadır.




Şekil 3.7. Evrişim katmanı çalışma prensibi

3.2.4.3. Havuzlama katmanı

Havuzlama Katmanı (Pooling Layer), Evrişimsel Sinir Ağları (CNN) mimarisinde, evrişim katmanlarından sonra gelen ve özellik haritalarının (feature maps) boyutlarını azaltarak modelin hesaplama yükünü düşüren, aynı zamanda önemli bilgileri koruyarak aşırı öğrenmeyi (overfitting) engellemeye yardımcı olan bir katmandır. Bu katman, giriş verisinin uzamsal boyutlarını (genişlik ve yükseklik) küçültürken, en belirgin özellikleri muhafaza eder. Havuzlama işlemi genellikle 2x2 boyutunda bir filtre

(kernel) kullanılarak gerçekleştirilir ve bu filtre, giriş verisi üzerinde belirli bir adım (stride) ile kaydırılır. Bu işlem sırasında, her bir alt bölgedeki değerlerin maksimumu (maksimum havuzlama) veya ortalaması (ortalama havuzlama) alınarak yeni bir özellik haritası oluşturulur. Maksimum havuzlama, özellikle kenar ve doku gibi belirgin özellikleri korumada etkilidir ve bu nedenle sıkça tercih edilir. Havuzlama katmanının temel avantajları arasında, modelin hesaplama maliyetini azaltması, parametre sayısını düşürmesi, konumsal kaymalara karşı dayanıklılık sağlaması ve aşırı öğrenmeyi önlemesi yer alır. Bu katman sayesinde, model daha soyut ve genel özellikleri öğrenerek daha iyi genelleme yapabilir. Havuzlama katmanları, CNN mimarisinde evrişim katmanlarıyla birlikte çalışarak, giriş verisinden anlamlı ve özetlenmiş özellikler çıkarılmasına olanak tanır.




Şekil 3.8. a) Maksimum havuzlama b) Ortalama havuzlama

3.2.4.4. Tam bağlantı katmanı

Tam Bağlantılı Katman (Fully Connected Layer), Evrişimsel Sinir Ağlarının son aşamasında yer alan ve daha önceki katmanlarda çıkarılmış olan özelliklerin sınıflandırılması ya da regresyon gibi nihai çıktılar hâline dönüştürülmesinde görev alan katmandır. Bu katman, geleneksel yapay sinir ağlarında olduğu gibi her bir nöronun bir önceki katmandaki tüm nöronlarla bağlantılı olduğu bir yapıya sahiptir. Bu nedenle “tam bağlantı” olarak adlandırılır. Önceki katmanlardan gelen veriler, genellikle düzleştirme

(flatten) işlemi ile tek boyutlu bir vektöre dönüştürülerek bu katmana iletilir. Ardından bu vektör, tam bağlantılı katman aracılığıyla öğrenilen ağırlıklar ve bias terimleriyle birlikte işlenerek, sınıflara ait olasılıkların tahmin edildiği softmax gibi aktivasyon fonksiyonlarına iletilir. Tam bağlantılı katmanların temel görevi, evrişim ve havuzlama katmanlarında çıkarılan düşük ve orta düzeydeki özellikleri kullanarak son bir karar vermektir (Goodfellow ve ark., 2016). Bu nedenle CNN’lerde genellikle birkaç tam bağlantılı katman bulunur ve son katman, çıktı sınıf sayısına eşit sayıda nöron içerir. Bu yapı, özellikle sınıflandırma problemlerinde çok etkilidir çünkü öğrenilen özelliklerin tümü bu aşamada dikkate alınır. Ancak bu katmanların çok fazla sayıda parametre içermesi nedeniyle aşırı öğrenme (overfitting) riski de taşımaktadır. Bu sebeple dropout gibi düzenleme teknikleri sıkça kullanılmaktadır (Srivastava ve ark., 2014). Tam bağlantı katmanının şematik yapısı Şekil 3.9’ da gösterilmiştir.




Şekil 3.9. Tam bağlantı katmanı

3.2.4.5. Aktivasyon fonksiyonları

Aktivasyon fonksiyonları, yapay sinir ağlarında ve özellikle CNN gibi derin öğrenme mimarilerinde, nöronlardan geçen bilgilerin doğrusal olmayan biçimde işlenmesini sağlayarak ağına karmaşık örüntüleri öğrenebilmesini mümkün kılan matematiksel işlemlerdir. Eğer bu fonksiyonlar olmasaydı, sinir ağları yalnızca doğrusal ilişkileri modelleyebilir ve derin yapıların potansiyelinden tam anlamıyla yararlanılamazdı. En yaygın kullanılan fonksiyonlardan biri olan ReLU (Rectified Linear Unit), negatif girişleri sıfıra çekerken pozitif değerleri olduğu gibi geçirerek hesaplama verimliliği sağlar ve gradyan sönümlenmesi problemini azaltır (Nair ve Hinton, 2010).

Sigmoid fonksiyonu, çıktıları 0 ile 1 arasında sınırlayarak özellikle iki sınıflı sınıflandırma problemlerinde tercih edilir; ancak doygunluk bölgelerinde gradyanı küçük olduğu için öğrenme yavaşlayabilir. Tanh (hiperbolik tanjant) fonksiyonu ise çıktıyı -1 ile 1 arasına dönüştürerek sıfır merkezli avantaj sağlar, fakat yine gradyan sönümlenmesine açıktır. Leaky ReLU gibi fonksiyonlar, negatif bölgelere küçük bir eğim vererek ReLU'nun sıfır gradyan sorununu azaltır. Derin ağlarda daha stabil öğrenme sağlamak amacıyla ELU ve SELU gibi gelişmiş fonksiyonlar da geliştirilmiştir (Clevert ve ark., 2015). Tüm bu fonksiyonların yanında, çok sınıflı sınıflandırma problemlerinin çözümünde Softmax fonksiyonu oldukça kritik bir rol oynar. Softmax, giriş logit değerlerini alarak her sınıfa ait olasılıkları hesaplar ve bunları 0 ile 1 arasında normalize eder; sonuçların toplamı daima 1 olur. Bu özellik sayesinde model, her bir sınıfa ait tahmin güvenini açıkça ortaya koyar ve en yüksek olasılığa sahip sınıf nihai tahmin olarak kabul edilir. Softmax genellikle çıktı katmanında yer alır ve çapraz entropi kaybı (cross-entropy loss) ile birlikte kullanılarak sınıflandırma görevlerinde etkin sonuçlar elde edilmesini sağlar. Aktivasyon fonksiyonlarının seçimi, modelin doğruluğu, öğrenme hızı ve genelleme kapasitesi üzerinde doğrudan belirleyici olduğu için her bir problem için özenle optimize edilmelidir (Goodfellow ve ark., 2016).



Şekil 3.10. En sık kullanılan aktivasyon fonksiyonları

3.2.5. Transfer öğrenme

Transfer öğrenme (Transfer Learning), bir alanda öğrenilen bilgi ve deneyimlerin farklı ama ilgili başka bir probleme uygulanması yaklaşımıdır. Özellikle derin öğrenme modellerinin yüksek sayıda parametre içermesi ve büyük veri gereksinimi göz önüne alındığında, transfer öğrenme, eğitim süresini kısaltmak, daha az veriye ihtiyaç duymak ve genelleme performansını artırmak gibi birçok avantaj sunar (Pan ve Yang, 2010). Transfer öğrenme yöntemleri genel olarak üç ana gruba ayrılır: özellik tabanlı transfer (feature-based), parametre tabanlı transfer (parameter-based) ve örnek tabanlı transfer (instance-based) yöntemler. Özellik tabanlı transfer yöntemleri, kaynak ve hedef görevler için ortak bir özellik uzayı öğrenmeyi amaçlar. Örneğin, “Domain-Adversarial Training of Neural Networks (DANN)” gibi yöntemlerde, modelin kaynak ve hedef domain’lerde aynı temsil uzayını öğrenmesi sağlanır. Bu sayede, veriler arasındaki dağılım farklılıklarına rağmen öğrenilen temsiller hedef görevde de başarılı bir şekilde kullanılabilir. Bu yaklaşımda genellikle özellik ayrıştırma (feature extraction) katmanları dondurularak yalnızca sınıflandırıcı yeniden eğitilir. Parametre tabanlı transfer yöntemleri ise, bir modelin (genellikle derin sinir ağı) önceden eğitilmiş parametrelerini, benzer görevlerde yeniden kullanmayı esas alır. En yaygın örneği, bir sinir ağının erken katmanlarının dondurulup son katmanlarının hedef veri ile yeniden eğitilmesidir (fine-tuning yöntemi). Bu yöntem, görsel görevlerde yaygın olarak kullanılır; örneğin ImageNet veri kümesi üzerinde eğitilmiş bir CNN, medikal görüntü sınıflandırmada başarıyla transfer edilebilir (Yosinski ve ark., 2014). Örnek tabanlı transfer yöntemleri, kaynak görevdeki verilerin doğrudan hedef görevde kullanılmasını içerir. Bu yaklaşımda, hedef görev için uygun olmayan örneklerin etkisi azaltılırken benzer örneklerin katkısı artırılır. Örnek ağırlıklama (instance weighting) teknikleri, bu yaklaşımın bir parçasıdır ve kaynak verilerin hedef görevdeki doğruluğunu artırmayı hedefler. Bunların yanında multi-task learning (çoklu görevli öğrenme), meta-öğrenme (learning to learn) gibi transfer öğrenmeye yakın fakat daha genel yöntemler de gelişmektedir. Bu yöntemlerde, model birden fazla görev üzerinde eğitilerek daha esnek bir öğrenme süreci gerçekleştirebilir. Transfer öğrenme, doğal dil işleme, görüntü tanıma, medikal teşhis sistemleri, robotik ve daha birçok alanda modelleme maliyetlerini azaltarak yüksek doğruluk elde etmeyi mümkün kılmaktadır. Sonuç olarak, transfer öğrenme yöntemleri, sınırlı veri ile güçlü modeller geliştirme yolunda önemli bir paradigma sunmaktadır.

3.2.6. RegNet nedir?

Derin öğrenme ve bilgisayarla görme alanında, evrimsel sinir ağları görüntü sınıflandırma, nesne tespiti ve segmentasyon gibi görevlerde temel yapı taşıdır. Ancak klasik CNN mimarileri, genellikle manüel tasarım ve mimari karmaşıklık nedeniyle performans-verimlilik dengesinde zorluklar yaşar. Bu noktada RegNet (Regularized Network) modelleri, yapısal düzen ve ölçeklenebilirliği ön planda tutarak, CNN tasarımında yeni bir paradigma sunar (Radosavovic ve ark., 2020). RegNet, temel olarak ağın farklı katmanlarındaki kanal genişlikleri ve blok sayıları gibi mimari parametrelerin matematiksel olarak düzenlenmesini hedefler. Bu düzenleme, mimarinin daha tutarlı, tekrarlanabilir ve optimize edilebilir olmasını sağlar. Böylece model, hem daha iyi genel performans hem de hesaplama verimliliği sunar. RegNet’in temel felsefesi, ağ yapısını “düzensiz” ve rastgele tasarlamak yerine, bir parametrik fonksiyon üzerinden düzenleyerek tüm katmanlarda benzer artış ve gelişim trendi sağlamaktır. Bu da RegNet’in yapılandırılmasını ve büyütülmesini kolaylaştırır (Radosavovic ve ark., 2020).

Matematiksel olarak RegNet modellerinde kanal genişliği w_i her aşama (stage) için şu şekilde hesaplanır:

$$w_i = w_0 + i \cdot \delta \quad (3.1)$$


Burada;

- w_0 başlangıç kanal genişliğini,
- δ kanal artış miktarını,
- i ise aşama indeksini gösterir.

Bu parametreler, modelin karmaşıklığına ve hedef hesaplama gücüne göre ayarlanır. Kanal sayılarının düzenli artışı, ağda verimli bilgi aktarımı ve hesaplama dengesi sağlar (Radosavovic ve ark., 2020). RegNet, iki ana versiyona sahiptir: RegNetX ve RegNetY. RegNetY modelleri, kanal bazında dikkat (attention) mekanizması sağlayan Squeeze-and-Excitation (SE) bloklarını içerirken, RegNetX daha basit yapıya sahiptir. RegNet modelleri, ImageNet gibi büyük ölçekli veri kümelerinde başarılı sonuçlar vermekte ve güncel mimarilerle rekabet etmektedir (Radosavovic ve ark., 2020).

RegNet, farklı hesaplama güçlerine ve kullanım senaryolarına uygun çeşitli model varyantları içeren düzenli ve parametrik bir ağ ailesidir. Modeller genellikle FLOPs (floating point operations) cinsinden hesaplama karmaşıklığına göre sınıflandırılır ve

düşük hesaplamadan yüksek hesaplama doğru genişleyen bir yapı gösterir. Her model, belirli bir derinlik, kanal genişliği ve grup sayısı ile optimize edilmiştir. RegNetX modelleri temel residual bottleneck bloklarını kullanırken, RegNetY modelleri aynı yapıya Squeeze-and-Excitation (SE) modüllerini ekleyerek performans artışı sağlar. Bu modeller, çeşitli uygulamalar için hız, verimlilik ve doğruluk arasında iyi bir denge sunar.



Şekil 3.11.RegNet modelinin mimari yapısı

RegNet modeli mimari şeması açıklaması

1. Girdi (Feature map):

- Modelin girişine üç kanallı (RGB benzeri) ve $r \times r$ boyutlarında bir özellik haritası (feature map) gelir. Burada r giriş görüntüsünün çözünürlüğünü temsil eder.

2. Stem Bloğu:

- Girdi görüntüsü önce bir 3×3 konvolüsyon katmanından geçer.
- Bu katman Batch Normalization (BN) ve ReLU aktivasyon fonksiyonu ile desteklenir.
- Buradaki konvolüsyonun stride (adım) değeri $r / 2$ şeklindedir, yani giriş çözünürlüğü yarıya iner.
- Stem bloğundan çıkan özellik haritasının kanal sayısı w_0 ile gösterilir.

3. Body (Ağ Gövdesi):

- Gövde kısmı 4 aşamadan (Stage 1, Stage 2, ..., Stage 4) oluşur.
- Her aşama, bir veya daha fazla blok içerir. Her aşamanın çıktı çözünürlüğü sırasıyla $r/2$, $r/4$, $r/8$, $r/32$ gibi azalan oranlarda olur.
- Aşamaların kanal genişlikleri $w_1, w_2, \dots, w_4$ ile ifade edilir.

4. Stage (Aşama) Detayı:

- Her aşama birden fazla bloğa sahiptir (d_i sayıda blok).
- Bu bloklar aynı yapıda, tekrarlanan konvolüsyon bloklarıdır.
- Bir aşamanın ilk bloğu, genellikle çözünürlüğü düşüren (stride=2 olan) bir konvolüsyon içerir; sonraki bloklar ise çözünürlüğü korur.

5. Block (Blok) Detayı:

- Her blok üç konvolüsyon katmanından oluşur:
 - İlk olarak 1×1 konvolüsyon (kanal sayısını azaltmak veya değiştirmek için) — ardından BN ve ReLU gelir.
 - İkinci katman, 3×3 grup konvolüsyonu (Group Conv) — burada kanal gruplarına ayrılarak işlem yapılır; yine BN ve ReLU destekli.
 - Son katman tekrar 1×1 konvolüsyon (kanal sayısını eski haline getirmek için) — burada sadece BN uygulanır, ReLU yoktur.
- Son olarak bu bloğun çıkışı, girdiye eklenir (residual bağlantı) ve ardından ReLU uygulanır.

6. Head (Baş) Bloğu:

- Tüm aşamalardan sonra gelen kısımdır.
- Burada Global Average Pooling (GAP) layer ile özellik haritaları ortalınır.
- Son olarak tam bağlantılı (Fully Connected, FC) bir katman kullanılarak sınıflandırma yapılır.
- Çıkış boyutu n sınıf sayısını, $1 \times 1 \times 1$ ise çıktı tensör boyutlarını gösterir.

3.2.6.1. RegNety-400MF modeli ve özellikleri


RegNetY-400MF, RegNet ailesinin bir parçası olup, derin öğrenme alanında CNN kullanılarak oluşturulmuş bir modeldir. RegNet serisi, daha önceki derin öğrenme modellerinden farklı olarak, ağ yapısının tasarımında hiperparametre arayışı yerine daha sistematik bir yaklaşım benimser. RegNet modelleri, model tasarımını optimize etmek amacıyla kanal genişliği, derinlik ve blok sayısının belirlenmesinde düzenli bir yapı izler

(Radoslav ve Choi, 2020). Bu model, geleneksel ağ tasarım stratejilerinin ötesine geçerek, model arama alanında verimliliği ve hesaplama kaynaklarının etkin kullanılmasını amaçlar. RegNetY-400MF, doğrudan hesaplama gücüne ihtiyaç duyulmadan, düşük maliyetle yüksek doğruluk elde edilmesini sağlar. Modelin bu tasarımı, özellikle görüntü sınıflandırma ve algılama gibi büyük veri kümelerinde büyük başarı sağlamaktadır. RegNet modellerinin temel avantajlarından biri de bu yapılandırmaların daha az sayıda parametre ile optimal sonuçlar vermesidir.

RegNetY-400MF'nin mimarisi, Squeeze-and-Excitation (SE) modülleri ile güçlendirilmiş bir yapıya sahiptir. SE modülleri, her bir kanalın önemini adaptif bir şekilde öğrenir ve bu öğrenilen bilgilere göre her kanalın katkısını artırıp azaltır. Bu, modelin kanal dikkatini (channel attention) daha iyi odaklayarak önemli özelliklerin ön plana çıkmasına yardımcı olur. SE modüllerinin kullanımı, özellikle görüntülerin içindeki ince ve küçük detayların daha etkili bir şekilde öğrenilmesini sağlar (Xie ve ark., 2020). Bu sayede model, daha güçlü ve doğru sonuçlar elde eder. RegNetY-400MF'nin SE modülleri, hem verimliliği artırır hem de sınıflandırma doğruluğunu iyileştirir. RegNetY-400MF'nin mimarisi, dört ana aşama (stage) üzerinden yapılandırılmıştır: Stage 1 (32 kanal), Stage 2 (64 kanal), Stage 3 (128 kanal) ve Stage 4 (256 kanal). Her bir aşama, modelin derinliği ve kanal sayısındaki artışla birlikte daha karmaşık özelliklerin çıkarılmasına olanak tanır. Modelin her bir stage'inde, bottleneck blokları yer alır. Bu bloklar, 1x1 konvolüsyon (channel genişletme) ve 3x3 konvolüsyon (derinlik wise) işlemlerini içerir. Bu yapı, derin özellik çıkarımı yapılırken aynı zamanda modelin parametre sayısının kontrol altında tutulmasını sağlar. Bottleneck blokları, kanal genişletme ve daraltma işlemleriyle optimizasyon yaparak, özelliklerin daha verimli çıkarılmasını mümkün kılar. Modelde kullanılan bir diğer önemli işlem ise global average pooling'dir. Bu işlem, her bir özellik haritası için ortalama alarak tüm çıktıları tek bir vektöre indirger. Bu, modelin çıktılarını daha kompakt hale getirirken, overfitting (aşırı uyum) riskini de azaltır. Global average pooling, ağırlık paylaşımını optimize eder ve modelin daha iyi genelleme yapabilmesine olanak tanır. Son olarak, tam bağlı (fully connected) katman kullanılarak 1000 farklı sınıf için sınıflandırma yapılır. Bu yapı, ImageNet gibi büyük veri kümelerinde sınıflandırma görevlerinin başarılı bir şekilde gerçekleştirilmesine olanak tanır.

RegNetY-400MF modeli, 400 milyon FLOP'a (floating point operations) sahip olup, bu değeri ile yüksek verimlilik sunar. Bu, modelin yüksek performansını sağlarken aynı zamanda hesaplama kaynaklarını optimize etmesini sağlar. RegNetY-400MF, derin

öğrenme uygulamalarında özellikle görüntü sınıflandırma, nesne algılama, medikal görüntüleme gibi alanlarda başarıyla kullanılmaktadır. Modelin verimli tasarımı ve güçlü öğrenme kapasitesi, onu büyük veri kümeleri ile yapılan görevlerde ideal bir seçim haline getirir. RegNetY-400MF'nin ImageNet gibi geniş veri kümelerinde test edilmesi, modelin farklı sınıflarda yüksek doğruluk oranlarına ulaşmasını sağlamaktadır. Ayrıca, medikal görüntüleme gibi çok daha özel ve küçük veri kümelerinde de başarılı sonuçlar verdiği görülmüştür. Bu model, modern derin öğrenme mimarilerinin, hesaplama verimliliği ve doğruluk arasındaki dengeyi nasıl optimize edebileceğini gösteren önemli bir örnek teşkil etmektedir. RegNet modellerinin sistematik yapısı, daha büyük modelleri ve veri kümelerini işlemek için uygun hale getirilmesine olanak tanır.




Şekil 3.12. RegNetY-400MF modelinin mimari yapısının şematik gösterimi

3.2.6.2. RegNetY-800MF modeli ve özellikleri

RegNetY-800MF, Facebook AI Research tarafından geliştirilen RegNet ailesinin bir üyesidir ve CNN kapsamında, görüntü sınıflandırma gibi görevlerde kullanılan modern ve verimli bir derin öğrenme modelidir. RegNet serisi, derin öğrenme ağlarının tasarımında standart hiperparametre arama yöntemlerinin ötesine geçerek, ağ yapısının sistematik ve düzenli parametrelerle yapılandırılması prensibine dayanır (Radoslav ve Choi, 2020). Bu model ailesi, kanal genişliği, blok sayısı ve ağ derinliği gibi önemli parametrelerin belirli matematiksel kurallar doğrultusunda seçildiği tasarım alanlarını kullanır. Böylece, RegNet modelleri hem yüksek doğruluk sağlar hem de hesaplama

açısından optimize edilmiş yapılardır. RegNetY-800MF modeli, yaklaşık 800 milyon FLOP (floating point operations) değerine sahiptir ve bu değer onu RegNet ailesi içinde orta seviye bir performans ve hesaplama maliyeti dengesi sunan model yapar. “Y” harfi, modelin Squeeze-and-Excitation (SE) modülleri içerdiğini gösterir. SE modülleri, her kanalın önemini öğrenerek modelin dikkat mekanizmasını güçlendirir ve böylece sınıflandırma performansını artırır (Hu, Shen, & Sun, 2018). Bu mekanizma, özellikle görüntülerdeki küçük ve karmaşık detayların algılanmasında önemli bir rol oynar. Mimari olarak RegNetY-800MF, girişte tipik olarak 224x224 boyutunda üç kanallı (RGB) görüntüyü alır ve ilk olarak 3x3 çekirdek boyutunda, stride=2 parametresi ile çalışan, yaklaşık 32 kanallı bir konvolüsyon katmanından geçirir. Ardından model, dört evrimsel aşamadan (stage) oluşur; her aşamada farklı sayıda bottleneck bloklar bulunur. Bu bloklar, 1x1 ve 3x3 konvolüsyon katmanlarından oluşan, kanal genişletme ve daraltma işlemlerini optimize eden yapılar olarak tanımlanır. RegNetY-800MF’de blok sayıları ve kanal genişlikleri, modelin hesaplama gereksinimi ve doğruluk hedeflerine göre belirlenmiştir. Örneğin, her aşamada kanal sayısı artarak, modelin derin ve yüksek seviyeli özellikler çıkarma kapasitesi yükseltilir. Her evrimsel blokta bulunan SE modülleri, kanal düzeyinde adaptif ağırlıklandırma yaparak modelin performansını iyileştirir. Bu sayede RegNetY-800MF, hem parametre sayısını hem de hesaplama yükünü verimli şekilde kullanarak, yüksek başarı sağlar. Evrim aşamalarını takiben model, global average pooling katmanıyla özellik haritalarını özetler ve ardından tam bağlı (fully connected) katman ile 1000 sınıflı bir çıktı üretir; bu çıktı genellikle ImageNet gibi veri setlerindeki sınıflandırma görevlerine karşılık gelir. RegNet modellerinin tasarım felsefesi, geleneksel derin öğrenme ağlarında sıkça karşılaşılan aşırı karmaşık hiperparametre arama süreçlerini minimize etmek ve mimarileri daha anlaşılır, modüler ve tekrarlanabilir hale getirmektir. Böylece RegNetY-800MF, özellikle kaynak kısıtlı ortamlarda ve gerçek zamanlı uygulamalarda performansından ödün vermeden etkin kullanım sağlar. Model, hem akademik araştırmalarda hem de endüstriyel uygulamalarda görsel tanıma, nesne algılama ve medikal görüntüleme gibi alanlarda başarıyla kullanılmaktadır.




Şekil 3.13. RegNetY-800MF modelinin mimari yapısının şematik gösterimi

3.2.7. EfficientNet-B0 modeli

Derin öğrenme alanında model performansını artırmak için genellikle modelin derinliği, genişliği veya giriş görüntüsü çözünürlüğü ayrı ayrı artırılır. Ancak bu tek boyutlu ölçeklendirme stratejileri, hesaplama maliyetlerinin hızla artmasına rağmen doğruluk artışlarında sınırlı kazanç sağlar. Bu sınırlamayı aşmak için geliştirilmiş EfficientNet modeli, derinlik (katman sayısı), genişlik (katman başına filtre sayısı) ve çözünürlük (giriş görüntüsünün boyutu) parametrelerini birleşik ve dengeli bir şekilde ölçeklendirmeyi önerir. Bu birleşik ölçeklendirme yaklaşımı, modelin her üç boyutunun da belirli oranlarda artırılmasını sağlayarak hem hesaplama verimliliğini korur hem de doğrulukta anlamlı iyileşmeler sağlar. EfficientNet ailesinin temel modeli olan EfficientNet-B0, bu birleşik ölçeklendirme yaklaşımının temelini oluşturmaktadır. EfficientNet-B0, otomatik mimari arama (Neural Architecture Search - NAS) yöntemleri kullanılarak optimize edilmiş temel bir modeldir. Diğer EfficientNet modelleri, EfficientNet-B0 modelinin derinlik, genişlik ve çözünürlük parametrelerinin birleşik ölçeklendirmesi ile elde edilir. EfficientNet-B0, makine öğrenmesi uygulamalarında

yüksek doğruluk ve düşük hesaplama maliyetlerini bir arada sunması nedeniyle yaygın olarak referans alınmaktadır.

EfficientNet-B0 modeli, diğer geleneksel CNN modellerine kıyasla, daha az parametre ile daha yüksek doğruluk elde eder. Model, mobil cihazlar gibi sınırlı donanım kaynaklarına sahip ortamlar için ideal çözümler sunarken, büyük veri setlerinde de rekabetçi performans göstermektedir. Bu verimlilik, EfficientNet'in ölçeklendirme stratejisinin ve optimize edilmiş temel mimarisinin bir sonucudur. Bu özellikleri sayesinde EfficientNet-B0, günümüz derin öğrenme uygulamalarında hem araştırma hem de endüstriyel uygulamalarda önemli bir rol oynamaktadır. Sonuç olarak, EfficientNet ve temel modeli EfficientNet-B0, derin öğrenme model ölçeklendirmesinde yeni bir paradigma sunmakta, hesaplama maliyetleri ile doğruluk arasındaki optimal dengeyi sağlayarak geniş uygulama alanlarına hitap etmektedir (Akash, 2023).




Şekil 3.14.EfficientNet modeli

Şekil 3.14'te gösterilen model ölçeklendirme stratejileri, derin öğrenme mimarilerinde performans ve verimlilik artışı için farklı boyutların nasıl artırılabilirliğini şematik olarak sunmaktadır. Temel model yapısı (a) olarak verilmiştir. Genişlik ölçeklendirmesinde (b), her katmandaki kanal sayısı artırılarak daha geniş katmanlar elde edilirken, derinlik ölçeklendirmesi (c) katman sayısının artırılmasıyla daha derin mimariler oluşturur. Çözünürlük ölçeklendirmesi (d) ise giriş görüntüsünün boyutlarını büyütürken modelin daha fazla detay üzerinde çalışmasını sağlar. EfficientNet'in yenilikçi birleşik ölçeklendirme yöntemi (e) ise bu üç boyutu dengeli ve eşzamanlı şekilde artırarak hem model performansını hem de hesaplama verimliliğini optimize etmektedir.

3.2.8. EfficientNet-B1 modeli

EfficientNet-B1 modeli, EfficientNet ailesinin temel modeli olan EfficientNet-B0'ın ölçeklendirilmiş ve geliştirilmiş versiyonudur. EfficientNet mimarisi, derinlik, genişlik ve çözünürlük parametrelerinin birleşik ölçeklendirilmesi prensibine dayanır. Bu üç boyutun dengeli artırımı, modelin hem doğruluğunu artırırken hem de hesaplama maliyetlerini optimal seviyede tutmasına olanak sağlar. EfficientNet-B1, EfficientNet-B0 temel modelinin bu birleşik ölçeklendirme kuralına göre daha büyük ve daha karmaşık hale getirilmiş bir versiyonudur. EfficientNet-B1'de, modelin derinliği, genişliği ve giriş görüntüsü çözünürlüğü, EfficientNet-B0'a kıyasla belirli oranlarda artırılmıştır. Bu ölçeklendirme, modelin daha fazla özellik öğrenmesini ve daha yüksek düzeyde temsil gücüne sahip olmasını sağlar. Özellikle çözünürlük boyutunun büyütülmesi, modelin giriş görüntüsünden daha fazla detay yakalamasına imkân tanır. Ayrıca genişlik ve derinlik artırımı, modelin karmaşıklığını ve kapasitesini yükseltir. Ancak, bu artırımlar, hesaplama ve bellek kullanımını da beraberinde getirdiği için, EfficientNet-B1'de ölçeklendirme katsayıları dikkatli bir şekilde belirlenmiştir. EfficientNet-B1 modeli, çeşitli görüntü sınıflandırma görevlerinde EfficientNet-B0'a kıyasla daha yüksek doğruluk değerleri sergilerken, hesaplama açısından da makul bir artış gösterir. Bu özellikleri sayesinde, EfficientNet-B1 hem araştırma hem de endüstriyel uygulamalarda tercih edilen bir model haline gelmiştir. Özellikle yüksek çözünürlüklü görüntülerin işlendiği görevlerde ve donanım kaynaklarının nispeten daha fazla olduğu ortamlar için uygundur. Sonuç olarak, EfficientNet-B1 modeli, EfficientNet ailesindeki ölçeklendirme prensiplerinin pratik bir uygulaması olup, temel modele göre daha güçlü bir mimari sunar. Bu model, hesaplama verimliliği ile yüksek doğruluk arasında dengeli bir performans sağlamak üzere optimize edilmiştir ve güncel derin öğrenme uygulamalarında önemli bir referans modeli olarak kabul edilmektedir (Akash, 2023).



Şekil 3.15. EfficientNetB1 topolojisi(Hrzić ve ark.,2021)

3.2.9. Karmaşıklık matrisi ve performans metrikleri

Derin öğrenme tabanlı tıbbi görüntü sınıflandırma problemlerinde, örneğin diyabetik ayak ülseri tespiti, model performansını objektif ve güvenilir şekilde değerlendirmek için çeşitli metrikler kullanılır. Bu metrikler, modelin pozitif ve negatif sınıflandırma başarılarını, hatalarını ve genel ayırt edicilik gücünü anlamaya yardımcı olur.

3.2.9.1. Karmaşıklık matrisi

Karmaşıklık matrisi, sınıflandırma modellerinin performansını detaylı şekilde analiz etmek için kullanılır. İki sınıflı (binary) sınıflandırma için matriste dört temel terim yer alır (Japkowicz ve Shah, 2011)


Tablo 3.1. Performans Metrik Tablosu

	Gerçek Pozitif	Gerçek Negatif
Tahmini Pozitif	True Positive(TP)	False Positive(FP)
Tahmini Negatif	False Negative(FN)	True Negative(TN)

- True Positive (TP): Hasta olanların doğru tespit edilmesi.
- True Negative (TN): Sağlıklı olanların doğru tespit edilmesi.

- False Positive (FP): Sağlıklı bireylerin yanlışlıkla hasta olarak sınıflandırılması.
- False Negative (FN): Hasta bireylerin yanlışlıkla sağlıklı olarak sınıflandırılması.

Karışıklık matrisi, modelin hata türlerini ve performans metriklerinin hesaplanmasını sağlar.



Şekil 3.16. Karmaşıklık Matrisi örneği (GeeksforGeeks, 2025)

3.2.9.2. Performans Metrikleri

Doğruluk (Accuracy): Modelin doğru sınıflandırdığı örneklerin toplam örneğe oranıdır. Genel başarıyı ölçer.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (3.2)$$

Dezavantaj: Dengesiz veri setlerinde yanıltıcı olabilir; örneğin, hasta oranı düşükse yüksek doğruluk sağlanabilir ama hasta tespiti kötü olabilir (Sokolova ve Lapalme, 2009).

Kesinlik (Precision): Modelin pozitif tahminlerinin doğruluk oranıdır. Yani, modelin hasta dediği örneklerden kaç tanesi gerçekten hastadır.

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3.3)$$

Klinik önemi: Yanlış pozitiflerin (sağlıklı kişiyi hasta göstermenin) azaltılması gereklidir (Powers, 2011).

Duyarlılık (Recall / Sensitivity): Gerçek pozitiflerin doğru tahmin edilme oranıdır. Hasta olanların ne kadarının model tarafından yakalandığını gösterir.

$$\text{Recall} = \frac{TP}{TP+FN} \quad (3.4)$$

Klinik önemi: Hasta kaçırmamak için kritik bir metriktir (Fawcett, 2006).

F1 Skoru: Kesinlik ve duyarlılığın harmonik ortalamasıdır, dengeli bir performans ölçer.


$$F1 = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (3.5)$$

Klinik Önemi: Dengesiz veri setlerinde tercih edilir. (Saito ve Rehmsmeier, 2015). Klinikte yanlış negatifler kadar yanlış pozitifler de risklidir. F1 skoru, bu iki durumu birlikte optimize ederek modelin pratikte uygulanabilirliğini göstermesi açısından çok önemlidir.

Özgüllük (Specificity): Bir modelin hasta olmayan bireyleri doğru bir şekilde “sağlıklı” olarak tanımlama oranıdır. Diğer bir deyişle, negatif olanları doğru tanıma yeteneği olarak tanımlanır.

$$\text{Özgüllük} = \frac{TN}{TN+FP} \quad (3.6)$$


Klinik Önemi: Model ne kadar iyi bir şekilde sağlıklıları sağlıklı olarak tanıyor? sorusuna yanıt verir.



Şekil 3.17. Precision, Recall ve F1 Score örneği(Raza ve ark.,2022)

AUC-ROC (Area Under the ROC Curve): ROC eğrisi, modelin farklı eşiklerdeki duyarlılık ve özgüllüğünü gösterir. AUC (Eğri Altındaki Alan), modelin sınıflandırma başarısını tek bir değer olarak özetler.

- ROC Eğrisi: Yatay ekseninde 1-Özgüllük (False Positive Rate), dikey ekseninde Duyarlılık (True Positive Rate) vardır.
- AUC Değeri: 0.5 rastgele, 1 mükemmel sınıflandırma anlamına gelir (Ling ve ark., 2003).
-



Şekil 3.18. ROC Eğrisi ve ROC-AUC Grafiği

4. BULGULAR

Bu tez çalışmasında, diyabetik ayak ülserlerinin erken ve doğru bir şekilde tespit edilmesi amacıyla derin öğrenme tabanlı modeller kullanılarak kapsamlı bir analiz gerçekleştirilmiştir. Çalışmada temel hedef, yüksek çözünürlüklü tıbbi görüntüler üzerinde etkili sonuçlar üretebilecek, klinik kullanıma uygun yapay zeka sistemlerinin geliştirilmesidir. Bu bağlamda, özellikle CNN mimarilerine dayanan gelişmiş modeller tercih edilmiş ve hem literatürde başarı sağlamış hem de pratik uygulamalarda kullanılabilirliği yüksek olan dört farklı model detaylı biçimde değerlendirilmiştir: RegNetY-400MF, RegNetY-800MF, EfficientNet-B0 ve EfficientNet-B1.

RegNet mimarisi, son yıllarda evrişimli sinir ağı tasarımında parametrik verimliliği ve yüksek doğruluğu birleştiren önemli bir yaklaşım olarak öne çıkmaktadır. RegNetY-400MF ve RegNetY-800MF, farklı kompleksite düzeylerine sahip iki versiyon olarak seçilmiş ve bu sayede model kapasitesinin doğruluk ve genelleme üzerindeki etkisi sistematik olarak incelenmiştir. Özellikle RegNetY-800MF, daha fazla filtre ve katman derinliği ile daha karmaşık yara yapılarının daha doğru bir şekilde analiz edilmesine olanak tanımaktadır. Bu modellerin, düşük parametre sayısına rağmen yüksek doğruluk oranları sunmaları, onları hem akademik hem de endüstriyel uygulamalarda cazip hale getirmiştir.

EfficientNet mimarileri ise, model ölçekleme prensiplerini optimize eden yapısı sayesinde hem verimlilik hem de doğruluk açısından güçlü performans sergilemektedir. Bu çalışmada kullanılan EfficientNet-B0 ve EfficientNet-B1 modelleri, sırasıyla temel ve bir üst seviye versiyonlar olarak seçilmiştir. EfficientNet-B0, özellikle sınırlı donanım kaynaklarına sahip sistemler için önerilen hafif bir model olarak değerlendirilmiştir. Buna karşın EfficientNet-B1, daha geniş katman yapısı sayesinde daha ayrıntılı doku görüntülerini öğrenebilme kapasitesi ile öne çıkmıştır. Bu iki modelin karşılaştırılması, ölçeklenebilirliğin DAU tespiti üzerindeki etkilerinin daha açık bir şekilde ortaya konulmasına olanak sağlamıştır.

Tüm bu modeller, Kaggle platformunda yayımlanmış olan DFUC2021 ve DFU veri setleri üzerinde eğitilmiş ve test edilmiştir. Veriler, yüksek çözünürlüklü ayak görüntülerinden oluşmakta ve farklı evrelerdeki ülserli ve sağlıklı bölgeleri içermektedir.


Modellerin eğitimi sırasında, transfer öğrenme stratejileri uygulanmış; ImageNet üzerinde önceden eğitilmiş ağırlıklar kullanılarak, modellerin daha hızlı ve stabil bir şekilde öğrenmeleri sağlanmıştır. Bu yöntem, sınırlı sayıda etiketli medikal görüntü ile çalışan araştırmalarda yaygın bir şekilde tercih edilmekte olup, model başarımını önemli ölçüde artırmaktadır. Buna ek olarak, veri ön işleme adımlarında kontrast artırma, gürültü giderme ve kenar keskinleştirme teknikleri uygulanmış; bu işlemlerin model tahmin doğruluğu üzerindeki etkileri analiz edilmiştir. Ayrıca veri çoğaltma (data augmentation) stratejileri ile eğitim veri seti zenginleştirilmiş ve böylece modellerin genelleme yetenekleri güçlendirilmiştir. Görüntüler üzerinde yapılan döndürme, ölçekleme ve yatay-aynalanma gibi işlemler, modelin farklı varyasyonlara karşı duyarlılığını artırmış ve öğrenme sürecinde çeşitlilik sağlamıştır. Sonuçların yorumlanacağı bölüme hazırlık amacıyla gerçekleştirilen bu deneysel süreçler, kullanılan her bir modelin hem teknik kapasitesini hem de klinik uygulamalara olan uygunluğunu çok boyutlu bir şekilde değerlendirmeyi mümkün kılmıştır. RegNet ve EfficientNet mimarilerinin, klasik CNN yaklaşımlarına kıyasla çok daha az parametre ile yüksek doğruluk sağlayabilmeleri, onları özellikle mobil sağlık uygulamaları ve düşük kaynaklı klinik ortamlar için ideal adaylar haline getirmiştir.

Bu bağlamda, çalışmanın sonuç bölümü; kullanılan modellerin karşılaştırmalı performans analizine, doğruluk oranlarına, hata tiplerine, genelleme kapasitesine ve klinik uygulanabilirliğine ilişkin kapsamlı bulgular sunarak, literatürdeki önemli boşlukları doldurmayı ve tıbbi yapay zeka alanına katkıda bulunmayı hedeflemektedir. Ayrıca bu analizler, diyabetik ayak ülserlerinin erken teşhisi için yapay zeka temelli sistemlerin güvenilir ve pratik bir çözüm sunabileceğine dair güçlü kanıtlar sağlamaktadır.

Makine öğrenmesi ve derin öğrenme modellerinin eğitim süreci boyunca elde ettikleri başarı düzeyini izlemek ve değerlendirmek amacıyla performans grafikleri önemli bir araç olarak kullanılmaktadır. Bu grafikler, genellikle doğruluk (accuracy), kayıp (loss), hassasiyet (precision) ve özgüllük (specificity) gibi metriklerin zaman içerisindeki değişimini, çoğunlukla eğitim döngüsü sayısı olan epoch bazında sunar. Performans grafiklerinin en temel işlevi, modelin aşırı öğrenme (overfitting) veya eksik öğrenme (underfitting) eğiliminde olup olmadığını gözlemlemeyi mümkün kılmasıdır. Eğitim ve test doğruluklarının bir arada gösterilmesi sayesinde, modelin yalnızca eğitim verisine mi uyum sağladığı yoksa genel veriler üzerinde de başarılı olup olmadığı anlaşılabilir. Ayrıca bu grafikler, optimum eğitim süresinin belirlenmesinde de rehberlik

eder; doğruluk artışının durağanlaştığı noktada eğitimin durdurulması, zaman ve kaynak tasarrufu sağlar. Bunun yanı sıra farklı mimarilere sahip modellerin performansları, eğitim ve test doğruluğu üzerinden nesnel bir biçimde karşılaştırılabilir. Bu çalışmada da bu yaklaşıma uygun olarak, dört farklı derin öğrenme mimarisine ait eğitim ve test doğruluğu eğrileri, 100 epoch boyunca izlenmiş ve modellerin zaman içerisindeki başarı eğilimleri ayrıntılı biçimde görselleştirilmiştir. Bu grafikler doğrultusunda, her bir modelin öğrenme performansı, kararlılığı ve genelleme kapasitesi detaylı biçimde analiz edilmiştir.

Şekil 4.1. de bu tez çalışmasında kullanılan transfer derin öğrenme modellerin DFU veri seti üzerinde test edilmesi durumunda elde edilen performans grafikleri verilmiştir.



Şekil 4.1. Modellere ait performans grafikleri

Şekil 4.1'e bakıldığında RegNetY-400MF modeli, parametrik olarak daha hafif bir RegNet mimarisi olup bu çalışmada derin öğrenme tabanlı DAU teşhisi için değerlendirilmiştir. Modelin eğitim eğrisi incelendiğinde, doğruluk oranının oldukça hızlı bir biçimde %99'un üzerine çıktığı ve bu seviyeyi eğitim süresince koruduğu görülmektedir. Bu durum, modelin eğitim verisini çok iyi öğrendiğini ve model kapasitesinin eğitim örnekleriyle oldukça iyi örtüştüğünü göstermektedir. Ancak test doğruluğu eğrisine bakıldığında, eğitim doğruluğunun biraz altında seyreden ve özellikle epoch'lar ilerledikçe ufak dalgalanmalar gösteren bir yapı dikkat çekmektedir. Bu

dalgalanmalar, modelin test verileri üzerinde zaman zaman kararsızlık yaşadığını ve genelleme yeteneğinde istikrarsızlık olabileceğini düşündürmektedir. Dolayısıyla bu model genel olarak yüksek doğruluk oranları sunsa da, eğitim verisine aşırı uyum sağlama eğilimi göstermesi nedeniyle hafif düzeyde bir overfitting etkisi sergilemektedir. Klinik uygulamalarda, modelin bu kararsızlığı dikkate alınarak dikkatli bir şekilde değerlendirilmesi gerekmektedir. RegNet mimarisinin daha geniş ve güçlü bir varyantı olan RegNetY-800MF modeli, bu çalışmada yüksek kapasiteli öğrenme yapısıyla önemli başarılar elde etmiştir. Eğitim süreci boyunca hem eğitim doğruluğu hem de test doğruluğu çok kısa sürede yaklaşık %99 seviyesine ulaşmış ve bu başarıyı grafik boyunca korumuştur. Eğitim ve test eğrilerinin birbirine çok yakın seyretmesi, modelin yalnızca eğitim verisine değil, aynı zamanda daha önce görmediği test verilerine karşı da yüksek doğrulukla tahmin yapabildiğini göstermektedir. Bu durum, modelin hem öğrenme hem de genelleme açısından oldukça dengeli ve istikrarlı bir performans sergilediğini ortaya koymaktadır. Test doğruluğunda gözlemlenen çok az sayıdaki dalgalanma, istatistiksel olarak anlamlı bir performans kaybı yaratmamış, aksine modelin yapısal esnekliğini ve dayanıklılığını desteklemiştir. RegNetY-800MF modeli, özellikle karmaşık yapı yapılarının bulunduğu görüntülerin analizinde yüksek başarı göstererek, klinik uygulamalar açısından güvenilir bir alternatif olduğunu kanıtlamaktadır. Daha yüksek model kapasitesi sayesinde, veri setindeki çeşitli varyasyonları daha iyi öğrenebilmekte ve yüksek doğruluk düzeyini sürdürebilmektedir.

EfficientNet-B0 modeli, bu çalışmada değerlendirilen en kompakt mimarilerden biri olarak öne çıkmaktadır. Ölçeklenebilir model yapısı sayesinde düşük hesaplama maliyeti ile yüksek doğruluk sunma kapasitesine sahiptir. Eğitim eğrisine bakıldığında, doğruluğun çok hızlı bir şekilde %99 seviyesine ulaştığı ve bu seviyede sabitlendiği görülmektedir. Test doğruluğu ise yaklaşık %98,5 civarında stabilize olmuş ve eğitim doğruluğu ile oldukça paralel bir seyir izlemiştir. Bu paralellik, modelin genelleme yeteneğinin yüksek olduğunu ve overfitting etkisinin çok düşük düzeyde kaldığını ortaya koymaktadır. Test doğruluğu eğrisinde zaman zaman çok küçük dalgalanmalar görülse de bu değişimler modelin genel başarımı üzerinde olumsuz bir etki yaratmamaktadır. EfficientNet-B0, özellikle düşük kaynaklara sahip cihazlar ya da mobil sağlık uygulamaları için ideal bir çözüm sunmaktadır. Yüksek doğruluğunun yanı sıra, hesaplama verimliliği de dikkate alındığında bu model, gerçek zamanlı klinik karar destek sistemlerinde kullanılabilecek etkili ve ekonomik bir alternatif olarak değerlendirilebilir. EfficientNet-B1 modeli, EfficientNet-B0 mimarisinin bir üst seviyesi olarak daha geniş

katman yapısına ve daha fazla parametreye sahiptir. Bu yapısal genişleme sayesinde model, daha karmaşık özellikleri öğrenebilmekte ve görüntüler üzerindeki ayrıntılı yapıları daha iyi temsil edebilmektedir. Eğitim süreci boyunca model doğruluk açısından çok hızlı bir yükseliş göstermiş ve her iki doğruluk eğrisi de %99 seviyesine ulaşmıştır. Ancak bu modelin grafiğinde dikkat çeken önemli bir nokta, test doğruluğunun eğitim doğruluğuna göre daha erken doygunluğa ulaşması ve eğitim boyunca oldukça stabil bir seyir izlemesidir. Bu durum, modelin genelleme kapasitesinin son derece güçlü olduğunu ve test verisi üzerindeki performansının yüksek düzeyde sürdürülebilir olduğunu göstermektedir. Eğitimin hiçbir aşamasında belirgin dalgalanmaların görülmemesi, modelin yüksek kararlılığa ve istikrara sahip olduğunu ortaya koymaktadır. EfficientNet-B1, özellikle yüksek doğruluk ve düşük varyans isteyen medikal görüntüleme görevlerinde güvenilir sonuçlar sağlayabilecek ileri seviye bir model olarak öne çıkmaktadır. Karmaşık yara yapılarının bulunduğu klinik veri setlerinde başarılı sonuçlar vermesi, onu pratik kullanım için ideal bir seçenek haline getirmektedir.


Bu dört modelin karşılaştırmalı analizi doğrultusunda, tamamının yüksek doğruluk oranlarına sahip olduğu ve diyabetik ayak ülseri teşhisi için uygulanabilir modeller sunduğu görülmektedir. Ancak RegNetY-800MF ve EfficientNet-B1 modelleri, özellikle test verileri üzerindeki kararlı ve yüksek doğruluk oranlarıyla dikkat çekmektedir. Bu iki model, genelleme yeteneklerinin güçlü olması, minimum dalgalanma sergilemeleri ve eğitim-test doğruluk farkının çok düşük olmasıyla öne çıkmaktadır. EfficientNet-B1 modeli, daha derin yapısı ve parametre kapasitesi sayesinde yüksek doğrulukla birlikte istikrarlı performans sunmakta ve klinik ortamlarda güvenilirlik açısından güçlü bir aday haline gelmektedir. Öte yandan, donanım kaynaklarının sınırlı olduğu durumlarda EfficientNet-B0 gibi daha kompakt mimariler, maliyet-etkin ve hızlı çözümler sunmaktadır. RegNetY-400MF ise eğitim başarımı yüksek olsa da test doğruluğundaki düzensizlikler nedeniyle diğer modellere göre daha sınırlı bir genelleme performansı göstermiştir. Sonuç olarak, her modelin kendi içinde sunduğu avantajlar farklı olmakla birlikte, klinik uygulanabilirlik açısından EfficientNet-B1 ve RegNetY-800MF modelleri bu çalışma özelinde öne çıkmaktadır.

Makine öğrenmesi ve derin öğrenme modellerinin başarımını değerlendirirken doğruluk (accuracy) grafikleri kadar kayıp (loss) grafikleri de büyük önem taşımaktadır. Kayıp, bir modelin yaptığı tahminlerin gerçek değerlerden ne ölçüde saptığını gösteren nicel bir ölçüttür. Modelin eğitim ve test süreçlerinde hesaplanan bu metrik, öğrenme süreci boyunca yapılan hataların seviyesini doğrudan yansıtır. Özellikle sınıflandırma

problemlerinde sıklıkla kullanılan cross-entropy loss gibi fonksiyonlar, modelin ürettiği çıktılarının güvenilirliğini optimize etmeye yardımcı olur. Kayıp fonksiyonunun değeri azaldıkça, modelin tahminlerinin doğru etiketlere olan yakınlığı artar; bu da öğrenme sürecinin verimli ilerlediğini gösterir.

Kayıp grafiklerinin yorumlanması, modelin eğitim sürecindeki performansına dair çok önemli ipuçları sağlar. Eğitim ve test kayıplarının eğrileri karşılaştırılarak, modelin yalnızca eğitim verisine mi odaklandığı (overfitting) ya da veriyi yeterince öğrenemediği (underfitting) gibi sorunlar kolaylıkla tespit edilebilir. Aynı zamanda, eğitim süresi boyunca modelin öğrenme başarımı iyileşiyor mu, yoksa belirli bir noktadan sonra duraklıyor ya da kötüleşiyor mu soruları da kayıp grafikleri ile yanıtlanabilir. Bu grafikler ayrıca, modelin farklı mimarileri ya da hiperparametre ayarları altında nasıl davrandığını karşılaştırmak için de oldukça etkilidir.

Bu çalışmada kullanılan dört farklı derin öğrenme modeline ait kayıp grafikleri dikkatle analiz edilmiştir. Her bir model için hem eğitim kaybı hem de test kaybı 100 epoch boyunca görselleştirilmiş, grafikler üzerinden modelin genelleme başarımı, öğrenme hızı ve istikrar düzeyi detaylı olarak değerlendirilmiştir. Bu analizler sonucunda, modellerin yalnızca doğruluklarına değil, aynı zamanda hata oranlarına ve bu hataların zaman içerisindeki seyirlerine göre de karşılaştırılması mümkün olmuştur. Bu kapsamda, kayıp grafikleri model seçimi ve optimizasyon sürecinde vazgeçilmez bir araç olarak değerlendirilmiştir. Kullanılan 4 modele ait yitim grafikleri ise Şekil 4.2’de verilmiştir.



Şekil 4.2. Modellere ait yitim fonksiyonları


Şekil 4.2'ye bakıldığında RegNetY-400MF modelinin kayıp grafiği incelendiğinde, eğitim kaybı eğrisinin (mavi çizgi) ilk birkaç epoch içerisinde çok hızlı bir şekilde azaldığı ve neredeyse sıfıra yakın değerlere ulaştığı görülmektedir. Bu durum, modelin eğitim verisi üzerinde oldukça iyi bir öğrenme gerçekleştirdiğini göstermektedir. Ancak test kaybı (turuncu çizgi), eğitim kaybına kıyasla daha yüksek seviyelerde seyretnmekte ve eğitim süresi boyunca belirli dalgalanmalar göstermektedir. Test kaybındaki bu düzensizlik, modelin eğitildiği veri dışında kalan örneklerde zaman zaman kararsız tahminlerde bulunduğunu ve sınırlı bir genelleme kapasitesine sahip olduğunu düşündürmektedir. Ayrıca test kaybının epoch ilerledikçe artış eğilimi göstermesi, modelin daha fazla eğitilmesi durumunda overfitting etkisinin belirginleşebileceğine işaret etmektedir. Bu nedenle RegNetY-400MF modeli, yüksek eğitim başarımına rağmen test verileri üzerindeki performansı açısından dikkatli bir değerlendirme gerektirmektedir. Daha geniş mimari kapasiteye sahip olan RegNetY-800MF modeli, eğitim süreci boyunca hem eğitim hem de test verisi üzerinde oldukça dengeli ve kararlı bir kayıp eğrisi sergilemiştir. Eğitim kaybı kısa sürede minimum seviyeye düşmüş ve eğitim boyunca düşük bir seyir izlemiştir. Test kaybı ise RegNetY-400MF'ye göre daha düşük seviyelerde sabitlenmiş ve dalgalanma oranı belirgin biçimde azalmıştır. Test ve eğitim kaybı arasındaki farkın minimal olması, modelin yalnızca eğitildiği veriyi değil, görmediği verileri de başarıyla tahmin edebildiğini, dolayısıyla yüksek bir genelleme yeteneğine sahip olduğunu göstermektedir. Bu yönüyle RegNetY-800MF modeli, yalnızca teorik doğruluk başarısı değil, aynı zamanda klinik uygulamalarda kararlı ve güvenilir tahminler sunma potansiyeli açısından da oldukça değerlidir.

EfficientNet-B0 modeli, mimari olarak daha kompakt bir yapıya sahip olmasına rağmen, eğitim verisi üzerinde oldukça başarılı bir öğrenme süreci geçirmiştir. Eğitim kaybı erken Epoch'larda hızla düşmüş ve sonrasında düşük seviyelerde sabitlenmiştir. Ancak test kaybı eğrisinde zaman zaman ani sıçramalar ve düzensiz dalgalanmalar gözlemlenmiştir. Özellikle eğitim sürecinin ikinci yarısında görülen bu değişimler, modelin bazı test örnekleri karşısında kararsız kaldığını göstermektedir. Bununla birlikte, genel test kaybı seviyesi hala kabul edilebilir düzeydedir ve modelin overfitting'e yatkın olmadığı anlaşılmaktadır. EfficientNet-B0, düşük hesaplama gücüne sahip sistemlerde çalışacak uygulamalar için yeterli doğrulukta ve oldukça pratik bir çözüm sunmaktadır. Ancak kayıp grafiğindeki dalgalanma, modelin erken durdurma (early stopping) veya öğrenme oranı ayarlamaları gibi yöntemlerle desteklenmesinin faydalı olabileceğini ortaya koymaktadır. EfficientNet-B1 modeli, bu çalışmada değerlendirilen modeller

arasında en istikrarlı ve güvenilir kayıp eğrisine sahip mimari olarak öne çıkmaktadır. Eğitim kaybı oldukça hızlı bir şekilde düşerek neredeyse sıfır seviyesine ulaşmış, test kaybı ise baştan sona kadar düşük düzeyde sabit kalmıştır. Test kaybının epoch'lar boyunca neredeyse yatay bir seyir izlemesi, modelin hem eğitim verisine hem de test verisine karşı kararlı ve tutarlı tahminler yapabildiğini göstermektedir. EfficientNet-B1 modeli, geniş mimari kapasitesine rağmen overfitting etkisinden uzak durarak yüksek genelleme başarısı göstermekte ve bu yönüyle klinik uygulamalarda kullanım için güçlü bir aday olmaktadır. Kayıp grafiğindeki bu yüksek kararlılık, modelin beklenmeyen veri örnekleri karşısında bile minimum hata ile çalışabildiğine dair önemli bir gösterge sunmaktadır.

Kayıp eğrileri karşılaştırıldığında, tüm modellerin eğitim verisi üzerindeki kayıplarının oldukça düşük seviyelere ulaştığı ve etkili bir öğrenme süreci gerçekleştirdiği anlaşılmaktadır. Ancak test verisi üzerindeki performans incelendiğinde, EfficientNet-B1 ve RegNetY-800MF modelleri açık ara en kararlı ve düşük kayıp seviyesine sahip modeller olarak öne çıkmaktadır. EfficientNet-B1 modeli, kayıp eğrilerinde dalgalanmaların neredeyse tamamen yokluğu sayesinde klinik uygulamalarda yüksek güvenilirlik sunmakta; RegNetY-800MF modeli ise daha geniş bir parametre yapısıyla benzer bir başarıyı sağlamaktadır. EfficientNet-B0, kompakt yapısına rağmen oldukça tatmin edici bir performans göstermiş, ancak bazı dönemlerde test kaybındaki dalgalanmalar nedeniyle stabilite açısından dikkatli kullanım gerektirmiştir. RegNetY-400MF ise başarılı bir öğrenme süreci sunmasına rağmen, test kaybındaki düzensizlikler ve artış eğilimi nedeniyle daha temkinli bir değerlendirme gerektirmektedir. Bu analizler göstermektedir ki, kayıp grafikleri sadece eğitim başarımını değil, aynı zamanda modelin pratikteki güvenilirliğini de değerlendirmek açısından vazgeçilmez bir göstergedir. Bu nedenle, doğruluk metrikleri kadar kayıp eğrileri de model seçimi sürecinde dikkatle incelenmelidir.

Karışıklık matrisi, sınıflandırma problemlerinde modelin ne ölçüde doğru ya da hatalı tahmin yaptığını sınıf bazında görselleştirmeye yarayan önemli bir analiz aracıdır. Bu matris, gerçek etiketlerle modelin tahmin ettiği etiketlerin çakışmasını göstererek, özellikle tıbbi uygulamalarda modelin güvenilirliğini değerlendirmek açısından oldukça faydalıdır. Diyabetik ayak ülseri gibi kritik bir klinik durumu doğru tespit etme kapasitesi, karışıklık matrisleriyle daha somut şekilde değerlendirilebilir. Bu bağlamda, aşağıda her bir modelin matrisi detaylı biçimde ele alınmıştır. Şekil 4.3'te modellerin başarıları için karışıklık matrisleri verilmiştir.



Şekil 4.3. Model performanslarına ait karışıklık matrisleri


Şekil 4.3'e bakıldığında RegNetY-400MF modelinin karışıklık matrisine bakıldığında, 190 adet ülserli (abnormal) görüntüyü doğru sınıflandırdığı, 4 tanesini ise sağlıklı deri olarak yanlış etiketlediği görülmektedir. Öte yandan, tüm sağlıklı deri örnekleri doğru sınıflandırılmıştır (163/163). Bu sonuç, modelin false negative (yanlış negatif) oranı açısından hafif bir zaafı olduğunu göstermektedir. Özellikle ülserli vakaları gözden kaçırmak, klinik açıdan ciddi sonuçlar doğurabileceği için bu durum dikkatle değerlendirilmelidir. Modelin genel performansı yüksek olmakla birlikte, az sayıda da olsa ülserli vakalarda hatalı sınıflama yapması, modelin test verisinde karşılaştığı bazı varyasyonlara tam anlamıyla uyum sağlayamadığını göstermektedir. RegNetY-800MF modeli, daha güçlü bir mimari kapasiteye sahip olmasıyla birlikte karışıklık matrisinde de bu avantajını sergilemiştir. Model, 192 ülserli örneği doğru şekilde tanımlarken sadece 2 tanesini yanlış etiketlemiştir. Sağlıklı deri örneklerinin tamamı da doğru sınıflandırılmıştır (163/163). Bu sonuç, modelin hem hassasiyet (sensitivity) hem de özgüllük (specificity) açısından oldukça başarılı olduğunu ortaya koymaktadır. Ülserli bölgeleri kaçırma olasılığı düşük olduğundan, modelin özellikle klinik güvenilirlik açısından yüksek başarı sağladığı söylenebilir. Düşük hata oranı ve yüksek doğruluk, bu modeli pratik uygulamalar için en güçlü adaylardan biri hâline getirmektedir.

EfficientNet-B0 modelinin karışıklık matrisi incelendiğinde, 191 ülserli görüntünün doğru sınıflandığı, yalnızca 3 görüntünün yanlışlıkla sağlıklı olarak etiketlendiği görülmektedir. Aynı şekilde, tüm sağlıklı deri örnekleri hatasız bir şekilde

doğru sınıflandırılmıştır. Bu durum, modelin düşük parametre sayısına rağmen oldukça etkili bir sınıflandırma performansı sergilediğini göstermektedir. EfficientNet-B0 modeli, özellikle mobil ya da düşük kaynaklı sistemlerde çalıştırılabilecek hafif bir model olarak, klinik doğruluk anlamında da güçlü bir alternatif sunmaktadır. Çok az sayıda hata yapması, sınıflar arasında dengesiz bir başarıyı sergilemediğini ve yüksek genelleme kapasitesine sahip olduğunu göstermektedir. EfficientNet-B1 modeli, karışıklık matrisine göre 191 ülserli vakayı doğru sınıflandırmış, 3 vakayı ise yanlış olarak sağlıklı etiketlemiştir. Tüm sağlıklı deri örnekleri ise doğru sınıflanmıştır. EfficientNet-B0 ile neredeyse aynı düzeyde doğruluk sunmakta olan bu model, daha geniş katman yapısı sayesinde veriyi daha ayrıntılı işleyebilmekte ve hata oranını düşük tutabilmektedir. Test setinde hatalı sınıfladığı ülserli örnek sayısı oldukça az olup, sağlıklı deri sınıfında sıfır hata ile çalışması modelin yanlış pozitif (false positive) üretme eğiliminin olmadığını göstermektedir. EfficientNet-B1 modeli, doğruluk ve istikrar açısından RegNetY-800MF ile birlikte en güvenilir modellerden biri olarak değerlendirilebilir.

Karışıklık matrisleri dikkate alındığında, dört modelin de sınıflandırma açısından oldukça başarılı olduğu, ancak özellikle RegNetY-800MF ve EfficientNet-B1 modellerinin yanlış sınıflandırma oranlarını minimize ederek klinik doğruluk açısından öne çıktığı görülmektedir. Tüm modellerin sağlıklı deri sınıfını %100 doğrulukla sınıflamış olması, özellikle normal vakaların yanlışlıkla ülserli olarak etiketlenmemesi açısından önemlidir. Bununla birlikte, ülserli sınıfta yapılan az sayıda hata, modelin gerçek pozitifleri yakalama kabiliyetinde küçük farklılıklar olduğunu göstermektedir. Sonuç olarak, hem hata sayısının azlığı hem de genel sınıflama başarısı göz önünde bulundurulduğunda, EfficientNet-B1 ve RegNetY-800MF modelleri klinik uygulamalarda en yüksek doğruluk ve güvenilirlik sunan mimariler olarak ön plana çıkmaktadır.

ROC eğrisi, sınıflandırma modellerinin performansını görsel olarak değerlendirmeye yarayan etkili bir araçtır. Bu eğri, yanlış pozitif oranı (False Positive Rate) ile doğru pozitif oranı (True Positive Rate) arasındaki ilişkiyi gösterir. ROC eğrisinin altında kalan alan (AUC - Area Under Curve), modelin sınıflar arasında ne kadar iyi ayırım yaptığına dair özet bir ölçüttür. AUC değeri 1'e yaklaştıkça, modelin sınıfları ayırt etme yeteneği artar. Bu bağlamda ROC eğrileri, özellikle tıbbi sınıflandırma gibi doğru pozitiflerin kritik öneme sahip olduğu alanlarda modelin güvenilirliğini değerlendirmede büyük avantaj sağlar. Şekil 4.4'te ROC eğrileri verilmiştir.



Şekil 4.4. ROC eğrileri

Şekil 4.4'e bakıldığında RegNetY-400MF modelinin ROC eğrisi, ideal sınıflayıcıya çok yakın bir performans sergilemiştir. Eğri, neredeyse eksenlere yapışarak 1.0 noktasına ulaşmakta ve AUC değeri 1,00 olarak hesaplanmıştır. Bu sonuç, modelin anormal (ülserli) ve normal (sağlıklı) örnekleri mükemmel bir şekilde ayırt ettiğini göstermektedir. Yanlış pozitif oranı sıfıra çok yakın seviyelerdeyken bile yüksek doğru pozitif oranı elde edilebilmesi, modelin klinik uygulamalarda son derece hassas ve özgül kararlar verebileceğini kanıtlamaktadır. Bu durum, özellikle ciddi durumların atlanmasının büyük risk taşıdığı diyabetik ayak ülseri gibi senaryolarda RegNetY-400MF modelini değerli kılmaktadır. RegNetY-800MF modeli, AUC değeri 0,99 olan oldukça başarılı bir ROC eğrisi sunmuştur. ROC eğrisinin yüksekliğini ve kıvrımını koruması, modelin doğru sınıflandırma oranının yüksek olduğunu, buna karşılık yanlış pozitif oranının çok düşük seviyelerde tutulduğunu ortaya koymaktadır. Her ne kadar AUC değeri RegNetY-400MF'ye kıyasla çok az düşük olsa da, pratikte bu fark ihmal edilebilecek düzeydedir. RegNetY-800MF modeli, ROC eğrisi bağlamında, hem yüksek doğruluk hem de kararlı genelleme performansı sunan üst düzey bir mimari olduğunu kanıtlamaktadır. Klinik risklerin minimize edilmesinde oldukça faydalı bir modeldir.

EfficientNet-B0 modelinin ROC eğrisi, AUC = 0,99 değeriyle yüksek performans sergileyen sınıflayıcılar arasında yer almaktadır. ROC eğrisi oldukça dik bir yükseliş

göstermekte ve bu da modelin düşük yanlış pozitif oranları ile yüksek doğru pozitif oranlarına ulaştığını göstermektedir. Kompakt mimarisine rağmen bu derece başarılı bir ROC eğrisi çizen EfficientNet-B0 modeli, özellikle mobil uygulamalarda ve düşük kaynaklı cihazlarda sınıflandırma yaparken yüksek hassasiyet gerektiren görevlerde kullanılabilecek etkili bir alternatif sunmaktadır. Küçük sapmalar dışında, eğri ideal modele oldukça yakındır. EfficientNet-B1 modeli de tıpkı EfficientNet-B0 gibi AUC = 0,99 değeri ile oldukça yüksek bir sınıflama performansı göstermektedir. ROC eğrisi, doğru pozitif oranını erken dönemde maksimum seviyeye ulaştırırken yanlış pozitif oranını oldukça sınırlı tutmuştur. Bu da modelin genel performansının, özellikle kritik durumları yakalama konusunda çok başarılı olduğunu göstermektedir. EfficientNet-B1, yalnızca yüksek doğruluk oranlarıyla değil, aynı zamanda düşük hata toleransı ile de klinik karar destek sistemleri için uygun bir adaydır. ROC eğrisindeki kararlılık, modelin farklı eşik değerlerinde de güvenilirliğini koruduğunu göstermektedir.

ROC eğrileri ve AUC değerleri değerlendirildiğinde, dört modelin tamamı yüksek ayrıştırma başarımı sergilemiştir. RegNetY-400MF, tam ayırım gücüne sahip bir model olarak 1.00 AUC ile dikkat çekerken; diğer üç modelin 0,99 seviyesindeki AUC değerleri de son derece başarılıdır. Bu analiz, modellerin yalnızca doğruluk açısından değil, sınıflar arasındaki ayrımı yapabilme kabiliyeti açısından da güçlü olduğunu ortaya koymaktadır. Özellikle RegNetY-800MF ve EfficientNet-B1 modelleri, kararlı ve yüksek hassasiyetli ROC performansları sayesinde klinik senaryolarda güvenilir tahminler üretebilecek düzeydedir. Dolayısıyla, bu dört modelin ROC eğrileriyle sunulan sonuçları, geliştirilen sistemin hem yüksek doğruluk hem de düşük hata riski taşıyan karar süreçlerinde etkin bir şekilde kullanılabileceğini göstermektedir.

Modellere ait performans değerleri Tablo 4.1’de verilmiştir. Tabloda, dört farklı derin öğrenme modeline ait sınıflandırma performans metrikleri detaylı şekilde sunulmuştur: kesinlik (precision), duyarlılık (recall/sensitivity), özgüllük (specificity) ve doğruluk (accuracy). Bu metrikler, özellikle tıbbi görüntü sınıflandırmasında modelin klinik açıdan güvenilirliğini değerlendirmek için oldukça kritiktir. Diyabetik ayak ülseri gibi potansiyel olarak uzuv kaybına neden olabilecek bir hastalığın tespiti söz konusu olduğunda, yalnızca genel doğruluk oranı değil; yanlış pozitif ve yanlış negatif oranlarına dayalı detaylı analizler de gereklidir. Bu bağlamda, her bir modelin sunduğu değerler aşağıda yorumlanmıştır. RegNetY-400MF modeli, %97,60 kesinlik ve %100 duyarlılık sunmaktadır. Bu durum, modelin tahmin ettiği ülserli vakaların %97,60’ının gerçekten ülserli olduğunu ve buna karşın hiç yanlış negatif üretmediğini göstermektedir. Başka bir

ifadeyle model, hiçbir ülserli hastayı gözden kaçırmamıştır. Ancak özgüllük değeri %97,94 olduğundan, az sayıda sağlıklı örnek yanlışlıkla ülserli olarak sınıflandırılmıştır. Bu da modelin yanlış pozitif üretme eğiliminin düşük olmakla birlikte tamamen sıfır olmadığını ortaya koymaktadır. Toplam doğruluk oranı ise %98,88 gibi oldukça yüksek bir seviyededir. Model, oldukça başarılı sonuçlar üretse de, bazı sağlıklı örneklerde hatalı sınıflamalar yapma potansiyeline sahiptir. Bu nedenle klinik karar süreçlerinde dikkatli kullanılmalıdır. RegNetY-800MF modeli, performans açısından tüm metriklerde en yüksek değerlere ulaşarak öne çıkmaktadır. %98,79 kesinlik ve %100 duyarlılık oranı ile model, yalnızca ülserli bireylerin tamamını doğru tanımakla kalmayıp, aynı zamanda çok az sayıda sağlıklı bireyi yanlış şekilde ülserli olarak sınıflandırmıştır. %98,97 özgüllük değeri, bu hatalı sınıflamaların oldukça sınırlı düzeyde olduğunu göstermektedir. Doğruluk oranı %99,44 olan bu model, hem yüksek güvenilirlik hem de güçlü genelleme kapasitesiyle dikkat çekmektedir. ROC eğrisi, karışıklık matrisi ve kayıp/başarım grafikleriyle de desteklenen bu tablo, RegNetY-800MF modelini diyabetik ayak ülseri teşhisi açısından en istikrarlı ve başarılı alternatif hâline getirmektedir. Klinik senaryolarda, özellikle riskli hastaların gözden kaçırılmasının tolere edilemeyeceği durumlarda bu model tercih edilebilir. EfficientNet-B0 modeli, %98,19 kesinlik ve %100 duyarlılık oranlarıyla oldukça etkili sonuçlar üretmiştir. Bu model de ülserli tüm vakaları doğru şekilde tanımlamış; yanlış negatif üretmemiştir. Özgüllük değeri %98,45 olup, az sayıda sağlıklı örneğin yanlış pozitif olarak sınıflandırıldığını göstermektedir. Doğruluk oranı %99,16 olan EfficientNet-B0 modeli, kompakt yapısına rağmen performans açısından büyük modellerle rekabet edebilecek düzeye ulaşmıştır. Özellikle mobil sağlık uygulamaları veya düşük donanım gereksinimi olan sistemlerde bu denli yüksek başarı sunabilmesi, onu pratik uygulamalarda öne çıkan bir seçenek hâline getirmektedir. EfficientNet mimarisinin parametrik verimliliği, bu tür klinik görevlerde oldukça avantaj sağlamaktadır. EfficientNet-B1 modeli, metrik düzeyinde EfficientNet-B0 ile birebir aynı değerleri sunmaktadır: %98,19 kesinlik, %100 duyarlılık, %98,45 özgüllük ve %99,16 doğruluk. Bu benzerlik, test seti üzerinde iki modelin eşdeğer performans sergilediğini ortaya koymakla birlikte; EfficientNet-B1'in daha yüksek parametre kapasitesi sayesinde farklı veri dağılımlarında daha stabil sonuçlar üretme potansiyeli olduğu unutulmamalıdır. ROC ve kayıp grafikleri de bu durumu desteklemektedir. EfficientNet-B1, yüksek performansı istikrarlı bir yapıyla birleştirerek hem düşük hata riski hem de yüksek genelleme yeteneği sunan bir model olarak değerlendirilmektedir.

Genel değerlendirme yapıldığında, tüm modellerin duyarlılık oranının %100 olması son derece dikkat çekicidir. Bu, hiçbir ülserli vakayı kaçırmadıkları anlamına gelir ki, bu tür tıbbi durumlar için modelin güvenilirliğini belirlemede altın standart kabul edilen bir özelliktir. Ancak, model seçiminde duyarlılıkla birlikte özgüllük ve kesinlik de önemli rol oynamaktadır. Yanlış pozitiflerin fazla olması, hastalara gereksiz korku veya tedavi yükü doğurabileceğinden, özgüllük değeri de klinik açıdan kritiktir. Bu yönüyle RegNetY-800MF modeli hem kesinlik hem de özgüllük bakımından en yüksek değerlere ulaşmış ve en dengeli performansı sunmuştur. EfficientNet modelleri ise daha az parametreyle benzer doğruluklara ulaşarak pratik uygulamalar için güçlü alternatifler sunmaktadır. Sonuç olarak, duyarlılığın yüksekliğiyle hastalık atlama riski ortadan kaldırılırken, özgüllük ve kesinlik gibi değerlerin yüksekliği de klinik kararların güvenilirliğini artırmaktadır. Bu tablonun sunduğu veriler, her bir modelin hem güçlü hem de sınırlı yönlerini ortaya koymakta ve karar destek sistemlerinde nasıl ve nerede kullanılmaları gerektiğine dair net bir yol haritası çizmektedir.

Tablo 4.1. Performans Değerleri (%70-30 Eğitim-test seti)

Model	Kesinlik (%)	Duyarlılık(%)	Özgüllük(%)	Doğruluk(%)	F1 Skor (%)
RegNetY-400MF	97,60	100	97,94	98,88	98,78
RegNetY-800MF	98,79	100	98,97	99,44	99,39
EfficientNet-B0	98,19	100	98,45	99,16	99,09
EfficientNet-B1	98,19	100	98,45	99,16	99,09

Tablo 4.2’de ise farklı eğitim-test oranları için RegNetY-800MF modelin performans sonuçları verilmiştir. Derin öğrenme modellerinin performansı, yalnızca model mimarisi ve optimizasyon tekniklerine değil; aynı zamanda eğitim ve test veri setlerinin oranlarına da büyük ölçüde bağlıdır. Eğitim verisi oranı arttıkça model daha fazla örnek üzerinde öğrenme fırsatı elde ederken, test verisi oranı arttıkça modelin genelleme yeteneği daha ciddi şekilde sınanır. Bu bağlamda, RegNetY-800MF modeli

farklı eğitim-test oranlarında değerlendirilmiş ve elde edilen metrikler doğrultusunda modelin duyarlılığı, kesinliği, özgüllüğü ve doğruluğu karşılaştırmalı olarak analiz edilmiştir.

Modelin %50 eğitim ve %50 test verisi ile eğitildiği senaryoda kesinlik oranı %98,91 , duyarlılık %99,63 , özgüllük %99,07 ve genel doğruluk oranı %99,33 olarak hesaplanmıştır. Eğitim verisinin sınırlı olduğu bu durumda bile model oldukça yüksek başarı sergilemiştir. Özellikle duyarlılık oranının %99'un üzerinde kalması, modelin ülserli vakaları büyük oranda doğru şekilde sınıflandırdığını göstermektedir. Ancak test setinin büyüklüğü nedeniyle hata toleransı daha geniş bir veri üzerinde sınanmakta ve bu durum bazı modellerde performans düşüşüne yol açabilecekken, RegNetY-800MF bu yükte de başa çıkabilmiştir. Bu sonuçlar, modelin kısıtlı eğitim verisiyle bile etkili genelleme yapabildiğini göstermektedir. Eğitim setinin %60'a çıkarıldığı bu senaryoda, modelin kesinlik oranı %98,63'e hafifçe düşerken, duyarlılık %99,54 ve özgüllük %98,84 olarak ölçülmüştür. Doğruluk oranı ise %99,16'dır. Burada gözlemlenen küçük sapmalar, veri dağılımının doğal varyasyonlarından kaynaklanabilir. Bununla birlikte, hem duyarlılık hem de özgüllük değerlerinin oldukça dengeli ve yüksek seviyede olması, modelin yanlış pozitif ve yanlış negatif üretme oranlarını oldukça düşük tuttuğunu ortaya koymaktadır. Bu oran, modelin hem eğitim verisini daha iyi öğrendiğini hem de daha küçük test seti üzerinde stabil sonuçlar verdiğini göstermektedir. %70 eğitim ve %30 test oranı, çoğu derin öğrenme uygulamasında yaygın olarak tercih edilen bir dağılımdır. Bu senaryoda, RegNetY-800MF modeli en yüksek performansını sergilemiştir. Duyarlılık oranı %100'e ulaşmış, yani model test setindeki tüm ülserli vakaları eksiksiz şekilde doğru sınıflandırmıştır. Kesinlik %98,79 , özgüllük %98,97 ve doğruluk ise %99,44 olarak gerçekleşmiştir. Bu veriler, modelin eğitim verisinden etkin şekilde öğrendiğini ve test verisi üzerinde son derece güvenilir tahminler yaptığını göstermektedir. Özellikle duyarlılık oranının %100 olması, klinik uygulamalarda hiçbir hasta vakasının gözden kaçırılmaması açısından son derece önemlidir. Bu oranla ilgili metrikler henüz tabloya girilmemiş olsa da, önceki oranlara bakıldığında, modelin %80 eğitimle daha da güçlü bir öğrenme gerçekleştireceği ve test verisindeki doğruluk oranlarını daha da yukarı taşıyabileceği öngörülebilir. Eğitim verisi arttıkça modelin hem düşük varyanslı hem de düşük bias'lı bir öğrenme yapısı kuracağı, böylece özellikle duyarlılık ve özgüllük oranlarının dengeli bir şekilde artacağı beklenmektedir. Bu oranla yapılacak değerlendirme, modelin daha çok veriyle daha stabil ve klinik olarak kullanılabilir bir hale gelip gelmeyeceği konusunda nihai çıkarımlar sunacaktır. Farklı eğitim-test oranları

altında elde edilen sonuçlar, RegNetY-800MF modelinin yalnızca güçlü bir mimari değil; aynı zamanda esnek ve veri bağımlılığı düşük bir öğrenme modeli olduğunu göstermektedir. Eğitim verisi miktarı arttıkça performans metriklerinde gözle görülür bir iyileşme yaşanmakta; özellikle duyarlılık oranı %100'e ulaşarak modelin hiçbir ülserli vakayı gözden kaçırmadığı teyit edilmektedir. Özgüllük ve kesinlik değerlerinin de yüksek seyretmesi, modelin sağlıklı bireyleri yanlış sınıflandırma eğiliminin oldukça düşük olduğunu göstermektedir. Bu bulgular, RegNetY-800MF'nin tıbbi görüntü sınıflandırma görevlerinde hem eğitim verisi sınırlı senaryolarda hem de geniş veriyle desteklenen durumlarda güvenilir biçimde kullanılabileceğini doğrulamaktadır. Bu bağlamda model, hem akademik araştırmalarda hem de pratik klinik sistemlerde yaygın şekilde tercih edilebilecek düzeyde bir performans sunmaktadır.

Tablo 4.2. Farklı Eğitim-test oranları için RegnetY-800MF modelin performansı

Eğitim-Test Oranı	Kesinlik (%)	Duyarlılık(%)	Özgüllük(%)	Doğruluk(%)
%50-50	98,91	99,63	99,047	99,33
%60-40	98,63	99,54	98,84	99,16
%70-30	98,79	100	98,97	99,44
%80-20				

5. SONUÇLAR VE ÖNERİLER

5.1. Derin Öğrenme Modellerinin Klinik Performansı Üzerine Tartışma

Bu çalışmada, DAU tespiti amacıyla geliştirilen derin öğrenme tabanlı sınıflandırma modellerinin etkinliği sistematik olarak değerlendirilmiştir. Tıbbi görüntülerin sınıflandırılması, özellikle doku örüntülerinin karmaşık olduğu DAU gibi durumlarda yüksek doğruluk, hassasiyet ve genelleme kapasitesi gerektiren bir görevdir. Bu bağlamda, çalışma kapsamında dört farklı CNN mimarisi seçilmiş ve her bir modelin çeşitli metrikler doğrultusunda başarımı ayrıntılı şekilde analiz edilmiştir: RegNetY-400MF, RegNetY-800MF, EfficientNet-B0 ve EfficientNet-B1.

Derin öğrenme modellerinin başarımını değerlendirirken yalnızca doğruluk oranı değil, duyarlılık, özgüllük, kesinlik, AUC gibi çok yönlü metriklerin bütünsel olarak yorumlanması gerekmektedir. Çalışmanın bulguları, her bir modelin DAU tespiti gibi hassas bir klinik problemi çözmede belirli ölçüde başarılı olduğunu ortaya koymuştur. Ancak bu başarı düzeyi her model için eşit derecede istikrarlı olmamış; özellikle test verisi üzerindeki performans dalgalanmaları, modellerin genelleme kapasitelerinde belirleyici olmuştur. RegNet mimarisi, parametrik verimliliği ve ölçeklenebilir yapısı ile literatürde son yıllarda dikkat çeken modeller arasında yer almakta; bu çalışmada kullanılan RegNetY-400MF ve RegNetY-800MF sürümleriyle farklı kompleksite düzeylerinin başarıya etkisi ölçülmüştür. RegNetY-800MF modeli, daha derin yapısı sayesinde yalnızca eğitim doğruluğunda değil, test doğruluğunda da istikrar sağlamış ve overfitting etkisini minimize ederek klinik veriler üzerinde güvenilir bir performans sunmuştur. Eğitim ve test doğruluğu eğrileri arasında çok az fark bulunması, modelin veriyi ezberlemeksizin öğrenebildiğini ve daha önce görmediği örneklerde de yüksek başarı ile çalıştığını göstermektedir.

EfficientNet mimarileri ise sınıflandırma görevlerinde sunduğu hesaplama verimliliği ile ön plana çıkmıştır. EfficientNet-B0 modeli, parametre sayısı düşük olmasına rağmen yüksek doğruluk oranı sergilemiş ve özellikle donanım sınırlamaları olan klinik ortamlarda kullanılabilecek bir alternatif sunmuştur. Ancak bu modelde test kaybındaki dalgalanmalar, karar sürecinde istikrarsızlığa yol açabilecek zayıf yönleri de

ortaya koymuştur. Buna karşın EfficientNet-B1 modeli, daha büyük parametre kapasitesi ve derinliği sayesinde hem eğitim hem de test verilerinde kararlı bir öğrenme süreci sergilemiş, ROC eğrisi, kayıp fonksiyonu ve karışıklık matrisleri bakımından en tutarlı sonuçları elde etmiştir.

Özellikle duyarlılık oranlarının dört modelde de %100'e yakın olması, çalışmanın en dikkat çekici çıktılarından. Bu, modellerin hiçbir ülserli vakayı gözden kaçırmadığını ve gerçek pozitif oranlarının en yüksek düzeyde gerçekleştiğini göstermektedir. Bu tür bir çıktı, klinik ortamlarda yaşam kurtarıcı öneme sahiptir. Ancak duyarlılığın bu denli yüksek olduğu senaryolarda, özgüllük değerleri de dikkatle incelenmelidir. Özgüllük değerlerinde %97–99 aralığında değişen sonuçlar, sağlıklı bireylerin yanlışlıkla ülserli olarak sınıflandırılma riskini göz önünde bulundurmaya gerekli kılmaktadır.

Sonuç olarak, ilk sayfa kapsamındaki analizler, modellerin teknik başarıları kadar klinik güvenilirliklerini de değerlendirmeyi amaçlamaktadır. Dört modelin tamamı, DAU tespitinde uygulanabilir düzeyde performans sergilemiş olsa da, özellikle EfficientNet-B1 ve RegNetY-800MF modelleri, genelleme kapasitesi, hata toleransı, ROC başarımı ve test istikrarı açısından öne çıkmakta; klinik ortamlarda kullanılabilirliği en yüksek modeller olarak değerlendirilmektedir.

5.2. Performans Göstergeleri, ROC Eğrisi ve Kayıp Fonksiyonları Açısından Değerlendirme

Derin öğrenme modellerinin sınıflandırma başarımlarını değerlendirirken tek bir metrik yerine çok sayıda performans ölçütünü bir arada incelemek daha anlamlı ve geçerli sonuçlara ulaşılmasını sağlar. Bu çalışmada doğruluk, kesinlik, duyarlılık ve özgüllük gibi temel metriklerin yanı sıra, modelin sınıflar arası ayrım yapabilme kapasitesini ortaya koyan ROC eğrisi ve AUC değeri de dikkatle analiz edilmiştir. Bunun yanında, eğitim sürecinin başarısını ve modelin öğrenme dinamiklerini gösteren kayıp (loss) eğrileri de modellenen sistemin davranışını kavramak açısından kritik bir rol oynamaktadır.

ROC eğrileri üzerinden yapılan analizlerde, dört modelin de yüksek AUC değerlerine ulaştığı gözlemlenmiştir. RegNetY-400MF modeli 1.00 AUC ile neredeyse ideal sınıflayıcıya eşdeğer bir performans sergilemiştir. Bununla birlikte, test doğruluğunda görülen dalgalanmalar ve kayıp fonksiyonundaki düzensizlik, bu modelin bazı örneklerde kararsızlık yaşadığını ve sınırlı genelleme kapasitesine sahip olduğunu

ortaya koymuřtur. RegNetY-800MF modelinde ise bu dezavantajların giderildiđi, ROC eđrisinin daha kararlı bir řekilde optimum bđlgeye ulařtıđı ve modelin sınıflar arasında daha bařarılı ayırım yapabildiđi gđrđlmüřtür. EfficientNet modelleri de yüksek AUC deđerleri ile dikkat çekmiř; EfficientNet-B1 modeli test örneklerinde çok daha kararlı ve tutarlı tahminler sunarak klinik kullanılabilirlik ağıısından önemli bir avantaj sađlamıřtır.

Kayıp fonksiyonu eđrileri incelendiđinde, EfficientNet-B1 modelinin hem eđitim hem de test setlerinde kayıp deđerlerini stabil ve düřük seviyede tutabildiđi belirlenmiřtir. Bu durum, modelin overfitting eđiliminden uzak durarak öđrenmesini sađladığını ve daha önce gđrmediđi veriler karřısında da yüksek dođrulukla çalıřabildiđini gđstermektedir. RegNetY-800MF modeli de benzer biçimde, hem düřük kayıp deđerleri hem de düřük varyanslı bir seyir ile genel bařarımı güçlendirmiřtir. EfficientNet-B0 modeli ise eđitim seti üzerinde bařarılı olmasına rađmen, test setinde zaman zaman gđrülen kayıp artıřları nedeniyle performans ağıısından bir miktar dengesiz davranmıřtır. Bu tür modellerde, erken durdurma (early stopping) ve dinamik öđrenme oranı ayarlamaları gibi yöntemlerle bu tür dalgalanmaların azaltılması mümkündür.

Ayrıca, çalıřmada kullanılan karıřıklık matrisleri modellerin sınıf bazında hangi örneklerde hata yaptıđını net bir řekilde ortaya koymuřtur. Özellikle ülserli sınıfa ait yanlış negatif oranının sıfıra yakın olması, sistemin hiçbir hasta vakayı atlamadıđını gđstermektedir. Bu, özellikle tıbbi sınıflandırmalarda, duyarlılıđın (sensitivity) en önemli performans kriterlerinden biri olduđu dikkate alındığında hayati bir sonuçtur. Öte yandan, bazı modellerin düřük de olsa yanlış pozitif (false positive) üretmiř olması, hasta olmayan bireylerin gereksiz yere ileri tetkiklere yönlendirilme riskini beraberinde getirmektedir. Bu bağlamda, özgüllük (specificity) deđeri de duyarlılık kadar önem arz etmekte ve EfficientNet-B1 ile RegNetY-800MF modelleri bu iki metriđi bir arada en yüksek seviyede sunabilen mimariler olarak dikkat çekmektedir.

İkinci sayfa kapsamında yapılan bu analizler gđstermektedir ki, modellerin sadece genel dođrulukları deđil, öđrenme kararlılıkları, sınıf bazlı bařarım dengeleri ve ROC/kayıp eđrileri gibi ileri düzey göstergeleri de deđerlendirmeye katıldıđında daha sađlam bir klinik karar destek sisteminin temelleri atılabilir. EfficientNet-B1 ve RegNetY-800MF modelleri, bu bütünsel çerçevede deđerlendirildiđinde en uygun ve klinik ağıısından en güvenilir derin öđrenme mimarileri olarak öne çıkmaktadır.

5.3. Veri Dağılımı, Eğitim-Test Oranları ve Klinik Uygulamalar Açısından Sonuçların Yorumlanması

Model performanslarının yalnızca mimari yapıya değil, aynı zamanda eğitim-test veri oranlarına da bağlı olarak değiştiği çalışmanın önemli bulgularından biri olmuştur. RegNetY-800MF modeli farklı eğitim-test oranlarında değerlendirilmiş ve %70-30 oranı ile en yüksek başarıya ulaşmıştır. Bu oran, literatürde sıklıkla tercih edilen ve dengeli bir test değerlendirmesi yapılmasına olanak tanıyan dağılım yapısıdır. %70'lik eğitim seti, modelin veriye dair temel örüntüleri sağlam biçimde öğrenmesine olanak tanırken, %30'luk test seti ise gerçek dünya koşullarını yansıtacak ölçüde yeterli bir deneme alanı sunmuştur. Bu dağılımda modelin duyarlılık oranı %100'e ulaşmış; yani tüm ülserli örnekler doğru şekilde sınıflandırılmıştır.

Elde edilen bu bulgu, tıbbi uygulamalarda hayati öneme sahip olan “hastalığı atlamama” hedefinin gerçekleştirilebildiğini göstermektedir. Ancak duyarlılığın mutlak olarak yüksek olması yeterli değildir; aynı zamanda sağlıklı bireylerin gereksiz yere hasta olarak sınıflandırılmasının önüne geçilmesi de önemlidir. Bu nedenle özgüllük ve kesinlik metrikleri de değerlendirilmiş, RegNetY-800MF'nin özgüllük oranının %98.97, kesinlik oranının ise %98.79 olarak gerçekleştiği belirlenmiştir. Bu durum, yalnızca hasta bireylerin doğru tespit edilmesini değil, sağlıklı bireylerin yanlışlıkla sistem tarafından hasta olarak işaretlenmemesini de sağladığını göstermektedir. Böylece modelin klinik karar süreçlerine entegre edildiğinde hatalı yönlendirme ya da gereksiz müdahale riskini minimuma indireceği anlaşılmaktadır.

EfficientNet-B1 modeli de benzer şekilde yüksek performans metrikleri ile öne çıkmış, parametre açısından daha verimli bir yapı sunarak klinik pratikte kullanımı kolaylaştırabilecek avantajlar sağlamıştır. Özellikle mobil ya da düşük kaynaklı ortamlarda bu tür kompakt modellerin hızlı yanıt süresi ve enerji verimliliği gibi teknik özellikleri, onları sahada uygulanabilir çözümler haline getirmektedir. Bu bağlamda, model seçimi yapılırken yalnızca istatistiksel performans değil, aynı zamanda operasyonel koşullar, donanım uyumluluğu ve kullanım senaryosu da göz önünde bulundurulmalıdır.

Bu çalışma özelinde elde edilen bulgular, tıbbi görüntü analizi alanında geliştirilecek yapay zeka sistemlerinin yalnızca doğruluk oranlarıyla değil, aynı zamanda klinik geçerlilik, güvenilirlik, sistemsel kararlılık ve pratik uygulanabilirlik boyutlarıyla da ele alınması gerektiğini açıkça ortaya koymuştur. RegNetY-800MF ve EfficientNet-

B1 modelleri, bu bütüncül çerçevede değerlendirildiğinde yüksek duyarlılık ve özgüllük oranları, istikrarlı ROC-AUC başarımları, minimal kayıp dalgalanmaları ve düşük yanlış sınıflandırma oranlarıyla klinik uygulamalara entegre edilebilecek güçlü adaylar olarak öne çıkmaktadır.

Sonuç olarak, bu tez çalışmasıyla diyabetik ayak ülseri gibi ciddi klinik durumların yapay zeka destekli karar sistemleri aracılığıyla erken, hızlı ve doğru şekilde tespit edilebileceği bilimsel olarak gösterilmiş; derin öğrenme modellerinin gerçek dünya klinik senaryolarında nasıl optimize edilebileceği konusuna katkı sunulmuştur. Bu bulgular, gelecekte geliştirilecek yapay zeka destekli tıbbi cihazlar, tele-tıp uygulamaları ve karar destek sistemlerinin daha güvenli ve etkili hale getirilmesi için güçlü bir temel sağlamaktadır.

5.4. Çalışmanın Eksiklikleri

- DAU veri seti belirli bir klinik merkezde ve sınırlı coğrafi dağılıma sahip hasta grubundan elde edilmiştir. Bu durum, modelin farklı etnik kökenlerden gelen hastalarda genellenebilirliğini kısıtlamaktadır.
- Veri setindeki ülserli ve sağlıklı görüntülerin dengeli dağıtılmasına rağmen, farklı ülser derecelerini ayırt etmeye yönelik etiketleme yapılmamıştır. Bu da modelin ülser evresi tespiti gibi alt görevlerde sınırlı kalmasına neden olmuştur.
- Kullanılan modeller yalnızca sınıflandırma görevine odaklanmıştır. Oysa klinik senaryolarda bölütleme (segmentation) gibi yara alanının sınırlarını tanımlayan işlemler de kritik öneme sahiptir.
- Veri çoğaltma (augmentation) stratejileri uygulanmış olsa da, kullanılan teknikler temel geometrik dönüşümlerle sınırlı kalmıştır. Renk bozulmaları, aydınlatma farklılıkları gibi daha karmaşık varyasyonlara dayalı augmentation yöntemleri kullanılmamıştır.
- Klinik doğruluk oranları yüksek olmakla birlikte, modellerin gerçek zamanlı performansı, kullanıcı etkileşimi ve klinik karar verme sürecine entegrasyonu değerlendirilmemiştir.
- Modelin eğitimi için transfer öğrenme kullanılmış olsa da, pretraining yapılan ImageNet veri seti, medikal görüntülerle doğrudan ilişkili olmayan genel görsel örüntülerden oluşmaktadır. Bu durum, domain adaptasyonu açısından sınırlayıcı olabilir.

- Overfitting'i önlemeye yönelik dropout ve regularizasyon stratejileri uygulanmış olsa da, hiperparametre optimizasyonu sistematik bir arama algoritması yerine deneysel gözlemlere dayalı olarak yapılmıştır.
- Modelin karar verme sürecinin açıklanabilirliği (explainability) sınırlı düzeyde ele alınmıştır. Grad-CAM gibi yöntemlerle hangi bölgelere odaklandığına dair görseller oluşturulmamış ve bu bağlamda XAI uygulamaları dahil edilmemiştir.
- Çalışmada elde edilen başarımlar tek bir veri seti üzerinde elde edilmiştir. Farklı kurumlardan alınmış, farklı görüntüleme protokollerine sahip veri setleriyle yapılan dış doğrulama çalışmaları eksiktir.
- Klinik etki ve fayda açısından modelin kullanıcı dostu bir yazılım arayüzüyle birlikte tasarlanması önerilmesine rağmen, bu yönde prototip bir uygulama geliştirilmemiştir.

5.5. Gelecek Çalışmalar İçin Öneriler

- Farklı coğrafi bölgelerden ve çeşitli sağlık merkezlerinden toplanmış, daha geniş ve temsili bir hasta popülasyonuna ait veri setleriyle modellerin dış geçerliliği test edilmelidir.
- Ülserlerin farklı evrelerini kapsayan çok sınıflı etiketleme yapılmalı; bu sayede ülserin ciddiyet düzeyinin tahmini gibi görevler de entegre edilmelidir.
- Segmentasyon tabanlı yaklaşımlar ile yalnızca ülserin varlığı değil, yara bölgesinin sınırları da otomatik olarak tespit edilerek tedavi planlamasında yardımcı olunabilir.
- Açıklanabilir yapay zeka (XAI) yöntemleri entegre edilerek modelin karar verirken hangi özellik ve alanlara odaklandığı daha iyi anlaşılmalı; bu sayede kullanıcı güveni artırılmalıdır.
- Modelin gerçek zamanlı performansı test edilerek, çeşitli cihazlarda çalışabilecek optimize edilmiş sürümleri geliştirilmeli ve test edilmelidir.
- Eğitim sürecinde sistematik hiperparametre optimizasyon algoritmaları (örneğin grid search, Bayesian optimization) kullanılmalıdır.
- Klinik uygulamalar için kullanıcı dostu bir mobil ya da masaüstü uygulama arayüzü geliştirilmeli; bu yazılım hekimlerin rutin pratiklerine kolayca entegre edilebilecek şekilde tasarlanmalıdır.

- Federated learning gibi gizliliğe duyarlı veri paylaşım yöntemleriyle, hastane dışı ortamlarda da model eğitimi yapılabilmesi sağlanmalıdır.
- Zaman serisi analizleri veya hasta geçmişi ile entegre çalışan modellerle, ülser oluşumu öncesinde risk tahmini yapan erken uyarı sistemleri geliştirilebilir.
- Tıbbi karar destek sistemlerinin etik, yasal ve kullanıcı deneyimi boyutları da bütüncül şekilde ele alınmalı ve saha denemeleri ile desteklenmelidir.



KAYNAKLAR

- Ahsan, M., Naz, S., Ahmad, R., Ehsan, H., & Sikandar, A. (2023). A deep learning approach for diabetic foot ulcer classification and recognition. *Information*, 14(1), 36.
- Almufadi, N., & Alhasson, H. F. (2024). Classification of Diabetic Foot Ulcers from Images Using Machine Learning Approach. *Diagnostics*, 14(16), 1807.
- Alzubaidi, L., Fadhel, M. A., Oleiwi, S. R., Al-Shamma, O., & Zhang, J. (2020). DFU_QUTNet: Diabetic foot ulcer classification using novel deep convolutional neural network. *Multimedia Tools and Applications*, 79(21–22), 15655–15677.
- Amin, J., Sharif, M., Anjum, M. A., Khan, H. U., Malik, M. S. A., & Kadry, S. (2020). An integrated design for classification and localization of diabetic foot ulcer based on CNN and YOLOv2-DFU models. *IEEE Access*, 8, 228586-228597.
- Araújo, A. L., Negreiros, F. D. d. S., Florêncio, R. S., et al. (2024). Preventive interventions for diabetic foot ulcer adopted in different healthcare settings: A scoping review protocol. *PLoS ONE*, 19(10), e0306486.
- Arnia, F., Saddami, K., Roslidar, R., Muharar, R., & Munadi, K. (2024). Towards accurate Diabetic Foot Ulcer image classification: Leveraging CNN pre-trained features and extreme learning machine. *Smart Health*, 33, 100502.
- Arumuga Maria Devi, T., & Hepzibai, R. (2023). Clinical assessment of diabetic foot ulcers using GWO-CNN based hyperspectral image processing approach. *IETE Journal of Research*, 69(12), 8705-8716.
- Arumuga Maria Devi, T., & Hepzibai, R. (2024). Diabetic foot ulcer classification of hybrid convolutional neural network on hyperspectral imaging. *Multimedia Tools and Applications*, 83(18), 55199-55218.
- Athira, A. J., Varshepally, A., Manogna, A., & Sridhar, A. (2024). Ensemble Model Classifier in Hybrid CNN to Predict Diabetic Foot Ulcers. *B V Raju Institute of Technology*.
- Athira, A. J., Varshepally, A., Manogna, A., Sridhar, A., & Vivek, D. (2024, June). Ensemble Model Classifier in Hybrid CNN to Predict Diabetic Foot Ulcers. In *2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1-7). IEEE.
- Avinash, B., Alam, M. S., Ghamande, M. V., Gupta, K. K., & Rastogi, R. (2023, November). Automatic Detection of Infection in Diabetic Foot Ulcer Images Using Improved-CNN-SVM Approach. In *2023 7th International Conference on Electronics, Communication and Aerospace Technology (ICECA)* (pp. 505-510). IEEE.

- Bansal, N., & Vidyarthi, A. (2024). DFootNet: A Domain Adaptive Classification Framework for Diabetic Foot Ulcers Using Dense Neural Network Architecture. *Cognitive Computation*, 16(5), 2511-2527.
- Clevert, D.-A., Unterthiner, T., & Hochreiter, S. (2015). Fast and accurate deep network learning by exponential linear units (ELUs). *arXiv preprint arXiv:1511.07289*.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted Boltzmann machines. In *Proceedings of the 27th International Conference on Machine Learning (ICML-10)* (pp. 807–814).
- Crevier, D. (1993). *AI: The Tumultuous History of the Search for Artificial Intelligence*. Basic Books.
- Das, S. K., Namasudra, S., & Sangaiah, A. K. (2024). HCNNet: hybrid convolution neural network for automatic identification of ischaemia in diabetic foot ulcer wounds. *Multimedia Systems*, 30(1), 36.
- Das, S. K., Roy, P., & Mishra, A. K. (2022). Recognition of ischaemia and infection in diabetic foot ulcer: a deep convolutional neural network based approach. *International Journal of Imaging Systems and Technology*, 32(1), 192-208.
- Dayan, S. (2022). *Enfeksiyon Hastalıkları Tanı ve Tedavi El Kitabı*. Ankara: Hipokrat Yayınevi.
- Dhar, M. K. (2024). *Deep Learning in Wound Care: Segmentation of Wound Area and Tissue in Diabetic Foot Ulcers* (Doctoral dissertation, The University of Wisconsin-Milwaukee).
- Fadhel, M. A., Alzubaidi, L., Gu, Y., Santamaría, J., & Duan, Y. (2024). Real-time diabetic foot ulcer classification based on deep learning & parallel hardware computational tools. *Multimedia Tools and Applications*, 83(27), 70369-70394.
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861-874. <https://doi.org/10.1016/j.patrec.2005.10.010>
- Floridi, L., Cowls, J., Beltrametti, M., Chatila, R., Dignum, V., Luetge, C., ... & Vayena, E. (2018). AI4People—An ethical framework for a good AI society. *Minds and Machines*, 28(4), 689–707. <https://doi.org/10.1007/s11023-018-9482-5>
- Ganesan, R., & Orgill, D. P. (2024). Diabetic Foot Ulcers: Current Status and Future Directions. *Journal of Clinical Medicine*, 13(5), 123-136.
- GeeksforGeeks. (2025, 16 Mayıs). Confusion matrix in machine learning. Erişim tarihi: 31 Mayıs 2025,
- LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.

- Dumoulin, V., & Visin, F. (2018). A guide to convolution arithmetic for deep learning. arXiv preprint arXiv:1603.07285.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT Press.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1), 1929–1958.
- Gudivaka, R. K., Gudivaka, R. L., Gudivaka, B. R., Basani, D. K. R., Grandhi, S. H., & Khan, F. (2025). Diabetic foot ulcer classification assessment employing an improved machine learning algorithm. *Technology and Health Care*, 09287329241296417.
- Haryanto, A., Rahmawati, A., Khairillah, Y. N., Erwhani, I., Purnamawati, D. A., Mentari, T. A., & Fitriana, E. E. (2024). Development of infection category detection in diabetic foot ulcers using machine learning. *Frontiers in Health Informatics*, 13(3), 1669–1675..
- Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Pearson.
- Hrzić, F., Janisch, M., Štajduhar, I., Lerga, J., Sorantin, E., & Tschauner, S. (2021). Modeling uncertainty in fracture age estimation from pediatric wrist radiographs. *Mathematics*, 9(24), 3227.
- Hu, J., Shen, L., & Sun, G. (2018). Squeeze-and-Excitation Networks. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 7132–7141. <https://doi.org/10.1109/CVPR.2018.00745>
- Japkowicz, N., & Shah, M. (2011). *Evaluating Learning Algorithms: A Classification Perspective*. Cambridge University Press.
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255–260. <https://doi.org/10.1126/science.aaa8415>
- Kanti Dhar, M., Wang, C., Patel, Y., Zhang, T., Niezgoda, J., Gopalakrishnan, S., ... & Yu, Z. (2024). Wound Tissue Segmentation in Diabetic Foot Ulcer Images Using Deep Learning: A Pilot Study. arXiv e-prints, arXiv-2406.
- Karthik, R., Ajay, A., Jhalani, A., Ballari, K., & K, S. (2025). An explainable deep learning model for diabetic foot ulcer classification using swin transformer and efficient multi-scale attention-driven network. *Scientific Reports*, 15(1), 4057.
- Khalil, M., Naeem, A., Naqvi, R. A., Zahra, K., Muqarib, S. A., & Lee, S. W. (2023). Deep learning-based classification of abrasion and ischemic diabetic foot sores using camera-captured images. *Mathematics*, 11(17), 3793.
- Khandakar, A., Chowdhury, M. E., Reaz, M. B. I., Ali, S. H. M., Kiranyaz, S., Rahman, T., ... & Hasan, A. (2022). A novel machine learning approach for severity classification of diabetic foot complications using thermogram images. *Sensors*, 22(11), 4249.

- Khosa, I., Raza, A., Anjum, M., Ahmad, W., & Shahab, S. (2023). Automatic diabetic foot ulcer recognition using multi-level thermographic image data. *Diagnostics*, 13(16), 2637.
- Kolachi, M. A., Kumar, S., Yadav, A. S., & Agarwal, M. (2025). To study efficacy of foot temperature monitoring and footprint study in preventing diabetic foot ulcer in type 2 diabetic patients. *Asian Journal of Medical Sciences*, 16(1).
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Ling, C. X., Huang, J., & Zhang, H. (2003). AUC: a better measure than accuracy in comparing learning algorithms. *Proceedings of the 6th International Conference on Artificial Intelligence and Statistics (AISTATS)*.
- Manjunath, A. K., Kumar, S., Yadav, A. S., & Agarwal, M. (2025). Early identification of high-risk individuals for DFU prevention using foot temperature monitoring and footprint analysis. *Asian Journal of Medical Sciences*, 16(1).
- Mayya, V., Tummala, V., Reddy, C. U., Mishra, P., Boddu, R., & Olivia, D. (2023). Applications of Machine Learning in Diabetic Foot Ulcer Diagnosis using Multimodal Images: A Review. *IAENG International Journal of Applied Mathematics*, 53(3).
- Nair, V., & Hinton, G. E. (2010). Rectified linear units improve restricted Boltzmann machines. In *Proceedings of the 27th International Conference on Machine Learning (ICML-10)* (pp. 807–814).
- Öztemel, E. (2012). *Yapay zekâ: Teori ve uygulamaları* (3. bs.). Papatya Yayıncılık.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- Pan, S. J., & Yang, Q. (2010). A survey on transfer learning. *IEEE Transactions on Knowledge and Data Engineering*, 22(10), 1345–1359. <https://doi.org/10.1109/TKDE.2009.191>
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. *Journal of Machine Learning Technologies*, 2(1), 37-63.
- Radosavovic, I., Kosaraju, R. P., Girshick, R., He, K., & Dollár, P. (2020). Designing Network Design Spaces. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 10428–10436. <https://doi.org/10.1109/CVPR42600.2020.01044>
- Radoslav, B., & Choi, J. (2020). RegNet: Designing Network Design Spaces. *arXiv:2003.13678*.

- Raza, M. O., Khuhro, T. A., Bhatti, S., & Memon, M. (2022). Evaluation of deep learning approaches for classification of drought stages using satellite imagery for Tharparker. *Sir Syed University Research Journal of Engineering & Technology*, 12(2), 101-108.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>
- Russell, S. J., & Norvig, P. (2021). *Artificial Intelligence: A Modern Approach* (4th ed.). Pearson.
- Saito, T., & Rehmsmeier, M. (2015). The precision-recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLOS ONE*, 10(3), e0118432. <https://doi.org/10.1371/journal.pone.0118432>
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information Processing & Management*, 45(4), 427-437. <https://doi.org/10.1016/j.ipm.2009.03.002>
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 15(1), 1929–1958.
- Tan, M., & Le, Q. (2019, May). Efficientnet: Rethinking model scaling for convolutional neural networks. In *International conference on machine learning* (pp. 6105-6114). PMLR.
- Turing, A. M. (1950). Computing machinery and intelligence. *Mind*, 59(236), 433–460.
- Wu, M., Guo, F., He, X., Zheng, D., Ye, W., Li, S., ... & Wang, F. (2024). Analysis of distribution and drug susceptibility test results of pathogenic bacteria in diabetic foot ulcers. *Diabetes Therapy*, 15(7), 1627-1637.
- Xie, S., Girshick, R., & He, K. (2020). Exploring Randomly Wired Neural Networks for Image Recognition. *arXiv:1911.02161*.
- Ünsal, E. (2023). Diyabetik Ayak Yaraları ve Tedavi Yöntemleri. *Sağlık Bilimleri Araştırmaları Dergisi*, 20(3), 45-60.
- Yosinski, J., Clune, J., Bengio, Y., & Lipson, H. (2014). How transferable are features in deep neural networks? In *Advances in Neural Information Processing Systems* (pp. 3320–3328).
- Youldash, M., Rahman, A., Alsayed, M., Sebiany, A., Alzayat, J., Aljishi, N., Alshammari, G., & Alqahtani, M. (2024). Early Detection and Classification of Diabetic Retinopathy: A Deep Learning Approach. *AI*, 5(4), 2586–2617.