

**T.C.
BURDUR MEHMET AKİF ERSOY ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ**

**DIYABETİK RETİNOPATİ TANISINA YÖNELİK
DERİN ÖĞRENME TABANLI SINIFLANDIRMA**

Osman CEYLAN

Danışman: Doç. Dr. Onur SEVLİ

BURDUR, 2024

ETİK KURALLARA UYGUNLUK BEYANI

Burdur Mehmet Akif Ersoy Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim Öğretim ve Sınav Yönetmeliğinin ilgili hükümleri uyarınca **Yüksek Lisans** Tezi olarak sunduğum “**Diyabetik Retinopati Tanısına Yönelik Derin Öğrenme Tabanlı Sınıflandırma**” başlıklı bu tezin;

- Kendi çalışmam olduğunu,
- Sunduğum tüm sonuç, doküman, bilgi ve belgeleri bizzat ve bu tez çalışması kapsamında elde ettiğimi,
- Bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara atıf yaptığımı ve bunları kaynaklar listesinde usulüne uygun olarak verdiğimi,
- Kullandığım verilerde değişiklik yapmadığımı,
- Tez çalışması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını,
- Bu tezin herhangi bir bölümünü bu üniversite veya diğer bir üniversitede başka bir tez çalışması içinde sunmadığımı,
- Bu tezin planlanmasından yazımına kadar bütün safhalarda bilimsel etik kurallarına uygun olarak davrandığımı,

bildirir, aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul edeceğimi beyan ederim.

12/08/2024

(İmza)

Osman CEYLAN

ÖNSÖZ

Bu tez çalışmasının planlanmasında, araştırılmasında ve oluşumunda ilgi ve desteğini esirgemeyen,engin bilgi ve tecrübelerinden yararlandığım, bilgi ve tecrübesi ile her aşmamda yardımcı olan değerli Danışman Hocam **Doç. Dr. Onur SEVLİ**'ye teşekkürlerimi sunarım.

Ayrıca bu yolda beni yalnız bırakmayan, çalışmam esnasında manevi desteğini her zaman hissettiğim sevgili eşim Merve CEYLAN'a sevgi, saygı ve teşekkürlerimi sunarım. Tüm eğitim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen her zaman yanımda olan sevgili ve canım aileme teşekkürlerimi bir borç bilirim.

Ağustos, 2024

Osman CEYLAN

İÇİNDEKİLER

	Sayfa
ÖNSÖZ	i
İÇİNDEKİLER	ii
ŞEKİLLER DİZİNİ.....	iv
ÇİZELGELER DİZİNİ	viii
SİMGELER VE KISALTMALAR DİZİNİ	ix
ÖZET	x
ABSTRACT.....	xi
1. GİRİŞ	1
1.1. Tezin Amacı.....	4
1.2. Tezin Organizasyonu	5
2. LİTERATÜR TARAMASI.....	6
3. DİYABETİK RETİNOPATİ.....	13
3.1. Gözün Anatomik Yapısı	13
3.2. Diyabet Hastalığı	14
3.3. Diyabetik Retinopati ve Evreleri	15
3.4. Diyabetik Retinopati Teşhisi.....	18
4. GÖRÜNTÜ TABANLI DERİN ÖĞRENME	19
4.1. Yapay Sinir ağları	19
4.2. Derin öğrenme	20
4.3. Evrişimli Sinir Ağları.....	23
4.3.1. Evrişim Katmanı	24
4.3.2. Havuzlama Katmanı.....	25
4.3.3. Tam Bağlantılı Katman	26
4.4. Yaygın ESA Mimarileri.....	27
4.4.1. ResNet152	27
4.4.2. ResNet101	28
4.4.3. MobileNet	28
4.4.4. MobileNetV2	29
4.4.5. DenseNet169	30
4.4.6. NASNet Large.....	31
4.5. Performans Değerlendirme Metrikleri.....	31
4.5.1. Karışıklık Matrisi (Confusion Matrix).....	32
4.5.2. Doğruluk	32
4.5.3. Kesinlik	33
4.5.4. Duyarlılık	33
4.5.5. F1 Skor (F1 Score)	33
5. MATERYAL VE YÖNTEM	34
5.1. Kullanılan Veri Seti	34
5.2. Uygulama Ortamı ve Kütüphane	37
5.3. Görüntü Ön İşleme.....	37
5.3.1. Gürültü Azaltma.....	37
5.3.2. Kontrast Geliştirme	38
5.3.3. Görüntü Yeniden Boyutlandırma	38
5.3.4. Gri Ölçekleme	39
5.3.5. Segmentasyon	39
5.3.6. Özellik Çıkarımı.....	40

5.4. Transfer Öğrenme	41
5.5. Transfer Öğrenme Yaklaşımları	42
5.5.1. Ön Eğitimli Modelin Sınıflandırıcı Olarak Kullanımı	43
5.5.2. Ön Eğitimli Modelin Öznitelik Çıkarıcı Olarak Kullanımı	43
5.5.3. İnce Ayar (Fine-Tuning)	44
5.6. Çalışmada Kullanılan Mimari.....	44
6. ARAŞTIRMA BULGULARI VE TARTIŞMA.....	47
6.1. Model Sonuçlarının Değerlendirilmesi.....	47
6.2. Tartışma	75
7. SONUÇ VE ÖNERİLER	82
KAYNAKLAR	84



ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1. Gözün yapısı	14
Şekil 3.2. a) Sağlıklı bir bireyin görüşü, (b) DR hastalığına sahip bireyin görüşü	15
Şekil 3.3. DR semptomları	16
Şekil 3.4. DR hastalığının sınıfları.....	17
Şekil 3.5.(a) Retinaya ait dijital görüntü veren oftalmoskop cihazı ve (b) fundus cihazı.....	18
Şekil 4.1. Basit bir YSA mimarisi	20
Şekil 4.2. Derin öğrenme ağının genel mimari gösterimi.....	21
Şekil 4.3. ESA mimari yapısı.....	23
Şekil 4.4.Örnek bir girdi görüntüsünün çekirdek ile çarpımı sonucunda elde edilen çıktı	23
Şekil 4.5. Örnek bir hava taşıtı sınıflaması yapan ESA mimarisinin konfigürasyonlarını, girişler ve çıkışlar sistemin çalışma prensibi gösterimi	24
Şekil 4.6. Evrişim katmanının çekirdek filtresi ile çıktı süreci örneği.....	25
Şekil 4.7. Maksimum ve ortalama havuzlama	26
Şekil 4.8. ResNet-152 Mimarisi	27
Şekil 4.9. ResNet 101 mimarisi	28
Şekil 4.10. MobileNET Mimarisi	29
Şekil 4.11. MobileNET v2 Mimarisi	30
Şekil 4.12. DenseNet169 Mimarisi	30
Şekil 4.13. NasNetLarge mimarisi.....	31
Şekil 4.14. Karışıklık matrisi gösterimi	32
Şekil 5.1. Sınıflara göre dağılım sütun grafiği.....	35
Şekil 5.2. Filtre uygulanmamış DR veri kümesi.....	36
Şekil 5.3. Gaussian filtre uygulanmamış DR veri kümesi.....	36
Şekil 5.4. Grayscale filtre uygulanmamış DR veri kümesi.....	37
Şekil 5.5. Gürültü azaltma filtreleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri resim	38
Şekil 5.6. Kontrast geliştirme filtreleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri resim.....	38

Şekil 5.7. Kontrast geliştirme filtreleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri resim.....	39
Şekil 5.8. Gri ölçek filtreleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri resim	39
Şekil 5.9. Segmentasyon teknikleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri resim	40
Şekil 5.10. Özellik çıkarma teknikleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri resim	40
Şekil 5.11. Transfer öğrenme diyagramı	45
Şekil 5.12. Önerilen fine-tuning modeli	46
Şekil 6.1. ResNet152V2 modelinin filtresiz veri kümesi üzerindeki performans grafikleri	48
Şekil 6.2. ResNet101V2 modelinin filtresiz veri kümesi üzerindeki performans grafikleri	49
Şekil 6.3. MobileNet modelinin filtresiz veri kümesi üzerindeki performans grafikleri	49
Şekil 6.4. MobileNetV2 modelinin filtresiz veri kümesi üzerindeki performans grafikleri	50
Şekil 6.5. DenseNet169 modelinin filtresiz veri kümesi üzerindeki performans grafikleri	50
Şekil 6.6. NasNetLarge modelinin filtresiz veri kümesi üzerindeki performans grafikleri	51
Şekil 6.7. ResNet152V2 modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi	52
Şekil 6.8. ResNet101V2 modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi	53
Şekil 6.9. MobileNet modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi	53
Şekil 6.10. MobileNetV2 modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi	54
Şekil 6.11. DenseNet169 modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi	55
Şekil 6.12. NasNetLarge modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi	56

Şekil 6.13. ResNet152V2 modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri	57
Şekil 6.14. ResNet101V2 modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri	57
Şekil 6.15. MobileNet modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri	58
Şekil 6.16. MobileNetV2 modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri	58
Şekil 6.17. DenseNet169 modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri	59
Şekil 6.18. NasNetLarge modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri	60
Şekil 6.19. ResNet152V2 modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi	61
Şekil 6.20. ResNet101V2 modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi	62
Şekil 6.21. MobileNet modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi	62
Şekil 6.22. MobileNetV2 modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi	63
Şekil 6.23. DenseNet169 modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi	64
Şekil 6.24. NasNetLarge modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi	65
Şekil 6.25. ResNet152V2 modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri	66
Şekil 6.26. ResNet101V2 modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri	66
Şekil 6.27. MobileNet modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri	67
Şekil 6.28. MobileNetV2 modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri	68
Şekil 6.29. DenseNet169 modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri	68

Şekil 6.30. NasNetLarge modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri	69
Şekil 6.31. ResNet152V2 modelinin beş sınıflandırılmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi	70
Şekil 6.32. ResNet101V2 modelinin beş sınıflandırılmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi	71
Şekil 6.33. MobileNet modelinin beş sınıflandırılmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi	72
Şekil 6.34. MobileNetV2 modelinin beş sınıflandırılmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi	72
Şekil 6.35. DenseNet169 modelinin beş sınıflandırılmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi	73
Şekil 6.36. NasNetLarge modelinin beş sınıflandırılmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi	74

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 3.1. DR şiddet derecelendirme ölçeği.....	17
Çizelge 5.1. Literatürde DR hastalığı ile ilgili bazı veri kümesi örnekleri	34
Çizelge 5.2. Görüntü sayısı ve sınıfları.....	35
Çizelge 5.3. Çalışmada kullanılan ESA tabanlı modellerin performans karşılaştırmaları	42
Çizelge 6.1. 6 modelin filtresiz beş sınıflı veri kümesindeki testlerinden elde edilen doğruluk, kesinlik, duyarlılık ve F1 skor ortalama değerlerinin karşılaştırılması.....	56
Çizelge 6.2. 6 modelin Grayscale filtreli beş sınıflı veri kümesindeki testlerinden elde edilen doğruluk, kesinlik, duyarlılık ve F1 skor ortalama değerlerinin karşılaştırılması.....	65
Çizelge 6.3. Altı modelin Gaussian filtreli beş sınıflı veri kümesindeki testlerinden elde edilen doğruluk, kesinlik, duyarlılık ve F1 skor ortalama değerlerinin karşılaştırılması.....	74
Çizelge 6.4. Üç farklı veri kümesi için en yüksek doğruluğun elde edildiği modellerin karşılaştırılması.....	75
Çizelge 6.5. Önerilen modelin literatürdeki çalışmalar ile kıyaslanması	78
Çizelge 6.6. Önerilen modellerin doğruluk ve süre karşılaştırılması	81

SİMGELER VE KISALTMALAR DİZİNİ

CNN	Convolutional Neural Network
DBN	Deep Belief Network
DN	Doğru Negatif
DP	Doğru Pozitif
DR	Diyabetik Retinopati
DSA	Derin Sinir Ağı
ESA	Evrişimli Sinir Ağları
FFA	Fundus Florresein Anjiografi
GAN	Generative Adversarial Networks
GİB	Grafik İşlem Birimi
LSTM	Long short-term memory
MİB	Merkezi İşlem Birimi
NASNET	Neural Architecture Search Network
NPDR	non-proliferatif Diyabetik Retinopati
RBM	A restricted Boltzmann machine
RESNET	Residual Neural Networks
RGB	Red Green Blue
RNN	A recurrent neural network
YN	Yanlış Negatif
YP	Yanlış Pozitif
YSA	Yapay Sinir Ağları

ÖZET

Yüksek Lisans Tezi

Diyabetik Retinopati Tanısına Yönelik Derin Öğrenme Tabanlı Sınıflandırma

Osman Ceylan

Burdur Mehmet Akif Ersoy Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Doç. Dr. Onur SEVLİ

Ağustos, 2024

Diyabetik Retinopati (DR), diyabetli kişilerde gözün arkasındaki ışığa duyarlı doku tabakası olan retinanın kan damarlarını etkileyen görme kaybına ve körlüğe sebep olabilen bir komplikasyondur. DR hastalığının erken evrelerinde retinadaki kan damarlarının duvarı zayıflar ve çıkıntılar yapar. Bunun sonucunda doku şişer veya kan sızdırır. Bu durum görüntüleme cihazları ve doktor muayenesi ile tespit edilmektedir. Bu tez çalışmasında, DR hastalığının teşhisinde evrişimli sinir ağları (ESA) mimarileri kullanılarak en yüksek doğruluğun elde edilmesi için yaklaşım sunulmaktadır. DR hastalığının ESA modelleri ile tespiti için literatürde yaygın kullanılan ve güncel beş sınıflı APTOS 2019 veri seti tercih edilmiştir. Yüksek sınıflandırma doğruluğu elde edebilmek için veri setinin orijinali yanında Grayscale ve Gaussian filtre kullanarak oluşturulan veri setleri ile üç farklı veri kümesine dönüştürülmüştür. Elde edilen üç farklı veri kümesi, görüntü tabanlı ESA mimarilerinden ResNET152V2, ResNet101V2, MobileNet, MobileNetV2, DenseNet169 ve NASNetLarge ile aynı optimum parametreler ile eğitilmiş ve test sonuçları değerlendirilmiştir. Modeller No DR, Mild, Moderate, Severe ve Proliferative DR olmak üzere beş farklı sınıflandırma uygulanmış ve sınıflandırma performansının değerlendirilmesinde doğruluk, kesinlik, duyarlılık ve f1 skoru metrikleri kullanılmıştır. Elde edilen sonuçlar değerlendirildiğinde, orijinal APTOS 2019 veri kümesi üzerindeki eğitimlerde NasNetLarge modeli % 98,96, Grayscale filtreli veri kümesinde MobileNet V2 modeli %99,26 ve Gaussian filtreli model de ise MobileNet V2 % 99,54 ile en yüksek doğruluk değerlerine ulaşmıştır. Orijinal veri kümesine uygulanan filtrelerin sınıflandırma doğruluğunun artmasına katkı sağladığı görülmektedir. Sonuç olarak DR hastalığının teşhisi için Gaussian filtreli veri kümesinde MobileNetV2 modelinin kullanımının hastalık teşhisinde çok yüksek doğruluk ile sınıflandırma yaptığı görülmektedir.

Anahtar Kelimeler: Diyabetik Retinopati, Evrişimli Sinir Ağları, Sınıflandırma, Filtreleme, Derin Öğrenme

ABSTRACT

M.Sc. Thesis

Deep Learning Based Classification for Diabetic Retinopathy Diagnosis

Osman Ceylan

**Burdur Mehmet Akif Ersoy University
Graduate School of Natural and Applied Sciences
Department of Computer Engineering**

Supervisor: Assoc. Prof. Dr. Onur SEVLİ

August 2024

Diabetic Retinopathy (DR) is a complication that can cause vision loss and blindness in people with diabetes, affecting the blood vessels of the retina, the light-sensitive tissue layer at the back of the eye. In the early stages of DR, the walls of the blood vessels in the retina weaken and protrude. As a result, the tissue swells or leaks blood. This condition is detected by imaging devices and medical examination. In this thesis, we present an approach to achieve the highest accuracy in the diagnosis of DR using convolutional neural network (CNN) architectures. For the detection of DR disease with ESA models, the APTOS 2019 dataset with five classes, which is widely used and up to date in the literature, was preferred. To achieve high classification accuracy, the original dataset was transformed into three different datasets with datasets created using Grayscale and Gaussian filters. The three different datasets were trained with the same optimal parameters with the image-based ESA architectures ResNET152V2, ResNet101V2, MobileNet, MobileNetV2, DenseNet169, and NASNetLarge, and the test results were evaluated. The models were applied to five different classifications No DR, Mild, Moderate, Severe, and Proliferative DR, and accuracy, precision, sensitivity, and f1 score metrics were used to evaluate the classification performance. When the results obtained are evaluated, the NasNetLarge model achieved the highest accuracy values with 98.96% in training on the original APTOS 2019 dataset, the MobileNet V2 model with 99.26% in the Grayscale filtered dataset and MobileNet V2 with 99.54% in the Gaussian filtered model. It is seen that the filters applied to the original dataset contributed to the increase in classification accuracy. As a result, it is seen that the use of the MobileNetV2 model in the Gaussian filtered dataset for the diagnosis of DR disease provides very high accuracy in disease diagnosis.

Keywords: Diabetic Retinopathy, Convolutional Neural Networks, Classification, Filtering, Deep Learning

1. GİRİŞ

Diyabet, pankreasın yeteri miktarda insülin hormonu üretememesi veya vücudun ürettiği insülin hormonun görevini tam anlamıyla yerine getirmemesi nedeniyle karbonhidrat, yağ ve proteinlerin organizmaya yeterince fayda sağlamaması ve buna bağlı olarak da kan şekeri seviyesinin yükselmesi sonucu ortaya çıkan kronik bir hastalıktır. Dünya Sağlık Örgütü'nün yayınlamış olduğu kronik hastalıklar raporunda diyabet hastalığı ilk sırada yer almaktadır (Ünal vd., 2015). Diyabet her yaştan insanı etkileyen önemli bir halk sağlığı sorunudur (Ikram ve Imran, 2023). Uluslararası Diyabet Federasyonu'na göre, Dünya çapında diyabetten etkilenen kişi sayısı 2021 yılında yaklaşık olarak 537 milyon kişi olduğu ve bu sayı dünya nüfusunun da yaklaşık %10,5'ine karşılık geldiği bildirilmiştir. Bu sayı 2030 yılında 643 milyon, 2045 yılında ise 783 milyon olması tahmin edilmektedir. Bu sayılar dikkate alındığında Dünya çapında her dört kişiden üçü diyabet rahatsızlığına sahip olduğu görülmektedir (Bhulakshmi ve Rajput, 2024).

Diyabetik Retinopati (DR), diyabetin tipik bir komplikasyonudur. İstatistiklere göre Diyabet hastalarının üçte birinde DR'ye bağlı görme bozukluğu görülmesi muhtemel bir durumdur (Dayana vd., 2023). DR, Dünya genelinde meydana gelen görme bozukluğunun en önemli nedenidir. Dünya Diyabet Vakfı, dünya çapında DR hasta sayısının 2030 yılına kadar muhtemelen 191 milyona çıkacağını tahmin ediyor (Attia vd., 2020). DR, uzun süreli kan şekeri seviyesinin yükselmesi veya değişiklik göstermesi sonucunda retinada bulunan kan damarlarının zarar görmesi sonucunda meydana gelir (Özçelik vd., 2021). DR'de kan damarları sızlayabilir ve şişebilir, bunun sonucunda da kan damarı kapanabilir ve kan dolaşımı azalır. Hatta bazı durumlarda retinada anormal yeni kan damarları oluşabilir. Tüm bu değişiklikler sonucunda görme kaybı veya önlenemez körlük meydana gelebilir (Attia vd., 2020). Bazı durumlarda da DR, retina hasarına ve geri dönüşü olmayan körlüğe neden olabilir (Dayana vd., 2023).

DR önemli bir göz hastalığı olup, erken teşhisi ve tedavisi hayati öneme sahiptir. Geç kalmış teşhis ve tedavi görmeyi bozabileceği ve körlük riskini artırabileceği için DR tanısında erken teşhis çok önemlidir. DR, ilerleyen aşamalarda görme kaybına neden olabileceği için iş hayatındaki kişiler için önemli bir endişe kaynağı haline gelmiştir. Makine öğrenmesi tekniklerinden önce tıp uzmanları, DR tanısı için ağırlıklı olarak

manuel yöntemler ile fundus görüntü değerlendirmesini ve geleneksel yöntemleri kullanıyorlardı. DR tespiti için retinanın yüksek çözünürlüklü renkli fotoğraflarını çekerek, kan damarlarını, optik sinirleri ve diğer retina bileşenlerini görmek için belli özelliklere sahip kameralar kullanır (Bhulakshmi vd., 2024). DR şiddeti ve hastalığın derecesi fundus görüntülerine göre sınıflandırılır. Ayrıca DR'nin görme yeteneği üzerindeki etkisini değerlendirmek için görme keskinliği testi kullanılır. DR hastalığını tespit etmek için kullanılan bütün bu teknikler zaman alıcı olabilir ve hastalığın erken teşhis edilmesini zorlaştırır. Gözün geleneksel yöntemler ile manuel olarak incelenmesi zaman alıcıdır ve DR hastalığının teşhisi ve derecesini belirlemek için çok fazla gayret ve uzmanlık gerekmektedir (Safi vd., 2018).

Makine öğrenimi, yapay zekânın bir alt alanı olmakla birlikte bir problemin çözümü için o probleme ait veri setlerini kullanarak deneyimlerden kendi kendine öğrenir. Verileri kullanma ve öğrenme sürecinde bilgisayar algoritmaları kullanmaktadır. Oluşturulan modeller, en iyi performans elde etmek için tasarlanır (Shinde and Shah, 2018). Kullanılan veri setlerine ait özellikler makine öğrenmesinde manuel olarak çıkarılırken çok katmanlı mimari özelliğine sahip derin öğrenmede özellik çıkarımı ve istenilen sınıflandırma işlemleri algoritmalar tarafından gerçekleştirilmektedir (Mahesh, 2020). Bilgisayar teknolojindeki yaşanan son gelişmeler hem merkezi işlem birimlerinin (MİB) hem de grafik işlem birimlerinin (GİB) performansının artmasını sağlamıştır. CPU ve GPU performanslarının artması aynı zamanda yapay zeka çalışmalarının ve yapay zeka araçlarının performansların artmasını da doğrudan etkilemiştir. Verilere ait özelliklerin çıkarılması ve sınıflandırma işlemlerinin derin öğrenme algoritmaları ile yapılması işlemlerinde bilgisayarların MİB ve GİB'leri kullanıldığı için MİB ve GİB performanslarının artması derin öğrenme işlemlerinde sınıflandırma ve öznitelik çıkarma işlemleri süreçlerinin gelişmesini sağlamıştır (Şeker vd., 2017)

Gelişen teknoloji ile yapay zekâ ve makine öğrenimi yaklaşımlarının birçok hastalık sınıflandırma için kullanılması ile son yıllarda DR tespitinin verimliliğini ve doğruluğunu önemli ölçüde artırdı (Bhulakshmi vd., 2024). Etkili bir derin öğrenmeye dayalı tarama yöntemi, manuel teşhis için gerekli çabayı en aza indirerek ve sınırlı kaynaklardan yararlanarak sağlık hizmetlerini iyileştirebilir (Dayana vd., 2023). Derin öğrenme hastalık tespitinde başarılı sonuçlar vermektedir. Diyabetik retinopati lezyonlarının otomatik ve veri setlerinden bağımsız olarak tespit edildiği ve tespit edilen lezyonların sınıflandırıldığı derin öğrenmeye dayalı bir yöntem mümkündür (Erciyas vd., 2021).

Sağlıklı bir retina ile DR'den teşhisi konan bir retina arasında ayırım yapmak için tıp uzmanları ve makine öğrenmesi teknikleri, retina fundus görüntülerindeki çeşitli özellikleri ve anormallikleri analiz edilmektedir. Bu yöntemler ile hastalığı teşhis etmek ve değerlendirmek için kan damarlarını, mikroanevrizmaları, eksüdalari, makulayı, optik diskleri ve kanamaları analiz eden derin öğrenme uygulamasının arka planında retinopati derecelendirmesi dahil olmak üzere önemli sinyallere ve özelliklere odaklanılmaktadır. Bu özellikler, DR'yi özerk bir şekilde tanımak ve kategorize etmek için derin öğrenme modelleri için öznitelik girdisi olarak kullanılır. Derin öğrenme modelleri, özellikle fundus görüntülerinde DR'yi tespit etmek için veri setlerinde yer alan karmaşık özelliklerin öğrenilmesinde çok önemli rol oynamaktadır. Geleneksel görüntü analizi teknikleri, fundus resimlerinde karmaşık desenleri yakalamakta genellikle zorlanmakta ve bu da doğru DR tanısı için derin öğrenme modellerinin, özellikle de konvensiyonel sinir ağlarına ihtiyaç duyulduğunu göstermektedir. DL modelleri, katmanlar arasında geçişlerde soyut ayrıntıları öğrenerek veri setinde yer alan resimlerden piksel değerlerine göre anlamlı bilgiler çıkarabilir. Bu sayede farklı hastalık evrelerinin etkili bir şekilde sınıflandırılmasına veya sağlıklı fundus resimlerinin tanımlanmasına olanak sağlar. Derin öğrenme modelleri hastalıkların erken teşhis ve müdahale için çok uygun bir yöntem olup, DR'nin hızlı bir şekilde tespit edilmesine olanak sağlayarak yeni fundus görüntülerine uyum sağlamak için sürekli olarak geliştirilebilir performansı artırılabilir (Bhulakshmi vd., 2024).

Literatürde yer alan geçmiş çalışmalarda, diyabetik retinopatinin tespiti için çeşitli makine öğrenimi ve derin öğrenme teknikleri kullanılmıştır. Makine öğrenimi tabanlı yöntemler arasında özellikle Destek Vektör Makineleri, Karar Ağaçları, Rastgele Ormanlar, Naïve Bayes ve topluluk modelleri bulunmaktadır (Bhatia vd., 2016, Wu vd., 2021). Bu modeller, doğruluk, duyarlılık ve özgüllük açısından farklı başarı düzeyleri elde etmiştir. Ancak, bu modellerin ortak sınırlamaları arasında veri kümesi boyutlarının küçük olması, Diyabetik retinopati türü veya ciddiyet sınıflandırmasının eksikliği ve ikili sınıflandırma (Diyabetik retinopati veya Diyabetik retinopati değil) bulunmaktadır. Diğer yandan, derin öğrenme tabanlı yöntemler özellikle Inception, VGG, ResNet, DenseNet ve EfficientNet gibi öne çıkan evrişimli sinir ağlarını içermektedir. Bu derin öğrenme modelleri, ML tabanlı modellerle karşılaştırıldığında, doğruluk, hassasiyet ve özgüllük açısından önemli iyileştirmeler göstermiştir (Al-Dujaili, 2023).

1.1. Tezin Amacı

Tıbbi görüntülemede bilgisayarlı görme kullanımıyla mümkün olan bu DR hastalıklarının erken teşhisi büyük bir fayda sağlar. Kaliteli fotoğraf çekimi ve doğru tıbbi teşhis elde etmek için bu yöntemler şarttır. Bu teknolojiler, hekimlere yüksek doğrulukta bilgi sağlayarak, olasılıklara güvenmeksizin basit bir şekilde teşhis ve tedavi planı yapmalarına yardımcı olur; bu durumda hasta, en iyi tedaviyi alır. Diyabetik Retinopatinin yaygın olması, sağlık kurumlarının hastaları tedavi etmek için daha fazla maliyetle karşılaşabileceğini göz ardı etmemiz gereken bir husustur. Geleneksel sistemik tedavilerin etkisinin uzun zaman alması ve hastalığın kronik olması, tedavilerin sürekli takip gerektirmesi nedeniyle bu maliyeti artırır.

Bu tez çalışmasının temel amacı, derin öğrenme odaklı DR hastalık teşhis probleminin çözümünü sağlamaktır. Bu durum diyabetik retinopatinin tanısını hızlandırmak ve iyileştirmek amacıyla derin öğrenme tabanlı bir sınıflandırma sağlayacaktır. Bu bağlamda, diyabet hastalarında oluşan retinal bozuklukların, yani diyabetik retinopati hastalığının teşhisi için derin öğrenme tabanlı bir sistem tasarlanmıştır. Bu sınıflandırma sistemi, diyabetik retinopatiyi sağlıklı veya hastalığın dört evresine (0- No DR, 1 – Mild, 2 – Moderate, 3 – Severe, 4 – Proliferate_DR) göre toplamda 5 sınıflandırmayı önermektedir.

Doktorun hastalığı yanlış teşhis etmesi durumunda hastanın hayatı tehlikeye girebilir. Gerçekleştirilmesi planlanan tez çalışmasının başlıca amaçları aşağıdaki gibidir.

- Sağlıklı ve hastalıklı retina fundus dokularını ayırt etmek için bir retinopati segmentasyon tekniği için en iyi sınıflandırma yapacak bir yapay zekâ sisteminin oluşturulması,
- Retinopatileri sınıflandırmak ve derecelendirmek için bir yapay zekâ destekli sistem oluşturulması.

Doktorun hastalığı tehisinde yardımcı olacak sınıflandırıcı bir sonuç elde edilerek ve bu hastalığın teşhisini erken ve kolay bir yolla sağlamayı amaçlayan önemli bir sonucu literatüre kazandırılması sağlanacağı düşünülmektedir.

1.2. Tezin Organizasyonu

Tez çalışmasının organizasyonu řu bölüm ve başlıklar altında organize edilmiştir. İkinci bölüm altında araştırma problemiyle ilgili olarak, literatürde yer alan çalışmalara ait özetler sunulmuştur. Üçüncü bölüm başlığı altında, diyabetik retinopati hastalığı ile ilgili olarak gözün yapısı ve hastalığın bilgisi ve türlerine ilişkin bilgiler verilmiştir. Dördüncü bölümde ise görüntü tabanlı derin öğrenme ve evriřimli sinir ağıları ile ESA algoritmalarından bahsedilmiştir. Beşinci bölümde de gerçekleştirilen deneysel çalışmalara ait materyal ve yöntem bilgileri detaylıca anlatılmıştır. Altıncı bölümde de çalışmada elde edilen araştırma ve bulgulara ait sonuçlara ve grafiklere yer verilmiş ve bulgular literatürdeki çalışmalar ile karşılaştırmalı olarak bir değerlendirilmesi gerçekleştirilmiştir. Son bölüm olan yedinci bölümde ise tez çalışmasına ait bulgulardan elde edilen sonuçlardan ve gelecekteki çalışmalar için çeşitli önerilerden bahsedilmiştir.

2. LİTERATÜR TARAMASI

Retina görüntülerinin analizi için günümüzde derin öğrenme modelleriyle ilgili birçok araştırma yapılmıştır. Retinal kan damarlarının, kanamaların, sert ve yumuşak eksudaların otomatik olarak çıkarılması DR hastalığının erken tahmininde önemli rol oynamaktadır Yüksek doğrulukta elde edilen sonuçlarla daha iyi performans sağlamak için de kullanılabilir (Lalithadevi ve Krisnaveni, 2022). Bu bölümde, derin öğrenme yöntemleri kullanılarak Diyabetik Retinopati ve katarakt sınıflandırılmasıyla ilgili yapılan çalışmalar ele alınmıştır. Literatürde, Diyabetik Retinopati hastalık seviyelerini tespit etmeye yönelik birçok çalışma bulunmaktadır.

Math ve Fatima, (2021) tarafından önerilen bir yaklaşım ile DR ve DR lezyonlarını tespit etmek ve sınıflandırmak amacıyla derin öğrenme kullanılmıştır. Bu yöntem, bölütleme tabanlı bir öğrenme stratejisinden yararlanmaktadır. Çalışma kapsamında, farklı kontrast, görüntü çözünürlüğü ve aydınlatma seviyelerine sahip retina görüntüleri kullanılmıştır. Elde edilen görüntü verileri ön işleme tabi tutulmuştur. Görüntü bölütleri, önceden işlenmiş verilere dayanarak çıkarılmış ve diyabetik retinopatinin bölüt seviyesi göz önüne alınarak Evrişimli Sinir Ağı ile modellenmiştir. Düzensiz DR lezyonlarını daha etkili bir şekilde belirlemek için uçtan uca bölütleme tabanlı bir öğrenme stratejisi kullanılmıştır. Önerilen modelin doğruluğu yaklaşık olarak %96,3 olarak ölçülmüştür.

Özçelik ve Altan, (2021) yapmış oldukları çalışmada, DR hastalığının daha erken evrede teşhisi için APTOS 2019 veri setini kullanmışlardır. Veri setinde yer alan görüntülere sinyal işleme tekniği kullanarak aşırı öğrenmeyi engellemek istemişlerdir. Transfer öğrenme modelini kullandıkları çalışmada VGG-19 modeli için DR hastalığının beş sınıf türü için eğitimle yapmışlardır. Önerilen modelin sınıflandırma başarısı için hesaplanan doğruluk, kesinlik, geri çağırma ve F1-skoru değerleri sırasıyla %97,8, %97,6, %97,7 ve %97,6'dır.

Tariq vd., (2021) yaptıkları makalelerinde derin transfer öğrenmesi yöntemini kullanmışlardır. Beş evrişimli sinir ağı tasarımı tercih etmişlerdir, bu tasarımlar şunlardır: AlexNet, GoogleNet, Inception V4, Inception, ResNetV2 ve ResNeXt-50. Veri setini DR hastalığının şiddetine göre farklı kategorilere sınıflandırmışlardır. Yapılan deneylerin sonuçlarına göre, önceden eğitilmiş model ResNeXt-50, kullanılan diğer modeller arasında %97,53 ile en yüksek sınıflandırma doğruluğunu sağlamıştır.

Huynh vd., (2022) yılındaki çalışmalarında Diyabetik Retinopati'nin beş aşamasını (sağlıklı, hafif, orta, şiddetli ve çoğalan) derin öğrenme teknikleri kullanarak sınıflandırmışlardır. 5.590 görüntü üzerinde gerçekleştirilen çapraz doğrulama eğitimi ve testi sonrasında, diyabetik retinopati aşamalarını sınıflandırmak için önceden eğitilmiş MobileNetV2 modelini tercih etmişlerdir. Yapılan çalışmanın sonuçlarına göre, modelin ortalama doğruluğu %94,00 olarak belirlenmiştir.

Türkmen, (2021) tarafından yürütülen çalışmada, DR (Diyabet Retinopatisi) teşhisi ve sağlıklı durumu belirleme, aynı zamanda 4 evresine yönelik sınıflandırma işlemi Aptos 2019 veri seti kullanılarak gerçekleştirilmiştir. Bu araştırmada, derin öğrenme ve görüntü işleme yöntemleri entegre edilmiştir. Çalışmada, görüntü işleme metotları olarak Gauss bulanıklaştırma filtresi ve CLAHE (Kontrast Sınırlı Adaptif Histogram Eşitleme) kullanılmıştır. İki farklı görüntü işleme yönteminin, modelin başarısına olan etkisi detaylı bir şekilde incelenmiştir. Yazar, sınıflandırma sürecinde EfficientNET modelini tercih etmiştir. Çalışmanın sonuçlarına göre, EfficientNet-B7 modeli, bulanıklaştırma filtresi ile %85,18 doğruluk, %85,06 kesinlik, %85,18 duyarlılık, %84,98 F1 skoru ve 0,9135 Kappa skoru elde etmiştir. CLAHE ile ise %84,21 doğruluk, %84,85 kesinlik, %85,21 duyarlılık, %84,41 F1 skoru ve 0,9128 Kappa skoru elde edilmiştir. Ayrıca, Gauss bulanıklaştırma filtresinin, CLAHE tekniğine göre biraz daha yüksek başarı elde ettiği belirtilmiştir.

Aykat ve Senan, (2023) yaptıkları çalışmada, retina hastalıklarının tespiti için derin öğrenme tabanlı yöntemleri kullanmışlardır. Veri seti olarak Kaggle veri seti kullanmıştır. Bu veri seti, sağlıklı bireylerle diyabetik retinopati ve katarakt hastalarının fundus görüntülerinden oluşmaktadır. Çalışmalarında, ilk olarak Kaggle veri seti üzerinde histogram eşitleme yöntemi uygulanarak ön işlenmiş bir veri seti hazırlanmıştır. Ardından, ResNet50, InceptionV3, MobileNet, Xception ve EfficientNetV2S gibi geleneksel derin öğrenme modelleri üzerinde hiper parametre ayarı yapılarak eğitimler gerçekleştirmişlerdir. Son aşamada ise veri setlerinde en yüksek başarıya ulaşan MobileNet tabanlı bir hibrit model geliştirilmiştir. Önerilen hibrit model, ön işlenmiş veri setinde %99 doğruluk oranı elde etmiştir. Hibrit modelin sınıflandırma başarısının, ele alınan diğer derin öğrenme modellerinden daha yüksek olduğu gözlemlenmiştir.

Shaban vd., (2020), beş sınıf türünün olduğu APTOS 2019 veri kümesi için üç sınıf türü ile sınıflandırma çalışması gerçekleştirmişlerdir. Veri seti içerisinde yer alan dengesiz dağılımı yok etmek için bazı verileri birleştirmişlerdir. DR hastalığını sınıflandırmak için önerilen modellerinde 18 evrişim katmanı ve 3 tam bağlantılı katman

bulunmaktadır. Eğitim ve test aşamasında beş ve on kat çapraz doğruluma kullanmışlar ve sırasıyla doğrulukları %88, %89 ve duyarlılıkları %87, %89 ve son olarak da özgüllük değerlerini %94, %95 olarak hesaplamışlardır.

Oltu vd., (2023) yılında yaptıkları çalışmada, 2016-2021 yılları arasında DR tespiti için kullanılan derin sinir ağları ve transfer öğrenme yaklaşımlarını temel alan 43 yayın kullanılan veri seti açısından incelemişlerdir. Son yıllarda, literatürde DR tespiti için birçok yöntem önerildiğini ancak özellikle Evrişimli Sinir Ağı (ESA) modelleri içeren derin sinir ağlarının en çok tercih edilen yaklaşım haline geldiğini belirtmişlerdir. Çalışmalarında yeni ESA mimarilerini baştan tasarlamak ve eğitmek, özellikle tıbbi görüntüler için büyük bir çaba gerektiren zahmetli bir süreç olduğu vurgulanmıştır. Ayrıca, bu süreç çok sayıda parametrenin eğitimini içerdiğinden dolayı transfer öğrenme yaklaşımları, özellikle önceden eğitilmiş modellerin kullanılması, son yıllarda daha yaygın hale geldiğinden bahsedilmiştir.

Khalife vd., (2019) yaptıkları çalışmada APTOS 2019 veri seti ile AlexNet, ResNet18, SqueezeNet, GoogleNet, VGG16 ve VGG19 gibi farklı ESA modellerinin kullanarak DR hastalığının tespit edilmesi için deneysel çalışma yapmışlardır. En yüksek test doğruluğu %97,9 ile AlexNet modeliyle elde edilmiş olup, toplam ortalama doğruluk %96,3 olarak gerçekleşmiştir. AlexNet için hesaplanan F1 Skor değeri de %95,82 olarak bulunmuştur.

Alrubaye, (2024) tarafından yapılan tez çalışmasında, DR hastalığının otomatik sınıflandırılması için derin sinir ağlarını kullanılmıştır. APTOS 2019 veri seti kullanılarak gerçekleştirilen bu çalışmada model olarak ResNet50, Densenet201 ve InceptionV3 modelleri tercih edilmiştir. İki farklı deney yapılan çalışmanın ilk deneyde transfer öğrenme gerçekleştirilirken ikinci deneyde aşırı örnekleme ve büyütme ile veri arttırma gerçekleştirilmiştir. Bu veri dengeleme işleminden sonra veri setinin sınıflandırma performansı %85'ten %90'a çıktığı görülmektedir. Bu sonuçlar, dengeli veri seti üzerinde önerilen veri arttırımı fikrinin retinal görüntüleri yüksek doğrulukla sınıflandırabildiğini göstermiştir.

Lahmar ve Idri, (2023) yaptıkları çalışmada özellik çıkarımı için VGG16, VGG19, InceptionV3, DenseNet201, MobileNetV2, ResNetV2 ve ResNet50 olmak üzere farklı DL modellerini kullandılar. Çalışmalarını üç farklı veri kümesinde (APTOS, Kaggle DR ve Messidor-2) üzerinde gerçekleştirdiler. Modellerine ait performanslar, doğruluk, hassasiyet, kesinlik ve F1 Skor kullanılarak ölçülmüştür. Elde edilen sonuçlarda en iyi

mimariye sahip model MobilNetV2 olmuştur ve APTOS, Kaggle DR ve Messidor-2 veri kümelerinde gösterdiği doğruluk başarısı sırasıyla %88,80, %84,01 ve %84,05 olmuştur.

Esfahan vd., (2018) Diyabetik retinopati sınıflandırmasını içeren Kaggle veri tabanından alınan görüntüleri, ResNet34 ağını kullanarak diyabetik retinopati yok veya diyabetik retinopati olarak sınıflandırdı ve görüntü işleme teknikleri, Gaussian filtreleme ve ağırlıklandırma kullanarak görüntülerin kalitesini artırdı. Ayrıca sınıflandırma için kullanılan görseller 512×512 piksel boyutunda olup, bu çalışmada kullanılan sınıflandırma işlemi için elde edilen görsel sayısı 35.000 görsel olup, %86 hassasiyet oranı, %85 doğruluk oranı elde edilmiştir.

Sarki, (2019) ImageNet veri tabanında önceden eğitilmiş ESA kullandığı çalışmada transfer öğrenme konsepti kullanılarak 13 model için bir sınıflandırma çalışması gerçekleştirilmiştir. İnce ayar, veri artırma ve hacim artışı gibi performans optimizasyon teknikleri kullanıldı. Çalışma sonucunda en yüksek doğruluğa ulaştığı model %81,6 değeri ile RsNet50 olduğu görülmüştür.

Hagos ve Kant, (2019) InceptionNetV3 ağı aracılığıyla önerilen derin öğrenmeye dayalı bir yöntem kullanarak gerçekleştirdikleri çalışmada diyabetik retinopatiyi tespit etmek amacıyla beş sınıflı bir sınıflandırma gerçekleştirdi. Veri arttırımının yapılmadığı çalışmada önceden eğitilmiş olan modelin transfer öğrenmesi yöntemi ile kullanılan modelin doğruluğu %90,9 olarak hesaplanmıştır.

Wang ve Schaefer, (2020) fundus görüntülerinin teşhisi için gerçekleştirdikleri çalışmada, MobileNetV2 ön eğitilmiş model için testler yapmışlardır. Çalışmalarında herhangi bir veri arttırımı kullanmamışlardır. Kullandıkların model için eğitim, geliştirme ve test doğruluğu için sırasıyla 0,8327, 0,7309 ve 0,7847 değerleri buldukları görülmüştür (Wang ve Schaefer, 2020)

Pak vd., (2020) EfficientNet, DenseNet ve ResNet modellerini kullandıkları çalışmada sonuçları karşılaştırılmıştır. APTOS 2019 veri kümesinin kullanıldığı çalışmada retina görüntüsünü 5 sınıflandırma yapılmıştır. Sınıflandırma işleminde öznitelik olarak çeşitli klinik belirtilerinden (kan damarları, eksüdalar, mikrovasküler anevrizmalar vb.) yararlanılmıştır. Elde edilen sonuçlar DenseNet 121, ResNet50, Resnet101 ve EfficientNet-b4 için sırasıyla %69, %70,8, %73,4 ve %79 olarak hesaplanmıştır.

"Taufiqurrahman vd., (2020) DR hastalığını sınıflandırmak için APTOS 2019 veri setini kullanarak bir çalışma gerçekleştirmişlerdir. Model eğitimi için kullanılan veri

setinde herhangi bir ön işlem uygulamanın sınıflandırma başarısını etkilemediği hata düşürdüğü için bir ön işlem uygulanmamıştır. Ancak veri kümesinde sadece veri boyutunda büyütme ve yeniden örnekleme uygulamışlardır. Sınıflandırma modeli olarak da MobileNETV2-SVM ikili bir hibrit bir model kullandıkları görülmüştür. Çalışma sonucunda DR hastalığı sınıflandırması için beş sınıflandırma türüne yönelik olarak %85'lik doğruluk elde etmişlerdir.

Li vd., (2022) yapay zekayı kullanarak, diyabetik retinopati sınıflandırması için iki farklı veri kümesinin kullanılarak InceptionV3, ResNet-50 ve DenseNet modelleri ile bir çalışma yapmışlardır. Çalışma iki ana plana göre yapıldı; ilki, temel olarak yüzeysel öğrenenleri geliştirmektir. Aynı öğrenme oranında (0.0001) ve iki farklı batch size değerleri (16,32) kullanılarak gerçekleşen eğitimler sonucunda InceptionV3, ResNet-50 ve DenseNet'in doğruluk değerleri sırasıyla %78, %79 ve %80 olarak hesaplanmıştır.

Qummar vd., (2019) yapıtlıkları çalışmada, EyePACS veri setini kullanarak DR hastalığını sınıflandırmak için retina görüntülerinden DR'nin farklı aşamalarını otomatik olarak tespit etmeyi amaçladılar. Çalışmalarında, ESA tabanlı Xception, Dense-121, Resnet-50, Inception-v3, Dense-169 transfer öğrenme modellerini kullanmışlardır. DR'nin beş farklı sınıfı için elde edilen sonuçlar Resnet50, Xception, Dense121, InceptionV3 ve DenseNet169 hassasiyet değerleri sırasıyla, %48, %51, %65, %69, %84 olarak hesaplamışlardır.

Lazuardi vd., (2020) EfficientNet modelini kullanılarak DR hastalığının tespiti için bir çalışma gerçekleştirdiler. Öncelikle görüntü üzerinde histogram eşitleme ve görüntü kıpma olmak üzere iki ön işleme işlemleri gerçekleştirdiler. EfficientNet-B4 ve EfficientNet-B5 modelleri, görüntü veri seti üzerinde farklı sınıf oranlarına sahip iki veri kümesi haline getirildi. Bu iki model için doğruluk oranları sırasıyla %83,87 ve %83,89 olarak bulunmuştur.

Gulshan vd., (2016) diyabetik retinopati sınıflandırmak için yapmış oldukları çalışmada, Messidor-2 ve EyePACS-1 veri kümesini kullanmışlardır. Sınıflandırma işlemi model olarak transfer öğrenme modellerinden Inception-V3 ile yapılmıştır. Çalışma sonucunda, EyePACS veri seti için %90,3 duyarlılık ve %98,1 özgüllük sonucu elde ederken Messidor-2 veri seti için ise %87 duyarlılık ve %98,5 özgüllük değerine ulaşmışlardır.

Patel ve Chaware, (2020), DR görüntülerine ait veri kümesinden özelliklerin çıkarılması için transfer öğrenme yöntemini kullanarak bir çalışma gerçekleştirdiler. Bu

çalışmada önceden eğitilmiş modeller transfer edildi ve yeni katmanlar eklenmesi ile retinal görüntülerin bir veri sınıflandırma modeli oluşturulmuştur. Modelin performansını daha da artırmak için bazı katmanlarda ince ayar yapılmıştır. Deney sonucunda doğruluk %81'e olarak hesaplanmıştır.

Mushtaq ve Siddiqui, (2021) DR hastaşığı tespiti için DenseNet169 modelini kullanarak iki veri kümesi (Diyabetik Retinopati Tespiti 2015 ve Aptos) kullandıkları bir çalışma gerçekleştirdiler. Eğitim öncesinde veri kümeleri üzerinde temizleme, yeniden boyutlandırma ve büyütme gibi ön işleme adımlarını uyguladılar. Derin öğrenme modeli eğitim doğruluk değeri %95, doğrulama doğruluk değeri %90 olarak hesaplanmıştır.

Chuzdik vd., (2018) yılında yapmış oldukları çalışmada DR hastalığı için ikili sınıflandırma gerçekleştirmişlerdir. Bu çalışmada sınıflandırma modeli olarak VGG16, VGG19, InceptionV3, ResNetV2 ve Xception modelleri kullanılmıştır. EyePAC veri kümesi üzerinde gerçekleştirilen çalışmada en iyi doğruluk değeri ResNetV2 modelinde %96,8 olarak hesaplanmıştır.

Aldujailı, (2023) yapmış olduğu çalışmada, yeni bir DR yaklaşımı tanımlamıştır. VGG-16, VGG-19, Inception, Xception, EfficientNet ve NasNetLarge modelleri ile kendi oluşturduğu bir modeli kullandığı çalışmada eğitim öncesinde görüntülerde ön işlem uygulamıştır. İki farklı eğitim gerçekleştirdiği veri kümesinin ilkinde dengesiz veri küme seti üzerinde, ikincisini de dengeli veri kümesi seti üzerinde gerçekleştirmiştir. Çalışmasında sınıflandırma için veri kümesinde bulunan beş sınıfı iki sınıfa düşürmüştür. Beş sınıf türü için %92 ile en iyi doğruluk sonucunu veren modeller NasNetLarge ve EfficientNet modeli olurken ikili sınıflandırma için önerilen model de bu değer %99,46 olarak hesaplanmıştır.

Abdelmaksoud vd., (2021) yapmış oldukları çalışmada derin öğrenme tekniğine dayanan kapsamlı bir bilgisayar destekli teşhis makine öğrenme sistemi önermişlerdir. APTOS 2019 veri kümesini kullanıldığı ve veri kümesi üzerinde transfer öğrenmeyi uygulamak için üç derin öğrenme modeli seçilmiştir. Veri kümesinde öncelikle gürültü ortadan kaldırılarak kaliteyi artırmışlar ve retinal görüntülerin boyutlarını standart hale getirmişlerdir. Sırasıyla DenseNet169, DenseNet121 ve ResNet50 modelleri için %96,54, %90,93 ve %90,93 sınıflandırma doğrulukları elde ettiği görülmüştür.

Ergün, (2023) yapmış olduğu çalışmada DR teşhisi için makine öğrenmesi ve derin öğrenme modellerini test etmiştir. DR hastalığının erken evrede teşhis edebilmek için K en yakın komşu, destek vektör makinesi, naive Bayes, karar ağacı, rastgele orman,

XGBoost ve evrişimli sinir ağıları yöntemleri kullanılmıştır. Hem diyabet hem de diyabetik retinopati hastalığı için başarılı sonuçlar elde edilmiş olup sırasıyla %99,04 ve %95,55 oranında doğruluk değeri elde edilmiştir.

Rahman ve Dola, (2021) sınıf dengelemesi için orijinal RGB formatındaki görüntülere veri artırma teknikleri uyguladı. Daha sonra APTOS 2019 veri kümesinde transfer öğrenmeyi uygulamak için üç derin öğrenme ağı uyguladılar. DenseNet169, DenseNet121 ve ResNet50 modelleri için sırasıyla %96,54, %90,93 ve %90,93 sınıflandırma doğruluğu bildirdiler.

Dwivedi ve Attry, (2021) yaptıkları çalışmada APTOS 2019 veri kümesini kullanarak DR'nin ikili sınıflandırması için transfer öğrenme yaklaşımlarını ile MobilenetV2, DenseNet121, InceptionV3, ResNet50, VGG16 gibi farklı modellerde deneyler yapmışlardır. MobileNetV2 modeli kullanılarak elde edilen doğruluk ve F1 puanı %96,73 olduğu görülmektedir.


Sanjana vd., (2021) DR hastalığını tespit etmek için yaptıkları çalışmada APTOS 2019 veri kümesini kullanmışlardır. 1115 retinal fundus görüntülerini içeren iki genel veri kümesi bulunmaktadır. Çalışmalarında transfer öğrenme yöntemi modeli olarak, InceptionResNetV2, Xception, MobileNetV2, NASNetMobile ve DenseNet121 modellerini kullandılar. İkili sınıflandırmanın yapıldığı çalışma sonrasında Xception, InceptionResNetV2, MobileNetV2, DenseNet121 ve NASNetMobile modellerinin doğruluk başarıları sırasıyla %83,41, %86,10, %84,75, %74,44 ve %70,85 olarak hesaplanmıştır. Ayrıca F1 puanları da sırasıyla, %82,29, %85,01, %83,16, %68,5 ve %65,60 olarak hesaplanmıştır.

Adriman vd., (2021) DR hastalık tespiti için APTOS 2019 veri setindeki retina görüntülerini kullanarak ikili sınıflandırma gerçekleştirdikleri çalışmada model olarak ResNet, DenseNet ve DetNet modellerini kullanmışlardır. Bu çalışmada, derin öğrenme sınıflandırması için ikili model tabanlı özellik çıkarımı uygulanmıştır. En yüksek doğruluk ResNet34 modeli kullanılarak %96,35 olarak ölçülmüştür. Densenet121 ve DetNet59 modelleri için ise sırasıyla %84,05 ve %93,99 doğruluk değerleri hesaplanmıştır.

3. DİYABETİK RETİNOPATİ

3.1. Gözün Anatomik Yapısı

Vücudumuzdaki beş temel duyu organlarından birisi olan göz, etrafımızda bulunan nesnelerin algılanmasını sağlayan en önemli ve başlıca organdır. Görme fonksiyonumuzu sağlayan göz, yaklaşık olarak 2.5 cm çapa sahiptir. Anatomik olarak yapısı incelendiğinde gözümüz sert, damar ve ağ tabakaları olmak üzere üç temel tabakadan oluşmaktadır (Willoughby vd., 2010). Göz üzerinde bulunan altı adet kas gözün hareketini sağlarken, optik sinirler de beyin ile bağlantı sağlanır (Malhotra vd., 2011). Küre şeklindeki gözde, göz yuvarlağının en dışında beyaz lif şeklinde olan göz akı (sklera) saydam bir görünümdedir ve korneayı oluşturmaktadır. Sert tabakada olan kornea koruyucu bir tabaka yapıdadır ve ışığın odaklanmasını sağlayarak göz bebeğine ulaştırır. Kan damarının bulunmadığı korneada çok sayıda sinir ucu bulunduğu için hassas bir yapı özelliğine sahiptir. Sert ve ağ tabaka arasında yer alan damar tabaka da ise kan damarları yer almaktadır. Bu tabakada yer alan kan damarları göz hücrelerinin beslenmesini sağlar (Hassan vd., 2012). Ayrıca bu tabakada siyah renk pigmentler yer alır ve bunlar da net görüntünün oluşmasını sağlamak için yansımaya engel olur. Damar tabakada yer alan diğer yapılar ise iris ve göz bebeğidir. İris, gözün rengini belirleme görevine sahiptir ve kaslı bir yapıdan oluşur. İrisin kontrolünü sağlayan kaslar, korneadan gelen ışığa göre göz bebeğinin büyütüp küçülterek gözün net görmesine katkı sağlar (Akbar vd., 2019). En içte yer alan ve en son tabaka olan ağ tabaka, aynı zamanda retina olarak da bilinir. Görme olayının gerçekleştiği ve görme sinirlerinin bulunduğu bu tabakada göz merceği, sarı benek ve kör nokta bölgeleri de yer alır. Göz merceği, retinanın ön kısmıdır ve göz bebeği üzerine gelen ışınları gözdeki kaslar ile kırması ile meydana gelen ters görüntünün sarı beneğe iletilmesini sağlar (Malhotra vd., 2011). Ayrıca kırma derecesinin değiştirilmesini sağlayarak odaklama ve görme netliğinin ayarlanmasını sağlar. Retinada yer alan ve görüntünün en net halinin ters olarak oluştuğu bölgeye sarı benek, yine retina içerisinde bulunan ve bu ters görüntünün sarı benekten alınarak beyine iletilmesini sağlayan yapıya da kör nokta denir (Akbar vd., 2019). Şekil 3.1’de göze ait yapılar detaylı bir şekilde görülmektedir. Bu yapıların her biri görüntünün algılanmasında görevlidir.



Şekil 3.1. Gözün yapısı (Gündoğan, 2024)

Görüntünün gözde algılanma süreci, cisimden yansıyan ışığın korneadan girmesi ve irisin arkasında bulunan göz merceğine ulaşması ile başlar. Göz merceğinde kırılan ışık, retina tabakasına düşer ve sarı benek üzerinde ters bir görüntü oluşmasını sağlar. Oluşan bu ters görüntü gözde bulunan milyonlarca sinir yardımıyla beyindeki görme merkezine iletilerek görme olayının gerçekleşmesini sağlar (Rahman ve Dola, 2021).


3.2. Diyabet Hastalığı

Diyabet kan şekeri seviyesinde gerçekleşen düzensiz değişimlerden kaynaklı olarak ortaya çıkan ve tedavisi olmayan ölümcül bir hastalıktır. Diyabet, kronik bir hastalık olmakla beraber hastaların vücutlarında ciddi hasara yol açmaktadır. Kalp, gözler, sinir sistemi, kan damarları, böbrek hastalıkları, cilt ve deri enfeksiyonları ve bağışıklık sistemi gibi çeşitli organ ve sistemleri diyabetten doğrudan etkilenmektedir. Diyabetin günümüzde karşılaşılan 2 tipi vardır. Tip 1 diyabet, pankreasın ürettiği insülin miktarının kan şekeri seviyesini dengelemeye yetmediği bir hastalık türüdür. Tip 2 diyabette ise tip 1 diyabet hastalığında karşılaşılan insülin eksiliği aynı zamanda vücudu da etkilemektedir (Akkaya vd., 2018). Dünya Sağlık Örgütü'nün raporunda yer alan bilgiye göre her yıl 400 milyonun üzerinde insana diyabet teşhisi konmakta ve 1,6 milyon insan da bu hastalık sebebiyle hayatını kaybetmektedir (Ergün, 2023). Ayrıca bu sayıların her geçen yıl arttığı da görülmektedir. Bu rahatsızlık ile mücadele etmek ve hastada bıraktığı etkiyi azaltmak için erken evrede teşhis edilmesi oldukça önem taşımaktadır. Tanısı konulan hastaların yarısında diyabet hastalığının oluşturduğu hasar ortaya çıktığı görülmektedir (Ambady

vd., 2008). Hastaların tedavisini sağlamak, hastalığın etkisini en aza indirerek yaşam kalitesini arttırmak için erken evrede hastalığın teşhis edilerek tedaviye başlanması çok önemlidir.

3.3. Diyabetik Retinopati ve Evreleri


Diyabet hastalığı ile ilişkili bir rahatsızlık olan DR kandaki yüksek şeker seviyesine bağlı olarak ortaya çıkmaktadır. Erken teşhis edilmemesi ve uygun tedavinin zamanında uygulanmaması durumunda görme bozukluğu ve körlük ile sonuçlanan bir rahatsızlıktır. Yaşları 20 ile 80 arasında değişen diyabet hastaları arasında, DR sonucunda görme bozukluğu sorunları yaşanabilir. Vücutta yer alan kan dolaşımı sisteminde retina dokusundaki mikro boyuttaki kan damarlar aracılığı ile kan gözlere ulaşır (Lalithadevi vd., 2022) DR, klinik olarak gözle görülmesi zor olan mikrovasküler değişikliklerin ve retinadaki ortaya çıkan ve ilerleyen damar bozukluklarının bir sonucudur. Gözdeki retina damarlarında hasar oluşmasına neden olan DR'nin proliferatif diyabetik retinopati (PDR) ve non-proliferatif diyabetik retinopati (NPDR) olmak üzere 2 farklı evresi vardır ve evresine göre insanda etkisi, belirti göstermeme, aralıklı görme kaybı (Şekil 3.2), görme bulanıklığı, renklerin soluklaşması, lekelenme veya körlükle sonuçlanmaktadır (Akkaya vd., 2018).



Şekil 3.2. a) Sağlıklı bir bireyin görüşü, (b) DR hastalığına sahip bireyin görüşü
(Completeeyecare, 2024)


NPDR, DR'nin erken evre aşamasıdır ve yalnızca hafif semptomlar ile kendini gösterir (Wu vd., 2017). Hastalık ilerledikçe NPDR, PDR aşamasına ilerler ve bu durum da DR'nin ileri evre aşamasıdır. NPDR evresinde teşhis edilmeyen DR, retinada yeni

damarların ortaya çıkmasına neden olur ve bu damarlar kolay bir şekilde kanama yapabilir (Şekil 3.3). Oluşan kanamanın büyüklüğü arttıkça kısmi veya tam görme kaybının oluşma olasılığı da o kadar artar (Carrera vd., 2017).



Şekil 3.3. DR semptomları (Bruce, 2024)

NPDR aşaması ayrıca patolojilerin dağılımına bağlı olarak hafif(mild), orta(moderate) ve şiddetli(severe) olarak sınıflandırılmakta ve Şekil 3.4'te DR'nin tüm aşamaları görülmektedir (Bhulakshmi vd., 2024). DR'de ilk evre olan NPDR aşamasında gözlemlenen klinik bulgular arasında kan damarı duvarındaki deformasyonları tanımlayan mikroanevrizmalar, kanın kılcal damarlardan fazla sızdığına ortaya çıkan eksudalar, noktalar, alevler veya lekeler şeklinde oluşan kanamalar ve makula etrafındaki damarlardan sızıntı sonucu oluşan ödemler yer alır (Akbar vd.,2019). Mikroanevrizmalar, kılcal damar duvarlarında ortaya çıkan küçük kırmızı şişliklerdir ve bunlar, bozulmuş retina kılcal damarlarının tükenmesi nedeniyle ortaya çıkan DR'nin ilk klinik semptomlarıdır (İnan, 2014). Kanamalar, zayıflamış kan damarlarının yırtılmasıyla ortaya çıkar ve retinada kan ve sıvı sızıntısına neden olur (Hassan vd., 2012). Eksüdalar, anormal zayıf kan damarlarından lipid proteinlerinin sızması ve yağların birikmesi nedeniyle oluşan parlak sarı-beyaz benzeri düzensiz yama şeklindeki yapılardır (Dayana ve Emmanuel, 2023).



Şekil 3.4. DR hastalığının sınıfları


Çizelge 3.1, DR şiddet düzeyinin değerlendirilmesine yönelik standart derecelendirmesi belirtilere göre oftalmolog tarafından dört ana seviyede derecelendirilmiştir (Akbar vd.,2019).

Çizelge 3.1. DR şiddet derecelendirme ölçeği

DR derecesi	Belirti
No DR	Fundus görüntüsünde anormallik yok.
Mild NPDR	Retinada vasküler kanamaya ve sıvı sızıntısına neden olabilecek Mikroanevrizmalar gözükür.
Moderate NDPR	Mikroanevrizmalar büyüyerek belirgin bir sıvı ve kan sızıntısına neden olur.
Severe NPDR	Retinada yeni kan damarları oluşur ve mevcutta olan damarlar da büyüme gözlemlenir.
PDR	Yeni oluşan kan damarları, kırılma ve kanama olasılığına sahip hassas yapıdadır. Görme bozukluğu artık ilerleme gözlemlenmiş veya tamamen körlük oluşmuştur.

3.4. Diyabetik Retinopati Teşhisi

Çıplak gözle görülemeyecek yapıya sahip olan retina, Fundus Florresein Anjiografi (FFA) tekniği ile ayrıntılı bir şekilde gözlemlene ve tespit etme imkânı veren bir sistemdir. FFA tekniği, 1961 yılında Indiana Üniversitesinde tıp öğrencisi olan H.R. Novonty ve D.L. Alvis tarafından ilk defa tanımlanmış ve uygulanmıştır. Donald Gass bu 1967 yılında bu tekniğe ait deneyimlerini yayınlamaya başlamış ve bu sayede retinal hastalıklara ait görüntülerin değerlendirilmesi sürecinde FFA tekniğinin kullanılmasının yaygınlaşmasına katkı sağlamıştır (Atcı, 2024). Bilgisayar ve bilişim teknolojilerinde yaşanan gelişmeler ile de bu FFA tekniğinin verimini arttırmıştır. FFA tekniği retinadaki ayrıntıların görülmesini sağlar. Bu tekniğin kullanımı esnasında floresein denilen bir boya maddesinden faydalanılır. Bu sayede yüksek çözünürlüklü kameraların da yardımıyla fundus görüntüleri işlenerek hastalık teşhisi gerçekleştirilmektedir. Fundus cihazı Şekil 3.5'te görülmektedir. Sağlık gözde FFA yöntemi ile elde edilen görüntü Şekil 3.5'te görülmektedir.



Şekil 3.5. (a) Retinaya ait dijital görüntü veren oftalmoskop cihazı ve (b) fundus cihazı (Atcı, 2024, Venividigöz, 2024)

4. GÖRÜNTÜ TABANLI DERİN ÖĞRENME

4.1. Yapay Sinir ağları

Yapay Sinir Ağları (YSA), 1980’li yıllardan bu yapan yapay zekâ alanının gündeminde olan bir alandır. İnsan beynindeki sinir ağının bilgi işleme açısından basitleştirerek bir model oluşturup ve bu modeller arası bağlantılara göre farkı ağlar oluşturma prensibi üzerine ortaya atılmıştır (Şekil 4.1). YSA, beyin sinir ağını işleme ve hafıza bakımından simüle etmeye çalışan bir modeldir (Wu ve Feng, 2018). YSA doğrudan sinir ağı veya nöral ağ olarak da isimlendirilmektedir. YSA birbirine bağlı çok sayıda düğüm (nöron) oluşan hesaplama modelidir. Her düğüm aktivasyon fonksiyonu olarak isimlendirilen bir çıktı fonksiyonu temsil eder. Her iki düğüm arasındaki bağlantı, YSA’nın hafızasına eşdeğer olan ve ağırlık olarak adlandırılan bağlantıdan geçen sinyal için bir ağırlığı temsil eder. Ağın çıktısı, ağın nasıl bağlandığına, ağırlık değerine ve teşvik fonksiyonuna bağlı olarak değişecektir. Bununla birlikte, ağın kendisi genellikle doğadaki bir tür algoritma veya fonksiyona ait bir yaklaşımdır (Asadollahfardi ve Asadollahfardi, 2015).

YSA’daki nöron kavramı insan beynindeki nöronun görevlerini simüle etmek için geliştirilmiş sinir ağı bileşenidir. Şekil 4.1’de gösterildiği gibi basit bir YSA mimarisinde gelen bağlantılarının her birine bir nörona ağırlık olarak bilinen bir değer atanır. YSA etkin olduğunda Denklem 4.1’de verildiği gibi her girdi x_i , hesaplamada girdinin önemini ayarlayan bir ağırlık olan w_i ’dir. Her x_i ’nin kendisine karşılık gelen w_i ile çarpılması ve tüm sonuçların toplanması sonucunda z isimli nöron oluşur ve bu nöron için z , çıktı üretilmesi için bir transfer fonksiyonuna aktarılır. YSA içerisinde en yaygın kullanılan transfer fonksiyonu sigmoid’tir. z , tercih edilen $f(x)$ fonksiyonuna göre eşik değerin altındaysa, düğüm bir sonraki katmana hiçbir veri iletmez. Aynı şekilde z , $f(x)$ ’de belirlenen eşik değerini aşarsa, düğüm ateşlenir (Vogels vd., 2005).

$$z = \sum_{i=1}^n w_i x_i + b \quad (4.1)$$

Giriş Katmanı: Giriş sinyalini yani verilerin alındığı katmandır.

Gizli Katmanlar: Ağırlıklar ve aktivasyon fonksiyonları ile hesaplamaların gerçekleştiği katmandır.

Çıktı Katmanı: Sonuç yani tahmin veya sınıflandırmanın üretildiği katmandır.

Ağırlıklar: Nöronlar arasındaki her bağlantıda taşıyan verilerin öğrenme sürecindeki değerini temsil eden bir kavramdır. Eğitim süreci sırasında bu ağırlıkların ayarlanması öğrenme sürecini olumlu etkileyen ince ayarlardan biridir.


Aktivasyon Fonksiyonu: Aktivasyon fonksiyonları YSA modelleri içerisinde doğrusal olmayan bir yapı oluşturmak için veriler içindeki karmaşık örüntüleri ve ilişkileri öğrenmesini sağlar. Örneği bir YSA'nın içerisinde bir nöronun girişine bağlı olarak etkinleştirilme ve aktarılması durumunu belirleyerek ağına derinlik katar (Rasamoeline vd., 2020). YSA içerisinde yaygın olarak Eşik (Denklem 4.2), Sigmoid (Denklem 4.3), ReLU (Denklem 4.4), hiperbolik tanjant (Denklem 4.5) fonksiyonları tercih edilmektedir.

$$f(x) = \begin{cases} 0 & \text{if } 0 > x \\ 1 & \text{if } x \geq 0 \end{cases} \quad (4.2)$$

$$\sigma(x) = \frac{1}{1+e^{-x}} \quad (4.3)$$

$$f(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases} \quad (4.4)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (4.5)$$




Şekil 4.1. Basit bir YSA mimarisi

4.2. Derin öğrenme

Derin Öğrenme, Şekil 4. 2’de gösterildiği gibi giriş ve çıkış katmanları arasında birden fazla katman bulunan ve makine öğrenmesi alt kümesi olan yapay sinir ağıdır. Her katman, giriş verileri üzerinde hesaplamalar yapan birden fazla düğümden oluşur (Cichy ve Kaiser, 2019). Derin öğrenme modellerindeki derin kelimesi aslında bir ağına girdi

parametrelerindeki verilerden karmaşık gösterimleri öğrenmesini sağlayan birden fazla gizli katmanın varlığını ifade etmektedir. Böylelikle geleneksel YSA modellerinden daha karmaşık öğrenme süreçlerini ve görevleri çözmesini sağlar.



Şekil 4.2. Derin öğrenme ağının genel mimari gösterimi

Derin öğrenmedeki gizli katmanlar tam bağlı katmanlar olarak bilinmektedir. Tam bağlı katmandaki her nöron, önceki ve sonraki katmandaki her nörona bağlıdır. Derin öğrenme modellerindeki bu tam bağlı katman mimarisi verilerdeki karmaşık ilişkileri öğrenmek için oldukça uygun hale getirir (Galvan ve Mooney, 2021). Derin öğrenme modellerindeki bu gizli katmanlar birbirinin basit kopyalarından oluşmamaktadır. Her bir gizli katman algoritma içerisinde farklı katman türüne sahip karmaşık bir yapıya dönüşebilir (Heo ve Lee, 2019).

- Giriş verilerine bir dizi öğrenilebilir filtre uygulayan evrişim katmanları,
- Sıralı verilerdeki bağımlılıkları yakalayan uzun kısa süreli bellek katmanları,
- Ağ bilgisinin akışını kontrol etmek için geçitlemeyi kullanan kapılı tekrarlayan birim katmanları,
- Tahmin yaparken girdi dizisinin belirli kısımlarına odaklanan dikkat katmanları,
- Derin sinir ağının eğitimini sabitleyen ve hızlandıran normalizasyon katmanları olarak örneklendirilebilir.


Derin öğrenme modellerinin günümüzde birçok yapay zekâ uygulamasında tercih edilmesinde grafik işlem birimi kapasitelerinin artması, Derin öğrenme modellerinin öğrenmesi için gerekli veri kümelerinin (Metin, Ses, Görsel ve Video) artması ve erişebilir olması, bilgi işleme alanındaki iyileştirmeler ana etken olmuştur. Aynı zamanda derin öğrenme modellerinin algoritmalarının oluşturulmasında büyük kolaylık sağlayan Keras, Tensorflow, Theano, Caffe ve Pytorch kütüphanelerinin geliştirilmesi Derin öğrenmenin gelişim sürecinin hızlandırmaktadır (Joseph vd., 2021).

Derin öğrenme modellerini geliştirilirken veri kümesi ve çıktıya göre çeşitli algoritmalara bölünür. Her algoritmanın denetimli veya denetimsiz öğrenme tabanlı özellik çıkarma ve dönüştürme için doğrusal olmayan birbirinden farklı katmanları bulunur. Derin öğrenme modellerinde veri kümesine göre yaygın tercih edilen mimariler şunlardır.

- **Evrişimli Sinir Ağı (Convolutional Neural Network (CNN)):** Derin öğrenme süreçlerinde özellikle görüntü ve video tabanlı veri kümelerinin eğitiminde tercih edilir. Sinir ağının giriş verilerine filtreler uygulanabilen evrişim katmanları kullanılır. Özellikle sınıflandırma ve mekânsal ilişkileri çıkarma problemlerde etkin çıkarımlar yapmaktadır (Zha vd., 2022).
- **Tekrarlayan Sinir Ağı (Recurrent Neural Network (RNN)):** Veri kümeleri içerisinde doğan dil veya zaman serisi gibi ardışık verilerin işlenmesi ve öğrenilmesi için tercih edilir. Veri kümesi içerisindeki verilerin zaman içerisinde kalıcı olmasını sağlayan tekrarlayan bağlantılara sahiptir. Bu tekrarlayan yapılar verilerdeki bağımlılıkları yakalamaya çalışır (Yin vd., 2017).
- **Uzun-Kısa Vadeli Bellek (Long Short-Term Memory (LSTM)):** Özellikle dil çevirisi, duygu analizi, konuma tanıma ve zaman serisi gibi problemlerin çözümünde kullanılan LSTM modeli, uzun vadeli bağımlılıkları yakalamak için tasarlanmış bir RNN türüdür (Smagulova ve James, 2019).
- **Çekişmeli Üretici Ağ (Generative Adversarial Networks (GAN)):** Gerçek veri kümesine çok benzeyen görüntü veya metin gibi sentetik verileri üretmek için kullanılan GAN, üretici ve ayırıcı olarak bilinen iki sinir ağından oluşur (Nandhini vd., 2021).
- **Kısıtlı Boltzmann Makinesi (A Restricted Boltzmann Machine (RBM)):** Veri kümesindeki stokastik dağılımları öğrenebilen, görünür ve gizli katmanların simetrik bağlantılarından oluşan RBM daha yaygın sınıflandırma ve regresyon işlemlerinde kullanılır (Cheng vd., 2019).
- **Derin İnanç Ağı (Deep Belief Network (DBN)):** DBN derin öğrenme algoritması RBM modelindeki yığınları ile oluşan ve nesne, video hareket yakalama alanlarında kullanılan bir sinir ağıdır (Hu vd., 2019).

4.3. Evrişimli Sinir Ağları

Derin öğrenme mimarileri içerisinde CNN veya ConvNet olarak bilinen Evrişimli Sinir Ağları (ESA), Şekil 4.3'te gösterildiği gibi görüntü veya video gibi piksel ızgarası benzeri bir topolojiye sahip veri kümelerinde öğrenme gerçekleştirebilen bir sinir ağıdır. ESA modelleri özellikle görüntü sınıflandırma ve nesne tanıma problemlerinin çözümünde yaygın tercih edilmektedir (Kattenborn vd., 2021).




ESA girdi katmanındaki giriş görüntüsünü özellik haritasına dönüştürerek tahmin edilebilir bir sonuç üretmek için evrişimsel ve havuzlama katmanlarından geçirir. Burada karmaşık desenleri öğrenmek için girdi görüntüsünde çekirdek adı verilen filtreler uygulanır. Çekirdek (kernel), Şekil 4.4'te verildiği gibi seçilen görüntü parçasının öge kapsamında çarparak ve görüntü boyunca hareket ederek kenar, doku ve şekil özelliklerini çıkartır (Lu vd., 2021).

$$\begin{array}{|c|c|c|} \hline \text{Girdi} & & \\ \hline 0 & 1 & 2 \\ \hline 3 & 4 & 5 \\ \hline 6 & 7 & 8 \\ \hline \end{array} * \begin{array}{|c|c|} \hline \text{Çekirdek} & \\ \hline 0 & 1 \\ \hline 2 & 3 \\ \hline \end{array} = \begin{array}{|c|c|} \hline \text{Çıktı} & \\ \hline 19 & 25 \\ \hline 37 & 43 \\ \hline \end{array}$$

Şekil 4.4. Örnek bir girdi görüntüsünün çekirdek ile çarpımı sonucunda elde edilen çıktı

ESA modelleri diğer sinir ağları modellerindeki gibi ağırlıkları ve bias'ları öğrenen nöronlara sahiptir. ESA mimarisinde girdilerin görüntü olduğu varsayılır ve belirli


özellikler içine kodlanır (Chauhan vd., 2018). Buda ESA'nın hem verimliliği artırır hem de ağıdaki parametre sayısını azaltır. ESA'nın diğer sinir ağlarından en temel farkı genişlik, yükseklik ve derinlik olmak üzere üç boyutta düzenlenmiş nöronlara sahip olmasıdır. Şekil 4.5'te de görüldüğü gibi bir katmandaki nöronlar YSA'dan farklı olarak bir önceki katmandaki nöronların sadece bir kısmına bağlıdır. ESA modelleri genel olarak Evrişim, Havuzlama ve tam bağlı katmanlar olmak üzere üç ana bileşende incelenebilir.



Şekil 4.5. Örnek bir hava taşıtı sınıflaması yapan ESA mimarisinin konfigürasyonlarını, girişler ve çıkışlar sistemin çalışma prensibi gösterimi (Tabian vd., 2019).

4.3.1. Evrişim Katmanı

ESA mimarisi içerisinde girdi görüntülerinden özelliklerin çıkarıldığı Şekil 4.6'da gösterilen katman, evrişim katmanıdır. Bu katmanda giriş görüntüsündeki verinin kenarlar, dokular ve desenlerini tanımlamak için filtreler uygulanır. Filtrelerin boyutu ve sayıları geliştirici tarafından belirlenir. Her filtre, girdiyi sol üst köşeden sağ alt köşeye doğru tarar ve her biri bir özellik haritası oluşturur. Evrişim, giriş verilerinin küçük karelerini kullanarak görüntü özelliklerini öğrenerek pikseller arasındaki mekânsal ilişkiyi korur. Evrişim katmanı ESA mimarisinin çekirdeği (kernel) olarak bilinir. Evrişim katmanının çıktısı genellikle modele doğrusal olmama kazandırmak için ReLU aktivasyon fonksiyonundan geçer. Bu fonksiyon özellik haritasını işler ve tüm negatif değerleri sıfırla değiştirir.




Şekil 4.6. Evrişim katmanının çekirdek filtresi ile çıktı süreci örneği

4.3.2. Havuzlama Katmanı

Havuzlama katmanı, ESA modeli içerisinde evrişim katmanından gelen özellik haritalarındaki bilgileri yoğunlaştırmak ve böylece hesaplama gücünü azaltmak için maksimum veya ortalama değerleri hesaplayarak özellik haritalarının boyutunu azaltmak için kullanılır. Ayrıca, dönme ve konumsal olarak değişmez olan baskın özellikleri çıkarmak için elverişlidir. Böylece ESA modelinin etkili bir şekilde eğitme sürecine katkı sağlar. Havuzlama katmanı çekirdek tarafından gönderilen verinin işlenmesi için Şekil 4.7’de gösterildiği gibi maksimum (max pooling) ve ortalama (avg pooling) havuzlama olarak iki türe sahiptir (Yu vd., 2014).

Maksimum Havuzlama: Çekirdek tarafından kapsanan girdi görüntüsü bölümünden maksimum değeri döndürür. Aynı zamanda gürültülü aktivasyonları tamamen atar ve boyutsal azaltma ile gürültü giderme de gerçekleşir.

Ortalama Havuzlama: Çekirdek tarafından kapsanan girdi görüntüsü bölümünden tüm değerlerin ortalamasını döndürür (Cui vd., 2017).



Şekil 4.7. Maksimum ve ortalama havuzlama

Havuzlama işlemi, girdinin her bir derinlik dilimi üzerinde ayrı ayrı çalışarak hepsini aynı şekilde aşağı örneklemektedir. Dilimlerin her biri, havuzlama katmanını tanımlarken kullanıcı tarafından belirlenen filtre boyutuna eşit alana sahip bir dizi yamaya bölünecektir. En yaygın kullanılan filtre boyutu (2x2)' dir. Bu nedenle her dilim 2 nöron yüksekliğini ve 2 nöron uzunluğuna bölünecektir. Havuzlama katmanının çıktısı derinliği girişe eşit ama daha küçük bir hacime sahip olacaktır (Zafar vd., 2022). Örneğin, bir havuzlama katmanının girdisi $64 \times 64 \times 6$ hacmindeyse ve katmanın filtre boyutu (2x2) ise çıktı $32 \times 32 \times 6$ olur. Bu sonuç ile ağıın karmaşıklığında büyük bir azalma sağlanır.

4.3.3. Tam Bağlantılı Katman

ESA mimarisinde havuzlama işleminin ardından ortaya çıkan özellik haritalarını düzleştirilir ve geleneksel YSA mimarisine benzer şekilde katmandaki tüm nöronlara bağlayan geleneksel bir sinir ağı katmanıdır. Tam bağlantılı katman genellikle ESA mimarisinin sonunda görünür ve önceki evrişim ve havuzlama katmanlarından düzleştirilmiş özellik haritalarını girdi olarak alır. Evrişim ve havuzlama katmanları ReLU aktivasyon fonksiyonlarını kullanırken tam bağlantılı katmanlar genellikle girdileri 0 ve 1 arasında sınıflandırmak için bir Denklem 4.6'da verilen softmax aktivasyon fonksiyonunda yararlanır (Basha vd., 2020). Tam bağlı katman ESA mimarisi içerisinde son aşamada sınıflandırma veya regresyon gibi sonuçlar üretmek için yer almaktadır.

$$f(z) = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad (4.6)$$


4.4. Yaygın ESA Mimarileri

4.4.1. ResNet152

Residual Neural Networks (ResNet), ESA mimarilerinde yaşanan eğitim zorluklarına karşı getirdiği çözümlerle öne çıkan bir mimaridir. Genel olarak ResNet, klasik bir katman mimarisindeki çıkışa değil de girişin doğrudan bir sonraki katmanın çıkışına eklenmesi ve bununla beraber kaybolan gradyanların önlenmesine imkân sağlamaktadır.

ResNet mimarisinde bir önceki katmanda öğrenilemeyen bilgiler ResBlock katmanı ile eski katmandan yeni katmana uygulanır. ResBlock katmanı ResNet mimarisinde artık değerleri bir sonraki katmana besleyen bloklardır. Her iki katmanlı aktivasyonda ağırlık katmanları ile ReLU aktivasyon kodu arasında gerçekleşen bu atlama ile eklenen bu değer sistem hesabını değiştirir (Aksoy ve Salman, 2022).


ResNet152 algoritması Şekil 4.8’de gösterildiği gibi Conv2D ve Conv3D filtrelerinin mantığını kullanarak özellikleri çıkarmak için kullanılan ve atlama bağlantıları yoluyla kaybolan gradyan sorununun üstesinden gelen bir ESA mimarisidir. ResNet152 konvolüsyon katmanı ve havuzlama katmanları olarak iki bölümden oluşur (Hasanah vd., 2023). Çıkış kanallarının sayısını eşleştirmek için iki evrişim katmanı kullanır. Konvolüsyon katmanının çıktısını bir ReLU aktivasyon fonksiyonu ve toplu normalizasyon takip eder. ResNet152’nin ilk iki katmanı kanal çıktısı üreten 7×7 konvolüsyon katmanına sahiptir. Mimari içerisinde konvolüsyon işlemi gürültü azaltma ve özellik geliştirme aşaması için kullanılır (Roy vd., 2021).



Şekil 4.8. ResNet-152 Mimarisi (Roy vd., 2021)

4.4.2. ResNet101


ResNet-101 Şekil 4.9’da verildiği gibi toplamda 104 konvolüsyonel katman içeren ESA mimarisidir. Bununla birlikte toplam 33 blok katmandan oluşur ve bu blokların 29'u yukarıda artık bağlantılar olarak tanımlanan bir önceki bloğun çıktısını doğrudan kullanır. Bu artıklar sonraki blokların girdisini elde etmek için her bloğun sonunda kullanılan toplama operatörünün ilk operandı olarak kullanılır. Kalan 4 blok, bir önceki bloğun çıktısını alır ve 1×1 filtre boyutuna ve 1 adımına sahip bir konvolüsyon katmanında kullanır. Son adımda normalleştirme işlemini gerçekleştiren bir toplu normalleştirme katmanı gelir ve sonuçta elde edilen çıktı, o bloğun çıkışındaki toplama operatörüne gönderilir (Zhang, 2022).



Şekil 4.9. ResNet 101 mimarisi (Khan vd., 2022)

4.4.3. MobileNet


ESA mimarisi içerisinde MobileNet modeli standart bir konvolüsyonu derinlemesine konvolüsyona ve 1×1 konvolüsyona çarpanlara ayıran, çarpanlara ayrılmış konvolüsyonların bir biçimi olan derinlemesine ayrılabilir konvolüsyonlara dayanmaktadır. MobileNet ağlar için derinlemesine konvolüsyon her bir giriş kanalına tek bir filtre uygulamaktadır (Mijwil vd., 2023). Ayrıca noktasal konvolüsyon, derinlemesine konvolüsyonun çıktılarını birleştirmek için 1×1 konvolüsyon oluşturur. Standart konvolüsyon, girdileri hem filtreler hem de tek adımda yeni bir çıktı kümesinde birleştirir. Derinlemesine ayrılabilir konvolüsyon bunu filtreleme ve birleştirme için ayrı ayrı iki katman olarak ayırır. Bunu işlem MobileNet ağındaki hesaplama ve model boyutunu büyük ölçüde azaltma etkisine sahiptir (Şekil 4.10).



Şekil 4.10. MobileNET Mimarisi (Akter vd., 2021)

4.4.4. MobileNetV2

MobileNetV2, MobileNetV1'den doğrusal darboğaz modülleri ile ters çevrilmiş artık eklenerek geliştirilmiştir. Şekil 4.11'de gösterilen MobileNet mimarisi derinlemesine ayrılabilir konvolüsyona dayanmaktadır. Standart 2D konvolüsyon, derinlik boyutunda (kanal) da konvolüsyon yaparak bir çıkış kanalı üretmek için tüm giriş kanallarını doğrudan işler (Sanjaya ve Rakhmawan, 2020). Derinlemesine konvolüsyon, giriş görüntüsünü ve filtreyi farklı kanallara ayırır. Filtrelenmiş çıkış kanalı üretildikten sonra, bu çıkış kanalları daha sonra geri istiflenir. Ayrılabilir derinlikli konvolüsyonda, yığılmış çıkış kanalları daha sonra yığılmış çıkış kanallarını tek bir kanalda birleştirmek için noktasal konvolüsyon olarak adlandırılan 1×1 konvolüsyon kullanılarak filtrelenir. Derinlemesine ayrılabilir konvolüsyon, standart konvolüsyonla aynı çıktıyı üretir. Ancak sürece dahil olan parametre sayısını azalttığı için daha verimlidir. MobileNetV2, $224 \times 224 \times 3$ piksel boyutunda giriş görüntüleri alır (Toğaçar vd., 2021). Bu nedenle, veri kümesindeki giriş görüntüleri yeniden boyutlandırılır ve 224×224 piksele kırpılır. MobileNetV2, 32 filtreli ilk konvolüsyon katmanından sonra 19 ters çevrilmiş artık darboğaz katmanı ekler ve sonrasında $7 \times 7 \times 1280$ piksel boyutunda çıktı üreten noktasal bir konvolüsyonla sonlandırılır.




Şekil 4.11. MobileNET v2 Mimarisi (Dong vd., 2020)

4.4.5. DenseNet169

Yoğun bağlantılı konvolüsyonel ağlar veya DenseNet yakın zamanda önerilen bir ESA mimarisidir. DenseNet’de her katman kendinden sonraki tüm katmanlara doğrudan bağlıdır. DenseNet kompakt bir modeldir ve aşırı uyuma daha az eğilimlidir. Dört yoğun bloktan oluşur. DenseNet’teki her katman açıkça kayıp fonksiyonu gradyanlarına maruz kaldığından, kaybolan gradyan sorununu azaltmak, fonksiyonların yayılımını iyileştirmek, yeniden kullanımı teşvik etmek ve parametre sayısını büyük ölçüde azaltmak gibi iyileştirmeler sağlamaktadır (Firdaus vd., 2023).


DenseNet169 mimarisi, konvolüsyonel, maxpool, yoğun ve geçiş katmanları dahil olmak üzere çeşitli katman türlerinden oluşur (Şekil 4.12). Ayrıca mimari ReLU ve SoftMax olmak üzere iki aktivasyon fonksiyonu kullanmaktadır. Bunlardan ilki, SoftMax’ın kullanıldığı son katman hariç, mimari boyunca kullanılır (Ajesh and Abraham, 2021).



Şekil 4.12. DenseNet169 Mimarisi (Al-Rimy vd., 2023)

4.4.6. NASNet Large

NasNetLarge, optimum ESA mimarisini otomatik olarak arayan bir nöral mimari arama (NAS) ağıdır. Belirli bir görev için çok uygun olan bir mimariyi keşfetmek için takviye öğrenme tabanlı bir yaklaşım kullanır. NASNetLarge, maksimum 533 derinliğe ve yaklaşık 88,9 milyon eğitilebilir parametreye sahip önceden eğitilmiş modellerden biridir (Kanchanadevi ve Sandhia, 2023). Şekil 4.13'te mimarisi verildiği gibi hiperparametre optimizasyonuna çok benzer ve otomatik makine öğreniminin bir alt alanı olarak değerlendirilmektedir (Kalaiselvi vd., 2021).



Şekil 4.13. NasNetLarge mimarisi

4.5. Performans Değerlendirme Metrikleri

Performans değerlendirme metrikleri, derin öğrenme mimarilerinin oluşturulması, modelin eğitimi ve testi süreçlerinde geliştirilen modelin etkinliğinin ve doğruluğunun değerlendirilmesi önemli bir süreçtir. Aynı zamanda bu metrikler derin öğrenme modellerinin niceliksel olarak performansının ölçülmesinde ve sonrasında yapılan ince ayar iyileştirmelerin uygulanmasında kullanılır (Needham ve boyle, 2003). Kullanılan DSA modelleri ve çıktı çeşidine göre farklı performans değerlendirme metrikleri tercih edilir. Performans metriklerinin verdiği sonuçlara göre aynı zamanda veri kümesine göre doğru model seçimi konusunda da fikir verebilmektedir. Özellikle sınıflandırma problemlerinin çözümünde performans değerlendirmesi Karışıklık matrisi, kesinlik, duyarlılık, doğruluk ve F1 skoru metrikleri yaygın tercih edilmektedir (Song vd., 2022).

4.5.1. Karışıklık Matrisi (Confusion Matrix)

Karışıklık Matrisi, DSA modelinin bir test veri kümesi üzerindeki sınıflandırma performansını tahmin ve gerçek değerleri üzerinden değerlendiren bir matristir (Heydarian vd., 2022). Karışıklık Matrisi modelin sınıflandırmasında doğru ve yanlış örneklerinin sayısı üzerinden yorumlar ve iyileştirmelere katkı sağlar. Şekil 4.14'te gösterildiği gibi bir tablo görünümünde Doğru Pozitif (DP), Yanlış Pozitif (YP), Yanlış Negatif (YN) ve Doğru Negatif (DN) değerlerinden oluşmaktadır. Karışıklık Matrisi içerisinde yer alan etiketlemelerin gerçek ve tahmin arasındaki ilişki tanımı aşağıdaki gibi açıklanmıştır (Cavalin ve Oliveira, 2019).

Doğru Pozitif (DP): Modelin ikili olarak sınıflandığı bir tahminde gerçekte 1 olanın tahminde de 1 olduğu değerleri temsil eder.

Doğru Negatif (DN): Modelin ikili olarak sınıflandığı bir tahminde gerçekte 0 olanın tahminde de 0 olduğu değerleri temsil eder.

Yanlış Pozitif (YP): Modelin ikili olarak sınıflandığı bir tahminde gerçekte 1 olanın tahminde de 0 olduğu değerleri temsil eder.

Yanlış Negatif (YN): Modelin ikili olarak sınıflandığı bir tahminde gerçekte 0 olanın tahminde de 1 olduğu değerleri temsil eder.

		<u>Gerçek Değerler</u>	
		Pozitif	Negatif
<u>Tahmin Değerleri</u>	Pozitif	DP	YP
	Negatif	YN	DN

Şekil 4.14. Karışıklık matrisi gösterimi

4.5.2. Doğruluk

Denklem 4.7'de gösterildiği gibi formülize edilen doğruluk metriği modelin performansının en temel ölçüldüğü metriklerinden biridir. Doğruluk, model içerisindeki

sınıflandırmada doğru örneklerinin sayısı üzerinden bir doğruluk oranı hesaplar (Aggarwal vd., 2021).

$$\text{Doğruluk} = \frac{DP+DN}{DP+DN+YP+YN} \quad (4.7)$$

4.5.3. Kesinlik

Bir DSA modeli içerisinde yapılan sınıflandırma sonuçları üzerinde tahmin edilen pozitif örneklerin sayısı içindeki gerçek pozitif örneklerin sayısının oranını değerlendirilmesini sağlamaktadır. Denklem 4.8 'de verildiği gibi gerçek pozitif örneklerin sayısının gerçek pozitif ve yanlış pozitif örneklerin toplamına bölünmesiyle hesaplanır (Rai vd., 2023).

$$\text{Kesinlik} = \frac{DP}{DP+YP} \quad (4.8)$$

4.5.4. Duyarlılık

Duyarlılık metriği tüm gerçek pozitif örnekler içindeki gerçek pozitif örneklerin oranını ölçmektedir. Denklem 4.9'daki gibi gerçek pozitif örneklerin sayısının gerçek pozitif ve yanlış negatif örneklerin toplamına bölünmesiyle hesaplanır (Javaid vd., 2026).

$$\text{Duyarlılık} = \frac{DP}{DP+YN} \quad (4.9)$$

4.5.5. F1 Skor (F1 Score)

F1 skor, model sınıflandırmalarında en etkili performans değerlendirmesi ve ince ayar yapılmasına yardımcı olan metriklerdendir. F1 skor, Denklem 4.10'da verildiği gibi kesinlik ve duyarlılık metriklerinin harmonik ortalaması ile hesaplanmaktadır. F1 skor için aralık [0, 1]'dir. Sınıflandırıcınızın ne kadar kesin olduğunu (kaç örneği doğru sınıflandırdığını) ve ne kadar sağlam olduğunu (önemli sayıda örneği kaçırmadığını) gibi yorumların yapılmasını öngörmektedir (Alakus ve Turkoglu, 2020). F1 skor denklemi sonucunda elde edilen değer ne kadar büyükse, modelimizin performansı o kadar iyidir şeklinde yorumlama yapılmaktadır.

$$F1 \text{ skor} = 2 \times \left(\frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \right) \quad (4.10)$$

5. MATERYAL VE YÖNTEM

5.1. Kullanılan Veri Seti

Çizelge 5.1’de gösterildiği gibi DR hastalığının teşhisinde kullanılan veri setleri içerisinde, bu tez çalışmasında DR tespit çalışmalarında sıklıkla kullanılan ve en güncel veri setlerinden birisi olan APTOS 2019 veri seti kullanılmıştır (Oltu vd., 2023). DR hastalığına ait bir durum analizi yapmak amacıyla retinal görüntüleri kullanan Asya Pasifik Tele-Göz Hekimliği Derneği (Asia Pacific Tele- Ophthalmology Society- APTOS), APTOS 2019 veri setini oluşturmuştur. Açık kaynak bir veri kümesi olan APTOS 2019 veri seti, çeşitli kamera tiplerinin kullanılması ile farklı kliniklerden toplanan 3962 retinal görüntüden oluşmaktadır. Uzmanlar tarafından bu veri kümesindeki görüntüler, DR yok, hafif, orta, şiddetli ve yaygın DR olmak üzere beş farklı sınıfa ayrılmıştır. Görüntülerin sınıflar üzerindeki dağılımı Çizelge 5.2’de verilmiştir. Kaagle platformunda ücretsiz bir şekilde ulaşılabilinen bu veri seti, Gauss filtreleme ve Grayscale filtrelemeye tabi tutularak aynı veri kümesi için 3 farklı veri seti oluşturulmuştur. Bu veri kümesinin görüntüleri, transfer öğrenmeyi kullanarak her bir konvansiyonel sinir ağı modelinde kullanılması için 224x224x3 boyutlarında yeniden boyutlandırıldı. No DR (Diyabetik retinopati olmayan), Mild (Hafif), Moderate (Orta), Sever (Şiddetli) ve Proliferate DR (İleri evre diyabetik retinopati) olmak üzere 5 farklı klasöre DR hastalığının derecelerine göre ayrılmıştır. Modellerin eğitim ve test süreçlerinde üç farklı veri kümesi %80 eğitim ve %20 test verisi olarak bölümlenmiştir.

Çizelge 5.1. Literatürde DR hastalığı ile ilgili bazı veri kümesi örnekleri

Veri seti	Yayınlanma Yılı	Örnek Sayısı	Sınıf Sayısı
APTOS 2019	2019	3662	5
ODIR2019	2019	5814	8
Messidor	2014	1200	4
Messidor-2	2018	1748	5
IDRID	2018	516	5


Bu veriler, görüntü boyutları ve çözünürlük açısından genişlik ve yükseklikte 474 x 358 ila 3388 x 2588 piksel arasında ve tüm resimler “png” formatındadır. APTOS 2019 veri seti, farklı kamera türleri kullanılarak birden fazla klinikten toplanan 3662 retinal görüntüyü içerir.

No DR, Mild, Moderate, Severe ve Proliferative DR sınıflarında sırasıyla toplam 1805, 370, 999, 193 ve 295 görüntü bulunmaktadır. Her bir sınıf içerisinde yer alan DR sınıf sayıları ve dağılım yüzdesi Çizelge 5.2’de verilmiştir.

Çizelge 5.2. Görüntü sayısı ve sınıfları


Sınıf	Görüntü Sayısı	Yüzde (%)
No DR	1805	49,29
Mild	370	10,10
Moderate	999	27,28
Severe	193	5,27
Proliferative DR	295	8,06
Toplam	3662	100

Ayrıca DR veri kümesinde bulunan sınıfların sayıları ve sınıflara göre dağılımı gösteren sütun grafiği Şekil 5.1’de gösterilmektedir.




Şekil 5.1. Sınıflara göre dağılım sütun grafiği

Tez çalışmasında veri kümesi olarak DR veri setinde yer alan her sınıftaki tüm görüntüler herhangi bir filtreleme uygulanmadan 224x224x3 boyutlarında ayarlanmak üzere ön işleminden geçirilmiştir. Filtresiz DR veri setinde yer alan beş farklı sınıfa ait örnek görüntüler Şekil 5.2’de görülmektedir.




Şekil 5.2. Filtre uygulanmamış DR veri kümesi

Ön işlemeden geçen filtresiz görüntüler üzerine yeni bir veri kümesi oluşturmak için Gaussian filtre uygulanmıştır. Her bir sınıfa ait 2224x224x3 boyutlarındaki Gaussian filtreli görüntüler Şekil 5.3'te verilmiştir.



Şekil 5.3. Gaussian filtre uygulanmamış DR veri kümesi

Filtresiz DR hastalığına ait görüntülere, Grayscale filtreleme işlemi uygulanarak 224x224x3 boyutlarındaki yeni veri kümesine ait görüntüler oluşturulmuştur. Grayscale filtreli DR hastalığına ait ve beş farklı sınıfta bulunan örnek görüntüler Şekil 5.4'te gösterilmektedir.



Şekil 5.4. Grayscale filtre uygulanmamış DR veri kümesi

5.2. Uygulama Ortamı ve Kütüphane

ESA modellerinin eğitimi ve test değerlendirme süreçleri Intel I9 12200X 12 Core işlemci, 64 GB RAM ve 24 GB NVIDIA RTX ekran kartlı makinede GPU hızlandırılması ile gerçekleştirilmiştir. Çalışma Python programlama dili kullanılarak kodlanmıştır. Python programlama dilinde varsayılan kütüphaneler dışında; numpy, pandas, matplotlib, openCV, tensorflow, keras, sklearn, imblearn, yellowbrick gibi kütüphaneler kullanılmıştır.


5.3. Görüntü Ön İşleme

Görüntü ön işleme, görüntü tabanlı ESA uygulamalarında ham görüntü verilerini kullanılabilir ve anlamlı bir biçime dönüştürme sürecidir. Görüntü veri kümelerindeki istenmeyen bozulmaların ortadan kaldırılmasına ve bilgisayarlı görüş uygulamaları için gerekli olan belirli niteliklerin geliştirilmesine olanak tanır. Ön işleme, görüntü verilerinizi ESA modellerine aktarmadan önce hazırlamak için önemli bir ilk adımdır. ESA modellerinin geliştirilmesi için görüntü tabanlı veri setlerinde veri ön işleme aşamasında özellikle openCV kütüphanelerinde birçok ön işleme filtresi yer almaktadır (Bhattacharyya, 2011).

5.3.1. Gürültü Azaltma

Bir görüntü verisinde gürültü; düşük ışık, sensör gürültüsü ve sıkıştırma kaynakları gibi çeşitli faktörlerden kaynaklanabilmektedir. Bu gürültü sorunları için gürültü azaltma teknikleri uygulanır ve görüntünün temel özelliklerini korurken gürültüyü giderme


amaçlanır. Gürültü azaltma teknikleri içerisinde özellikle ESA modellerinde Gauss yumuşatma, medyan filtreleme ve dalgacık gürültüsü giderme teknikleri yaygın tercih edilir (Şekil 5.5) (Suhas ve Venugopal, 2017).



Şekil 5.5. Gürültü azaltma filtreleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri

5.3.2. Kontrast Geliştirme

Kontrast geliştirme teknikleri, Şekil 5.6’da gösterildiği gibi bir görüntünün kontrastını artırmayı ve farklı görüntü özellikleri arasında ayrım yapmayı kolaylaştırmayı amaçlamaktadır. Bu teknikler, tıbbi görüntüleme ve gözetim gibi uygulamalarda yardımcı olabilir. Yaygın makine öğrenmesi tabanlı uygulamalarda histogram eşitleme, uyarlanabilir histogram eşitleme ve kontrast germe gibi standart kontrast geliştirme teknikleri bulunmaktadır (Perumal ve Velmurugan, 2018).




Şekil 5.6. Kontrast geliştirme filtreleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri

5.3.3. Görüntü Yeniden Boyutlandırma

Görüntü yeniden boyutlandırma teknikleri, Şekil 5.7’de gösterildiği bir görüntünün boyutunu ayarlamak için kullanılır. Yeniden boyutlandırma, bir görüntüyü daha küçük


veya daha büyük yapmak veya en boy oranını deęiřtirmek için yapılabilir. Bazı tipik görüntü yeniden boyutlandırma teknikleri arasında en yakın komřu enterpolasyonu, ikili doęrusal enterpolasyon ve bikübik enterpolasyon bulunur (Sharma vd., 2020).



řekil 5.7. Kontrast geliştirme filtreleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri resim

5.3.4. Gri Ölçekleme

Gri ölçekli görüntüler, řekil 5.8’de gösterildięi gibi siyahtan beyaza kadar yalnızca gri tonlarını içeren görüntülerdir. Bu sonuç her pikselin kırmızı, yeřil ve mavi (RGB) bileřenleri hakkında bilgi içeren renkli görüntülerin tersidir. Gri ölçekli görüntüler, renkli görüntülere göre işlenmeleri daha kolay olduęu için genellikle bilgisayarla görme uygulamalarında kullanılır (Singh vd., 2022).



řekil 5.8. Gri ölçek filtreleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri resim

5.3.5. Segmentasyon

Segmentasyon teknikleri, bir görüntüyü içerięine göre bölgelere ayırmak için kullanılır. Segmentasyon, belirli yapıların veya organların görüntüden izole edilmesi


gereken tıbbi görüntüleme gibi uygulamalarda yardımcı olabilir (Şekil 5.9). Bazı standart segmentasyon teknikleri arasında eşikleme, kenar algılama ve bölge büyütme bulunur (Bhattacharyya, 2011).



Şekil 5.9. Segmentasyon teknikleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri resim

5.3.6. Özellik Çıkarması

Özellik çıkarma teknikleri, Şekil 5.10’da verildiği gibi bir görüntüden ilgili özellikleri belirlemek ve çıkarmak için yaygın kullanılan bir tekniktir. Çıkarılan bu özellikler, nesne tanıma ve görüntü sınıflandırma uygulamalarında kullanılmaktadır. Bazı standart özellik çıkarma teknikleri arasında kenar algılama, köşe algılama ve doku analizi bulunmaktadır (Remeseiro ve Bolon-Canedo, 2019).



Şekil 5.10. Özellik çıkarma teknikleri uygulanmış örnek DR hastalığına ait orijinal resim ve ön işlemleri resim

5.4. Transfer Öğrenme

Belirli bir amaç için oluşturulan modellerin başka amaçlar için kullanılma olanağı sunan makine öğrenimi algoritmalarına yönelik bir optimizasyon yöntemidir. Verilerin basit bir şekilde bir modelden diğerine aktarımının ötesinde, verilerin boyutu ne olursa olsun aktarılabilme kolaylığı sağlar (Parkavi vd., 2023). Transfer öğrenme, genel olarak daha önceden öğrenilen süreçten yararlanmaktadır. Bu sayede önceki modellerden elde edilen ağırlık ve özellikler yeni modellerin daha kolay ve hızlı eğitilmesini sağlar. Örnek olarak, basketbol oynamayı bilen biri hentbol öğrenmek için eğitim aldığı anda mevcut spor oyunları bilgisini hentbol öğrenme sürecinde kullanarak ve daha hızlı öğrenme gerçekleştirecektir. Benzer şekilde de bir hastalık tanıma ve sınıflandırma modeli çok hızlı şekilde başka bir hastalığı tanıma ve sınıflandırma için kullanılabilir. Transfer öğrenme esnasında ilk katman ve son tamamen bağlı katmanla birlikte ağız tümüne ince bir ayar yapılır veya onun tamamı üzerinden sıfırdan eğitimler gerçekleştirilir. Transfer öğrenme ile oluşturulan model üzerinde güncelleme yapmak ve eğitmek, genellikle sıfırdan oluşturulmuş bir modeli eğitmekten daha kolay ve hızlıdır. Günümüzde çoğu sınıflandırma işlemlerinde farklı bir problemi çözmek için bir ağız tarafından belirli bir problem üzerinde öğrenilen modele ait özellikler kullanılmaktadır. Burada amaç önceden öğrenilen bir model üzerindeki bilginin yeniden kullanılmasıdır. Sınırlı bir eğitim veri kümesine sahip veri seti varlığında veya zaman ve hesaplama kaynağı gibi maliyetlerden tasarruf etmek için transfer öğrenmeyi kullanmak faydalıdır. Daha öncesinde ImageNet gibi çok büyük bir veri kümesinde önceden eğitilmiş modellerin elde edilen ağırlıkları yeni bir modelin ağız yapısında kullanılmaktadır. Bu sayede araştırmacılar çalışmaları için kullandıkları önceden eğitilmiş modeller sayesinde araştırmalarını hızlandırabileceklerdir. Transfer öğrenme tekniği ile büyük bir veri kümesi ile daha öncesinde eğitilmiş olan modellerdeki ağırlıkların birçok bilgiyi barındırması ve bu öğrenilmiş bilgilerin daha küçük bir veri kümesinde kullanılması ile model eğitiminin daha hızlı olacak ve önceden eğitilmiş modellere yeni tam bağlantılı katmanlar eklenmesiyle modelin daha iyi başarılı sonuç göstermesi sağlanmış olacaktır (Sajana vd., 2021).

Literatürdeki DR sınıflandırma çalışmalarında yaygın olarak fundus görüntülerinin ve yöntem olarak da transfer öğrenme modelinin kullanıldığı görülmektedir (Erciyas, 2022). DR hastalığı sınıflandırılması için kurgulanan model performansının iyileştirilmesi, daha yüksek bir tanıma ve tahmin doğruluğuna ulaşılması ve hesaplama

maliyetinin düşürülmesi için transfer öğrenme yöntemi kullanılması avantaj sağlamaktadır. Böylece verileri baştan eğitim sürecine alma, hesaplama süresinin uzun sürmesi, güçlü CPU ve GPU özelliklerine sahip bilgisayarlara duyulan ihtiyaç, modeli sıfırdan eğitime, genelleştirme ve aşırı öğrenmeye yatkınlık konularında avantaj elde edilmiş olunur.

Transfer öğrenme uygulamalarında kullanılan modeller önceden eğitilmiş ağırlıklara sahip olan derin öğrenme modelleridir. Bu modeller görüntü tabanlı birçok veri seti üzerinden özellik çıkarma ve ince ayar işlemleri uygulanarak sınıflandırma görevleri için kullanılmaktadır. Gerçekleştirilen tez çalışmasında kullanılan MobileNet, MobileNetV2, DenseNet169, NasNetLarge, Resnet101V2 ve Resnet152V2 modellerine ait bilgiler Çizelge 5.3'te verilmiştir.

Çizelge 5.3'te kullanılan önceden eğitilmiş modellerin ImageNet veri seti üzerindeki skorları karşılaştırılmaktadır. İlk 1 ve ilk 5 doğruluk, modelin ImageNet doğrulama veri kümesindeki performansını göstermektedir. Derinlik, ağız topolojik derinliğini göstermektedir. CPU ve GPU süreleri ise modellerin işlemleri gerçekleştirmek için bu birimler üzerinde ne kadar süre harcadığını ifade etmektedir. Tablodaki değerler incelendiğinde, MobilNet ve MobilNetV2 düşük boyut ve hızlı çalışma özelliğine sahipken, DenseNet169 ve ResNet modellerinin daha yüksek doğruluk oranlarına sahip olduğu görülmektedir. Altı model arasında en yüksek doğruluk oranına sahip olan NasNetLarge ise en büyük boyut ve en uzun çalışma süresine de sahiptir.

Çizelge 5.3. Çalışmada kullanılan ESA tabanlı modellerin performans karşılaştırmaları (Keras, 2024).

Model	Boyut (MB)	İlk-1 Doğruluk (%)	İlk-5 Doğruluk (%)	Parametre Sayısı (milyon)	Derinlik	CPU süre (ms)	GPU süre (ms)
MobileNet	16	70,4	89,5	4,3	55	22,6	3,4
MobileNetV2	14	71,3	90,1	3,5	105	25,9	3,8
DenseNet169	57	76,2	93,2	14,3	338	96,4	6,3
NasNetLarge	343	82,5	96,0	88,9	533	344,5	20,0
Resnet101V2	171	77,2	93,8	44,7	205	72,7	5,4
Resnet152V2	232	78,0	94,2	60,4	307	107,5	6,6

5.5. Transfer Öğrenme Yaklaşımları

Araştırmacılar transfer öğrenmeyi farklı stratejilerde kullanırlar. İlk yaklaşımda, CNN'in önceden eğitilmiş katmanları, tamamen bağlı katmanların kaldırılması ve bir

sınıflandırıcı katmanının eklenmesiyle özellik çıkarıcı olarak kullanılır. İkinci strateji, tamamen bağlı katmanları kaldırarak ve gerekli göreve dayalı olarak uygun bir sınıflandırıcı katmanı ekleyerek tüm ağ ağırlıklarına ince ayar yapar. Üçüncü yaklaşım, tamamen bağlı katmanları kaldırmak, alt katmanları donmuş halde tutarken üst katmanlara ince ayar yapmak ve göreve dayalı bir sınıflandırıcı katman eklemektir. Son yaklaşım mimariyi seçmek ve onu sıfırdan eğitmektir. Yaygın olarak kullanılan önceden eğitilmiş CNN modelleri ResNet, InceptionNet, VGG, DenseNet, GoogleNet, EfcientNet ve AlexNet'dir. Çalışmaların çoğunda sınıflandırma modelinin performansını analiz etmek için farklı mimariler kullanılmıştır. Ancak çok az çalışma tek bir özellik çıkarma ve sınıflandırma mimarisini kullanmaktadır (Dayana ve Emmanuel, 2023).

5.5.1. Ön Eğitilmiş Modelin Sınıflandırıcı Olarak Kullanımı

Önceden eğitilmiş bir model üzerinden bir değişiklik yapılmadığı ve ekstra bir eğitim gerçekleştirilmeden yeni bir veri kümesinin sınıflandırmak için doğrudan kullanılmasıdır. Uygulama esnasında ağ mimarisi ve ağırlıkların indirilerek doğrudan yeni veri kümesi üzerinde kullanılarak sonuçlar elde edilir. Örneğin kedi cinslerinin sınıflandırılmasının yapıldığı bir çalışmada doğru tahminler yapmak için baştan bir model oluşturmak yerine ImageNet veri kümesi üzerinden transfer öğrenme uyguladığımızda ImageNet veri kümesi ile eğitilmiş ağda yüzlerce kedi cinsine ait binlerce kedi etiketli görseller bulunacağından dolayı başarılı sınıflandırma performansı elde etmek kaçınılmazdır (Elegendy, 2020).

5.5.2. Ön Eğitilmiş Modelin Öznitelik Çıkarıcı Olarak Kullanımı

Önceden eğitilmiş modelin öznitelik çıkarımı olarak kullanımı yaklaşımında, önceden eğitilmiş bir modele ait mimari kullanılırken öznitelik çıkarma katmanları dondurulur. Modeldeki sınıflandırma işleminin gerçekleştirildiği katman olan tam bağlı katman kaldırılarak yeni sınıflandırıcı katmanlarımızın eklenmesi ve sadece bu kısım için eğitimler gerçekleştirilir. Bu uygulama sayesinde öğrenilen öznitelik bilgileri yeni modele aktarılmış ve eğitilecek yeni veri kümesine bir sınıflandırıcı eklenerek önceden öğrenilen öznitelik bilgileri yeni veri kümesinde kullanılarak sınıflandırma işlemi gerçekleştirilir (Elegendy, 2020).


5.5.3. İnce Ayar (Fine-Tuning)

Bir evrişimli sinir ağının öğrenilen özelliklerini başka bir evrişimli sinir ağına aktarılmasından önce temel veri seti üzerinde eğitilir ve daha sonra ikinci hedef ağı aktarılır. Öznetelik çıkarma için kullanılan birkaç ağı dondurulması (ağırlıklarının sabit tutulması) ve önceden eğitilmiş modelin hem dondurulmuş katmanlarını hem de yeni eklenen sınıflandırıcı katmanlarını birlikte eğitme sürecidir. Burada öznetelik çıkarma katmanlarını yeniden eğitilmesi durumunda daha yüksek seviyedeki öznetelik temsilleri yeni veri kümesinin sınıflandırılması için daha uygun hale getirilmesinden dolayı ince ayar olarak adlandırılmaktadır. Bu daha önceden eğitilmiş çıktı katmanının, veri kümesindeki sınıf sayısını saklayan diğer başka bir katmanla değiştirilmesi sürecidir (Patel ve Chaware, 2020). Temelde optimize edilmiş ağırlıkları, rastgele ağırlıklarla sıfırdan eğitmek yerine yeni modele uyarlanmış olur (Elegendy, 2020).

5.6. Çalışmada Kullanılan Mimari


Transfer Öğrenme modellerinde sınıflandırma yapmak sadece son katmanda elde edilmek istenilen amaca yönelik değişiklikler yapmaktır. Yani eğitim esnasında belirli katmanları dondururken (ağırlıkları sabit tutma işlemi) diğer katmanları ise modelin performansına yönelik olarak iyileştirme aşamalarından oluşturmaktadır (Sanjana vd, 2021). Bunu yapmadaki temel amaç daha kısa süre içerisinde eğitimi tamamlamak ve daha iyi performans elde etmektir. ESA modellerinin mimari yapıları ve çalışma gerçekleştirilen alanlara göre transfer öğrenme çalışmaları birçok çeşitlilik içermekte olup temel yapı itibarıyla ortak çoğu transfer öğrenme bir dizi adımları takip etmektedir.

Daha küçük ve farklı veri setleri ile daha hızlı ve başarılı performans gösteren sonuçlar alabilmek için ImageNet veri kümesi üzerinde önceden eğitilmiş çok sayıda model literatürde yer almaktadır (Patel ve Chaware, 2020). Gerçekleştirilen tez çalışmasında da transfer öğrenme yöntemi tercih edilmiştir. Şekil 5.11'de uygulanan transfer öğrenme modelinin blok diyagramı verilmiştir. Büyük boyuttaki ImageNet veri seti üzerinde eğitilen modeller hesaplanan ağırlıkları ile transfer edilip arkasında uygun bir sınıflandırma katmanı eklenerek çalışmada kullanılan mimari kurgulanmıştır.



Şekil 5.11. Transfer öğrenme diyagramı

DR veri kümesi kullanılarak beş farklı sınıflandırılma işleminin gerçekleştirildiği çalışmanın akış diyagramı Şekil 5.12’de verilmiştir. Görüntü özelliklerinin çıkarımı için ImageNet veri seti üzerinde eğitilen ağırlıkların transferi ile ResNet151V2, ResNet101V2, MobileNet, MobileNetV2, DenseNet169 ve NasNetLarge modelleri kullanılmıştır. Her bir modelden sonra özdeş sınıflandırma katmanları eklenmiştir. Eklenen sınıflandırma katmanlarının özeti Şekil 5.12’de görülmektedir. APTOS 2019 DR veri kümesinde bulunan görüntülerin boyutları 474 x 358 ila 3388 x 2588 piksel arasında değişmektedir. İlk aşamada tüm görüntüler, kullanılan mimariler üzerinde işlenmeye uygun 224x224x3 boyutlarına getirilmiştir. Toplam 5 farklı sınıfta 3662 adet görüntüden oluşan APTOS 2019 veri seti üzerine Gaussian ve Grayscale olmak üzere iki ayrı filtre uygulanarak orijinal filtresiz veri setinin türevlerinden oluşan iki ayrı veri seti daha oluşturulmuştur. Her bir veri kümesi için ayrı ayrı altı ESA modeli için transfer öğrenme ile ImageNet veri setine ait sınıflandırma ağırlıklarının transfer edilmiştir. Son olarak çalışmaya üç yeni tam bağlı katman uygulanmıştır. Bu tam bağlı katmanlardan iki tanesinde aktivasyon fonksiyonu olarak ReLU aktivasyon fonksiyonu, diğerinde ise Sigmoid aktivasyon fonksiyonu kullanılmıştır. Sınıflandırma işlemini gerçekleştirmek için de çıktı katmanında Softmax aktivasyon fonksiyonu kullanılarak beş sınıflandırma işlemi gerçekleştirilmiştir. DR hastalığı tahmini için beş sınıflandırma türüne ait performans değerlendirme metrikleri hesaplanmış ve her bir sınıflandırma işleminin doğruluk ve hata grafikleri oluşturulmuştur. Sınıflandırma işlemlerinin performanslarını karşılaştırmak için karışıklık matrisleri oluşturulmuş ve matris üzerinden elde edilen doğruluk, kesinlik, duyarlılık ve F1 skor değerleri raporlanmıştır.



Şekil 5.12. Önerilen fine-tuning modeli


6. ARAŞTIRMA BULGULARI VE TARTIŞMA

6.1. Model Sonuçlarının Değerlendirilmesi

DR'nin, hastaların yaşam kalitesi üzerindeki doğrudan etkisinin olmasının yanında, sağlık sistemleri pazarı üzerinde de önemli bir ekonomik etkisi bulunmaktadır. DR, 20 ila 74 yaş arası kişilerde gözlemlenen körlüğün en yaygın nedeni arasındadır. Bu yaş aralığı dikkate alındığında DR'den etkilenen kişi sayısı oldukça fazladır. Dünya Diyabet Vakfı raporunda, 2030 yılında yaklaşık olarak 191 milyon kişi DR hastası olacağı belirtilmektedir (Attia vd., 2020). Diyabet hastalarının sayısındaki artış, yaşlı nüfustaki artış, diyabetle ilişkili körlük teşhislerindeki artış ve hastanın yaşam kalitesini etkilememek için erken teşhise daha fazla odaklanması ekonomik olarak da piyasayı bu alana yönlendirmektedir. Yeni teknolojik gelişmelerle birlikte göz tedavilerinde kullanılan ve hızlı iyileşme sağlayan lazer prosedürleri ulaşılabilir hale gelmesiyle birlikte, hastaların cerrahi uygulamalara yönelmelerinde artış beklenmektedir. Ayrıca, göz tedavisinde kullanılan yeni oftalmik cihazlar ve sistemler, teşhis ve cerrahi prosedürlerinde kolaylık sağlamaktadır. Bundan dolayı da bu durum cihazların ve sistemlerin endüstrinin ve pazar hacminin büyümesine yardımcı olmuştur. Küresel diyabetik retinopati pazarına bakıldığında DR pazarının, 2023-2032 tahmin dönemi boyunca %6,4'lük bir bileşik büyüme oranı artış göstermesi ve 6,7 milyar ABD dolarına ulaşması öngörülmektedir (Marketsource, 2024). Hem hastanın yaşam kalitesi hem de pazardaki önemi dikkate alındığında DR hastalığının erken evrede başarılı bir şekilde teşhis edilmesi ve tedavinin hızlı ve prosedürlere uygun olarak gerçekleştirilmesi önemlidir.


Gerçekleştirilen tez çalışmasında, DR hastalığının erken teşhisi için ResNet151v2, ResNet101v2, MobileNet, MobileNetV2, Dense169 ve NasNetLarge mimarileri kullanılarak optimum doğruluk değerlerinin elde edilmesini sağlayan bir yaklaşım sunulmuştur. Kullanılan modeller ham veri seti, aynı veri setinin Gaussian filtreli formu ve Grayscale filtreli formundan oluşan 3 ayrı küme üzerinde eğitilerek test edilmiştir. Modellerin eğitim sürecinde eğitim tekrar sayısı olan epoch başlangıçta 100 olarak girilmiş ve elde edilen sonuçlarda yaklaşık 45. epoch sonrası maksimum doğruluk ve minimum loss değeri sağlanmıştır. Bu yüzden eğitim modellerine ait grafiklerdeki sonuçların gösterimi doğruluğun ve loss'un değişmediğini de göstermek için epoch=60 olarak seçilmiştir.

Şekil 6.1’de filtresiz veri kümesi kullanılarak ResNet152V2 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 6587,08 saniye sürmüştür. ResNet152V2 modelden eğitim süreci sonunda doğruluk değeri 0,9898 ve hata ise 0,0133 olarak elde edilmiştir. ResNet152V2 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.




Şekil 6.1. ResNet152V2 modelinin filtresiz veri kümesi üzerindeki performans grafikleri

Şekil 6.2.’de filtresiz veri kümesi kullanılarak ResNet101V2 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 4479,13 saniye sürmüştür. ResNet101V2 modelden eğitim süreci sonunda doğruluk değeri 0,9898 ve hata ise 0,0151 olarak elde edilmiştir. ResNet101V2 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.



Şekil 6.2. ResNet101V2 modelinin filtresiz veri kümesi üzerindeki performans grafikleri


Şekil 6.3'te filtresiz veri kümesi kullanılarak MobileNet modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 1148,78 saniye sürmüştür. MobileNet modelden eğitim süreci sonunda doğruluk değeri 0,9822 ve hata ise 0,0393 olarak elde edilmiştir. MobileNet modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.



Şekil 6.3. MobileNet modelinin filtresiz veri kümesi üzerindeki performans grafikleri


Şekil 6.4'te filtresiz veri kümesi kullanılarak MobileNetV2 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 1355,99 saniye sürmüştür. MobileNetV2 modelden eğitim süreci sonunda doğruluk değeri 0,9795 ve hata ise 0,0247 olarak elde edilmiştir. MobileNetV2 modelinin ilk

eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.




Şekil 6.4. MobileNetV2 modelinin filtresiz veri kümesi üzerindeki performans grafikleri

Şekil 6.5'te filtresiz veri kümesi kullanılarak DenseNet169 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 4385,99 saniye sürmüştür. DenseNet169 modelden eğitim süreci sonunda doğruluk değeri 0,9890 ve hata ise 0,0292 olarak elde edilmiştir. DenseNet169 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.



Şekil 6.5. DenseNet169 modelinin filtresiz veri kümesi üzerindeki performans grafikleri


Şekil 6.6’de filtresiz veri kümesi kullanılarak NasNetLarge modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 10719,13 saniye sürmüştür. NasNetLarge modelden eğitim süreci sonunda doğruluk değeri 0,9716 ve hata ise 0,0765 olarak elde edilmiştir. NasNetLarge modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.



Şekil 6.6. NasNetLarge modelinin filtresiz veri kümesi üzerindeki performans grafikleri

Tez çalışması içerisinde DR hastalığının teşhisi için kullanılan beş modelin eğitim performansını değerlendirdikten sonra veri kümesindeki beş sınıf için ayrı ayrı performanslarını değerlendirmek için her modelin karışıklık matrisi oluşturulmuştur. Yine bu beş model için beş sınıflandırma filtresiz veri kümelerinde ayrı ayrı test edilerek yorumlanmıştır.


Şekil 6.7’deki karışıklık matrisinde ResNet152V2 modelinin filtresiz veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %98,28, Moderate: %97,44, No_DR: %98,56, Prolidetre_DR: %97,78 ve Severe: %97,62 doğruluk oranları elde edilmiştir. ResNet152V2 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde en az veri görüntüsü olan Severe sınıfına ait doğruluğun en düşük çıktığı ve veri görüntüsü sayısının en fazla olduğu No_DR sınıfının doğruluğun da en yüksek çıktığı tespit edilmiştir.



Şekil 6.7. ResNet152V2 modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi


Şekil 6.8’deki karışıklık matrisinde ResNet101V2 modelinin filtresiz veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %98,28, Moderate: %98,72, No_DR: %99,04, Prolidetre_DR: %95,56 ve Severe: %100 doğruluk oranları elde edilmiştir. ResNet101V2 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde en az veri görüntüsü olan Severe sınıfına ait doğruluğun en yüksek çıktığı ve veri görüntüsü diğerlerine göre daha az olduğu Prolidetre_DR sınıfının doğruluğun da en düşük çıktığı tespit edilmiştir.

Şekil 6.9’deki karışıklık matrisinde MobileNet modelinin filtresiz veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %98,28, Moderate: %98,72, No_DR: %99,52, Prolidetre_DR: %97,78 ve Severe: %96,49 doğruluk oranları elde edilmiştir.




Şekil 6.8. ResNet101V2 modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi

MobileNet modelinde (Şekil 6.9) yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde en az veri görüntüsü olan Severe sınıfına ait doğruluğun en düşük çıktığı ve veri görüntüsü sayısının en fazla olduğu No_DR sınıfının doğruluğun da en yüksek çıktığı tespit edilmiştir.




Şekil 6.9. MobileNet modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi

Şekil 6.10'daki karışıklık matrisinde MobileNetV2 modelinin filtresiz veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %96,55, Moderate: %98,72, No_DR: %98,56, Prolidetre_DR: %97,78 ve Severe: %97,62 doğruluk oranları elde edilmiştir. MobileNetV2 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Mild sınıfına ait doğruluğun en düşük çıktığı ve Moderate sınıfının doğruluğun da en yüksek çıktığı tespit edilmiştir.




Şekil 6.10. MobileNetV2 modelinin beş sınıflandırmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi

Şekil 6.11'deki karışıklık matrisinde DenseNet169 modelinin filtresiz veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %98,28, Moderate: %98,72, No_DR: %98,56, Prolidetre_DR: %97,78 ve Severe: %98,25 doğruluk oranları elde edilmiştir. DenseNet169 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Prolidetre_DR sınıfına ait doğruluğun en düşük çıktığı ve Moderate sınıfının doğruluğun da en yüksek çıktığı tespit edilmiştir.



Şekil 6.11. DenseNet169 modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi

Şekil 6.12'deki karışıklık matrisinde NasNetLarge modelinin filtresiz veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %98,28, Moderate: %98,08, No_DR: %99,28, Prolidetre_DR:%98,89 ve Severe:%98,25 doğruluk oranları elde edilmiştir. NasNetLarge modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Moderate sınıfına ait doğruluğun en düşük çıktığı ve veri görüntüsü sayısının en fazla olduğu No_DR sınıfının doğruluğun da en yüksek çıktığı tespit edilmiştir.



Şekil 6.12. NasNetLarge modelinin beş sınıflandırılmalı ve filtresiz veri kümesinden elde edilen karışıklık matrisi


Filtresiz veri kümesinin altı farklı model ile yapılan testleri sonucunda elde edilen DN, DP, YN ve YP değerleri üzerinden doğruluk, kesinlik, duyarlılık ve F1 skor metrik değerleri hesaplanmış ve Çizelge 6.1’de verilmiştir. Aynı optimum hiper parametre koşullarında ve aynı veri kümesinde her bir modelin performansı değerlendirildiğinde F1 skor ve doğruluk metrik değeri üzerinden en yüksek doğruluğa NasNetLarge modelinin sahip olduğu görülmektedir.

Çizelge 6.1. 6 modelin filtresiz beş sınıflı veri kümesindeki testlerinden elde edilen doğruluk, kesinlik, duyarlılık ve F1 skor ortalama değerlerinin karşılaştırılması

Model	Filtresiz			
	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
NasNetLarge	0,9876	0,9878	0,9876	0,9896
ResNet101 V2	0,9861	0,9862	0,9861	0,9871
MobileNet	0,9865	0,9867	0,9860	0,9865
DenseNet169	0,9843	0,9847	0,9843	0,9844
ResNet152 V2	0,9814	0,9816	0,9814	0,9819
MobileNet V2	0,9814	0,9822	0,9814	0,9816


Şekil 6.13’te Grayscale filtreli veri kümesi kullanılarak ResNet152V2 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 6628,93 saniye sürmüştür. ResNet152V2 modelden eğitim süreci sonunda

doğruluk değeri 0,9871 ve hata ise 0,0216 olarak elde edilmiştir. ResNet152V2 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.




Şekil 6.13. ResNet152V2 modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri

Şekil 6.14’te Grayscale filtreli veri kümesi kullanılarak ResNet101V2 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 4430,75 saniye sürmüştür. ResNet101V2 modelden eğitim süreci sonunda doğruluk değeri 0,9882 ve hata ise 0,0190 olarak elde edilmiştir. ResNet101V2 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.




Şekil 6.14. ResNet101V2 modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri

Şekil 6.15'te Grayscale filtreli veri kümesi kullanılarak MobileNet modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 1137,70 saniye sürmüştür. MobileNet modelden eğitim süreci sonunda doğruluk değeri 0,9693 ve hata ise 0,0745 olarak elde edilmiştir. MobileNet modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.



Şekil 6.15. MobileNet modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri


Şekil 6.16'da Grayscale filtreli veri kümesi kullanılarak MobileNetV2 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 1355,99 saniye sürmüştür.



Şekil 6.16. MobileNetV2 modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri


MobileNetV2 (Şekil 6.16) modelden eğitim süreci sonunda doğruluk değeri 0,9765 ve hata ise 0,0395 olarak elde edilmiştir. MobileNetV2 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.

Şekil 6.17’de Grayscale filtreli veri kümesi kullanılarak DenseNet169 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 4338,52 saniye sürmüştür. DenseNet169 modelden eğitim süreci sonunda doğruluk değeri 0,9765 ve hata ise 0,0602 olarak elde edilmiştir. DenseNet169 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.



Şekil 6.17. DenseNet169 modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri


Şekil 6.6’de Grayscale filtreli veri kümesi kullanılarak NasNetLarge modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 10693,20 saniye sürmüştür. NasNetLarge modelden eğitim süreci sonunda doğruluk değeri 0,9829 ve hata ise 0,0499 olarak elde edilmiştir. NasNetLarge modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.



Şekil 6.18. NasNetLarge modelinin Grayscale filtreli veri kümesi üzerindeki performans grafikleri

Tez çalışması içerisinde DR hastalığının teşhisi için kullanılan altı modelin eğitim performansını değerlendirdikten sonra veri kümesindeki beş sınıf için ayrı ayrı performanslarını değerlendirmek için her modelin karışıklık matrisi oluşturulmuştur. Yine bu beş model için beş sınıflandırma Grayscale filtreli veri kümelerinde ayrı ayrı test edilerek yorumlanmıştır.


Şekil 6.19'daki karışıklık matrisinde ResNet152V2 modelinin Grayscale filtreli veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %96,64, Moderate: %98,57, No_DR: %99,26, Prolidetre_DR: %99,14 ve Severe: %98,63 doğruluk oranları elde edilmiştir. ResNet152V2 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Mild sınıfına ait doğruluğun en düşük çıktığı ve veri görüntüsü sayısının en fazla olduğu No_DR sınıfının doğruluğun da en yüksek çıktığı tespit edilmiştir.



Şekil 6.19. ResNet152V2 modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi


Şekil 6.20'deki karışıklık matrisinde ResNet101V2 modelinin Grayscale veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %97,50, Moderate: %98,72, No_DR: %99,53, Prolidetre_DR: %97,53 ve Severe: %95,45 doğruluk oranları elde edilmiştir. ResNet101V2 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde en az veri görüntüsü olan Severe sınıfına ait doğruluğun en düşük çıktığı ve veri görüntüsü en yüksek olduğu No_DR sınıfının doğruluğun da en yüksek çıktığı tespit edilmiştir.

Şekil 6.21'deki karışıklık matrisinde MobileNet modelinin Grayscale veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %97,50, Moderate: %100, No_DR: %99,07, Prolidetre_DR: %97,78 ve Severe: %100 doğruluk oranları elde edilmiştir.




Şekil 6.20. ResNet101V2 modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi

MobileNet modelinde (Şekil 6.21) yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Prolidetre_DR sınıfına ait doğruluğun en düşük çıktığı ve No_DR ve Severe sınıflarının doğruluğun da en yüksek çıktığı tespit edilmiştir.




Şekil 6.21. MobileNet modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi

Şekil 6.22'deki karışıklık matrisinde MobileNetV2 modelinin Grayscale veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %100, Moderate: %100, No_DR: %99,07, Prolidtare_DR: %97,78 ve Severe: %100 doğruluk oranları elde edilmiştir. MobileNetV2 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Mild, Moderate ve Severe sınıflarına ait doğruluğun en yüksek çıktığı ve Prolidtare_DR sınıfının doğruluğun da en düşük çıktığı tespit edilmiştir.




Şekil 6.22. MobileNetV2 modelinin beş sınıflandırmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi

Şekil 6.23'teki karışıklık matrisinde DenseNet169 modelinin Grayscale veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %95, Moderate: %97,44, No_DR: %97,66, Prolidtare_DR: %95,56 ve Severe: %95,45 doğruluk oranları elde edilmiştir. DenseNet169 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Mild sınıfına ait doğruluğun en düşük çıktığı ve veri kümesi sayısının en fazla olduğu No_DR sınıfının doğruluğun da en yüksek çıktığı tespit edilmiştir.



Şekil 6.23. DenseNet169 modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi

Şekil 6.24'teki karışıklık matrisinde NasNetLarge modelinin Grayscale veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %100, Moderate: %98,72, No_DR: %99,04, Prolidetre_DR: %100 ve Severe: %96,30 doğruluk oranları elde edilmiştir. NasNetLarge modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Severe sınıfına ait doğruluğun en düşük çıktığı ve veri görüntüsü sayısının en fazla olduğu No_DR ve Prolidetre_DR sınıflarının doğruluğun da en yüksek çıktığı tespit edilmiştir.



Şekil 6.24. NasNetLarge modelinin beş sınıflandırılmalı ve Grayscale filtreli veri kümesinden elde edilen karışıklık matrisi


Grayscale filtreli veri kümesinin altı farklı model ile yapılan testleri sonucunda elde edilen DN, DP, YN ve YP değerleri üzerinden doğruluk, kesinlik, duyarlılık ve F1 skor metrik değerleri hesaplanmış ve Çizelge 6.2’de verilmiştir. Aynı optimum hiper parametre koşullarında ve aynı veri kümesinde her bir modelin performansı değerlendirildiğinde F1 skor ve doğruluk metrik değeri üzerinden en yüksek doğruluğa MobileNet V2 modelinin sahip olduğu görülmektedir.

Çizelge 6.2. 6 modelin Grayscale filtreli beş sınıflı veri kümesindeki testlerinden elde edilen doğruluk, kesinlik, duyarlılık ve F1 skor ortalama değerlerinin karşılaştırılması

Model	Grayscale Filtreli			
	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
MobileNet V2	0,9924	0,9925	0,9921	0,9926
NasNetLarge	0,9912	0,9900	0,9899	0,9909
MobileNet	0,9899	0,9903	0,9899	0,9900
ResNet152 V2	0,9875	0,9874	0,9872	0,9875
ResNet101 V2	0,9874	0,9873	0,9872	0,9875
DenseNet169	0,9699	0,9700	0,9672	0,9778


Şekil 6.25’te Gaussian filtreli veri kümesi kullanılarak ResNet152V2 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 6586,24 saniye sürmüştür. ResNet152V2 modelden eğitim süreci sonunda

doğruluk değeri 0,9901 ve hata ise 0,0163 olarak elde edilmiştir. ResNet152V2 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.




Şekil 6.25. ResNet152V2 modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri

Şekil 6.26’de Gaussian filtreli veri kümesi kullanılarak ResNet101V2 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 4457,79 saniye sürmüştür. ResNet101V2 modelden eğitim süreci sonunda doğruluk değeri 0,9890 ve hata ise 0,0118 olarak elde edilmiştir. ResNet101V2 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.




Şekil 6.26. ResNet101V2 modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri

Şekil 6.27’de Gaussian filtreli veri kümesi kullanılarak MobileNet modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 1116,09 saniye sürmüştür. MobileNet modelden eğitim süreci sonunda doğruluk değeri 0,9776 ve hata ise 0,0407 olarak elde edilmiştir. MobileNet modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.




Şekil 6.27. MobileNet modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri

Şekil 6.28’de Gaussian filtreli veri kümesi kullanılarak MobileNetV2 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 1359,73 saniye sürmüştür. MobileNetV2 modelden eğitim süreci sonunda doğruluk değeri 0,9636 ve hata ise 0,1025 olarak elde edilmiştir. MobileNetV2 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.



Şekil 6.28. MobileNetV2 modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri


Şekil 6.29’de Gaussian filtreli veri kümesi kullanılarak DenseNet169 modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 4366,45 saniye sürmüştür. DenseNet169 modelden eğitim süreci sonunda doğruluk değeri 0,9640 ve hata ise 0,0917 olarak elde edilmiştir. DenseNet169 modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.



Şekil 6.29. DenseNet169 modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri

Şekil 6.30’de Gaussian filtreli veri kümesi kullanılarak NasNetLarge modelinin epoch=60 değeri için hata ve doğruluk değişim grafikleri verilmiştir. Eğitim süreci ortalama 10709,20 saniye sürmüştür. NasNetLarge modelden eğitim süreci sonunda

doğruluk değeri 0,9882 ve hata ise 0,0093 olarak elde edilmiştir. NasNetLarge modelinin ilk eğitim turlarında elde edilen sonuçlar düşük olsa da epoch sayısı ilerledikçe modelin performansında istenilen değerlere ulaştığı görülmektedir.



Şekil 6.30. NasNetLarge modelinin Gaussian filtreli veri kümesi üzerindeki performans grafikleri

Tez çalışması içerisinde DR hastalığının teşhisi için kullanılan altı modelin eğitim performansını değerlendirdikten sonra veri kümesindeki beş sınıf için ayrı ayrı performanslarını değerlendirmek için her modelin karışıklık matrisi oluşturulmuştur. Yine bu beş model için beş sınıflandırma Gaussian filtreli veri kümelerinde ayrı ayrı test edilerek yorumlanmıştır.

Şekil 6.31'deki karışıklık matrisinde ResNet152V2 modelinin Gaussian filtreli veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %97,50, Moderate: %100, No_DR: %99,04, Prolidetre_DR: %100 ve Severe: %97,62 doğruluk oranları elde edilmiştir. ResNet152V2 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Mild sınıfına ait doğruluğun en düşük çıktığı ve veri görüntüsü sayısının en fazla olduğu No_DR, Moderate ve Prolidetre_DR sınıflarının doğruluğun da en yüksek çıktığı tespit edilmiştir.




Şekil 6.31. ResNet152V2 modelinin beş sınıflandırmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi

Şekil 6.32'deki karışıklık matrisinde ResNet101V2 modelinin Gaussian veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %97,50, Moderate: %100, No_DR: %97,61, Prolidetre_DR: %100 ve Severe: %97,62 doğruluk oranları elde edilmiştir. ResNet101V2 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Mild sınıfına ait doğruluğun en düşük çıktığı ve veri görüntüsü en yüksek olduğu No_DR ve Prolidetre_DR sınıflarının doğruluğun da en yüksek çıktığı tespit edilmiştir.




Şekil 6.32. ResNet101V2 modelinin beş sınıflandırılmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi

Şekil 6.33'teki karışıklık matrisinde MobileNet modelinin Gaussian veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %97,50, Moderate: %100, No_DR: %98,56, Prolidetre_DR: %100 ve Severe: %97,62 doğruluk oranları elde edilmiştir. MobileNet modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Mild sınıfına ait doğruluğun en düşük çıktığı ve veri görüntüsü en yüksek olduğu Moderate ve Prolidetre_DR sınıflarının doğruluğun da en yüksek çıktığı tespit edilmiştir.



Şekil 6.33. MobileNet modelinin beş sınıflandırılmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi

Şekil 6.34'teki karışıklık matrisinde MobileNetV2 modelinin Gaussian veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %100, Moderate: %100, No_DR: %99,04, Prolidetre_DR: %97,78 ve Severe: %100 doğruluk oranları elde edilmiştir.



Şekil 6.34. MobileNetV2 modelinin beş sınıflandırılmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi

MobileNetV2 modelinde (Şekil 6.34) yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Mild, Moderate ve Severe sınıflarına ait doğruluğun en yüksek çıktığı ve Prolidetare_DR sınıfının doğruluğun da en düşük çıktığı tespit edilmiştir.

Şekil 6.35'teki karışıklık matrisinde DenseNet169 modelinin Gaussian veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %97,50, Moderate: %98,72, No_DR: %99,04, Prolidetare_DR: %100 ve Severe: %97,62 doğruluk oranları elde edilmiştir. DenseNet169 modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde Mild sınıfına ait doğruluğun en düşük çıktığı ve Prolidetare_DR sınıfının doğruluğun da en yüksek çıktığı tespit edilmiştir.



Şekil 6.35. DenseNet169 modelinin beş sınıflandırmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi

Şekil 6.36'daki karışıklık matrisinde NasNetLarge modelinin Gaussian veri kümesi içerisinde beş farklı DR hastalığı durumunu sınıflandırdığı sonuçları gösterilmiştir. Buna göre sırasıyla Mild: %98,28, Moderate: %100, No_DR: %99,04, Prolidetare_DR: %100 ve Severe: %100 doğruluk oranları elde edilmiştir. NasNetLarge modelinde yanlış sınıflandırmaların daha çok DR hastalığına ait beş sınıfta hastalık görüntülerinin birbirine çok yakın olduğu sınıflara daha çok kaydığı görülmektedir. Ayrıca veri kümesi içerisinde

Mild sınıfına ait doğruluğun en düşük çıktığı ve Moderate, Prolidetre_DR ve Severe sınıflarının doğruluğun da en yüksek çıktığı tespit edilmiştir.



Şekil 6.36. NasNetLarge modelinin beş sınıflandırılmalı ve Gaussian filtreli veri kümesinden elde edilen karışıklık matrisi

Gaussian filtreli veri kümesinin altı farklı model ile yapılan testleri sonucunda elde edilen DN, DP, YN ve YP değerleri üzerinden doğruluk, kesinlik, duyarlılık ve F1 skor metrik değerleri hesaplanmış ve Çizelge 6.3'te verilmiştir. Aynı optimum hiper parametre koşullarında ve aynı veri kümesinde her bir modelin performansı değerlendirildiğinde F1 skor ve doğruluk metrik değeri üzerinden en yüksek doğruluğa MobileNet V2 modelinin sahip olduğu görülmektedir.

Çizelge 6.3. Altı modelin Gaussian filtreli beş sınıflı veri kümesindeki testlerinden elde edilen doğruluk, kesinlik, duyarlılık ve F1 skor ortalama değerlerinin karşılaştırılması

Model	Gaussian Filtreli			
	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
MobileNet V2	0,9927	0,9928	0,9943	0,9954
NasNetLarge	0,9930	0,9931	0,9930	0,9944
ResNet152 V2	0,9902	0,9904	0,9900	0,9909
DenseNet169	0,9879	0,9880	0,9883	0,9891
MobileNet	0,9855	0,9862	0,9855	0,9870
ResNet101 V2	0,9830	0,9833	0,9823	0,9830

Çalışma kapsamında DR hastalığının teşhisinde en yüksek doğruluğun elde edilmesi amaçlanmaktadır. Bu doğrultuda veri kümesindeki görüntülere Grayscale ve Gaussian filtresi ekleyerek model eğitimleri gerçekleştirilmiştir. Çizelge 6.4'te üç farklı veri kümesi için en yüksek doğrulukların elde edildiği modeller ve metrik değerleri verilmiştir. Buna göre Gaussian filtreli veri kümesinde Mobile Net V2 modeli DR hastalığının teşhisinde yaklaşık %99,54 doğruluk performansı ile en yüksek sonucu vermektedir. Yine MobileNetV2 Grayscale filtreli veri kümesinde de %99,26 ile en yüksek doğruluğu sağlamıştır. Sonuç olarak DR hastalığının teşhisinde kullanılan veri kümesine uygulanan filtreler modelin doğruluğunu artırmakta ve DR hastalığının teşhisi için veri kümesinde Gaussian filtrenin doğruluk performansı için en iyi seçim olacağı görülmektedir.

Çizelge 6.4. Üç farklı veri kümesi için en yüksek doğruluğun elde edildiği modellerin karşılaştırılması

Model	Filtresiz			
	Doğruluk	Kesinlik	Duyarlılık	F1 Skor
NasNetLarge	0,9876	0,9878	0,9876	0,9896
Grayscale Filtre ile				
MobileNet V2	0,9924	0,9925	0,9921	0,9926
Gaussian Filtre ile				
MobileNet V2	0,9927	0,9928	0,9943	0,9954

6.2. Tartışma

Derin öğrenme modelleri, son yıllarda DR hatalıklarını sınıflandırma görevlerinde başarılı performans göstermiştir. Bununla beraber ESA modelleri ve bu modellerin transfer öğrenme gerçekleştirilerek yeni katmanlar eklenmesi ile oluşturulan yeni modellerin de DR hastalığı için görüntü sınıflandırma görevlerinde başarılı sonuçlar elde edilmiştir (Oltu vd., 2023).

Sahip olunan teknolojik cihazların ve zamanın sınırlı olması nedeniyle model olarak kullanılan ağın öğrenme hızı, veri kümesine göre sınırlılık gösterebilir. Dahası ESA modellerini tıbbi görüntülerin sınıflandırılması çalışmalarında baştan tasarlamak ve eğitmek, zahmetli ve yoğun bir süreçtir. Tıbbi görüntülerin boyutunun ve sayısının büyük olduğu durumlarda bu süreç daha da zorlaşacaktır. Bu durumların üstesinden gelmek için son zamanlarda sınıflandırma çalışmaları için önceden eğitilmiş modelin ağırlıklarının transfer edilmesi yönteminin kullanılması yaygınlaşmıştır (Oltu vd., 2023). Dayana ve Emmanuel, (2023) diyabetik retinopati tespiti ve derecelendirmesi için yaptıkları

kapsamlı literatür çalışmasında 2017 ve 2022 yılları arasında yayınlanan 105 araştırma makalesini incelemişler ve 2017 ve 2022 yılları arasında DR tespiti için yayınlanan 105 araştırma makalesinden 50 tanesinde transfer öğrenmeye dayalı DR sınıflandırma gerçekleştirildiğini belirtmişlerdir. Ayrıca literatürde transfer öğrenme yöntemi ile gerçekleştirilen çalışmalarda daha başarılı sonuçlar elde edildiği görülmüştür (Çizelge 6.5). Bu çalışmamızda kullandığımız 6 ESA modeline (ResNet151v2, ResNet101v2, MobileNet, MobileNetV2, Dense169 ve NasNetLarge) transfer öğrenme yöntemi uygulanmıştır. Çalışmada kullanılan bu 6 ESA modeli seçilmeden önce deneylere 13 model ile başlanmıştır. 13 ESA modeli içerisinde en yüksek doğruluk değeri gösteren 6 model seçilmiştir. Oltu vd., (2023) DR hastalığının sınıflandırılmasında kullanılan transfer öğrenme ile ilgili 2016-2021 yılları arasında yapılmış 43 yayını inceledikleri çalışmada 12 farklı DR veri kümesi kullanılarak çalışma yapıldığı ve 43 yayından sadece dört tanesi APTOS 2019 veri kümesinin kullandığını belirtmiştir. Dayana ve Emmanuel, (2023) fundus görüntüleri ile yapılmış yayınları inceledikleri çalışmalarında 14 farklı DR veri kümesi toplam 153 sınıflandırma çalışmada kullanıldığı ve APTOS veri kümesi bu çalışmalardan sadece 21 tanesinde yer aldığı görülmektedir. Bu 14 farklı veri kümelerinde yer alan fundus görüntülerinden sadece APTOS 2019 veri kümesinin farklı kamera ayarlarından dolayı hem verilerde hem de etiketlerde gürültü ve değişikliklerin olduğunu belirtmişlerdir. Ayrıca çeşitli görüntü işleme uygulamalarında genellikle AlexNet, ResNet, VGGNet, GoogleNet, InceptionNet, XceptionNet, EfcientNet, DenseNet ve MobileNet ESA modellerinin kullanıldığını ve önceden eğitilmiş ESA modellerinden en yaygın kullanılanlarında ResNet, InceptionNet, VGGNet, DenseNet, GoogleNet, EfcientNet, NASNet ve AlexNet olduğunu belirtmişlerdir. Oltu vd, (2023) çalışmalarında 30 farklı ESA modelinin kullanıldığını raporlamışlardır. Bu 30 farklı ESA modelinden 13 tanesi bir kere kullanıldığı görülmektedir. En çok kullanılan ESA modeli ise InceptionV3(20), VGG16(15), AlexNet(12), GoogleNet(10), VGG19(9), ResNet50(9), InceptionResNetV2(9) ve Xception(9) olduğu belirtilmiştir. Diğer kalan 22 model ise üç, iki ve bir kez kullanılmıştır. Bu 30 model incelendiğinde, çalışmamız arasına yer alan modellerden sadece MobileNet(2) ve MobileNetV2(1) yer aldığı görülmektedir. Bu tez çalışmasında da literatürde transfer öğrenme modeli olarak çok kullanılmadığını tespit ettiğimiz ve Keras tarafından yayınlanan ESA tabanlı modellerin performans karşılaştırmalarının yer aldığı çizelgede (Çizelge 5.3) başarılı sonuçlar aldığı görülen farklı ResNet151v2, ResNet101v2, Dense169 ve NasNetLarge modeller tercih

edilmiştir. Oltu vd., (2023) çalışmalarında belirttikleri veri kümeleri arasında toplam kullanma sıralamasında da APTOS 2019 veri kümesi beşinci sırada yer almaktadır. Buna rağmen veri boyutu açısından incelendiğinde APTOS 2019 veri kümesi üçüncü sırada yer aldığı görülmektedir. Literatürde daha az çalışma bulunduğu için APTOS 2019 veri kümesi çalışmamızda kullanılmıştır.

Klinik olarak, erken evre DR ve ileri evre DR sınıfı olmak üzere DR iki sınıfa ayrılır (Dayana ve Emmanuel, 2023). Ancak literatürde yer alan araştırmalarda, DR derecelerini gruplandırarak DR hastalığını ikili, üçlü, dördü ve beşli olmak üzere farklı şekilde sınıflandırıldığı görülmektedir. DR hastalığının tespit edilmesi için yapılan sınıflandırma çalışmalarında veri kümesinin özelliklerine göre literatürde farklı sınıflandırma çalışmaları gerçekleştirildiği görülmüştür. En sık karşılaşılan ve yüksek doğruluk elde edilen sınıflandırma tür sayısı ikidir. Daha sonra en sık karşılaşılan ve veri kümesindeki dengesiz dağılımdan dolayı nispeten daha düşük başarıların elde edildiği beşli sınıflandırmadır. Oltu vd., (2023) DR hastalığı için yapılan sınıflandırma çalışmalarını inceledikleri 43 çalışmada (bazı çalışmalarda birden fazla sınıflandırma işlemi gerçekleştirildiği görülmüştür) 26 ikili, 19 da beşli sınıflandırmayı tercih ettiği görülmüştür. Önerilen tez çalışmasında ise beşli sınıflandırma (No DR, Mild, Modareta, Severe, Proliferate DR) için model yaklaşımı oluşturuldu.

Tıbbi görüntülerin boyutunun ve sayısının fazla olması ve elde edilen görüntülerin bazılarında düzensizlik ve benzerlik sorunlarının üstesinden gelmek için model eğitimlerinden önce veri kümesine bazı ön işleme adımları uygulanır. Ancak ön işleme aşamasını göz ardı etmek veya etkisiz ön işleme gerçekleştirmek DR hastalığı derecelendirmesini olumsuz olarak etkilemektedir (Dayana ve Emmanuel, 2023). Dayana ve Emmanuel (2023) çalışmalarında, literatürde birkaç görüntü ön işleme tekniği olmasına rağmen yalnızca birkaç yazarın, model performansını artırmak için araştırmalarında bunları uyguladığından bahsetmişlerdir. Oltu vd., (2023) inceldikleri çalışmaların çoğunda en ön işleme adımlarının uygulandığını ve bunlardan en çok olanında veri kümesinde bulunan verilerin yeniden boyutlandırılması olduğunu belirtmiştir. Yeniden boyutlandırma işlemi, ESA modellerinin uygulanabilmesi için modele ait giriş boyutlarına ayarlamak önemli bir adımdır. Bu 43 çalışmada kullanılan ön işlem adımları arasında filtreleme yöntemi olarak sadece bir çalışmada Gaussian Smoothing Filter (Gaussian Düzleştirme Filtresi) yöntemi uygulandığı görülmektedir. Literatürdeki diğer çalışmalarda orijinal görüntülere ek olarak filtreli görüntülerin

kullanıldığı benzer çalışmaların eksikliği göze çarpmaktadır. Dayana ve Emmanuel, (2023) diyabetik retinopati tespiti için inceledikleri 105 farklı çalışmanın sadece 63 tanesinde farklı ön işlem tekniklerinin uygulandığı ve bunlardan dokuz tanesinde Grayscale dönüşümü ve yedi tanesinde de Gaussian filtreleme gerçekleştirildiğinden bahsetmişlerdir. Vij ve Arora, (2023) diyabetik retinopati tespiti ile ilgili inceledikleri 115 çalışmada, uygulanan çeşitli veri ön işleme yaklaşımlarını ele almış ve bu çalışmalardan sadece dördünde Gaussian filtre uygulandığı ve iki çalışmada da Grayscale dönüşümü gerçekleştirildiği belirtilmiştir. Gerçekleştirilen tez çalışmasında APTOS 2019 orijinal veri kümesinde yer alan görüntülere Grayscale ve Gaussian filtreleri uygulanarak elde edilen yeni veri kümeleri de orijinalleri ile analize tabi tutuldu. Filtresiz, Grayscale ve Gaussian filtreli olmak üzere üç farklı veri kümesinde görüntü türü üzerinden ResNet151v2, ResNet101v2, MobileNet, MobileNetV2, Dense169 ve NasNetLarge modelleri transfer öğrenme yöntemi kullanılarak eğitilmiş ve sonuçlar elde edilmiştir

Çizelge 6.5'te APTOS 2019 veri seti ve literatürdeki diğer veri setleri kullanılarak gerçekleştirilen çalışmaların skorları yer almaktadır. Bu çalışmada filtersiz ve filtreli görüntüler üzerinde gerçekleştirilen analizlerde en yüksek skor elde edilen modeller de mevcut literatürle karşılaştırmak için çizelgeye eklenmiştir.

Çizelge 6.5. Önerilen modelin literatürdeki çalışmalar ile kıyaslanması

Sıra	Referans	Metot	Doğruluk	F1 Skor
1	Esfahani vd., 2018	Veri arttırımı uygulanmış ResNet34	%86	-
2	Sarki vd., 2019	Veri arttırımı uygulanmış MobileNet MobileNetV2 DenseNet169 ResNet50 NasNetLarge	%58,3 %78,1 %64,2 %81,6 %81,3	-
3	Taufiqurrahman vd., 2020	MobileNETV2-SVM	%85	-
4	Hagos ve Kant 2019	Transfer öğrenme InceptionNetV3	%90,9	-
5	Wang ve Schaefer, 2020	Transfer öğrenme MobileNetV2	%83,27	-
6	Pak vd., 2020	Veri ön işleme uygulanmış, EfficientNetB4	79%	-
7	Li vd., 2022	Veri ön işleme uygulanmış, InceptionV3 ResNet50 DenseNet	%78 %79 %80	-

8	Khalife vd., 2019	AlexNet	%97,9	%95,82
9	Shaban vd., 2020	CNN modeli	%89	-
10	Lazuardi vd., 2020	Veri ön işleme uygulanmış, EfficientNetB4 EfficientNetB5	83,87% 83,89%	-
11	Patel ve Chaware, 2020	Transfer öğrenme MobileNetV2	81%	-
12	Alrubaye, 2024	APTOS 2019 veri kümesi Veri sayısı artırma ResNet50 Densenet201 InceptionV3 CNN Modeli	%82 %82 %80 %90	%66 %68 %64 %70
13	Özçelik ve Altan, 2021	İki boyutlu sinyal işleme VGG-19	%97,8	%97,6
14	Türkmen, 2021	Görüntü işleme uygulanmış EfficientNetB7 (Gaussian) EfficientNetB7 (Clahe)	%85,18 %84,21	%84,98 %84,81
15	Lahmar ve Idri, 2023	Üç farklı veri kümesi MobileNetV2 (APTOS) MobileNetV2 (Kaggle DR) MobileNetV2 (Messidor-2)	%88,80 %84,01 %84,05	%93,53 %80,28 %85,23
16	Mushtag ve Siddiqui, 2021	APTOS 2019 veri kümesi Ön işleme uygulanmış DenseNet169	%95	-
17	Chuzdik vd., 2018	EyePAC veri kümesi ResNetV2	%96,8	-
18	Aldujailı, 2023	İkili sınıflandırma işlemi NasNetLarge CNN Modeli	%92 %99,46	-
19	Türkmen, 2021	EfficientNet (Gauss) EfficientNet (Clahe)	%85,18 %84,21	%84,98 %84,41
20	Abdelmaksoud, 2021	APTOS 2019, DenseNet169 DenseNet121 ResNet50	%96,54 %90,93 %90,93	-
21	Ergün, 2023	APTOS 2019 veri kümesi CNN modeli	%95,55	-
22	Rahman ve Dola, 2021	APTOS 2019 veri kümesi Transfer öğrenme DenseNet169	%96,54	-
23	Dwivedi ve Attry, 2021	APTOS 2019 veri kümesi MobileNetV2	%96,73	%96,73
24	Sanjana vd., 2021	APTOS 2019 veri kümesi Transfer öğrenme MobileNetV2,	%84,75	%83,16
25	Adriman vd., 2021	APTOS 2019 veri kümesi İkili sınıflandırma ResNet34	%96,35	

		DenseNet121 DetNet59	%84,05 %93,99	-
26	Erciyas, 2022	Messidor veri kümesi Görüntü etiketleme Dört sınıflama DenseNet169 MobileNet	%95,3 %87	-
27	Önerilen Çalışma	APTOS 2019 veri kümesi Transfer öğrenme Beşli sınıflandırma Gaussian ve Grayscale filtre ile ön işleme NasNetLarge (Filtresiz) MobileNet V2 (Grayscale) MobileNet V2 (Gaussian)	%98,76 %99,24 %99,27	%98,96 %99,26 %99,54

Çizelge 6.5 incelendiğinde, MobileNetV2 diğer ön eğitilmiş modeller arasında en çok tercih edilen mimari olup, DenseNet169 modeli ve ResNet50 modelleri de en sık kullanılan mimarilerdir. Çizelge 6.5'te verilen doğruluk sonuçlarında transfer öğrenme uygulanan modellerin doğruluk değerlerindeki başarı transfer öğrenme uygulanmayan modellerle elde edilen doğruluk değerlerinden daha yüksek olduğu görülmektedir. Çalışmalarda yüksek başarı elde edilen modellerde beşten daha az sınıflandırma yapıldığı veya model eğitimlerinden önce çeşitli ön işleme işlemlerinin gerçekleştirildiği görülmektedir. Çalışmada kullanılan modeller genel olarak benzer nitelikteki, aynı veri kümesi ve transfer öğrenme yöntemini kullanan çalışmalar ile karşılaştırılmıştır. Tüm bu karşılaştırma parametreleri dikkate alındığında bu tez çalışmasında önerilen modellerde elde edilen doğruluk değerleri ve görüntü işleme ile oluşturulan veri kümesi de dahil üç veri kümesinde en başarılı sonuç elde edilen ESA modellerinin literatürde yer alan benzer çalışmalardan daha başarılı sonuç verdiği görülmektedir. Önerilen bu model, farklı görüntü işleme yöntemleri de dikkate alınarak DR hastalığının sınıflandırılması ve benzer tıbbi görüntülerin öz nitelik çıkarımı ve sınıflandırılmasında uygulanabileceği öngörülmektedir.

Bu çalışmada kullanılan altı ESA modeli, bu modellerin başarı performansını gösteren doğruluk değerleri ile modellerin eğitim süreleri karşılaştırmalı olarak Çizelge 6.6'da gösterilmiştir. Üç farklı veri kümesi için bu değerler süre değerleri kısıdan uzuna doğru olacak şekilde sıralanmıştır. Üç veri kümesi içinde birbirine yaklaşık değerlerin elde edildiği çalışmada, kullanılan modellerin sıralamasının değişmediği görülmektedir. Anca Çizelge 6.6 detaylı incelendiğinde eğitim sürelerinin benze doğruluk gösteren

modeller arasında oldukça ciddi bir fark olduğu görülmektedir. Bu farklılık veri kümesinden bağımsız olarak olduğu dikkat çekmektedir. Örneğin üç veri kümesinde de benzer doğruluk başarısı elde edilen ve en kısa eğitim süresine sahip MobileNet modelinde %98,65-%99,02 arasında doğruluk başarısı elde edilirken, yine üç veri kümesinde de benzer doğruluk başarısı elde edilen ve en uzun eğitim süresine sahip NasNetLarge modelinde %98,76-%99,30 arasında doğruluk başarısı elde edildiği görülmektedir. İki model arasında yaklaşık olarak 10 kat eğitim süresi farkı olduğu görülmektedir. Bu fark daha büyük boyutlara ve sayıya sahip tıbbi görüntülerin sınıflandırılması ve hastalıkların teşhisi düşünüldüğünde dezavantaj olabileceği dikkatlerden kaçmamalıdır.

Çizelge 6.6. Önerilen modellerin doğruluk ve süre karşılaştırılması

Model	Filtresiz		Grayscale		Gaussian	
	Doğruluk (%)	Time (sn)	Doğruluk (%)	Time (sn)	Doğruluk (%)	Time (sn)
MobileNet	98,65	1148,78	98,99	1137,70	99,02	1169,09
MobileNet V2	98,14	1355,99	99,24	1341,62	99,27	1359,73
DenseNet169	98,43	4385,99	96,99	4338,52	98,30	4366,45
ResNet101 V2	98,61	4479,13	98,74	4430,75	98,55	4457,79
ResNet152 V2	98,14	6587,08	98,75	6628,93	98,79	6586,24
NasNetLarge	98,76	10719,13	99,12	10693,20	99,30	10709,70

Keras tarafından yayınlanan ESA tabanlı modellerin performans karşılaştırmalarının yer aldığı Çizelge 5.3 incelendiğinde benzer farkın orda da yer aldığı görülmektedir. Modeller arasındaki eğitim süresindeki bulunan bu fark transfer öğrenme esnasında MobileNet'den veri boyutu ve parametre sayısı bakımından çok daha fazla olan NasNetLarge modelinin eğitim esnasında ağırlıkların transfer edilmesinden kaynaklı olduğu unutulmamalıdır. Ancak model performanslarının karşılaştırıldığı Çizelge 5.3'te en başarılı sonucun NasNetLarge modelinde elde edildiği unutulmamalıdır. Zaman probleminin ve veri boyutunun fazla olmadığı görüntülerin kullanıldığı sınıflandırma ya da hastalık teşhislerinde NasNetLarge modelinin tercih edilmesi bu çalışmada elde edilen sonuçlar ile bir kez daha görülmüştür.

7. SONUÇ VE ÖNERİLER

DR, diyabet hastalığının neden olduğu ve retinadaki kan damarlarının hasar görmesi ile sonucunda ortaya çıkan ve gözde ciddi rahatsızlıklara neden olabilecek diyabet komplikasyonlarından biridir. DR erken evrede teşhis edilmezse körlüğe neden olabilir. DR hastalığının erken evrede tespiti, görme bozukluğunu önüne geçebilir. DR görüntülerinin otomatik bir yöntem ile sınıflandırılması, tıp uzmanlarının teşhis sürecinde kolaylık sağlayabilir ve zaman tasarrufu sağlayarak tıp uzmanlarının daha az yorulmasına ve bu sayede hastalarla geçireceği zaman verimliliğini artırır. Son yıllarda retina görüntülerinin analizi ve sınıflandırılması ile ilgili çalışmalarda makine öğrenme ve derin öğrenme mimarilerinin kullanımının yanında ESA algoritmaları da sıklıkla kullanılmaktadır. Ancak büyük veri kümesine sahip tıbbi görüntülerde, ESA modellerinin eğitimi ve sınıflandırma sürecinde uzun zaman sürelerine ve emek gerektirdiğinden son zamanlarda transfer öğrenme yaklaşımları tercih edilmektedir.

Bu tez çalışmasının amacı DR hastalığının teşhisinde ESA mimarileri kullanılarak en yüksek doğruluğun elde edilmesi için yaklaşım sunmaktır. DR hastalığın ESA modelleri ile tespiti için literatürde çok tercih edilen ve güncel beş sınıflı APTOS 2019 veri seti tercih edilmiştir. Bu doğrultuda herhangi bir ön işlem uygulanmamış veri kümesindeki görüntülere Grayscale ve Gaussian filtresi uygulanarak üç farklı veri kümesi oluşturulmuş ve model eğitimleri gerçekleştirilmiştir. Elde edilen üç farklı veri kümesi, görüntü tabanlı ESA mimarilerinden ResNET152V2, ResNet101V2, MobileNet, MobileNetV2, DenseNet169 ve NASNetLarge ile aynı optimum parametreler ile eğitilmiş ve test sonuçları değerlendirilmiştir. Elde edilen sonuçlar değerlendirildiğinde, orijinal APTOS 2019 veri kümesi üzerindeki eğitimlerde NasNetLarge modeli % 98,96, Grayscale filtreli veri kümesinde MobileNet V2 modeli %99,26 ve Gaussian filtreli model de ise MobileNet V2 % 99,54 ile en yüksek doğruluk değerlerine ulaşmıştır. Orijinal veri kümesine uygulanan filtrelerin sınıflandırma doğruluğunun artmasına katkı sağladığı görülmektedir. Sonuç olarak DR hastalığının teşhisi için Gaussian filtreli veri kümesinde MobileNetV2 modelinin kullanımının hastalık teşhisinde çok yüksek doğruluk ile sınıflandırma yaptığı görülmektedir. Bu çalışma özellikle filtreleme uygulanan görüntülerin sınıflandırılması ile ilgili çalışmalarda transfer öğrenme uygulanan ESA modellerinin daha iyi anlaşılmasına katkıda bulunacaktır. Bu ESA modellerle elde edilen başarılı performanslar, ESA stratejilerinin DR hastalığının doğru

sınıflandırılması ve teşhis edilme potansiyeline ışık tutmaktadır. Ayrıca DR hastalığı görüntülerinin sınıflandırma çalışmalarında yüksek doğruluk ve eğitim için harcanan sürenin daha az olan MobileNet modelinin dikkate alınması ve kullanılması önerilmektedir. Araştırmacılar daha dengeli dağılıma sahip ve daha büyük DR veri kümesi üzerinde, MobileNetV2 ve NasNetLarge modeller için hiper parametre ayarları yapılarak hangi ESA modellerinin daha en iyi performans göstereceği ile ilgili araştırmalar yapılması gerekebilir. Bununla birlikte, diğer ESA modellerin daha büyük ve daha çeşitli veri kümeleri üzerindeki performansını doğrulamanın yanı sıra alternatif modeller üzerinde hem performansı artıracak hem de eğitim süresini azaltmak için daha fazla araştırma yapılması gerekmektedir.



KAYNAKLAR

- Abdelmaksoud, E., El-Sappagh, S., Barakat, S., Abuhmed, T., ve Elmogy, M. (2021). Automatic diabetic retinopathy grading system based on detecting multiple retinal lesions. *IEEE Access*, 9, 15939-15960.
- Adriman, R., Muchtar, K., ve Maulina, N. (2021). Performance evaluation of binary classification of diabetic retinopathy through deep learning techniques using texture feature. *Procedia Computer Science*, 179, 88-94.
- Aggarwal, R., Sounderajah, V., Martin, G., Ting, D. S., Karthikesalingam, A., King, D., ve Darzi, A. (2021). Diagnostic accuracy of deep learning in medical imaging: a systematic review and meta-analysis. *NPJ digital medicine*, 4(1), 65.
- Ajesh, F., ve Abraham, A. (2021). Detection and classification of age-related macular degeneration using integration of densenet169 and convolutional neural network. *In International Conference on Innovations in Bio-Inspired Computing and Applications* (pp. 226-238).
- Akbar, S., Sharif, M., Akram, M. U., Saba, T., Mahmood, T., ve Kolivand, M. (2019). Automated techniques for blood vessels segmentation through fundus retinal images: A review. *Microscopy research and technique*, 82(2), 153-170.
- Akkaya, S., Açıkalın, B., Asilyazıcı, E., Yılmaz, A., Yamiç, M., ve Kocapınar, Y. (2018). Diyabetik Retinopatinin Tanı ve Tedavisi. *The Journal of RetinaveVitreous*, 27(4), 390-401.
- Aksoy, B., ve Salman, O. K. M. (2022). Prediction of Covid-19 disease with Resnet-101 deep learning architecture using Computerized Tomography images. *Türk Doğa ve Fen Dergisi*, 11 (2), 36-42.
- Al-Rimy, B. A. S., Saeed, F., Al-Sarem, M., Albarrak, A. M., ve Qasem, S. N. (2023). An adaptive early stopping technique for DenseNet169-based knee osteoarthritis detection model. *Diagnostics*, 13(11), 1903.
- Alakus, T. B., ve Turkoglu, I. (2020). Comparison of deep learning approaches to predict COVID-19 infection. *Chaos, Solitons and Fractals*, 140, 110120.
- AlDujaili, S. I. H. (2023). *Diabetic Retinopathy Detection Using Ensemble Transfer Deep Learning. (Yüksek Lisans Tezi)*. Karabük Üniversitesi, Lisansüstü Eğitim Enstitüsü, Karabük.
- Alrubaye, M. M. (2024). *Diyabetik Retinopatinin Otomatik Sınıflandırılması için Derin Sinir Ağlarında Ensemble Oylama Yaklaşımının Uygulanması. (Yüksek Lisans Tezi)*. Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Ambady, R., ve Chamukuttan, S. (2008). Early diagnosis and prevention of diabetes in developing countries. *Reviews in Endocrine and Metabolic Disorders*, 9, 193-201.

- Asadollahfardi, G., ve Asadollahfardi, G. (2015). Artificial Neural Network Water Quality Management: Assessment and Interpretation, 77-91.
- Atcı, Ş. Y. (2024). *Shap Görselleştirme Tekniği ve Makine Öğrenmesi Yöntemleri ile Diyabetikretinopatinin Erken Tanı Modellemesi. (Doktora Tezi)*. İstanbul Aydın Üniversitesi, Lisansüstü Eğitim Enstitüsü. İstanbul.
- Attia, A., Akhtar, Z., Akrouf, S., ve Maza, S. (2020). A survey on machine and deep learning for detection of diabetic Retinopathy. *ICTACT Journal on Image and Video Processing*, 11(2), 2337-2344.
- Aykat, Ş., ve Senan, S. (2023). Derin Öğrenme Kullanılarak Fundus Görüntülerinden Katarakt ve Diyabetik Retinopati Tespiti. *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 5(2), 312-324.
- Basha, S. S., Dubey, S. R., Pulabaigari, V., ve Mukherjee, S. (2020). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*, 378, 112-119.
- Bhatia, K., Arora, S., ve Tomar, R. (2016, October). Diagnosis of diabetic retinopathy using machine learning classification algorithm. In *2016 2nd international conference on next generation computing technologies (NGCT)* (pp. 347-351). IEEE.
- Bhattacharyya, S. (2011). A brief survey of color image preprocessing and segmentation techniques. *Journal of Pattern Recognition Research*, 1(1), 120-129.
- Bhulakshmi, D., ve Rajput, D. S. (2024). A systematic review on diabetic retinopathy detection and classification based on deep learning techniques using fundus images. *PeerJ Computer Science*, 10, e1947.
- Bruce, A. *Diabetic Retinopathy*. Erişim adresi <https://www.akbruce.com/instructional> (Son Erişim Tarihi: 10/07/2024)
- Carrera, E. V., González, A., ve Carrera, R. (2017). Automated detection of diabetic retinopathy using SVM. In *2017 IEEE XXIV international conference on electronics, electrical engineering and computing (INTERCON)* (pp. 1-4). IEEE.
- Cavalin, P., ve Oliveira, L. (2019). Confusion matrix-based building of hierarchical classification. In *Progress in Pattern Recognition, Image Analysis, Computer Vision, and Applications: 23rd Iberoamerican Congress, CIARP 2018, Madrid, Spain, November 19-22, 2018, Proceedings 23* (pp. 271-278). Springer International Publishing.
- Chauhan, R., Ghanshala, K. K., ve Joshi, R. C. (2018). Convolutional neural network (CNN) for image detection and recognition. In *2018 first international conference on secure cyber computing and communication (ICSCCC)* (pp. 278-282).

- Cheng, W., Sun, Y., Li, G., Jiang, G., ve Liu, H. (2019). Jointly network: a network based on CNN and RBM for gesture recognition. *Neural Computing and Applications*, 31, 309-323.
- Chudzik, P., Majumdar, S., Caliva, F., Al-Diri, B., ve Hunter, A. (2018). Microaneurysm detection using deep learning and interleaved freezing. In *Medical imaging 2018: image processing* (Vol. 10574, pp. 379-387). SPIE.
- Cichy, R. M., ve Kaiser, D. (2019). Deep neural networks as scientific models. *Trends in cognitive sciences*, 23(4), 305-317.
- Completeeyecare, (2024). *Diabetic Retinopathy*. Erişim adresi <https://completeeyecare.com/diabetic-retinopathy/> (Son Erişim Tarihi: 10/07/2024)
- Cui, Y., Zhou, F., Wang, J., Liu, X., Lin, Y., ve Belongie, S. (2017). Kernel pooling for convolutional neural networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 2921-2930).
- Dayana, A. M., ve Emmanuel, W. S. (2023). A comprehensive review of diabetic retinopathy detection and grading based on deep learning and metaheuristic optimization techniques. *Archives of Computational Methods in Engineering*, 30(7), 4565-4599.
- Dong, K., Zhou, C., Ruan, Y., ve Li, Y. (2020). MobileNetV2 model for image classification. In *2020 2nd International Conference on Information Technology and Computer Application (ITCA)* (pp. 476-480). IEEE.
- Dwivedi, S. A., ve Attry, A. (2021). Juxtaposing deep learning models efficacy for ocular disorder detection of diabetic retinopathy for ophthalmoscopy. In *2021 6th International Conference on Signal Processing, Computing and Control (ISPCC)* (pp. 352-357). IEEE.
- Elgendy, M. (2020). *Deep Learning for Vision Systems*. Simon and Schuster.
- Erciyas, A. (2022). *Diyabetik Retinopati Hastalığının Derin Öğrenme ile Tespit Edilmesi. (Doktora Tezi)*. Gazi Üniversitesi Fen Bilimleri Enstitüsü. Ankara.
- Ergün, Ö. N. (2023). *Diyabet ve Diyabetik Retinopati Teşhisinde Derin Öğrenmeye Dayalı Yaklaşımların Uygulanması. (Yüksek Lisans Tezi)*. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü. İstanbul.
- Esfahani, M. T., Ghaderi, M., ve Kafiye, R. (2018). Classification of diabetic and normal fundus images using new deep learning method. *Leonardo Electron. J. Pract. Technol*, 17(32), 233-248.
- Firdaus, M. H., Utami, E., ve Ariatmanto, D. (2023). Detection And Classification of Citrus Diseases Based on A Combination of Features Using the Densenet-169 Model. *Sinkron: jurnal dan penelitian teknik informatika*, 7(4), 2592-2601.

- Galván, E., ve Mooney, P. (2021). Neuroevolution in deep neural networks: Current trends and future challenges. *IEEE Transactions on Artificial Intelligence*, 2(6), 476-493.
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., ve Webster, D. R. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *jama*, 316(22), 2402-2410.
- Gündoğan, F. Ç. (2024). Gözün Yapısı. <https://gozdoktor.net/gozun-yapisi/> (Son Erişim Tarihi: 05/07/2024)
- Hagos, M. T., ve Kant, S. (2019). Transfer learning-based detection of diabetic retinopathy from small dataset. *arXiv preprint arXiv:1905.07203*.
- Hasanah, S. A., Pravitasari, A. A., Abdullah, A. S., Yulita, I. N., ve Asnawi, M. H. (2023). A deep learning review of resnet architecture for lung disease Identification in CXR Image. *Applied Sciences*, 13(24), 13111.
- Hassan, S. S. A., Bong, D. B., ve Premseenthil, M. (2012). Detection of neovascularization in diabetic retinopathy. *Journal of digital imaging*, 25, 437-444.
- Heo, S., ve Lee, J. H. (2018). Fault detection and classification using artificial neural networks. *IFAC-PapersOnLine*, 51(18), 470-475.
- Heydarian, M., Doyle, T. E., ve Samavi, R. (2022). MLCM: Multi-label confusion matrix. *IEEE Access*, 10, 19083-19095.
- Gotadki, R. (2024). *Diabetic Retinopathy Market*. Erişim adresi <https://www.marketresearchfuture.com/reports/diabetic-retinopathy-market-5792> (Son Erişim Tarihi:15/07/2024.)
- Hu, C. H., Pei, H., Si, X. S., Du, D. B., Pang, Z. N., ve Wang, X. (2019). A prognostic model based on DBN and diffusion process for degrading bearing. *IEEE Transactions on Industrial Electronics*, 67(10), 8767-8777.
- Huynh, H. N., Do, M. T., Huynh, G. T., Tran, A. T., Tran, T. N., City, M., ... ve Le, Q. (2022). Classification of stages diabetic retinopathy using mobilenetv2 model. *Kalpa Publications in Engineering*, 4, 147-157.
- Ikram, A., ve Imran, A. (2023). Review on Detection and Classification of Diabetic Retinopathy using Fundus Images. In *2023 17th International Conference on Open-Source Systems and Technologies (ICOSST)* (pp. 1-5). IEEE.
- İnan, S. (2014). Diabetik Retinopati ve Etiyopatogenezi. *Kocatepe Tıp Dergisi*, 15(2), 207-217.
- Javaid, A., Niyaz, Q., Sun, W., ve Alam, M. (2016). A deep learning approach for network intrusion detection system. In *Proceedings of the 9th EAI International Conference*

on *Bio-inspired Information and Communications Technologies (formerly BIONETICS)* (pp. 21-26).

Joseph, F. J. J., Nonsiri, S., ve Monsakul, A. (2021). Keras and TensorFlow: A hands-on experience. *Advanced deep learning for engineers and scientists: A practical approach*, 85-111.

Kalaiselvi, A., Nagarathinam, S., Paul, T. D., ve Alagumeenaakshi, M. (2021). Detection of autism spectrum disorder using transfer learning. *Turkish Journal of Physiotherapy and Rehabilitation*, 32(2), 926-933.

Kanchanadevi, K., ve Sandhia, G. K. (2023). A comparative survey of maize leaf diseases using pre-trained convolutional neural networks. In *2023 Third International Conference on Advances in Electrical, Computing, Communication and Sustainable Technologies (ICAECT)* (pp. 1-6). IEEE.

Karthik, Maggie, Sohler Dane. (2019). *APTOS 2019 Blindness Detection*. Kaggle. Erişim adresi <https://kaggle.com/competitions/aptos2019-blindness-detection> (Son Erişim Tarihi: 3/6/2024)

Kattenborn, T., Leitloff, J., Schiefer, F., ve Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS journal of photogrammetry and remote sensing*, 173, 24-49.

Keras (2024). *Keras Applications*. Erişim adresi <https://keras.io/api/applications/> (Son Erişim Tarihi: 15/07/2024)

Khalifa, N. E. M., Loey, M., Taha, M. H. N., ve Mohamed, H. N. E. T. (2019). Deep transfer learning models for medical diabetic retinopathy detection. *Acta Informatica Medica*, 27(5), 327.

Khan, A., Khan, M. A., Javed, M. Y., Alhaisoni, M., Tariq, U., Kadry, S., ... ve Nam, Y. (2022). Human Gait Recognition Using Deep Learning and Improved Ant Colony Optimization. *Computers, Materials and Continua*, 70(2).

Lahmar, C., ve Idri, A. (2023). Deep hybrid architectures for diabetic retinopathy classification. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging and Visualization*, 11(2), 166-184.

Lalithadevi, B., ve Krishnaveni, S. (2022). Detection of diabetic retinopathy and related retinal disorders using fundus images based on deep learning and image processing techniques: A comprehensive review. *Concurrency and Computation: Practice and Experience*, 34(19), e7032.

Lazuardi, R. N., Abiwinanda, N., Suryawan, T. H., Hanif, M., ve Handayani, A. (2020). Automatic diabetic retinopathy classification with efficientnet. In *2020 IEEE REGION 10 CONFERENCE (TENCON)* (pp. 756-760). IEEE.

- Li, Y., Hsu, J. S., Bari, N., Qiu, X., Viswanathan, M., Shi, W., ... ve Wang, M. D. (2022). Interpretable evaluation of diabetic retinopathy grade regarding eye color fundus images. *In 2022 IEEE 22nd International Conference on Bioinformatics and Bioengineering (BIBE)* (pp. 11-16). IEEE.
- Lu, J., Tan, L., ve Jiang, H. (2021). Review on convolutional neural network (CNN) applied to plant leaf disease classification. *Agriculture*, 11(8), 707.
- Mahesh, B. (2020). Machine learning algorithms-a review. *International Journal of Science and Research (IJSR)*. 9(1), 381-386.
- Malhotra, A., Minja, F. J., Crum, A., ve Burrowes, D. (2011). Ocular anatomy and cross-sectional imaging of the eye. *In Seminars in Ultrasound, CT and MRI* (Vol. 32, No. 1, pp. 2-13). WB Saunders.
- Math, L., ve Fatima, R. (2021). Adaptive machine learning classification for diabetic retinopathy. *Multimedia Tools and Applications*, 80(4), 5173-5186.
- Mijwil, M. M., Doshi, R., Hiran, K. K., Unogwu, O. J., ve Bala, I. (2023). MobileNetV1-based deep learning model for accurate brain tumor classification. *Mesopotamian Journal of Computer Science*, 2023, 29-38.
- Mushtaq, G., ve Siddiqui, F. (2021). Detection of diabetic retinopathy using deep learning methodology. *In IOP conference series: materials science and engineering* (Vol. 1070, No. 1, p. 012049). IOP Publishing.
- Nandhini Abirami, R., Durai Raj Vincent, P. M., Srinivasan, K., Tariq, U., ve Chang, C. Y. (2021). Deep CNN and Deep GAN in Computational Visual Perception-Driven Image Analysis. *Complexity*, 2021(1), 5541134.
- Needham, C. J., ve Boyle, R. D. (2003). Performance evaluation metrics and statistics for positional tracker evaluation. *In International Conference on Computer Vision Systems* (pp. 278-289). Berlin, Heidelberg: Springer Berlin Heidelberg.
- Oltu, B., Karaca, B. K., Erdem, H., ve Özgür, A. (2021). A systematic review of transfer learning-based approaches for diabetic retinopathy detection. *Gazi University Journal of Science*, 36(3), 1140-1157.
- Özçelik, Y. B., ve Altan, A. (2021). Diyabetik retinopati teşhisi için fundus görüntülerinin derin öğrenme tabanlı sınıflandırılması. *Avrupa Bilim ve Teknoloji Dergisi*, (29), 156-167.
- Pak, A., Ziyaden, A., Tukeshev, K., Jaxylykova, A., ve Abdullina, D. (2020). Comparative analysis of deep learning methods of detection of diabetic retinopathy. *Cogent Engineering*, 7(1), 1805144.
- Parkavi, A., Tiriyar, Y., Borthakur, P. J., Patil, P., ve Haleem, M. B. (2023). Deep learning techniques for the detection and classification of oral cancer using histopathological

- images. *In 2023 international conference on circuit power and computing technologies (ICCPCT)* (pp. 1625-1630). IEEE.
- Patel, R., ve Chaware, A. (2020). Transfer learning with fine-tuned MobileNetV2 for diabetic retinopathy. *In 2020 international conference for emerging technology (INCET)* (pp. 1-4). IEEE.
- Perumal, S., ve Velmurugan, T. (2018). Preprocessing by contrast enhancement techniques for medical images. *International Journal of Pure and Applied Mathematics*, 118(18), 3681-3688.
- Qummar, S., Khan, F. G., Shah, S., Khan, A., Shamshirband, S., Rehman, Z. U., ... ve Jadoon, W. (2019). A deep learning ensemble approach for diabetic retinopathy detection. *IEEE Access*, 7, 150530-150539.
- Rahman, M. T., ve Dola, A. (2021). Automated grading of diabetic retinopathy using densenet-169 architecture. *In 2021 5th International Conference on Electrical Information and Communication Technology (EICT)* (pp. 1-4). IEEE.
- Rai, N., Zhang, Y., Ram, B. G., Schumacher, L., Yellavajjala, R. K., Bajwa, S., ve Sun, X. (2023). Applications of deep learning in precision weed management: A review. *Computers and Electronics in Agriculture*, 206, 107698.
- Rasamoelina, A. D., Adjailia, F., ve Sinčák, P. (2020). A review of activation function for artificial neural network. *In 2020 IEEE 18th World Symposium on Applied Machine Intelligence and Informatics (SAMI)* (pp. 281-286). IEEE.
- Remeseiro, B., ve Bolon-Canedo, V. (2019). A review of feature selection methods in medical applications. *Computers in biology and medicine*, 112, 103375.
- Roy, P., Chisty, M. M. O., ve Fattah, H. A. (2021). Alzheimer's disease diagnosis from MRI images using ResNet-152 Neural Network Architecture. *In 2021 5th International Conference on Electrical Information and Communication Technology (EICT)* (pp. 1-6). IEEE.
- Safi, H., Safi, S., Hafezi-Moghadam, A., ve Ahmadi, H. (2018). Early detection of diabetic retinopathy. *Survey of ophthalmology*, 63(5), 601-608.
- Sanjaya, S. A., ve Rakhmawan, S. A. (2020). Face mask detection using MobileNetV2 in the era of COVID-19 pandemic. *In 2020 International Conference on Data Analytics for Business and Industry: Way Towards a Sustainable Economy (ICDABI)* (pp. 1-5). IEEE.
- Sanjana, S., Shadin, N. S., ve Farzana, M. (2021). Automated diabetic retinopathy detection using transfer learning models. *In 2021 5th International Conference on Electrical Engineering and Information Communication Technology (ICEEICT)* (pp. 1-6). IEEE.

- Sarki, R., Michalska, S., Ahmed, K., Wang, H., ve Zhang, Y. (2019). Convolutional neural networks for mild diabetic retinopathy detection: an experimental study. *bioRxiv*, 763136.
- Shaban, M., Ogur, Z., Mahmoud, A., Switala, A., Shalaby, A., Abu Khalifeh, H., ... ve El-Baz, A. S. (2020). A convolutional neural network for the screening and staging of diabetic retinopathy. *Plos one*, 15(6), e0233514.
- Sharma, P., Hans, P., ve Gupta, S. C. (2020). Classification of plant leaf diseases using machine learning and image preprocessing techniques. *In 2020 10th international conference on cloud computing, data science and engineering (Confluence)* (pp. 480-484). IEEE.
- Shinde, P. P., ve Shah, S. (2018). A review of machine learning and deep learning applications. *In 2018 Fourth international conference on computing communication control and automation (ICCUBEA)* (pp. 1-6). IEEE.
- Singh, A., Gaba, G. S., ve Hedabou, M. (2022). Robust and effective image preprocessing conglomerate method for denoising of both grayscale and color images. *Journal of Electronic Imaging*, 31(4), 041203-041203.
- Smagulova, K., ve James, A. P. (2019). A survey on LSTM memristive neural network architectures and applications. *The European Physical Journal Special Topics*, 228(10), 2313-2324.
- Song, Y., Hu, Z., Li, T., ve Fan, H. (2022). Performance evaluation metrics and approaches for target tracking: A survey. *Sensors*, 22(3), 793.
- Suhas, S., ve Venugopal, C. R. (2017). MRI image preprocessing and noise removal technique using linear and nonlinear filters. *In 2017 International Conference on Electrical, Electronics, Communication, Computer, and Optimization Techniques (ICECCOT)* (pp. 1-4). IEEE.
- Şeker, A., Diri, B., ve Balık, H. H. (2017). Derin öğrenme yöntemleri ve uygulamaları hakkında bir inceleme. *Gazi Mühendislik Bilimleri Dergisi*, 3(3), 47-64.
- Tabian, I., Fu, H., ve Sharif Khodaei, Z. (2019). A convolutional neural network for impact detection and characterization of complex composite structures. *Sensors*, 19(22), 4933.
- Tariq, H., Rashid, M., Javed, A., Zafar, E., Alotaibi, S. S., ve Zia, M. Y. I. (2021). Performance analysis of deep-neural-network-based automatic diagnosis of diabetic retinopathy. *Sensors*, 22(1), 205.
- Taufiqurrahman, S., Handayani, A., Hermanto, B. R., ve Mengko, T. L. E. R. (2020). Diabetic retinopathy classification using a hybrid and efficient MobileNetV2-SVM model. *In 2020 IEEE Region 10 Conference (Tencon)* (pp. 235-240). IEEE.

- Toğaçar, M., Cömert, Z., ve Ergen, B. (2021). Intelligent skin cancer detection applying autoencoder, MobileNetV2 and spiking neural networks. *Chaos, Solitons and Fractals*, 144, 110714.
- Türkmen, A. (2021). *Konvolüsyonel yapay sinir ağları ve görüntü işleme teknikleri ile biyomedikal görüntülerden diyabetik retinopati teşhisi. (Yüksek Lisans Tezi)*. Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Elektrik Elektronik Mühendisliği Anabilim Dalı, Ankara.
- Türkmen, A. (2021). *Konvolüsyonel Yapay Sinir Ağları ve Görüntü İşleme Teknikleri ile Biyomedikal Görüntülerden Diyabetik Retinopati Teşhisi. (Yüksek Lisans Tezi)*. Ankara Üniversitesi, Fen Bilimleri Enstitüsü. Ankara.
- Ünal, E., Akan, O., ve Üçler, S. (2015). Diyabet ve nörolojik hastalıklar. *Okmeydanı Tıp Dergisi*, 31(1), 45-51.
- Venividigöz, 2024. *Göz Hastalıkları*. Erişim adresi <https://venividigoz.com/goz-hastaliklari/oct-optik-koherens-tomografi> (Son Erişim Tarihi: 15/07/2024)
- Vij, R., ve Arora, S. (2023). A systematic review on diabetic retinopathy detection using deep learning techniques. *Archives of Computational Methods in Engineering*, 30(3), 2211-2256.
- Vogels, T. P., Rajan, K., ve Abbott, L. F. (2005). Neural network dynamics. *Annu. Rev. Neurosci.*, 28(1), 357-376.
- Wang, L., ve Schaefer, A. (2020). Diagnosing diabetic retinopathy from images of the eye fundus. cs230.
- Willoughby, C. E., Ponzin, D., Ferrari, S., Lobo, A., Landau, K., ve Omid, Y. (2010). Anatomy and physiology of the human eye: effects of mucopolysaccharidoses disease on structure and function—a review. *Clinical and Experimental Ophthalmology*, 38, 2-11.
- Wu, B., Zhu, W., Shi, F., Zhu, S., ve Chen, X. (2017). Automatic detection of microaneurysms in retinal fundus images. *Computerized Medical Imaging and Graphics*, 55, 106-112.
- Wu, J. H., Liu, T. A., Hsu, W. T., Ho, J. H. C., ve Lee, C. C. (2021). Performance and limitation of machine learning algorithms for diabetic retinopathy screening: meta-analysis. *Journal of medical Internet research*, 23(7), e23863.
- Wu, Y. C., ve Feng, J. W. (2018). Development and application of artificial neural network. *Wireless Personal Communications*, 102, 1645-1656.
- Yin, W., Kann, K., Yu, M., ve Schütze, H. (2017). Comparative study of CNN and RNN for natural language processing. *arXiv preprint arXiv:1702.01923*.

- Yu, D., Wang, H., Chen, P., ve Wei, Z. (2014). Mixed pooling for convolutional neural networks. *In Rough Sets and Knowledge Technology: 9th International Conference, RSKT 2014, Shanghai, China, October 24-26, 2014, Proceedings 9* (pp. 364-375). Springer International Publishing.
- Zafar, A., Aamir, M., Mohd Nawi, N., Arshad, A., Riaz, S., Alruban, A., ... ve Almotairi, S. (2022). A comparison of pooling methods for convolutional neural networks. *Applied Sciences*, 12(17), 8643.
- Zha, W., Liu, Y., Wan, Y., Luo, R., Li, D., Yang, S., ve Xu, Y. (2022). Forecasting monthly gas field production based on the CNN-LSTM model. *Energy*, 260, 124889.
- Zhang, Q. (2022). A novel ResNet101 model based on dense dilated convolution for image classification. *SN Applied Sciences*, 4, 1-13.

