T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

DOKTORA TEZİ

DERİN ÖĞRENME KULLANARAK OPTİK KOHERENS TOMOGRAFİ GÖRÜNTÜLERİNDEN RETİNA HASTALIĞI TESPİTİ

Şükrü AYKAT

DANIŞMAN
Doç. Dr. Sibel SENAN

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

Aralık, 2023

TEZ KABUL VE ONAYI

Şükrü AYKAT tarafından, **Doç. Dr. Sibel SENAN** danışmanlığında hazırlanan ***"DERİN ÖĞRENME KULLANARAK OPTİK KOHERENS TOMOGRAFİ GÖRÜNTÜLERİNDEN RETİNA HASTALIĞI TESPİTİ"*** başlıklı bu çalışma, jürimiz tarafından **18/12/2023** tarihinde yapılan sınav sonucunda **oy birliği** ile başarılı bulunarak **Doktora Tezi** olarak kabul edilmiştir.

Tez Jürisi

		İmza	**Sonuç**
DANIŞMAN	Doç. Dr. Sibel SENAN İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Prof. Dr. Ahmet SERTBAŞ İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Doç. Dr. Selçuk SEVGEN İstanbul Üniversitesi-Cerrahpaşa Bilgisayar Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Doç. Dr. Abidin ÇALIŞKAN Batman Üniversitesi Bilgisayar Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret
ÜYE	Doç. Dr. Neyir ÖZCAN SEMERCİ Bursa Uludağ Üniversitesi Elektrik-Elektronik Mühendisliği Anabilim Dalı		☐ Kabul ☐ Ret

BEYAN

Bu tez çalışmasının kendi çalışmam olduğunu, tezin planlanmasından yazımına kadar bütün aşamalarda etik dışı davranışımın olmadığını, bu tezdeki bütün bilgileri akademik ve bilimsel etik kuralları içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve bu kaynakları da kaynaklar listesine aldığımı, yine bu tezin çalışılması ve yazımı sırasında patent ve telif haklarını ihlal edici bir davranışımın olmadığını ve her türlü hukuki sorumluluğu aldığımı kabul ederim.

Şükrü AYKAT

(İmza)

Aileme, eşim Izgayre'ye, kızım Zeynep'e ve oğlum Fatih Erdem'e ithaf ediyorum.

BÜTÇE DESTEKLERİ

DERİN ÖĞRENME KULLANARAK OPTİK KOHERENS TOMOGRAFİ GÖRÜNTÜLERİNDEN RETİNA HASTALIĞI TESPİTİ

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.

TEŞEKKÜR

Öncelikle doktora dönemi boyunca her zaman yol gösteren, anlayış gösteren, teşvik eden, her adımda desteğini hiç esirgemeyen ve bu tez çalışmamı bitirmemdeki katkılarından dolayı çok değerli hocam Doç. Dr. Sibel Senan'a en derin teşekkürlerimi sunuyorum.

Araştırmalarım süresince yapıcı eleştirileri ve tavsiyeleri ile bilgi ve deneyimlerinden yararlandığım Tez İzleme Komitesi üyeleri Doç. Dr. Selçuk Sevgen ve Doç. Dr. Abidin Çalışkan hocalarıma da en içten saygı ve teşekkürlerimi sunuyorum.

Çalışmamıza veri toplama sürecinde değerli zamanını ayırarak katkı sağlayan Göz Hastalıkları Uzmanı Uzm. Dr. Mehmet Masum Taş'a teşekkür ederim. Tez savunması sürecinde bana çok destek olan yeğenim Enes Öz'e sevgilerimi sunuyorum.

Hem ders döneminde hem de tez sürecinde desteklerinden, anlayışlarından ve sabırlarından dolayı ailem, eşim Izgayre, kızım Zeynep ve oğlum Fatih Erdem'e de sonsuz teşekkürler ediyorum.

Aralık 2023 **Şükrü AYKAT**

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI ..... **ii**
BEYAN ..... **iii**
BÜTÇE DESTEKLERİ ..... **v**
TEŞEKKÜR ..... **vi**
İÇİNDEKİLER ..... **vii**
ŞEKİL LİSTESİ ..... **x**
TABLO LİSTESİ ..... **xii**
SİMGE VE KISALTMA LİSTESİ ..... **xiv**
ÖZET ..... **xvii**
ABSTRACT ..... **xix**
1. GİRİŞ **1**
2. KAVRAMSAL ÇERÇEVE **5**
2.1. GÖZ ANATOMİSİ 5
2.1.1. Retina 5
2.1.2. Sert Tabaka 6
2.1.3. Kornea 6
2.1.4. İris 6
2.1.5. Göz Bebeği 6
2.1.6. Silyer Cisim 6
2.1.7. Lens 6
2.1.8. Vitreus Jeli 7
2.1.9. Koroid (Damar Tabaka) 7
2.1.10. Görme Siniri 7
2.1.11. Sarı Nokta (Makula) ve Fovea 7
2.1.12. Kör Nokta (Optik Disk) 7
2.2. RETİNA HASTALIKLARI 7
2.2.1. Diyabetik Retinopati Hastalığı 8
2.2.2. Yaşa Bağlı Makula Dejenerasyonu Hastalığı 10

2.3. RETİNA GÖRÜNTÜLEME TEKNİKLERİ 13
2.3.1. Fundus Görüntüleme 13
2.3.2. Optik Koherens Tomografisi 14
2.3.3. Floresan Anjiyografi 15
2.3.4. Ultrasonografi 16
2.4. YAPAY ZEKA 17
2.4.1. Makine Öğrenmesi 18
2.4.2. Yapay Sinir Ağı 20
2.4.3. Derin Öğrenme 22
2.4.4. Evrişimli Sinir Ağı 24
2.5. LİTERATÜR ARAŞTIRMASI 27
3. YÖNTEM 36
3.1. VERİ SETİ OLUŞTURMA 36
3.1.1. OKT Görüntülerinin Toplanması 36
3.1.2. Veri Önişleme 37
3.1.3. Veri Arttırma 37
3.2. UCSD OKT VERİ SETİ 39
3.3. DERİN ÖĞRENME MODELLERİ 39
3.3.1. ResNet-50 Modeli 39
3.3.2. DenseNet-201 Modeli 40
3.3.3. Inception-V3 Modeli 41
3.3.4. InceptionResNet-V2 Modeli 42
3.3.5. Xception Modeli 42
3.3.6. MobileNet Modeli 44
3.3.7. EfficientNet Modeli 45
3.4. HİPERPARAMETRE AYARI 46
3.5. ÖNERİLEN HİBRİT MODEL 47
4. BULGULAR 51
4.1. PERFORMANS METRİKLERİ 51
4.2. VERİ SETİ SINIFLANDIRMA SONUÇLARI 52
4.2.1. Veri Seti İçin Derin Öğrenme Modellerinin Sınıflandırma Sonuçları 53
4.2.2. Veri Seti Üzerinde Hiperparametre Ayarlı Derin Öğrenme Modellerinin Sınıflandırma Sonuçları 54
4.3. ÖN İŞLENMİŞ VERİ SETİ SINIFLANDIRMA SONUÇLARI 57
4.3.1. Ön İşlenmiş Veri Seti İçin Derin Öğrenme Modellerinin Sınıflandırma Sonuçları 57

4.3.2. Ön İşlenmiş Veri Seti İçin Hiperparametre Ayarlı Derin Öğrenme Modellerinin Sınıflandırma Sonuçları....59
4.4. GRİ TONLAMALI VERİ SETİ SINIFLANDIRMA SONUÇLARI....61
4.4.1. Gri Tonlamalı Veri Seti İçin Derin Öğrenme Modellerinin Sınıflandırma Sonuçları 61
4.4.2. Gri Tonlamalı Veri Seti İçin Hiperparametre Ayarlı Derin Öğrenme Modellerinin Sınıflandırma Sonuçları....63
4.5. UCSD VERİ SETİ SINIFLANDIRMA SONUÇLARI....66
4.5.1. UCSD Veri Seti İçin Derin Öğrenme Modellerinin Sınıflandırma Sonuçları 66
4.5.2. UCSD Veri Seti İçin Hiperparametre Ayarlı Derin Öğrenme Modellerinin Sınıflandırma Sonuçları....68
5. TARTIŞMA VE SONUÇ....72
KAYNAKLAR....74
İNTİHAL RAPORU İLK SAYFASI....91
ETİK KURUL İZİN YAZISI....92
KURUM İZNİ YAZILARI....93
ÖZGEÇMİŞ....94

ŞEKİL LİSTESİ

Sayfa No

Şekil 2.1: Gözün anatomisi (Gündoğan, 2023). 5
Şekil 2.2: DR aşamaları. 8
Şekil 2.3: DR lezyon türleri. 9
Şekil 2.4: YBMD hastasının OKT görüntüsü. 12
Şekil 2.5: Fundus kamerası (NIDEK AFC-330). 14
Şekil 2.6: OKT görüntüleme sistemi (ZEISS CIRRUS 5000). 15
Şekil 2.7: Floresan anjiyografi sistemi (APS-BER). 16
Şekil 2.8: US görüntüleme sistemi (MEDA MD-2300S). 17
Şekil 2.9: YZ, makine öğrenmesi ve DÖ arasındaki ilişki. 18
Şekil 2.10: Biyolojik nöron taslağı. 21
Şekil 2.11: Yapay nöron mimarisi. 22
Şekil 2.12: Makine öğrenmesi ve derin öğrenme arasındaki fark. 24
Şekil 2.13: Evrişimli sinir ağı (ESA) mimarisi. 24
Şekil 2.14: ESA evrişim işlemi 25
Şekil 2.15: En çok kullanılan aktivasyon fonksiyonlarının grafikleri. 26
Şekil 2.16: ESA maksimum ve ortalama havuzlama işlemleri. 26
Şekil 3.1: ZEISS CIRRUS HD-OCT. 36
Şekil 3.2: Ham veri setine uygulanan maskeler sonrasında oluşan yeni veri seti örnekleri. 37
Şekil 3.3: Bir OKT görüntüsünün veri artırmadan sonra oluşan yeni görüntüleri. 38
Şekil 3.4: ResNet-50 mimarisinin blok diyagramı. 40
Şekil 3.5: Artık ağ blok yapısı. 40
Şekil 3.6: DenseNet-201 mimarisinin blok diyagramı. 41

Şekil 3.7: Inception-V3 mimarisinin blok diyagramı. 41
Şekil 3.8: InceptionResNet-V2 mimarisinin blok diyagramı. 42
Şekil 3.9: Xception mimarisinin blok diyagramı..... 42
Şekil 3.10: Standart evrişim blok diyagramı. 43
Şekil 3.11: Derinlemesine evrişim ve noktasal evrişim blok diyagramları. 43
Şekil 3.12: MobileNet mimarisinin blok diyagramı. 44
Şekil 3.13: EfficientNet-B0 mimarisinin blok diyagramı. 45
Şekil 3.14: Gradyan iniş. 47
Şekil 3.15: Modelin eğitim boyunca öğrenme oranı. 47
Şekil 3.16: Önerilen hibrit model. 48
Şekil 3.17: Tez çalışmasının yol haritası. 49
Şekil 4.1: Veri kümesi için sınıflandırma modellerinin doğruluk oranları..... 56
Şekil 4.2: Ön işlenmiş veri kümesi için sınıflandırma modellerinin doğruluk oranları. 61
Şekil 4.3: Gri tonlamalı veri kümesi için sınıflandırma modellerinin doğruluk oranları. 65
Şekil 4.4: UCSD veri kümesi için sınıflandırma modellerinin doğruluk oranları..... 70

TABLO LİSTESİ

Sayfa No

Tablo 2.1: YBMD sınıflandırma sistemleri. 12

Tablo 3.1: Veri arttırmadan sonra veri seti OKT görüntülerinin dağılımı. 39

Tablo 3.2: Hiperparametre ayarlı derin öğrenme modellerinin ve önerilen hibrit modelinin parametre değerleri. 48

Tablo 4.1: Karışıklık matrisi. 51

Tablo 4.2: Veri seti OKT görüntülerinin dağılımı. 53

Tablo 4.3: Veri seti için derin öğrenme modellerinin sınıflandırma sonuçları. 53

Tablo 4.4: Veri seti için derin öğrenme modellerinin karışıklık matrisleri. 54

Tablo 4.5: Veri seti üzerinde hiperparametre ayarlı derin öğrenme modellerinin sınıflandırma sonuçları. 55

Tablo 4.6: Veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri. 55

Tablo 4.7: Ön işlenmiş veri seti için derin öğrenme modellerinin sınıflandırma sonuçları. 57

Tablo 4.8: Ön işlenmiş veri seti için derin öğrenme modellerinin karışıklık matrisleri. 58

Tablo 4.9: Ön işlenmiş veri seti için hiperparametre ayarlı derin öğrenme modellerinin sınıflandırma sonuçları. 59

Tablo 4.10: Ön işlenmiş veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri. 59

Tablo 4.11: Gri tonlamalı veri seti için derin öğrenme modellerinin sınıflandırma sonuçları. 62

Tablo 4.12: Gri tonlamalı veri seti için derin öğrenme modellerinin karışıklık matrisleri. 62

Tablo 4.13: Gri tonlamalı veri seti için hiperparametre ayarlı derin öğrenme modellerinin sınıflandırma sonuçları. 63

Tablo 4.14: Gri tonlamalı veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri. 64

Tablo 4.15: UCSD veri seti OKT görüntülerinin dağılımı. 66

Tablo 4.16: UCSD veri seti için derin öğrenme modellerinin sınıflandırma sonuçları. 66

Tablo 4.17: UCSD veri seti için derin öğrenme modellerinin karışıklık matrisleri. 67

Tablo 4.18: UCSD veri seti üzerinde hiperparametre ayarlı derin öğrenme modellerinin sınıflandırma sonuçları. 68

Tablo 4.19: UCSD veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri. 69

Tablo 4.20: Önerilen hibrit model ve literatürdeki çalışmaların UCSD veri seti için sınıflandırma performans sonuçları. 70

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
∂	: Kısmi Türev
α	: Öğrenme Oranı
%	: Yüzde
≥	: Büyük Eşittir
≤	: Küçük Eşittir
µm	: Mikrometre
f(Net)	: Aktivasyon Fonksiyonu
L	: Kayıp Fonksiyonu
X_a	: Özellik Haritasının Yükseklik ve Genişliği
X_b	: Filtre Boyutu
x_i	: Girdi Vektörü
w_i	: Ağırlık Vektörü
T	: Çıkış Nöronu
Y	: Giriş Kanallarının Sayısı
Z	: Çıkış Kanalı Boyutu

Kısaltmalar	Açıklama
Adam	: Adaptif Moment Tahmin (Adaptive Moment Estimation)
CLAHE	: Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (Contrast Limited Adaptive Histogram Equalization)
CNTK	: Bilişsel Araç (Cognitive Toolkit)
CSR	: Santral Seröz Retinopati (Central Serous Retinopathy)
DA	: Derinlemesine Ayrılabilir
DB	: Yoğun Blok (Dense Block)
DenseNET	: Yoğun Bağlı Ağlar (Densely Connected Networks)
Diğ.	: diğerleri
DMÖ	: Diyabetik Makula Ödem
DÖ	: Derin Öğrenme
DR	: Diyabetik Retinopati
DWConv	: Derinlemesine Evrişim Katmanı (DepthWise Convolution Layer)
ESA	: Evrişimli Sinir Ağı
FA	: Floresan Anjiyografi
GN	: Gerçek Negatif
GP	: Gerçek Pozitif
IDF	: Uluslararası Diyabet Federasyonu (International Diabetes Federation)
KNV	: Koroidal Neovaskülarizasyonu
Mak	: Maksimum
MBConv	: Mobil Evrişim Bloğu (Mobile Convolution Block)
MH	: Maküler Delik (Macular Hole)
NPDR	: Non-Proliferatif Diyabetik Retinopati
OCT	: Optik Koherens Tomografisi (Optical Coherence Tomography)
OCTA	: Optik Koherens Tomografi Anjiyografi (Optical Coherence Tomography Angiography)
OKT	: Optik Koherens Tomografisi
OCTID	: Optik Koherens Tomografi Görüntü Veritabanı (Optical Coherence Tomography İmage Database)
Ort	: Ortalama
PDF	: Taşınabilir Belge Biçimi (Portable Document Format)
PDR	: Proliferatif Diyabetik Retinopati
ReLU	: Doğrultulmuş Lineer Birim (Rectified Linear Unit)
ResNET	: Artık Sinir Ağı (Residual Neural Network)

RPE	: Retina Pigment Epitel
SD-OCT	: Spektral Alan Optik Koherens Tomografi (Spectral Domain Optical Coherence Tomography)
SERI	: Alt Olay İlişkisi Çıkarımı (Sub-event Relation Inference)
SGD	: Stokastik Gradyan Azalma(Stochastic Gradient Descent)
tanh	: Tanjant
TSA	: Tekrarlayan Sinir Ağı
UCSD	: Kaliforniya San Diego Üniversitesi (University of California San Diego)
US	: Ultrasonografi
vd	: ve diğerleri
VGG	: Görsel Geometri Grubu (Visual Geometry Group)
YN	: Yanlış Negatif
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağı
YZ	: Yapay Zeka
YBMD	: Yaşa Bağlı Makula Dejenerasyonu
WHO	: Dünya Sağlık Örgütü (World Health Organization)

ÖZET

DOKTORA TEZİ

DERİN ÖĞRENME KULLANARAK OPTİK KOHERENS TOMOGRAFİ GÖRÜNTÜLERİNDEN RETİNA HASTALIĞI TESPİTİ

Şükrü AYKAT

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı

Bilgisayar Mühendisliği Programı

Danışman : Doç. Dr. Sibel SENAN

Retina hastalıkları, insanların en önemli duyu organlarından olan gözlerde görme kayıplarının önde gelen nedenleri arasında yer almaktadır. Retina hastalıklarının erken teşhisi, gözlerde bu geri döndürülemez kayıpların engellenmesi için çok büyük önem taşımaktadır. Tez çalışmasında retina hastalıkları arasında önde gelen Diyabetik Retinopati ve Yaşa Bağlı Makula Dejenerasyonu hastalıklarının erken teşhisi için derin öğrenme temelli bir hibrit model geliştirilmiştir. Bu amaçla, İstanbul İl Sağlık Müdürlüğü Kanuni Sultan Süleyman Eğitim ve Araştırma Hastanesi'nden optik koherens tomografi görüntüleri toplanarak özgün bir veri seti oluşturulmuştur. Bu veri seti üzerinde görüntü işleme ve veri artırma yöntemleri kullanılarak ön işlenmiş ve gri tonlamalı veri setleri oluşturulmuştur. Ardından bu çalışma kapsamında hiperparametre ayarı yapılarak yeniden yapılandırılan dokuz derin öğrenme modeli ve geliştirilen hibrit derin öğrenme modeli oluşturulan veri seti ve literatürde çok kullanılan UCSD (University of California San Diego) veri seti üzerinde eğitilmiştir. Hiperparametre ayarlı modellerin sınıflandırma performansları hiperparametre ayarı uygulanmamış derin öğrenme modelleri ve literatürdeki diğer çalışmalarla karşılaştırılmıştır. Hiperparametre ayarlı modellerin, orijinal versiyonlarına göre daha başarılı sonuçlar sağladığı gösterilmiştir. Sınıflandırma sonuçları, önerilen hibrit modelin bu çalışmada ele alınan diğer modellere göre en başarılı sonuçları verdiğini ortaya koymuştur.

Aralık 2023, 115 sayfa.

Anahtar kelimeler: oftalmoloji, diyabetik retinopati, yaşa bağlı makula dejenerasyonu, retina hastalıkları, yapay zeka, makine öğrenmesi, derin öğrenme, evrişimli sinir ağı

ABSTRACT

Ph.D. THESIS

RETINAL DISEASE DETECTION FROM OPTICAL COHERENCE TOMOGRAPHY IMAGES USING DEEP LEARNING

Şükrü AYKAT

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Computer Engineering

Programme of Computer Engineering

Supervisor : Assoc. Prof. Dr. Sibel SENAN

Retinal diseases are among the leading causes of vision loss in the eyes, one of the most important sense organs of people. Early diagnosis of retinal diseases is of great importance to prevent these irreversible losses in the eyes. In the thesis study, a deep learning-based hybrid model was developed for the early diagnosis of Diabetic Retinopathy and Age-Related Macular Degeneration, which are the leading retinal diseases. For this purpose, an original data set was created by collecting optical coherence tomography images from Istanbul Provincial Health Directorate, Kanuni Sultan Süleyman Training and Research Hospital. Pre-processed and grayscale data sets were created on this data set using image processing and data augmentation methods. Then, within the scope of this study, nine deep learning models restructured by hyperparameter adjustment and the developed hybrid deep learning model were trained on the created data set and the UCSD (University of California San Diego) data set, which is widely used in the literature. The classification performances of models with hyperparameter adjustment were compared with deep learning models without hyperparameter adjustment and other studies in the literature. It has been shown that hyperparameter-tuned models provide more successful results than their original versions. Classification results revealed that the proposed hybrid model gave the most successful results compared to other models considered in this study.

December 2023, 115 pages.

Keywords: ophthalmology, diabetic retinopathy, age-related macular degeneration, retinal diseases, artificial intelligence, machine learning, deep learning, convolutional neural network

1. GİRİŞ

Göz, insanlarda en önemli duyu organlarından biridir. Günümüzde, retina hastalıkları ciddi görme kaybı ve körlüğün önde gelen nedenleri arasında yer almaktadır. Gözlerde bu geri döndürülemez hasarların oluşmaması için hastalığın erken teşhisi çok büyük önem arz etmektedir (Pennington ve DeAngelis, 2016). Diyabetik Retinopati (DR) ve Yaşa Bağlı Makula Dejenerasyonu (YBMD) en çok görülen retina hastalıklarının başında gelmektedir. Ayrıca DR dünya çapında bir salgın olarak kabul edilmektedir.

Diyabet hastalığı, pankreasın yeterli kan insülini üretememesi veya salgılayamaması nedeniyle kandaki glukoz seviyesinin yükselmesine neden olan kronik bir hastalıktır (Amin ve diğ., 2016). Diyabetin karaciğer, kalp, böbrek, eklem, göz gibi insan organları üzerinde olumsuz etkileri olmaktadır (Amin ve diğ., 2016; Kharroubi ve Darwish, 2015). Diyabete bağlı olarak kanda artan glukoz gözü besleyen kan damarlarında tıkanmaya neden olmaktadır. Gözlerde kan damarlarının şişmesine, sıvı sızdırmalarına ve ciddi göz hasarlarına neden olan diyabet, DR'nin doğrudan bir nedenidir. Retinadaki kan damarlarının anormal büyümesi retinada kanamaya ve sonuç olarak körlüğe neden olmaktadır (WHO, 2019). Erken teşhis ve zamanında tedavinin DR'den kaynaklanan görme kayıplarının çoğunu önleyebileceğine dair önemli bilimsel kanıtlar vardır (Liew ve diğ., 2014). Ancak bu rahatsızlığın ilk aşamasında herhangi bir belirti görülmez ve hastalığı tespit etmek zordur (Krause ve diğ., 2018). Dünya genelinde DR, körlük nedenlerinin %2,6'sını oluşturmaktadır (Mamtora ve diğ., 2017). Diyabet hastası olan yaklaşık 285 milyon kişinin üçte birinde DR belirtileri olup, bunların da üçte birinde görmeyi tehdit eden DR hastalığı vardır (R. Lee ve diğ., 2015).

Yaşlanma, genetik yatkınlık ve yaşam tarzı gibi faktörler YBMD hastalığına sebep olmaktadır (Heesterbeek ve diğ., 2020). YBMD, cisimleri ayrıntılı ve net görmemizi sağlayan retinanın makula bölgesini etkileyerek görme kaybına neden olan bir hastalıktır (H. R. Coleman ve diğ., 2008; Lim ve diğ., 2012). YBMD, sanayileşmiş ülkelerde yaşlılarda ciddi görme kaybının ana nedenidir ve görülme sıklığı giderek artmaktadır (Bourne ve diğ., 2018). YBMD, dünyada 65 yaşından büyüklerin %10'unu ve 75 yaşından büyüklerin %25'inden fazlasını etkileyen görme kaybının önemli bir nedenidir (Smith ve diğ., 2001). Günümüzde 200 milyon civarında olan YBMD hasta sayısının 2040 yılında 300 milyon olması ön görülmektedir (Wong ve diğ., 2014).

Retina hastalıklarının ilerlemesi ve saptanması, gözün retinasının optik disk, kan damarları ve fovea gibi farklı retina kısımlarında veya yakınındaki bozukluklar aracılığıyla gözlemlenmektedir (Farsiu ve diğ., 2014). Bu gözlemleri yapmak için retina görüntülerine ihtiyaç duyulmaktadır. Dijital Fundus Görüntüleme, Optik Koherens Tomografisi (OKT), Floresan Anjiyografi (FA) ve Ultrasonografi (US) retina görüntüleme tekniklerinden bazılarıdır. Retina görüntülerin doğru analiz edilebilmesi için retinanın doğal yapısında bulunan optik disk ve makula gibi yapıların doğru tanınması ve dejenerasyonlardan ayırt edilmesi gerekmektedir (Yavuz ve diğ., 2009). Göz doktorları bu görüntüleri analiz ederek retina hastalığını teşhis etmektedir.

OKT, retina yapısını mikroskobik çözünürlükte değerlendirebilen bir görüntüleme şeklidir (D. Huang ve diğ., 1991). OKT taramaları, bir OKT ışık kaynağı ile makulanın her tarafını hızla tarayarak elde edilmektedir. Işık doğrudan algılanamayacak kadar hızlı taradığı için yansıyan ışık ölçülmektedir. Ultrason görüntüsünde olduğu gibi, tarama doğrusal bir görüntü oluşturmak için birleştirilmektedir (Gabriele ve diğ., 2011).

Bazı çalışmalara göre gelecekte sınırlı sayıda göz doktorunun retina hastalarına bakamayacak durumda olacağı öngörülmektedir (Peng ve diğ., 2019). Retina hastaları ile göz hekimi sayısı arasındaki orantısız durum hizmetlerde gecikmelere yol açacaktır. Böyle bir durumda göz doktorlarının iş yükünü hafifletmek için göz hastalıklarını otomatik olarak tespit eden sistemlere büyük ihtiyaç olacaktır. Retina görüntülerinin manuel olarak incelenmesi yerine akıllı teşhis sistemlerinin kullanılması zamandan ve maliyetten büyük kazançlar sağlamaktadır (Keel ve diğ., 2019; Zabihollahy ve diğ., 2019).

Geçmişten günümüze araştırmacılar, görüntülerdeki özellikleri tanımlamak için matematiksel morfoloji görüntü işleme (Serra, 1982), şablon eşleştirme (Jo ve diğ., 2018), dalgacık analizi (T.-H. H. Lee, 2017), piksel sınıflandırma (Niemeijer ve diğ., 2009), bulanık C-ortalama kümeleme (Osareh ve diğ., 2003) yöntemlerini kullanmışlardır. Bu yöntemler mikroanevrizma, eksuda, kırmızı lezyon ve anormal damar özellikleri saptamak için kullanılmıştır. Son yıllarda ise tıp alanında yapay zekaya (YZ) dayalı yöntemler sıklıkla kullanılmaya başlanmıştır. Derin öğrenme (DÖ) modelleri kullanılarak retina görüntülerinin analizi için birçok çalışma yapılmıştır (Elgafi ve diğ., 2022; C. S. Lee ve diğ., 2017; Sandhu ve diğ., 2018). Tıbbi görüntüleme alanında DÖ kullanılarak yapılan analiz çalışmaları önemli sonuçlara ulaşmıştır.

Bu tez çalışmasında, OKT görüntüleri kullanılarak DÖ yaklaşımı ile DR ve YBMD retina hastalıklarının tespit edilmesi amaçlanmaktadır. Bu amaç doğrultusunda, retina hastalıklarının tespitini yüksek doğrulukla tahmin edebilen bir sistem geliştirilerek oftalmoloji alanında çalışma yapan hekimlerin iş yüklerinin azaltılması hedeflenmiştir.

Bu amaçla tez çalışması kapsamında gerçekleştirilmiş çalışmalar şu şekilde listelenebilir;

1. Retina hastalıklarının sınıflandırılması konusunda 2015-2022 yılları arasında yayınlanmış olan çalışmalar ile ilgili bir literatür taraması gerçekleştirilmiştir. İncelenen yayınların yıllara göre dağılım oranları, çalışmalarda kullanılan veri setleri ve kullanılan DÖ yöntemleri incelenerek analiz edilmiştir. Gerçekleştirilen bu çalışma "Machine Learning and AI Techniques in Interactive Medical Image Analysis" isimli kitapta, "Deep Learning in Retinal Diseases Diagnosis: A Review (2022)" başlığı ile kitap bölümü olarak yayınlanmıştır.

2. Göz tomografisi görüntülerinden makine öğrenmesi yöntemleri kullanılarak gözde oluşabilen ve bunun sonucunda kalıcı hasara yol açabilen sekiz retina hastalığının sınıflandırılması üzerine bir çalışma gerçekleştirilmiştir. Bu amaçla altı DÖ modeline hiperparametre ayarları uygulanmış, OCT-C8 veri seti üzerinde eğitim gerçekleştirilmiş ve performans analizleri yapılmıştır. Bu çalışmada sunulan hiperparametre ayarlı DenseNet121 modelinin sınıflandırma başarısının ele alınan diğer modellere göre daha yüksek olduğu görülmüştür. Gerçekleştirilen bu çalışma "International Journal of Computational and Experimental Science and Engineering" isimli dergide, "Using Machine Learning to Detect Different Eye Diseases from OCT Images (2023)" başlığı ile yayınlanmıştır.

3. Katarakt ve diyabetik retinopati hastalıkların erken teşhisi için DÖ yaklaşımlarını kullanan bir çalışma gerçekleştirilmiştir. Bu amaçla, fundus görüntüleri üzerinde geleneksel DÖ modelleri ve bu modellere hiperparametre ayarı yaptığımız mimariler uygulanmış ve elde edilen tanı tahmin sonuçlarının doğruluk performans analizleri sunulmuştur. Gerçekleştirilen bu çalışma "Mühendislik Bilimleri ve Araştırmaları" isimli dergide, "Derin Öğrenme Kullanılarak Fundus Görüntülerinden Katarakt ve Diyabetik Retinopati Tespiti (2023)" başlığı ile yayınlanmıştır.

4. Diyabetik drusen, koroidal neovaskülarizasyon ve makula ödemi retina hastalıklarının tespiti için DÖ tabanlı bir çalışma gerçekleştirilmiştir. Bu amaçla yeni bir hibrit DÖ modeli önererek ve modelin literatürdeki geleneksel DÖ modelleriyle karşılaştırmalı performans analiz

sonuçları verilmiştir. Bu karşılaştırma sonuçları, önerilen modelin sınıflandırma başarısının literatürdeki geleneksel DÖ modellerinin başarısından daha yüksek olduğunu görülmüştür. Gerçekleştirilen bu çalışma "Traitement du Signal" isimli dergide, "Advanced Detection of Retinal Diseases via Novel Hybrid Deep Learning Approach" başlığı ile kabul edilmiştir.

5. Tez çalışması kapsamında YBMD ve DR retina hastalıklarının tespiti için DÖ tabanlı bir çalışma gerçekleştirilmiştir. İlk önce etik kurul ve veri toplama izinleri alınarak YBMD, DR ve NORMAL OKT görüntüleri toplanmıştır. Görüntülerdeki gürültüler, maske ve görüntü işleme yöntemleri kullanılarak temizlenmiştir. Veri seti NORMAL OKT görüntülerinin sayısı DR ve YBMD OKT görüntülerine oranla çok az olduğundan dolayı NORMAL OKT görüntüleri üzerinde rastgele parlaklık, yatay döndürme, rastgele yakınlaştırma ve rastgele kesme görüntü işleme yöntemleri kullanılarak arttırılmıştır.

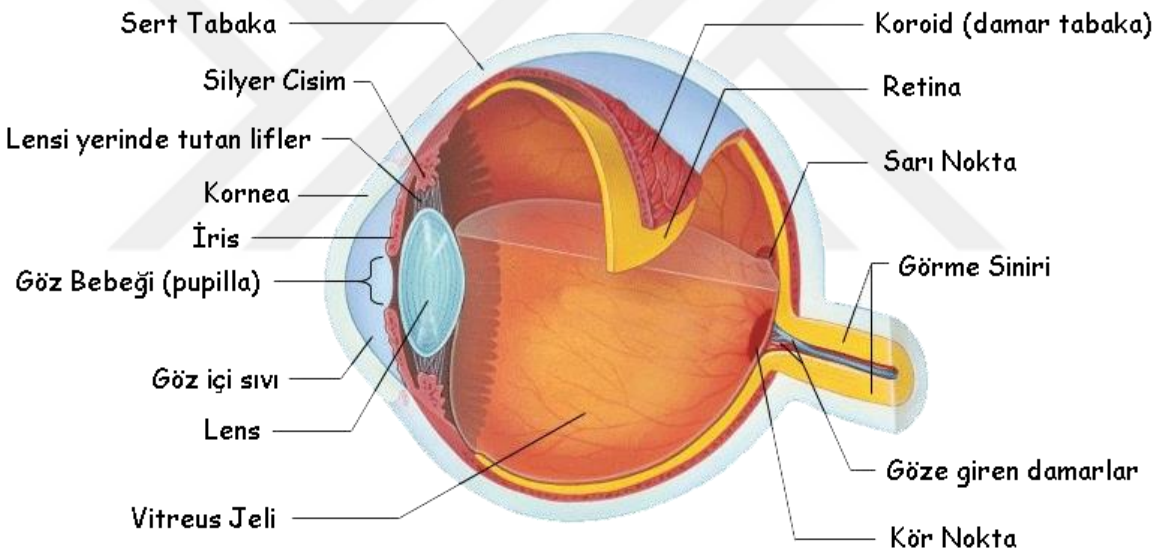
OKT görüntülerinden oluşturulan bu yeni bir veri seti üzerinde hastalık tespit başarı sonuçlarını analiz etmek için ilk olarak dokuz farklı DÖ modeli uygulanmıştır. Daha sonra bu modellerin performanslarını iyileştirmek için hiperparametre ayarı yapılmıştır. Ardından, bu modellerin en başarılısı olan EfficientNetV2S ile hibrit bir model geliştirilmiştir. Önerilen modelin etkinliğini göstermek için ele alınan modellerin doğruluk yüzdeleri sunularak performans değerlendirmeleri yapılmıştır. Bu ölçümlere göre önerilen DÖ modelinin doğruluk, hatırlama ve kesinlik değerleri %99,89 olarak elde edilmiştir.

2. KAVRAMSAL ÇERÇEVE

Bu bölümde göz anatomisi, retina hastalıkları, retina görüntüleme teknikleri, YZ, DÖ yöntemleri ve ayrıntılı bir literatür taraması sunulmuştur.

2.1. GÖZ ANATOMİSİ

Göz, ışığı algılayan ve optik sinir boyunca beyne bir görüntü oluşturan sinyaller ileten, böylece renkleri ve derinliği ayırt etme kabiliyetini sağlayan en önemli duyu organıdır (Yadav ve Singh, 2019). Gözün anatomisi Şekil 2.1'de gösterilmiştir.



Şekil 2.1: Gözün anatomisi (Gündoğan, 2023).

Gözü oluşturan bölümler aşağıda açıklanmıştır.

2.1.1. Retina

Göz küresinin arkasının iç yüzeyini kaplayan hassas zar, retina olarak bilinmektedir. Retina, ışığı elektrik sinyallerine dönüştürebilen özelleşmiş bir nöron tipi olan birçok fotoreseptörlerden oluşmaktadır. İnsan gözündeki çubuk ve koni iki tür fotoreseptör hücresidir. Çubuk fotoreseptörler hareketi algılar, siyah beyaz görüş sağlar ve düşük ışık koşullarına çok uygundur. En iyi şekilde orta ve güçlü ışıkta çalışan koniler ise merkezi görme ve renkli

görmeden sorumludur. Çubuklar tüm retina boyunca bulunmaktadır. Koniler ise retinanın küçük bir merkez kısmı olan makulada yoğunlaşmıştır (Subramanian ve diğ., 2022).

2.1.2. Sert Tabaka

Sert tabaka, göz küresinin dış destekleyici beyaz tabakasıdır. Korneadan optik sinire kadar uzanmaktadır (Mafee ve diğ., 1996). Sert tabaka koruyucu görevi görür, göz içi basıncını korur ve göz dışı kaslar için bağlantı sağlar. Sert tabakanın şekli ve kalınlığı yaşam boyunca değişmektedir. Erken çocukluk döneminde kalındır, artan göz içi basıncı ile gerilir ve yaşlandıkça daha sert hale gelmektedir (WH, 1985).

2.1.3. Kornea

Gözün en dış kısmıdır. Beş katmandan oluşan bir hücre ve protein grubudur (Vaishya ve diğ., 2014). Gözyaşı filmi kornea yüzeyini yıkar ve gözün tahriş edici maddelerden korunmasına yardımcı olmaktadır (Addo ve diğ., 2016).

2.1.4. İris

Gözbebeğini kontrol etmekten sorumlu dairesel, ince bir yapıdır. İris, lens ve kornea arasındaki boşluğu ön oda (kornea ve iris arasında) ve arka oda (iris ve lens arasında) olmak üzere iki bölüme ayırmaktadır. İrisin rengi genetik olarak belirlenir ve iristeki pigment miktarına bağlıdır (Addo ve diğ., 2016).

2.1.5. Göz Bebeği

Işığın lense ulaşmadan önce retinaya odaklandığı iristeki bir açıklıktır. Gözbebeğinin boyutu, maruz kaldığı ışık miktarına bağlıdır ve iris kasları boyutu kontrol etmektedir (Albert ve Gamm, 2023).

2.1.6. Silyer Cisim

Lensin düzgün odaklanmasına yardımcı olan ve göz içinde halka şeklinde kalınlaşmış bir dokudur. Ön kısım, nispeten düz ve pigmentli bir iç yüzeye sahiptir. Silyer cisim kas, damar ve epitelden oluşmaktadır (Giampani ve Junior, 2013).

2.1.7. Lens

Gözbebeğinin arkasındaki şeffaf ve elastik kısımdır. Esnekliği sayesinde kolayca şekil değiştirmektedir. Lens, yaşla birlikte (çoğunlukla 40-50 yaş) esnekliğini ve ışığı keskin bir şekilde odaklama yeteneğini kaybetmektedir (Addo ve diğ., 2016).

2.1.8. Vitreus Jeli

Mercek ile retina arasındaki boşluğu dolduran şeffaf, renksiz bir jel sıvıdır. Vitreus jeli yaklaşık %98 oranında su, hyaluronik asit içermektedir (Addo ve diğ., 2016).

2.1.9. Koroid (Damar Tabaka)

Sert tabaka ve retina arasında yer alan bağ dokuları, fibroblast ve melanosit içeren gözün damarsal bir tabakasıdır. Gözün arka kısmında yer alan koroid, retinaya oksijen ve besin sağlamaktadır. Pürüzsüz iç yüzey retina pigmentli epitele (RPE) tutunurken, dış yüzey sert tabakaya tutunmaktadır. Koroid ışık emilimine yardımcı olarak retinaya giren ışık miktarını azaltmaktadır. Aynı zamanda göz içi basıncının dengelemektedir (Nickla ve Wallman, 2010).

2.1.10. Görme Siniri

Kafa siniri olarak da bilinen görme siniri, gözü beyine bağlamaktadır. Yaklaşık 1,2 milyon sinir lifi içeren görme siniri, görsel uyarıları retinadan elektriksel uyarılarla beyindeki görme merkezine aktarmaktadır (Addo ve diğ., 2016).

2.1.11. Sarı Nokta (Makula) ve Fovea

Fovea ve makula, keskin merkezi görüş sağlayan retinanın en hassas kısmıdır. Fovea, makula merkezindeki küçük bir çöküntüdür. Fovea, retinada yalnızca koni fotoreseptörleri içeren ve maksimum görme keskinliği ve renk algısından sorumlu olan bir noktadır (Subramanian ve diğ., 2022).

2.1.12. Kör Nokta (Optik Disk)

Görme sinirinin gözün arka bölümünde çapı yaklaşık 1,5 mm olan bölgeye optik disk adı verilmektedir (Lens ve diğ., 2009). Fotoreseptör hücrelerin bulunmaması nedeniyle kör nokta olarak da bilinen optik disk, retinanın görme sinirinin gözden ayrıldığı kısmıdır (Addo ve diğ., 2016). Çubuk ve konilerden alınan sinyallerin görme siniri yoluyla beyindeki optik merkeze iletilmesinde rol oynamaktadır.

2.2. RETİNA HASTALIKLARI

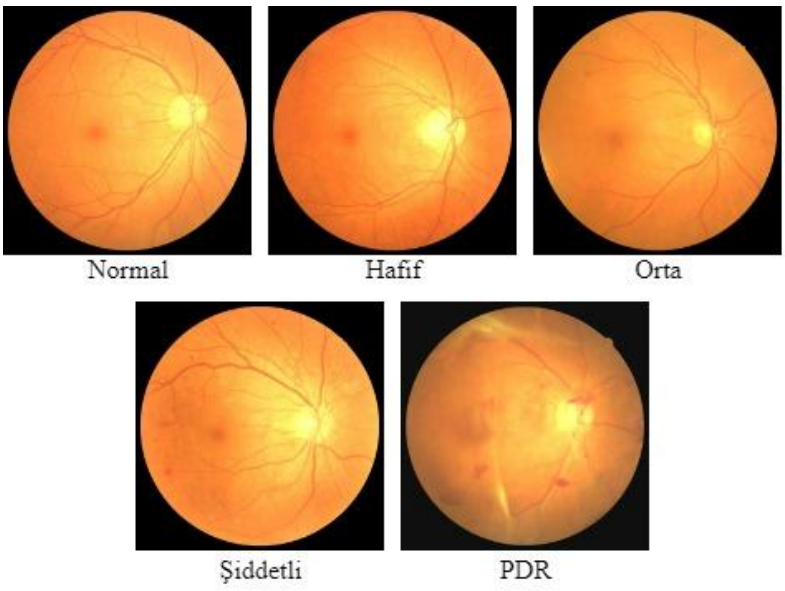
Son yıllarda, retina bozuklukları ciddi bir halk sağlığı sorunu haline gelmiştir. Retina bozuklukları yavaş ve belirgin belirtiler olmadan gelişmektedir. Her yıl, tüm dünyada milyonlarca kişiye retina hastalığı teşhisi konulmaktadır (Subramanian ve diğ., 2022). Dünya Sağlık Örgütü'nün raporuna göre, dünya çapında yaklaşık 2,2 milyar insanın göz

hastalıklarından etkilendiği tahmin edilmektedir (WHO, 2019). Santral seröz retinopati, YBMD, diyabetik makula ödem (DMÖ), DR, drusen, glokom, katarakt ve makula deliği bazı retina hastalıklarıdır. Çalışmamızda ele aldığımız DR ve YBMD hastalıkları aşağıda açıklanmıştır.

2.2.1. Diyabetik Retinopati Hastalığı

Diyabet hastalığı, insülin direncinin neden olduğu metabolik bozukluk olarak tanımlanmaktadır (American Diabetes, 2011). Uluslararası Diyabet Federasyonu 2019 raporuna göre dünyada 463 milyon kişinin diyabet hastası olduğu ve 2045 yılında bu sayının 700 milyona ulaşması tahmin edilmektedir (IDF, 2023). Diyabet hastalığı retina, kalp, sinirler ve böbrekleri etkilemektedir (Taylor ve Batey, 2012). Diyabet, 50 yaşın altındaki kişilerde körlüğün en önemli nedenlerinden biridir (WHO, 2019).

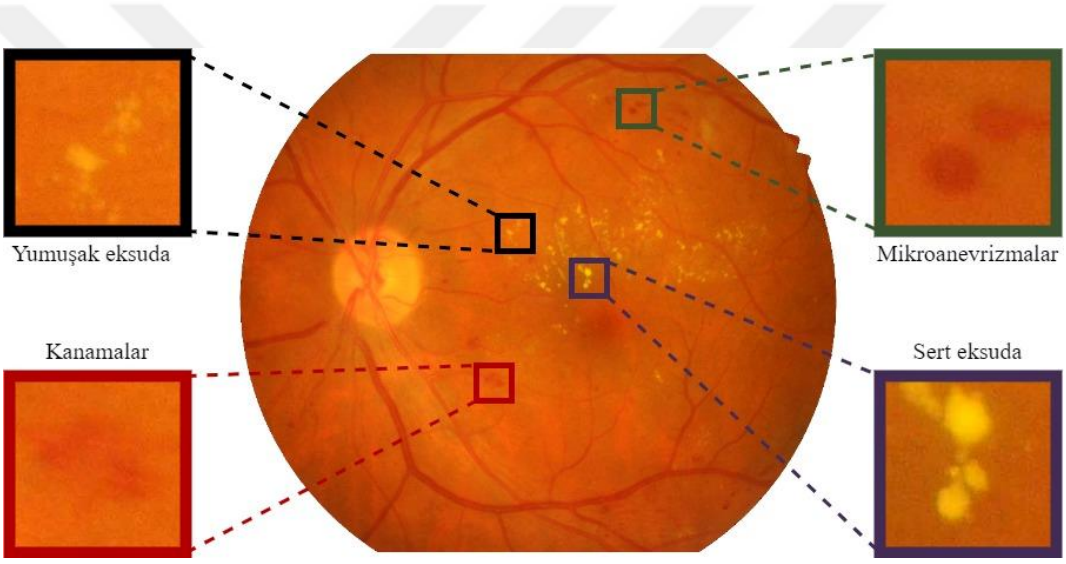
DR, diyabet hastası kişiler için en yaygın körlük ve görme bozukluğu nedenidir (Abramoff ve diğ., 2010; Gulshan ve diğ., 2016; Yau ve diğ., 2012). DR gelişme riski, diyabet süresi ile birlikte artar. İstatistiksel verilere dayanarak 5 yıl diyabet hastası olan bireylerde DR gelişme riski yaklaşık %17 iken, 15 yıl veya daha uzun süre diyabet tanısı olan hastalarda ise DR gelişme riski yaklaşık %97,5 olduğu sonucuna varılmaktadır (Behl ve diğ., 2014). Önümüzdeki yıllarda DR hastalarının artması beklenmektedir. Uzun süreli tedavi edilmeyen diyabetin sonuçları çok ağır olduğundan ve şiddetli DR yaygınlaşmasına yol açabileceğinden, diyabet hastalığının uygun ve erken tedavisi çok önemli bir hale gelmektedir (Mustafa ve diğ., 2015).



Şekil 2.2: DR aşamaları.

DR, non-proliferatif diyabetik retinopati (NPDR) ve proliferatif diyabetik retinopati (PDR) olmak üzere iki sınıfa ayrılmaktadır. NPDR'nin hafif, orta ve şiddetli olmak üzere üç aşaması bulunmaktadır. PDR ise DR'nin ileri bir aşamasıdır. DR aşamalarının fundus görüntüleri Şekil 2.2'de gösterilmiştir.

DR tespiti geleneksel olarak, uzman bir doktorun retina görüntülerini incelemesi ile olmaktadır. Genel olarak DR gözlerde mikroanevrizma, kanama, yumuşak eksuda ve sert eksuda olmak üzere dört tip lezyon şeklinde teşhis edilmektedir (Dubow ve diğ., 2014). DR lezyonlarının fundus görüntüsündeki şekilleri Şekil 2.3'te gösterilmiştir. Mikroanevrizmalar ve kanamalar genellikle kırmızı lezyonlar olarak görünürken, iki tip eksuda parlak lezyonlar olarak görünmektedir.



Şekil 2.3: DR lezyon türleri.

Mikroanevrizmalar, damar duvarı zayıflığı nedeniyle retina üzerinde küçük kırmızı yuvarlak noktaların bulunduğu diyabetik retinopatinin erken bir aşamasıdır. Noktalar, boyutu 125 mikrometreden fazla olmayan keskin kenar boşluklarıyla tanımlanırlar (Dubow ve diğ., 2014). Kanamalar, mikroanevrizmaların aksine, retina üzerinde 125 mikrometreyi aşan düzensiz kenar boyutlarına sahip büyük lekelerin varlığı ile teşhis edilmektedir. Kanamalar yüzeysel ve derindir (Murugesan ve diğ., 2015). Sert eksudalar, plazma sızıntısının bir sonucudur ve plazma sızıntısının neden olduğu retina üzerinde sarı noktalar olarak görülmektedir. Dış retina katmanlarını kaplarlar ve keskin kenarları bulunmaktadır (Amin ve diğ., 2016). Yumuşak eksudalar, sinir lifi şişmesinin bir sonucudur ve retina üzerinde görünür şekilde beyaz ovallerdir (Dubow ve diğ., 2014).

DR'nin erken teşhisi ve tedavisi görme kaybını önleyebilmektedir (Abramoff ve diğ., 2010). Önlenebilir görme bozukluğunun ortadan kaldırılması için uzman doktor sayısına ve gözün tedavisi için gerekli olan temel sağlık hizmetleri altyapısına bağlı olmaktadır (S. Lin ve diğ., 2016). DR'nin oftalmologlar tarafından manuel olarak teşhis edilmesi zaman alıcıdır, büyük çaba gerektirir ve yanlış hastalık teşhisine eğilim bulunmaktadır. Bu nedenle, bilgisayar destekli bir tanı sistemi kullanmak yanlış tanıyı önleyebilir ve toplam maliyeti, zamanı ve çabayı azaltabilir (Alyoubi ve diğ., 2021).

2.2.2. Yaşa Bağlı Makula Dejenerasyonu Hastalığı

YBMD, retinanın makula bölgesini etkileyen ve merkezi görme kaybına neden olan bir hastalıktır (Mitchell ve diğ., 2018). YBMD hastalığına genetik varyantlar ile çevresel ve yaşam tarzı faktörlerin birleşik etkisi neden olur (Chakravarthy ve diğ., 2010; Lim ve diğ., 2012; Wong ve diğ., 2014). YBMD'nin ilk belirtileri drusen adı verilen retina birikintilerinin ortaya çıkmasıdır (C. J. Thomas ve diğ., 2021). Drusen, RPE ile bruch zarı arasındaki hücre dışı kalıntı birikintileridir (Khan ve diğ., 2016). Drusen, proteinler, lipidler, kolesterol ve RPE'nin hücresel parçaları dahil olmak üzere çok çeşitli bileşenler içermektedir (Mullins ve diğ., 2000; L. Wang ve diğ., 2010). Drusen, yaşlanma sürecine bağlı olarak görülmektedir. Drusenin sayısına, boyutuna, şekline, dağılımına ve morfolojisine bağlı olarak YBMD'nin erken bir belirtisi olmaktadır (Khan ve diğ., 2016). Toplam drusen sayısı, ölçülen drusen alanı veya hacmi YBMD'nin ilerleme seviyesi için risk faktörleridir (Heesterbeek ve diğ., 2019; Joachim ve diğ., 2013; Lei ve diğ., 2017; Schlanitz ve diğ., 2017). Ayrıca, fovea civarında drusen bulunması durumunda gözlerde geç YBMD geliştirme olasılığı daha yüksek olduğundan, drusen konumu hastalığın ilerlemesi için öngörücü değer olmaktadır (Hallak ve diğ., 2019; Joachim ve diğ., 2013; Tikellis ve diğ., 2006).

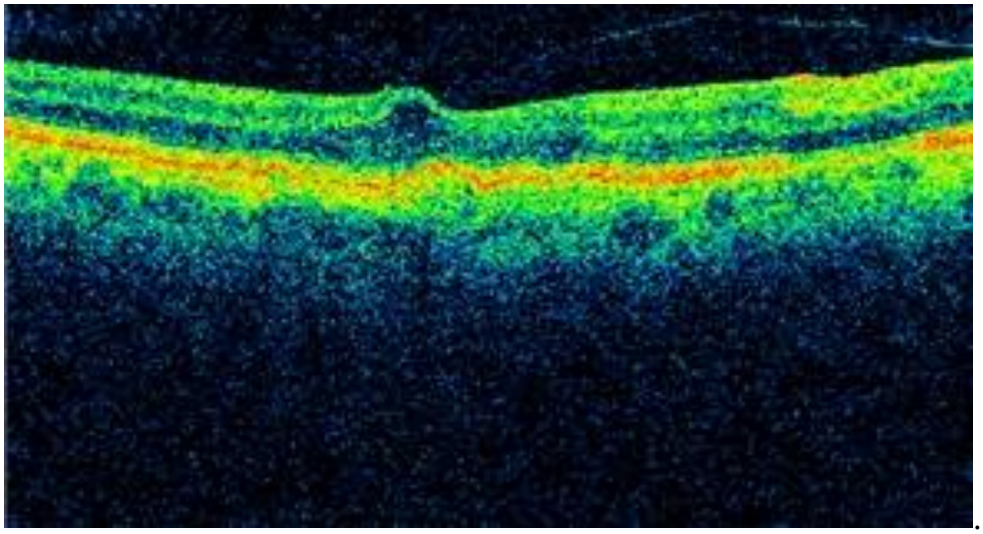
Hastalığın erken evrelerinde drusen sayısı azdır ve görme fonksiyonunu etkilemez. Drusen sayısı arttıkça veya RPE hücrelerinin değişimine bağlı olarak retinada pigment değişiklikleri görüldüğünden dolayı hastalığın erken YBMD'den orta YBMD'ye ilerlemesine neden olmaktadır (Chakravarthy ve diğ., 2010; Jager ve diğ., 2008). Hastalığın ilerlemesi durumunda YBMD'nin iki geç evresi olan neovasküler (ıslak YBMD) ve non-neovasküler (kuru YBMD) durumu ortaya çıkmaktadır. Non-neovasküler YBMD tüm vakaların neredeyse %80-85'ini oluşturmaktadır. Neovasküler YBMD, vakaların %15-20'ni oluşturmasına rağmen ciddi görme kayıplarının yaklaşık %80'ini oluşturmaktadır (Ferris ve diğ., 1984). Neovasküler YBMD, anormal kan damarlarının oluşmasıyla oluşmaktadır. Bu yeni oluşan damarlar kırılgandır ve

kolayca kırılarak retinaya kan sızar ve ani görme kaybına neden olur. Non-neovasküler YBMD, koroid kan damarlarında daralma olmasının yanı sıra RPE ve fotoreseptör hücrelerinin kademeli olarak değişiminin bir sonucudur (Chakravarthy ve diğ., 2010; Jager ve diğ., 2008).

Yaşlanma, etnik köken, beslenme alışkanlıkları ve sigara dumanının YBMD ile tutarlı bir şekilde ilişkili olduğu ortaya konmuştur (Chakravarthy ve diğ., 2010; Lim ve diğ., 2012; Wong ve diğ., 2014). 50 yaşın altındaki kişilerde seyrek olmakla birlikte, 75 yaşından büyük hastalarda YBMD'ye yakalanma riski 65 ile 74 yaş arasındaki hastalara göre üç kattan fazla artmaktadır (Klein ve diğ., 1992). Genel olarak ailede YBMD öyküsü olan bireylerde risk bulunmaktadır. YBMD hastası olan bir bireyin kardeşleri, genel popülasyona göre üç ile altı kat arasında yüksek riske sahiptir (Maller ve diğ., 2006). 40 yaşın üzerinde sigara içenlerin, aynı yaştaki sigara içmeyenlere göre YBMD geliştirme olasılığı iki ile dört kat daha fazladır (McCarty ve diğ., 2001). Diyetle antioksidan ve çinko alımı, yaşlı bireylerde YBMD gelişme riskini azaltmaktadır (J. S. L. Tan ve diğ., 2008; Van Leeuwen ve diğ., 2005). Bu takviyelerin YBMD ilerlemesini 5 yılda yaklaşık %25 oranında azaltabildiği gösterilmiştir (Chew ve diğ., 2013; Kassoff ve diğ., 2001; Van Leeuwen ve diğ., 2005).

Makuladaki pigment değişiklikleri erken YBMD'nin bir özelliğidir. Drusene ek olarak pigment değişikliklerinin olması, geç YBMD geliştirme riskini önemli ölçüde artırmaktadır (Connolly ve diğ., 2018; Shim ve diğ., 2016; Tikellis ve diğ., 2006). Büyük drusen ve pigment değişiklikleri olan hastalarda beş yıl içinde %47 oranında geç YBMD gelişme olasılığı bulunmaktadır (Ferris ve diğ., 2013). Erken YBMD hastalar, özellikle okurken hafif merkezi bozulma ve düşük parlaklıkta okuma yeteneğinin azaldığını fark etmektedirler. Geç YBMD ise merkezi görüşü etkiler ve neovasküler YBMD formda hızla ilerlemesi sağlamaktadır. YBMD'nin ilk belirtileri okurken, araba kullanırken veya televizyon izlerken bozuk görme ve merkezi görüşte yüzleri tanımakta güçlük çeken koyu veya gri bir yama içermektedir. Yalnızca bir göz etkilenirse, sağlam göz kapatılmayana kadar semptomlar belirgin olmayabilmektedir (Mitchell ve diğ., 2018).

YBMD gözlerdeki drusen ve pigment değişikliklerinden tespit edilmektedir. Şekil 2.4'te YBMD hastalığı olan bir gözün OKT görüntüsü yer almaktadır.



Şekil 2.4: YBMD hastasının OKT görüntüsü.

YBMD'nin birkaç sınıflandırma sistemi vardır (Bird ve diğ., 1995; Davis ve diğ., 2005; Ferris ve diğ., 2005; Klein ve diğ., 2014). Tablo 2.1'de YBMD için bazı sınıflandırma sistemleri gösterilmiştir.

Tablo 2.1: YBMD sınıflandırma sistemleri.

Sınıflandırma Sistemi	**Hastalık Türü**	**Açıklama**
Wisconsin epidemiyolojik derecelendirmesi (Davis ve diğ., 2005)	Erken YBMD	Büyük (≥125 μm) drusen veya pigment anormallikleri
	Geç YBMD	Neovasküler YBMD
Temel klinik sınıflandırması (Bird ve diğ., 1995)	Yaşlanma değişikliği yok	Drusen ve pigment anormallikleri yok
	Normal yaşlanma değişiklikleri	Küçük drusen (≤63 μm) var ve pigment anormallikleri yok
	Erken YBMD	Orta drusen (>63 μm ve ≤125 μm) var ve pigment anormallikleri yok
	Orta seviye YBMD	Büyük drusen (>125 μm) veya pigment anormallikleri
	Geç YBMD	Neovasküler YBMD
AREDS (Yaşa Bağlı Göz Hastalıkları Çalışması) basitleştirilmiş önem ölçeği puanları (Ferris ve diğ., 2005)	0	Her iki gözde de büyük drusen (>125 μm) veya pigment değişikliği yok
	1	Sadece bir gözde büyük drusen veya pigment değişiklikleri
	2	Sadece bir gözde büyük drusen ve pigment değişiklikleri veya her iki gözde büyük drusen veya pigment değişiklikleri; veya neovasküler YBMD
	3	Bir gözde büyük drusen ve pigment değişiklikleri ve diğer gözde büyük drusen veya pigment değişiklikleri
	4	Her iki gözde büyük drusen ve pigment değişiklikleri

2.3. RETİNA GÖRÜNTÜLEME TEKNİKLERİ

Oftalmolojideki teknolojik gelişmeler, son yıllarda önemli ölçüde gelişen retina görüntüleme yöntemleri ile etkileyici bir hızla ilerlemeye devam ekmektedir. Gözün optik özellikleri, retinanın görselleştirilmesine ve görüntülenmesine yardımcı olmaktadır. En çok kullanılan retina görüntüleme yöntemleri aşağıda açıklanmıştır.

2.3.1. Fundus Görüntüleme

Fundus kameralarının başlangıç noktası W. Jackman ve J. Webster (1886)'nın, canlı bir insan gözündeki retinanın fotoğrafını 2,5 saniyede çekmeleridir. Bu sayede optik diskin ve zor görülebilen bazı retina damarların siyah beyaz bir görüntüsünü elde etmişlerdir (Häner ve diğ., 2023). Fundus görüntüsü, gözün iç yüzeyinin bir yansımasıdır. Bu görüntüler retina yüzeyi, retina damarları, makula ve optik disk gibi gözlemlenebilir biyolojik yapılar hakkında bilgi içermektedir. Görüntü sensörleri tarafından görüntüler üç renkte kaydedilmektedir. Mavi ışık, normalde beyaz ışıkta neredeyse saydam olan ön retina katmanların görünürlüğünü artırmaktadır. Mavi ışık, RPE ve kan damarları tarafından emilerek, fundusun ön katmanlarındaki yansımaların ve saçılmanın arttığı koyu bir arka plan sağlamaktadır. Yeşil ışık kan tarafından emilir, ancak RPE tarafından mavi ışıktan daha fazla yansıtılmaktadır. Yeşil ışık mükemmel kontrast ve retinanın en iyi genel görünümünü sağlamaktadır. Retina damarlarının, kanamalarının, drusenın ve eksudaların görünürlüğünü arttırmaktadır. Kırmızı ışıkta, RPE daha şeffaf görünür ve koroid desenini ortaya çıkarmaktadır. Genel fundus kontrastı, kırmızı aydınlatma ile büyük ölçüde azalmaktadır. Retina damarları daha açık görünür ve daha uzun dalga boylarında daha az belirgin hale gelmektedir. Optik sinir daha hafif ve neredeyse özelliksiz görünmektedir. Kırmızı ışık, pigment bozukluklarını, koroid yırtılmalarını ve koroid bölünmelerini görüntülemek için kullanılmaktadır (Bennett ve Barry, 2009).

Şekil 2.5'te gösterilen fundus kameralar sayesinde fundus görüntüler elde edilmektedir. Fundus görüntüleme optik disk, makula ve retina anormalliklerinin görünümünü sağlamak için kullanılan popüler bir görüntüleme tekniğidir (Adiga, 2019). Fundus görüntülerinin basit ve uygun maliyetli bir tekniktir ve görüntülerin hızlı bir şekilde göz doktorlarının analiz etmelerini, taramalarını ve olası klinik önerilerde bulunmasını sağlamaktadır (Qureshi ve diğ., 2015).



Şekil 2.5: Fundus kamerası (NIDEK AFC-330).

2.3.2. Optik Koherens Tomografisi

OKT teknolojisi ilk olarak 1991 yılında Massachusetts Institute of Technology'de geliştirilmiştir. Ses yerine yakın kızılötesi ışığın kullanılması dışında ultrasona benzemektedir. Retinanın farklı katmanlarından geri saçılan ışığın dönüş süresi gecikmesi ölçülür ve analiz edilmektedir. Retina kalınlığı, yansımadaki en yüksek değişim oranlarını arayarak doku sınırlarını tespit etmek için bilgisayar algoritmaları kullanılarak enine kesit görüntülerin işlenmesiyle hesaplanmaktadır (Bennett ve Barry, 2009).

OKT görüntüleme, retina hastalıklarının saptanmasında objektif ölçüm ve klinik değerlendirme için makula, retina sinir lifi tabakası ve optik sinirin doğrudan enine kesitsel görüntülerini sağlamaktadır (Bennett ve Barry, 2009). Farklı oftalmik ve nörolojik hastalıklar, retinanın farklı katmanlarını çeşitli şekillerde etkilemektedir. Örneğin, neovasküler YBMD genellikle retinanın altındaki sıvı ile karakterize edilmektedir (Pekala ve diğ., 2019). OKT özellikle makula deliklerinin, makula ödeminin, retina altı sıvının ve RPE dekolmanlarının saptanmasında kullanılmaktadır (Bennett ve Barry, 2009).

Oftalmolojide OKT, DR ve YBMD'nin tanı ve tedavi yönetiminde etkilidir. OKT, oftalmologlar arasında yaygın olarak kabul edilen invaziv olmayan bir görüntüleme yöntemidir (Badar ve diğ., 2020). OKT invaziv olmadığından neredeyse tüm hastalarda kolaylıkla kullanılmaktadır (e. V. ve diğ., 2017). Gelişmiş dünyada çalışma çağındaki nüfus arasında önde

gelen körlük nedeni olan DR (Cheung ve Wong, 2008) ve Kuzey Amerika'da ve diğer gelişmiş ülkelerde 50 yaş ve üstü hastalarda merkezi görme kaybının önde gelen nedeni olan YBMD tespitinde OKT yaygın bir şekilde kullanılmaktadır (Bressler, 2004).

Çeşitli patolojiler ve bunların retina üzerindeki etkileri, retina OKT'de retina yapısını doğru bir şekilde analiz edebilmenin önemini ve özellikle doğru OKT bölütlemenin önemini ortaya koymaktadır. Manuel bölütleme emek ve zaman yoğun bir iş olmaktadır. Bu nedenle otomatik, güvenilir, doğru OKT bölütlenmesi, OKT teknolojisinin kullanışlılığını daha da genişletmek için çok önemli olmaktadır (Pekala ve diğ., 2019).

Şekil 2.6'da gösterilen OKT sistemleri sayesinde, retina katmanlarını ve altındaki koroidin ayrıntılı bir enine kesit görüntüsünü sağlayan OKT görüntüleri elde edilmektedir.



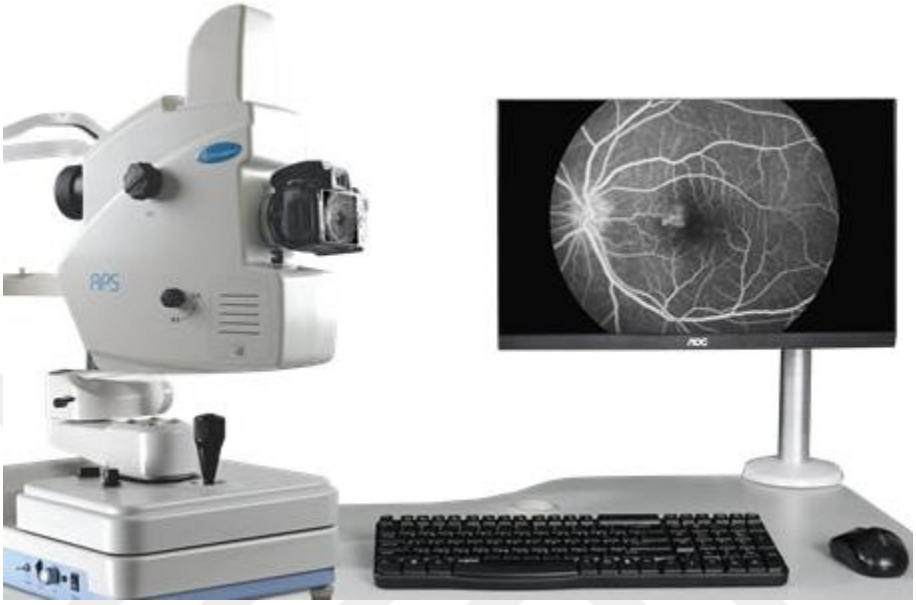
Şekil 2.6: OKT görüntüleme sistemi (ZEISS CIRRUS 5000).

2.3.3. Floresan Anjiyografi

FA'nın oftalmolojideki klinik rolü, iki tıp öğrencisi Herald Novotny ve David Alvis tarafından keşfedilmiştir (Marmor ve Ravin, 2011). Novotny ve Alvis, retinayı görüntülemek için mavi ve yeşil olmak üzere iki farklı filtreyi kullanmışlardır. 1961'de yayınlanan makalelerinde bildirilen ilk FA görüntülerini başarıyla elde etmişlerdir (Novotny ve Alvis, 1961).

FA'yı gerçekleştirmek için steril sulu bir solüsyonda sodyum floresein damardan enjekte edilmektedir. Kan dolaşımındaki floresan çoğunluğu proteinlere bağlanırken, %20'si bağlanmamaktadır. Sodyum floresan, mineral bazlı bir boyadır; mavi ışıkla uyarıldığında sarı-yeşil ışık veya floresan ışık yayar. FA, filtrelerle donatılmış bir fundus kamerası kullanarak çalışmaktadır. Flaştan gelen beyaz ışık, mavi bir uyarma filtresinden geçirilir ve daha sonra gözdeki atardamar ve damarlardan geçen bağlanmamış floresan molekülleri tarafından

emilmektedir. Moleküller daha sonra sarı-yeşil spektrumda daha uzun dalga boyuna sahip ışık yaymaktadır. Kameradaki filtre diğer dalga boylarını bloke eder, bu nedenle yakalanan görüntü yalnızca floresan molekülleri tarafından yayılan ışığı göstermektedir (Agarwal, 2008; ETDRS, 1987). FA sistemi Şekil 2.7'de gösterilmiştir.



Şekil 2.7: Floresan anjiyografi sistemi (APS-BER).

FA, invaziv bir tanı prosedürüdür. Retina ve koroidal dolaşımın anatomisini, fizyolojisini ve patolojisini değerlendirmeye yardımcı olmaktadır. Çeşitli retina hastalıklarının teşhisinde yardımcı olmaktadır (Khalilipour ve Hajizadeh, 2023). FA'nın ayrıca bir takım potansiyel yan etkileri bulunmaktadır. En sık görülen komplikasyonlar, hastaların yaklaşık %2,9'unda meydana gelen geçici mide bulantısı ve hastaların %1,2'sinde kusmadır (Kwiterovich ve diğ., 1991).

2.3.4. Ultrasonografi

Ultrasonografi (US), bir dönüştürücüden hedef dokuya yüksek frekansta iletilen ses dalgalarını kullanarak ve ardından değişen süre ve genliklerde dönüştürücüye geri dönen ses dalgalarını kullanarak gözün bir görüntüsünü oluşturmaktadır. Bu sinyaller daha sonra yorumlanır ve gözün iki boyutlu bir görüntüsünü oluşturmak için toplanmaktadır (D. J. Coleman ve diğ., 1977). Daha yüksek genlikler, dönüştürücüye daha fazla sinyal yansıtan ve görüntüde daha beyaz renkli görünen daha yüksek doku yoğunluklarına karşılık gelmektedir. Düşük genlikler, çok fazla ultrason sinyali yansıtmayan düşük yoğunluklu dokuları ifade etmektedir. US en çok, retinanın oftalmik muayenede doğrudan görüntülenemediği damar kanaması veya diğer medya

opasiteleri olan hastalarda kullanılmaktadır. US, bir retina dekolmanı olup olmadığını göstermektedir. Ayrıca damar kanaması veya arka damar dekolmanı gibi diğer retina patolojileri gösterebilmektedir (McLeod ve Restori, 1979).

Oftalmologlar 1940'lardan beri tanısal US'yi kullanmışlardır ve 1960'ların başlarında özellikle retina yırtıkları için kullanmaya başlamışlardır US görüntüleme sistemi Şekil 2.8'de gösterilmiştir.



Şekil 2.8: US görüntüleme sistemi (MEDA MD-2300S).

2.4. YAPAY ZEKA

YZ terimi, ilk olarak 1956'da "Öğrenmenin her yönünün veya zekanın herhangi bir özelliğinin prensipte kesin bir şekilde tanımlanabileceği varsayımına dayanarak onu simüle edecek bir makine yapılabilir." amacıyla bir atölye çalışması düzenleyen John McCarthy tarafından ortaya atılmıştır (Schmidt-Erfurth ve diğ., 2018). YZ, insan zekasının özelliklerini gösteren sistemleri anlamayı ve geliştirmeyi amaçlayan felsefe, matematik ve bilgisayar bilimlerini kapsayan bir bilimsel disiplindir (Panch ve diğ., 2018). Öğretme, mantık, kendi kendini düzeltme ve kendi kendini programlama gibi insan zekasının kapsamına giren eylemleri gerçekleştirmek için bir makinenin tasarlanmasını ve geliştirilmesini kapsayan bilim alanıdır. YZ'nin temel amacı, insanların yaptığı işi bilgisayarlara yaptırmaktır (Signorelli, 2018).

YZ sınırsız uygulama ve alana girmiştir. YZ, makinelere "akıl yürütme ve öğrenme" yeteneği vermektedir (Hassani ve diğ., 2020; Kao ve Venkatachalam, 2021). YZ araştırmasının temel hedefleri akıl yürütme, bilgi, planlama, öğrenme, doğal dil işleme, algılama ve nesneleri hareket ettirme ve manipüle etme becerisini içermektedir (Luger ve Stubblefield, 1993; Poole ve diğ., 1998; Russell ve Norvig, 2003). Bu yaklaşımlar istatistiksel yöntemleri, hesaplama zekasını ve geleneksel sembolik YZ'yi içermektedir. Arama ve matematiksel optimizasyon sürümleri, mantık, olasılığa dayalı yöntemler ve ekonomi dahil olmak üzere YZ'de birçok araç kullanılmaktadır. YZ alanı bilgisayar bilimi, matematik, psikoloji, dil bilimi, felsefe, nörobilim, yapay psikoloji ve diğer pek çok alandan yararlanmaktadır (Ongsulee, 2018). Makine öğrenmesi ve DÖ YZ'nin en çok kullanılan yöntemlerinden bazılarıdır. Bunlar arasındaki ilişki Şekil 2.9'da gösterilmiştir.



Şekil 2.9: YZ, makine öğrenmesi ve DÖ arasındaki ilişki.

2.4.1. Makine Öğrenmesi

Makine öğrenimi, 1959'da Arthur Samuel'e göre "bilgisayarlara programlanmadan öğrenme yeteneği" veren YZ'nin bir alt alanıdır (Muñoz, 2012). YZ'de örüntü tanıma ve hesaplamalı öğrenme teorisi çalışmasından geliştirilen (Chauhan ve Singh, 2019) makine öğrenmesi, verilerden öğrenebilen ve veriler üzerinde tahminler yapabilen algoritmaların incelenmesini ve oluşturulmasını araştırmaktadır (Kohavi ve Provost, 1998). Bu tür algoritmalar, örnek girdilerden bir model oluşturarak veriye dayalı tahminler veya kararlar vermektedir. Makine öğrenmesi, iyi performansa sahip algoritmalar tasarlamanın ve programlamanın zor veya mümkün olmadığı bir dizi bilgi işlem görevinde kullanılmaktadır (Ongsulee, 2018).

Makine öğrenmesinin amacı, makinenin performansını en üst düzeye çıkarmak için belirli bir görev için toplanan verilerden öğrenmektir. Dolayısıyla makine öğrenimi, toplanan verilerden yeni şeyler öğrenme sistemidir (Aggarwal ve diğ., 2022).

Makine öğrenmesi, bilgisayarların açık talimatlar kullanmadan belirli bir atamayı gerçekleştirmek için kullandıkları bir dizi algoritma ve istatistiksel modeldir. Makine öğrenimi algoritmaları, temel olarak eğitim verileri sağlayan bir veri örneğine dayanan bilimsel bir model oluşturmaktadır. Model, atamayı gerçekleştirmek için programlamadan tahminlerde bulunmaya veya kararlar almaya yönlendirmektedir. Verilerin davranışlarından sonuca varılmaktadır. Böylece, makine öğrenimi modelleri güvenilir kararlar veya değerli doğru tahminler sağlayabilmektedir (Aggarwal ve diğ., 2022).

En yaygın olarak benimsenen makine öğrenimi yöntemlerinden ikisi denetimli öğrenme ve denetimsiz öğrenmedir. Makine öğreniminin çoğu (yaklaşık yüzde 70'i) denetimli öğrenimdir. Denetimsiz öğrenme yüzdesi 10 ile 20 arasındadır. Yarı denetimli ve takviyeli öğrenme, bazen kullanılan diğer iki teknolojidir (Ongsulee, 2018).

2.4.1.1. Denetimli Öğrenme

Denetimli öğrenme algoritmaları, etiketli örnekler kullanarak eğitim gerçekleştirmektedir. Öğrenme algoritması, karşılık gelen doğru çıktılarla birlikte bir dizi girdi alır ve kendi çıktısını doğru çıktılarla karşılaştırarak öğrenmektedir. Denetimli öğrenme, geçmiş verilerin gelecekteki olası değerlerini tahmin ettiği uygulamalarda yaygın olarak kullanılmaktadır (Ongsulee, 2018).

Denetimli öğrenme yöntemlerindeki eğitim verilerinin etiketli örneklere ihtiyacı bulunmaktadır. Örneğin, bir sınıflandırma problemi için, sınıf etiketli örneklere veya bir regresyon problemi için her örnek için istenen çıktı değerine sahip örneklere ihtiyaç bulunmaktadır. Denetimli öğrenmede test numuneleri olarak da adlandırılan, modelin görmediği numuneler üzerinde tahminlerde bulunulmaktadır (Joshi, 2020).

2.4.1.2. Denetimsiz Öğrenme

Denetimsiz öğrenme, etiketi olmayan verilerde kullanılmaktadır. Denetimsiz öğrenmede, verileri keşfetmek ve içindeki bazı yapıları bulmak amaçlanmaktadır. Örneğin, pazarlama kampanyalarında benzer şekilde ele alınabilecek benzer özelliklere sahip müşteri segmentlerini belirleyebilmektedir. Popüler teknikler arasında kendi kendini organize eden haritalar, en yakın komşu haritalama, k-ortalama kümeleme ve tekil değer ayrıştırma yer almaktadır. Bu

algoritmalar ayrıca metin konularını bölümlere ayırmak, öğeler önermek ve veri aykırı değerlerini belirlemek için kullanılmaktadır (Ongsulee, 2018).

2.4.1.3. Yarı Denetimli Öğrenme

Yarı denetimli öğrenme, denetimli öğrenimle aynı uygulamalar için kullanılmaktadır. Eğitim için hem etiketlenmiş hem de etiketlenmemiş verileri kullanılmaktadır. Bu öğrenme türü sınıflandırma, regresyon ve tahmin gibi yöntemlerle kullanılabilmektedir. Yarı denetimli öğrenme, etiketleme ile ilgili maliyetin tamamen etiketlenmiş bir eğitim sürecine izin vermeyecek kadar yüksek olduğu durumlarda kullanılmaktadır. Bir kişinin yüzünün web kamerasında tanımlanmasını örnek verilebilir (Ongsulee, 2018).

2.4.1.4. Takviyeli Öğrenme

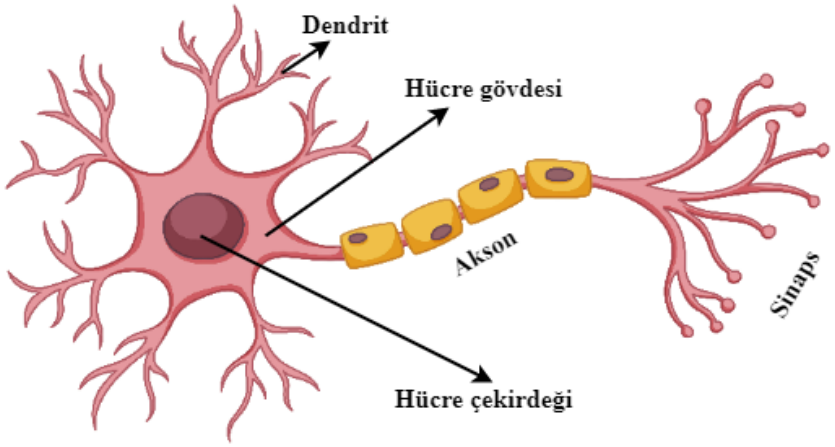
Takviyeli öğrenme genellikle robotik, oyun ve navigasyon için kullanılmaktadır. Takviyeli öğrenme ile algoritma, hangi eylemlerin en büyük ödülleri verdiğini deneme yanılma yoluyla keşfetmektedir. Bu tür öğrenmenin üç ana bileşeni vardır: ajan (öğrenen veya karar verici), çevre (ajanın etkileşimde bulunduğu her şey) ve eylemler (ajanın yapabilecekleri). Amaç, belirli bir süre boyunca beklenen ödülü en üst düzeye çıkaran eylemleri seçmektir. Ajan, iyi bir politika izleyerek hedefe çok daha hızlı ulaşmaktadır. Takviyeli öğrenmede amaç en iyi politikayı öğrenmektir (Ongsulee, 2018).

2.4.2. Yapay Sinir Ağı

Yapay Sinir Ağı (YSA), insan beyni gibi biyolojik nöronların mimarisinden esinlenerek oluşturulmuş bir makine öğrenmesi yöntemidir. İnsan beyni, birbirine bağlı çok sayıda nörondan oluşmaktadır. Her nöron, bir giriş sinyaline yanıt vermek gibi basit bir görevi yerine getiren bir hücredir. Bir nöron ağı, konuşma ve görüntü tanıma gibi karmaşık görevleri inanılmaz hız ve doğrulukla gerçekleştirebilmektedir (Zou ve diğ., 2008). Beynin avantajı, paralel bilgi işlem işleme yeteneğinin olmasıdır. İnsan beyni, birbirine bağlı 10 milyardan fazla nörondan oluşan bir koleksiyondur. Her nöron, bilgi almak, işlemek ve iletmek için biyokimyasal reaksiyonları kullanan bir hücredir (Abraham, 2005).

Bir insan nöronu, Şekil 2.10'da gösterildiği gibi dendritlerden, bir hücre gövdesinden, sinapslardan ve bir aksondan oluşmaktadır. Hücre gövdesinde hücre çekirdeği yer almaktadır. Dendritler, komşu nöronlardan hücre gövdesine bağlanan ve sinyal almak için uzanan dallardır. Akson komşu nöronlara sinyaller göndermektedir. Bir nöronun aksonunun ucu ile komşu nöronun dendritleri arasındaki bağlantı, iki nöron arasındaki iletişim birimi olan sinaps olarak

adlandırılmaktadır. Elektrokimyasal sinyaller sinapslar boyunca iletilmektedir. Bir nöronun aldığı sinyal sinaps eşiğinden büyük olduğunda, nöronun uyarılarak komşu nöronlara elektrokimyasal bir sinyal göndermesini sağlamaktadır (Hebb, 1993).

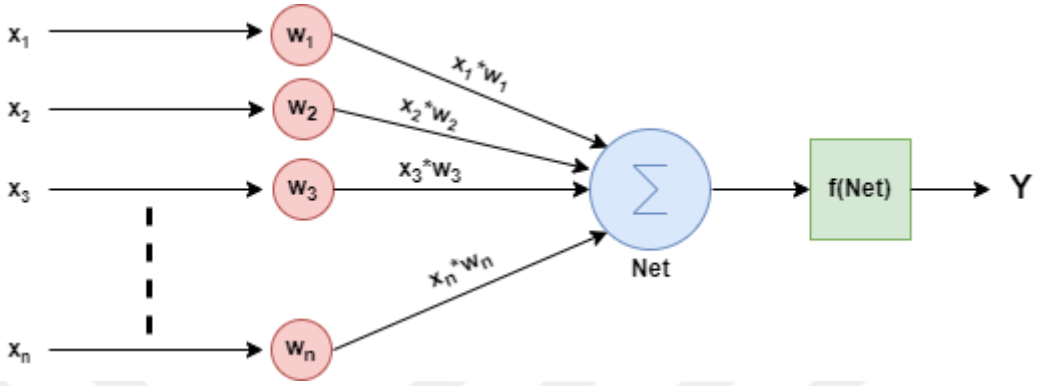


Şekil 2.10: Biyolojik nöron taslağı.

YSA, biyolojik sinir sistemlerinin matematiksel modellerinin geliştirilmesi ile ortaya çıkmıştır (Abraham, 2005). 1943'te McCulloch ve Pitts, bir nöronu diğer nöronlardan girdi alan ve toplam ağırlıklı girdiye bağlı olarak ya etkinleştirilen ya da devre dışı kalan bir anahtar olarak modellemişlerdir. Başka bir hücreden gelen bir girdinin çarpıldığı ağırlık, sinir hücreleri arasındaki sinapslara karşılık gelmektedir (Krogh, 2008). Rosenblatt (1958) tarafından ortaya atılan ve perseptron olarak adlandırılan nöron modeli ile birlikte sunulan öğrenme algoritması, örneklerden öğrenebilen bir yapı sunması ile YSA'lara olan ilgiyi artırmıştır. Ancak Minsky ve Papert (1969), basit perseptronların yalnızca çok sınırlı doğrusal olarak ayrılabilir problemler sınıfını çözebildiğini, doğrusal olmayan problemlerde çalışmadığını gösterdikten sonra bu ilginin azalmasına sebep olmuştur. Basit nöronlardan oluşan oldukça karmaşık ağların örneklerden öğrenmesini sağlayabilen geri yayılım yöntemi (Rumelhart ve diğ., 1986), bu ağların doğrusal olarak ayrılamayan problemleri çözebileceğini göstermiştir.

YSA'nın temel işlem elemanlarına yapay nöronlar veya nöronlar veya düğümler denir. Nöronun matematiksel modelinde sinapsların etkileri bağlı olduğu giriş sinyallerinin etkisini ağırlıklandırarak temsil edilmektedir. Nöronların sergilediği doğrusal olmayan özellik ise aktivasyon fonksiyonu ile temsil edilmektedir. Nöron çıkış sinyali, giriş sinyallerinin ağırlıklı toplamının aktivasyon fonksiyonuna uygulanması ile hesaplanmaktadır (Abraham, 2005).

Tipik bir yapay nöron Şekil 2.11'de gösterilmektedir. Şekil 2.11'e bakıldığında, $x_1,...,x_n$ girişlerinden gelen sinyal akışının, nöronun çıkış sinyal (Y) akışına doğru oklarla gösterildiği gibi tek yönlü olduğu kabul edilmektedir.



Şekil 2.11: Yapay nöron mimarisi.

Nöron çıkış sinyali olan Y aşağıdaki ilişki ile bulunmaktadır.

$$Y = f(Net) = f(\sum_{i=1}^{n} x_i * w_i) \quad (2.1)$$

Denklem 2.1'de Net değişkeni, ağırlık (w_i) ve girdi (x_i) vektörlerinin çarpımı sonucu bulunmaktadır. f(Net) aktivasyon fonksiyonudur ve Net fonksiyonunda üretilen çıktılara göre Y değerini kontrol etmek için yani nöronun aktif olup olmayacağına karar vermek için kullanılmaktadır.

Bir sinir ağı, bir dizi girdinin istenen çıktı kümesini üreteceği şekilde yapılandırılmalıdır. Bunun için sinir ağını, bazı öğrenme kurallarına göre ağırlıklarını değiştirmesine izin vererek eğitmek gerekmektedir. Bir nöronun öğrenme yeteneği, öğrenme algoritmasının sinir ağındaki ağırlıkları probleme uygun biçimde ayarlamasıyla elde edilmektedir.

2.4.3. Derin Öğrenme

DÖ, yapay sinir ağları kullanarak gerçek dünyadaki karmaşık sorunları çözmede insan beyninin düzeyine uyan bir model geliştirmeyi amaçlayan bir makine öğrenmesi dalıdır (Fong ve diğ., 2018; Lake ve diğ., 2016; Richards ve diğ., 2019). İnsan beyni bir grup nörondan oluşmaktadır (Herculano-Houzel, 2009; Schaefer ve diğ., 2021) ve DÖ, DÖ'nin özü olan yapay sinir ağı teknikleri ile insan beynini simüle ederek bu sinirsel bağlantıların seviyesine ulaşmaya çalışmaktadır. Bu nedenle, DÖ, insanların ulaşamayacağı fikir ve sonuçlara varabilmektedir.

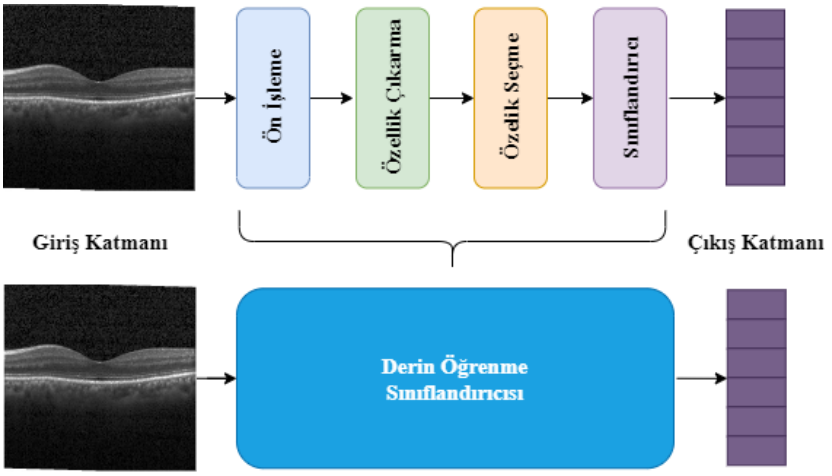
DÖ, görüntü tanıma, hava tahmin, tarım, otomotiv teknolojisi ve medikal alanlarda kullanılmaktadır (Aggarwal ve diğ., 2022).

YSA'nın en popüler türleri DÖ modelleri evrişimli sinir ağı (ESA) (Yamashita ve diğ., 2018) ve tekrarlayan sinir ağlarıdır (TSA) (Schmidt, 2019). ESA, özellikleri çıkarmak için filtreler kullanmak ve ardından genel matris çarpımı yerine evrişimleri kullanarak farklı katmanlarındaki özellikleri ilişkilendirmekle karakterize edilmektedir. Görüntü işleme, bilgisayar görüşü ve örüntü tanıma ESA'ların uygulamalarıdır. Öte yandan, TSA'lar, sıralı veri problemi için gerekli tüm hesaplamaları depolayan dahili belleğe sahip ESA'ların güncellenmiş bir versiyonudur. Bununla birlikte, TSA'ların uzun veri dizilerini işleme yeteneği zayıftır ve sınırlı tabloları vardır; bu nedenle, uzun süreli eğitim verileri için TSA'ların bir uzantısı olarak uzun kısa süreli bellek (Sherstinsky, 2020) önerilmiştir.

Ayrıca, DÖ, büyük miktarda sınıflandırılmış veri sağlamak için önemli çaba gerektirir; örneğin sürücüsüz bir araba geliştirmek, milyonlarca görüntü ve binlerce saatlik video gerekmektedir. DÖ yüksek bilgi işlem gücü gerektirmektedir. Yüksek performanslı grafik işlem birimleri, bu bilim için etkili olan paralel bir mimariye sahiptir. DÖ, kümeler veya bulut bilgi işlemle birleştirildiğinde, topluluk ekipleri derin bir öğrenme ağı için eğitim süresini haftalardan saatlere veya daha azına indirebilmektedir (Aggarwal ve diğ., 2022).

Geleneksel bir sinir ağında gizli katman sayısı 2-3 tane iken, DÖ'de girdi ve çıktı arasında birçok katman olmaktadır. Bir katman yüzlerce hatta binlerce sinir birimine sahip olabilmektedir. Girdi ve çıktı arasında kalan katmanlara gizli katmanlar, düğümlere ise gizli düğümler denir. Bu miktar, DÖ'nin kapsamlı verileri sinirsel bir yapıda eğitme yeteneğine sahip olduğunu göstermektedir. Geleneksel makine öğrenimi sınıflandırıcılarının dezavantajı, karmaşık bir hipotezi kendimiz yazmamız gerekmesidir, derin sinir ağında ise ağın kendisi tarafından üretilir, bu da onu doğrusal olmayan ilişkileri etkili bir şekilde öğrenmek için güçlü bir araç yapmaktadır (Dong ve diğ., 2021). Şekil 2.12'de makine öğrenmesi ile DÖ arasındaki farklılıklar gösterilmiştir. Makine öğrenmesinde, öznitelik çıkarımı manuel yapılmaktadır, DÖ'de öznitelikler otomatik olarak öğrenilmektedir.

DÖ, YSA'nın sınıflandırıcı görevinin yanında özellik çıkarıcı görevini de yapmaktadır. Böylece, tek bir derin sinir ağı ile hem sınıflandırıcı hem de özellik çıkarıcı görevleri yerine getirilmektedir.

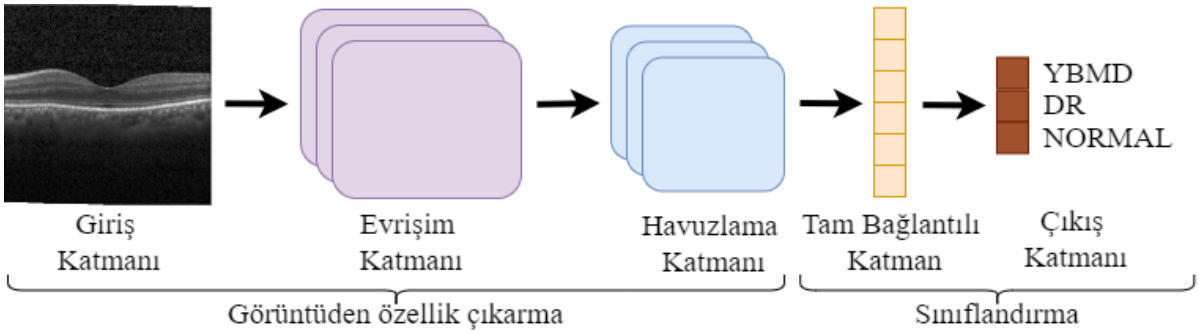


Şekil 2.12: Makine öğrenmesi ve derin öğrenme arasındaki fark.

Bu yeni öğrenme yaklaşımı, uyarlanabilir test, büyük veri, kanser tespiti, veri akışı, belge analizi ve tanıma, sağlık hizmetleri, nesne tespiti, konuşma tanıma, görüntü sınıflandırma, yaya tespiti, doğal dil işleme ve ses etkinliği tespiti alanlarında yaygın olarak kullanılmaktadır. Tensorflow, Pytorch, Keras, Caffe, Theano, Lasagne, MXNet, Pylearn, CNTK ve DIGIT gibi DÖ kütüphaneleri mevcuttur.

2.4.4. Evrişimli Sinir Ağı

ESA, hayvan görsel korteks sisteminden (Fukushima, 1980; Hubel ve Wiesel, 1968) ilham alan ve özellikleri otomatik ve uyarlanabilir bir şekilde öğrenmek için tasarlanmış, bir ızgara desenine sahip verileri işlemek için kullanılan DÖ modelidir. Geleneksel özellik çıkarma yöntemlerinden farklı olarak, giriş katmanı özellikleri otomatik olarak çıkarılmaktadır.



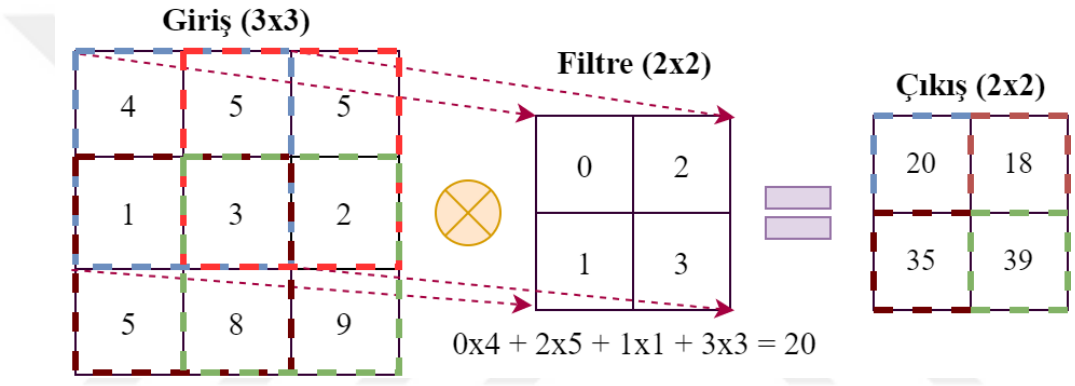
Şekil 2.13: Evrişimli sinir ağı (ESA) mimarisi.

ESA, temelde evrişim, havuzlama ve tam bağlantılı katman olmak üzere üç katmandan oluşan bir yapıdır. Evrişim ve havuzlama katmanları özellik çıkarımı gerçekleştirirken, tam bağlantılı katman çıkarılan özellikleri sınıflandırma yapmak üzere çıkış katmanına iletmektedir. ESA

modeli ve modelin temel katmanlar Şekil 2.13'te gösterilmiştir. ESA modeli katmanlarının görevleri aşağıda açıklanmıştır.

2.4.4.1. Evrişim Katmanı

Evrişim katmanı, özellik çıkarımı gerçekleştiren ESA mimarisinin temel bir bileşenidir. Evrişim katmanı bir dizi filtre içermektedir. Evrişim işleminde, filtre görüntünün sol üst kısmına yerleştirilmektedir. Filtrenin parametreleri ve giriş katmanında eşleşen parametreler ile iç çarpım gerçekleştirilmektedir. Filtre giriş görüntüsü üzerinde soldan sağa ve yukarıdan aşağıya doğru kaydırılarak iç çarpımlar yapılmaktadır. Bu işlemin sonucunda özellik haritası oluşmaktadır. Evrişim katmanın çalışma prensibi Şekil 2.14'te gösterilmiştir.

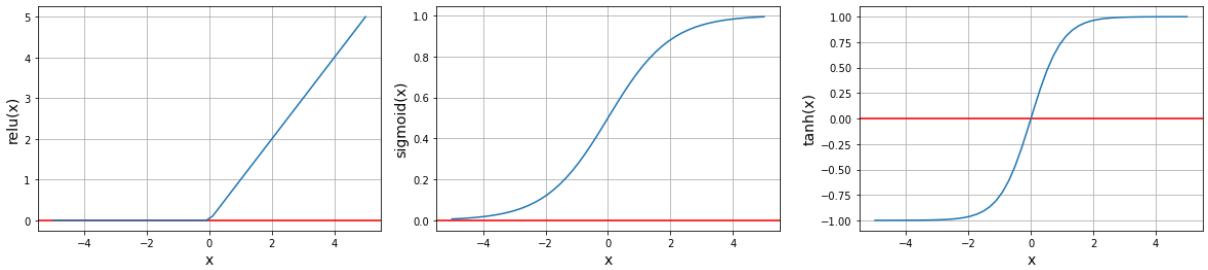


Şekil 2.14: ESA evrişim işlemi.

Evrişim gibi doğrusal bir işlemin çıktıları daha sonra doğrusal olmayan bir aktivasyon fonksiyonundan geçirilir. Denklem 2.2'de görüldüğü gibi ReLU aktivasyon fonksiyonu negatif girişler için 0 değerini alırken, pozitif girişler için ise giriş değerini almaktadır. Bu sayede model eğitilirken öğrenme hızı artmaktadır ve gradyanların ölmesi probleminin önüne geçilmektedir. Çünkü sigmoid ve tanh aktivasyon fonksiyonlarının türevleri hesaplanırken bölme işleminde üstel bir hesaplama yapılırken ReLU'nun türevi ise bir sabittir.

$$f(x) = \max(0, x) \tag{2.2}$$

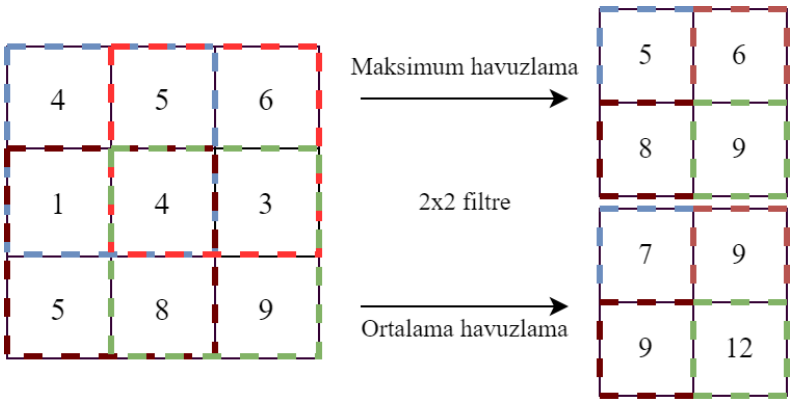
Sigmoid, tanh ve ReLU aktivasyon fonksiyonlarının -5 ile 5 arasındaki girişler için oluşan grafikleri şekil 2.15'te gösterilmiştir.



Şekil 2.15: En çok kullanılan aktivasyon fonksiyonlarının grafikleri.

2.4.4.2. Havuzlama Katmanı

Evrişim katmanından geçen özellik haritalarına havuzlama işlemi uygulanmaktadır. Bu katman giriş özellik haritalarından daha küçük özellik haritalarının oluşturulmasını sağlamaktadır. Havuzlama, seçilen işlemi uygulamak için görüntü üzerinde bir pencere kaydırılarak gerçekleştirilmektedir. En popüler havuzlama işlemleri maksimum ve ortalama havuzlamadır. Ortalama havuzlama girdi değerlerinin ortalamasını alırken maksimum havuzlama ise girdi değerlerinin maksimum değerini almaktadır (Nielsen, 2015). Havuzlama işleminin sağladığı en büyük avantajlar görüntü boyutunun küçültülmesi ve görsel özelliklerin bağımsız olarak görüntü üzerinde çıkarılmasıdır (Nielsen, 2015; Sankar ve diğ., 2016). Bu katman aynı zamanda aşırı öğrenmeyi de azaltmaktadır (Joshi, 2020). Maksimum ve ortalama havuzlama işlem adımları Şekil 2.16'da gösterilmiştir.



Şekil 2.16: ESA maksimum ve ortalama havuzlama işlemleri.

2.4.4.3. Tam Bağlantılı Katman

Genellikle, bir ESA'nın son katmanı tam bağlantılı katmandır. Bu katmanın ana görevi, evrişimli katmanlar ve havuzlama katmanları tarafından çıkarılan özellikler üzerinde sınıflandırma yapmaktır. Özellik haritaları, tam bağlantılı katmanlara giriş olarak verilmek için tek boyutlu bir vektöre dönüştürülmektedir (Lopez Pinaya ve diğ., 2020). Geleneksel YSA'nın

gizli katmanları gibi bu katmandaki tüm nöronlar önceki katmandaki tüm nöronlara bağlı olmaktadır (Rizwan I Haque ve Neubert, 2020).

2.5. LİTERATÜR ARAŞTIRMASI

Retina hastalıklarını tespit etmek için literatürde birçok yöntem bulunmaktadır. Bu tez çalışmasında DÖ kullanılarak OKT görüntülerinden retina hastalık teşhisi yapıldığı için bu bölümde literatürde OKT görüntüleri üzerinde uygulanan DÖ yöntemleri ile ilgili araştırmalar incelenmiştir.

Elgafi ve diğ. (2022) çalışmalarında, OKT kullanılarak DR tespiti için üç adımlı bir sistem sunmuşlardır. Çalışmada ilk olarak, giriş OKT görüntülerinden retina katmanlarını ayrılmışlardır. İkinci olarak, her bir retina katmanından 3 boyutlu özellikler çıkarmışlardır. Son olarak, OKT görüntülerini sınıflandırmak için geri yayılımlı sinir ağları kullanmışlardır. Önerdikleri sistemde çapraz doğrulama kullanarak %96,81'lik bir doğruluk elde etmişlerdir.

Sandhu ve diğ. (2018) DR derecelendirmesi için OKT'yi kullanmışlardır. Retinayı 12 katmana ayırıp ve her katmanın kalınlık, yansıtma ve eğrilik özellikleri belirlemişlerdir. Bu özellikleri kullanarak, görüntüleri normal veya DR olarak sınıflandırması için bir DÖ ağı ile eğitilmişlerdir. Önerilen sistemde %95 doğruluk elde etmişlerdir.

Lee ve diğ. (2017), VGG-16 modelinin değiştirilmiş bir versiyonunu kullanarak 52.690 normal ve 48.312 YBMD OKT görüntüsünü sınıflandırmışlar ve %93,45'lik bir genel doğruluk elde etmişlerdir.

Zhou ve diğ. (2022) YBMD ve DR'yi sınıflandırmak için OKT üç boyutlu görüntüleri kullanan TCAM-Resnet adlı yeni bir ağ yapısı önermişlerdir. TCAM-Resnet, ResNET ağına dayalı bir ağdır. Üç boyutlu bir evrişim dikkat modülü eklemişlerdir. Dikkat modülü, üç boyutlu görüntülerden kan damarlarının özelliklerini çıkarmışlardır ve bu da orijinal verilerin dikkat modülü sırasında daha fazla bilgi alınmasını sağlamışlardır. OCTA-500 veri setindeki deneysel sonuçlar, lezyon özelliği çıkarmada üç boyutlu evrişim ağının iki boyutlu evrişim ağına göre üstün olduğunu göstermişlerdir. Yeni modül eklenmesiyle ResNET hastalık sınıflandırma testlerinde daha yüksek doğruluk elde etmişlerdir. YBMD, DR ve NORMAL'in doğruluğunu %83,3'e, YBMD ve NORMAL'in doğruluğunu ise %98'e ulaşmasını sağlamışlardır.

Subramanian ve diğ. (2022) hafif bir derin sinir ağı kullanılarak retinanın OKT görüntülerinden YBMD, koroidal neovaskülarizasyonu (KNV), DRUSEN, DMÖ, DR, MH, CSR ve Normal gözleri sınıflandırmışlardır. Çalışmalarında Retina OKT görüntüleri veri setinde VGG16 ile %97 civarında. doğruluk elde etmişlerdir.

Baharlouei ve diğ. (2022), normal retina ile CSR, MH, YBMD ve DR olmak üzere dört patolojiyi tanımlamak için dalgacık saçılma ağı kullanmışlardır. Dalgacık saçılma ağı, doğrusal olmayan katsayı ve ortalama alma operatörleri ile basamaklı dalgacık dönüşümünden oluşan özel bir evrişimli ağdır. Bu ağın katmanlarındaki filtreler önceden tanımlanmış dalgacıklardır ve öğrenilmeleri gerekmez, bu da işlem süresinin ve karmaşıklığın azalmasını sağlamaktadır. Araştırmanın sonuçlarına göre OKT görüntülerini normal, CSR, MH, YBMD ve DR beş sınıfını sınıflandırmada %84,2'lik doğruluk elde etmişlerdir.

Perdomo ve diğ. (2019) üç retina OKT taramalarının otomatik olarak sınıflandırılması için uçtan uca DÖ'ye dayalı bir yöntem önermişlerdir. SERI+CUHK veri seti üzerinde sağlıklı, DMÖ ve DR hastalarını sınıflandıran model %93 kesinlik değeri elde etmişlerdir. A2A OKT veri setinde model, YBMD teşhisi için %88,57 doğruluk elde etmişlerdir.

Karri ve diğ. (2017) normal, YBMD ve DMÖ sınıflandırmak için GoogleNet tabanlı sistem önermişlerdir. En iyi modeli elde etmek için tekrarlanan 10 deney için sistem doğruluğu hesaplanmış olup elde edilen en yüksek doğruluğu %96 olarak elde etmişlerdir.

Ji ve diğ. (2018) OKT görüntülerinden YBMD ve DMÖ tanımlaması için transfer öğrenmeye dayalı otomatik bir yöntem sunmuşlardır. Algoritmalarında, retina OKT görüntülerinin sınıflandırma performansını iyileştirmeyi ve eğitim süresini kısaltmayı amaçlamışlardır. İlk olarak, Inception V3 modelinin son birkaç katmanı kaldırmışlar ve kalan kısmı özellik çıkarıcı olarak ekleme yapmışlardır. İki farklı retina OKT görüntü veri seti üzerindeki deneysel sonuçlara göre genel sistemin doğruluğunu %98'in üzerine çıkarmışlardır.

Meng ve diğ. (2018) makalelerinde, OKT görüntülerinden YBMD, DMÖ ve normal görüntüleri ayırmak için daha az hesaplama ile etkili yeniden birleştirilmiş bir artık ESA önermişlerdir. Çalışmalarında, düşük seviyeli ve yüksek seviyeli özellikleri çıkaran evrişimli katmanların bazılarını kaldırarak ve ESA'nın orta seviyeli özelliklerine ayıklama yeteneğini geliştirmişlerdir. Sonuç olarak %90'a varan yüksek genel doğruluk elde etmişlerdir.

Kaymak ve Serener (2018), OKT görüntülerinden DMÖ ve YBMD'nin otomatik tespiti için bir yöntem sunmuşlardır. Kullandıkları yöntem, sağlıklı, kuru YBMD, ıslak YBMD ve DMÖ kategorilerini sınıflandırmak için derin bir öğrenme algoritmasının eğitilmesine dayanmaktadır. Eğitim sırasında kullandıkları AlexNet modelinin doğruluğunu %97,1 olarak elde etmişlerdir.

Rasti ve diğ. (2018), normal retinayı ve iki yaygın makula patolojisini olan YBMD ve DMÖ'yü tanımlamak için topluluk modeline dayanan çok ölçekli evrişimli uzman sistemini sunmuşlardır. Yöntemin değerlendirilmesi için elde ettikleri 148 OKT görüntüsünden oluşan yerel bir veri seti ve 45 OKT görüntüsünden oluşan bir genel veri seti kullanılmışlardır. Sundukları modelde %98,86 kesinlik oranı elde etmişlerdir.

Treder ve diğ. (2018), OKT görüntülerinden YBMD otomatik tespiti için DÖ'yi kullanmışlardır. Bu çalışma için eksudalı YBMD'li hastalara ve sağlıklı bir kontrol grubuna ait toplam 1.112 OKT görüntüsü kullanmışlardır. İlk adımda, 1.012 OKT taraması (YBMD: 701; sağlıklı: 311) derin evrişimli sinir ağı eğitmişlerdir. Son adımda, oluşturulan DÖ sınıflandırıcısı ile 100 eğitilmemiş OKT görüntüsünü (YBMD: 50; sağlıklı: 50) YBMD'yi tespit etmede test etmişlerdir. YBMD için %98 doğruluk elde etmişlerdir.

Serener ve Serte (2019), derin evrişimli sinir ağları kullanılarak kuru ve ıslak YBMD'nin otomatik ve hızlı sınıflandırması önermişlerdir. Sınıflandırmalarda ResNet modelinin AlexNet modelinden daha iyi performans gösterdiği göstermişlerdir. UCSD (University of California San Diego) (Kermany ve diğ., 2018) veriseti üzerinde ıslak YBMD hastalığı için ResNet ve AlexNet modellerinin performanslarını sırasıyla %98,80 ve %96,50 olarak elde etmişlerdir. Ayrıca aynı veri seti üzerinde kuru YBMD hastalığı için ResNet ve AlexNet modellerinin performanslarını sırasıyla %99,50 ve %93,80 olarak elde etmişlerdir.

Banerjee ve diğ. (2019) eksuda olmayan YBMD gözlerinde YBMD ilerlemesi riskini tahmin etmek için hibrit bir sıralı DÖ modeli önermişlerdir. 10 katlı bir çapraz doğrulama ayarında makine öğrenimi modellerini eğitmek ve doğrulamak için 13.954 kuru YBMD gözlemiyle 671 normal gözü içeren veri kümesini kullanmışlardır. Önerdikleri Yinelemeli sinir ağı (RNN) modeli ile hem kısa vadeli hem de uzun vadeli YBMD ilerlemesinin tahmini için yüksek doğruluk elde etmişlerdir.

Wang ve Wang (2019), DMÖ ve YBMD lezyonlarını tespit etmek için iki OKT retina veri seti kullanarak DÖ'ye dayalı otomatik bir yöntem önermişlerdir. Önceden eğitilmiş modeller

üzerinde transfer öğrenme gerçekleştirmişlerdir. Kullandıkları 5 transfer modeli arasında CliqueNet %98'den fazla doğruluk değeri ile diğer ağ modellerine göre daha iyi sınıflandırma sonuçları elde etmişlerdir.

Saha ve diğ. (2019), erken YBMD OKT biyobelirteçlerinin otomatik tespiti ve sınıflandırılması için DÖ yöntemi geliştirmişlerdir. Derin ESA, OKT taramalarından drusen birikintilerinin otomatik tespiti ve sınıflandırılması için özel olarak eğitmişlerdir. 153 hastadan alınan yaklaşık 20.000 OKT tarama içeren bir görüntü veri seti üzerinde birkaç son teknoloji ESA'nın ve farklı transfer öğrenme protokollerinin performansını değerlendirmek için çok sayıda deney yapmışlardır. Erken YBMD biyobelirteçlerinin varlığını belirlemede genel olarak %87'lik bir doğruluk elde etmişlerdir.

Hwang ve diğ. (2019) çalışmalarında, YBMD hastalarından elde edilen etiketli 35.900 OKT görüntüsünden oluşan bir veri seti kullanmışlar ve bunları YBMD tanısını gerçekleştirmek için üç tip ESA'yı eğitmek için kullanmışlardır. Dört YBMD türünün tanılanmasında VGG16, InceptionV3 ve ResNet50 YZ modellerinin doğruluklarını sırasıyla %91,40, %92,67 ve %90,73 elde etmişlerdir.

An ve diğ. (2019) çalışmalarının amacı, normal ve YBMD sonrasında sıvılı YBMD ve sıvısız YBMD'yi sınıflandırmak için OKT görüntüleri ile DÖ modelleri oluşturmuşlardır. Çalışmalarında 185 normal OKT görüntüsü, 535 sıvılı YBMD OKT görüntüsü ve 514 sıvısız YBMD OKT görüntüsü eğitim verisi olarak; 49 normal OKT görüntüsü, 188 sıvılı YBMD OKT görüntüsü ve 154 sıvısız YBMD OKT görüntüsü test verisi olarak kullanmışlardır. DÖ modelleri oluşturmak için görüntü sayısını artırmak için veri artırma uygulamışlardır. İki adımlı sınıflandırma modeli oluşturmuşlardır. İlk adımda, VGG16 modeli ile sıvılı/sıvısız YBMD ile normal sınıflandırmasını yapmışlardır. Daha sonra ikinci adımda, birinci adımda ince ayarı yapılan model ile YBMD'nin sıvılı görüntülerini sıvısız görüntülerinden ayırt etmek için sınıflandırma yapmışlardır. İlk model ile normal ve YBMD OKT görüntülerini %99,2 doğrulukla sınıflandırmışlardır. İkinci modelde, sıvılı YBMD ve sıvısız YBMD'yi %95,1 doğrulukla sınıflandırmışlardır.

Motozawa ve diğ. (2019) çalışmalarında, OKT taramalarından YBMD'yi ayırt etmek için DÖ modelleri oluşturmak amaçlamışlardır. YBMD'li hastalar ve sağlıklı bir kontrol grubuna ait toplam 1621 OKT görüntüsü incelemişlerdir. İlk ESA modeli, 1382 YBMD görüntüsü ve 239 normal görüntü kullanılarak eğitmişler ve doğrulamışlardır. İkinci transfer öğrenme modeli,

eksuda değişiklikleri olan 721 YBMD görüntüsü ve eksuda içermeyen 661 YBMD görüntüsü ile eğitmişler ve doğrulamışlardır. İlk ESA modelini kullanarak YBMD ve normal OKT görüntülerini %99 doğrulukla sınıflandırmışlardır. İkinci transfer öğrenme modelinde, YBMD'yi %93,9 doğrulukla eksuda değişikliklere sahip olan veya olmayan olarak sınıflandırmışlardır.

Hassan ve diğ. (2020), retina OKT taramalarından sağlıklı, YBMD, DMÖ ve KNV sınıflandırmasını sağlamak için kademeli çok çekirdekli konvolüsyonlarla artık bağlantıları kullanan ve optimum eğitim sağlayan RRI-Net'i önermişlerdir. 108.312 OKT taraması kullanarak kapsamlı bir RRI-Net eğitimi gerçekleştirmişler ve önerilen çerçevenin performansını 1.000 OKT taraması üzerinde test etmişlerdir. Sonuçlar, RRI-Net'in sağlıklı, YBMD, DMÖ ve KNV arasındaki çok sınıflı sınıflandırma probleminde %98,8 doğruluk elde etmişlerdir.

A. Thomas, Harikrishnan, Ramachandran ve diğ. (2021) YBMD veya normal görüntüleri sınıflandırmak için altı evrişimli katmana sahip çok ölçekli ve çok yollu bir ESA modeli önermişlerdir. Çok ölçekli evrişim katmanı ile çeşitli filtre boyutlarıyla çok sayıda yerel yapının oluşturulmasını sağlamışlardır. Önerdikleri ağda destek vektör makinesi, çok katmanlı algılayıcı ve rastgele orman gibi farklı sınıflandırıcılar kullanılarak on katlı çapraz doğrulama yöntemlerini kullanmışlardır. ESA ağını, dört veri seti üzerinde eğitmişler ve %96,66, %98,97, %99,74 ve %99,78 doğruluk oranlarını elde etmişlerdir.

A. Thomas, Harikrishnan, Krishna ve diğ. (2021), YBMD'nin doğru teşhisi için yeni bir çok yollu ESA mimarisi önermişlerdir. Önerdikleri mimari, YBMD veya normal görüntüleri sınıflandırmak için kullanılan beş evrişimli katmana sahip çok yollu bir ESA'dır. Önerdikleri bu ağda sınıflandırıcı olarak sigmoid fonksiyonu kullanmışlardır. Önerdikleri ESA ağı, UCSD veri kümesi üzerinde eğitmişlerdir. Dört veri kümesi (UCSD, OCTID, Duke ve SD-OCT Noor) üzerinde değerlendirmişler ve sırasıyla %99,60, %99,61, %96,67 ve %93,87 doğruluk elde etmişlerdir.

Sotoudeh-Paima ve diğ. (2022), özellik piramit ağı yapısına dayalı çok ölçekli bir ESA yöntem önermişlerdir. Bu yöntem, kuru ve ıslak YBMD'nin normal ve iki yaygın türü olan drusen ile KNV teşhisi için kullanmışlardır. Önerdikleri yöntemi, bu çalışma için toplanan 441 hastanın 12.649 retina OKT görüntüsünden oluşan veri seti (NEH) ve 4.686 hastanın 108.312 OKT görüntüsünden oluşan UCSD veri seti (2018) üzerinde değerlendirmişlerdir. NEH veri seti

üzerinde 3 sınıflı bir sınıflandırmada %92 doğruluk elde etmişlerdir. Ayrıca UCSD veri setinde 4 sınıflı bir sınıflandırmada %93,90 doğruluk elde etmişlerdir.

Esfahani ve diğ. (2022), geleneksel evrişim katmanından çok daha az sayıda parametre ile farklı boyut ve açılardaki retina sınırlarını doğru bir şekilde çıkarmak için kenar evrişim katmanı adı verilen yeni bir katman tanıtmışlardır. Bu katmanı kullanarak, OCT görüntülerinin otomatik olarak sınıflandırılması için ESA yöntemini önermişlerdir. Önerdikleri yöntemi değerlendirmek için, 15 YBMD, 15 DMÖ ve 15 normal OKT görüntüsünden oluşan bir veri seti kullanmışlardır. Deneysel sonuçlara göre önerdikleri yaklaşım üç sınıflı bir sınıflandırmada ortalama %99,43'lük bir kesinlik performansı elde etmişlerdir.

Nabijiang ve diğ. (2022), blok dikkat mekanizması adlı yeni bir dikkat mekanizması önermişlerdir. Blok dikkat mekanizması ile tüm özellik haritasındaki bloklar arasındaki ilişki araştırılıp ve blokların önemini vurgulamak için farklı bloklara karşılık gelen katsayılar atanmıştır. Ayrıca, özellik haritasının kenar elemanları arasındaki ilişki araştırılıp özellik haritasındaki öğelerin önemini vurgulamak için özellik haritasında farklı konumlardaki öğelere karşılık gelen katsayılar atanmıştır. Deneysel sonuçlar, önerdikleri çerçevenin UCSD (Normal, KNV, DMÖ ve drusen) ve SD-OCT (YBMD, KNV ve DMÖ) iki genel retina veri kümesinde, sırasıyla %99,64 ve %96,54 doğruluk oranı elde etmişlerdir.

Eltanboly ve diğ. (2018), OKT görüntülerinden non-proliferatif DR'nin keşfi ve derecelendirilmesi için gelişmiş bir bilgisayar destekli tanı sistemi geliştirmişlerdir. Önerilen tanı sistemi birbirini takip eden üç aşamayı oluşmaktadır. Başlangıçta, şekil, yoğunluk ve mekansal bilgileri birleştiren bir ortak modele dayanan önceden geliştirdikleri bölütleme yaklaşımlarını kullanılarak 12 farklı retina katmanı elde etmişlerdir. İkinci olarak yansıma, eğrilik ve kalınlık bölünmüş katmanlardan ölçülmüştür. Son olarak, yığılmış negatif olmayan kısıtlama otomatik kodlayıcı (SNCAE) tarafından eğitilen iki aşamalı bir derin füzyon sınıflandırma ağı ile önce normal ve DR olarak, ardından DR derecesini erken evre ve hafif/orta olarak değerlendirmek için kullanmışlardır. 74 OCT görüntüsünden oluşan veri kümesi üzerinde tanı sistemi, %93 doğrulukla normal ve DR arasına sınıflandırma başarısıve %98 doğrulukla erken evre ve hafif/orta DR arasında sınıflandırma başarısı elde etmişlerdir.

Xuechen Li ve diğ. (2019) çalışmalarında, otomatik erken evre DR teşhisi için OKT görüntü tabanlı bir teşhis teknolojisi olan OCTD_Net'i önerdiler. Ağ, derin özellikleri ve katman bilgisini birleştirmek için iki bağımsız ağdan oluşmaktadır. Ağlardan biri orijinal OKT

görüntüsünden öznitelikleri çıkarırken, diğeri retina katmanı bilgisini çıkarmaktadır. Ağın doğruluk, duyarlılık ve özgüllük değerleri sırasıyla %92, %90 ve %95 olarak etmişlerdir.

Rong ve diğ. (2019) ESA'ya dayalı bir retina OKT görüntü sınıflandırma yöntemi önerdiler. Önerilen algoritmayı değerlendirmek için iki veri seti kullanılmışlardır. Gürültüyü azaltmak için önce görüntü üzerindeki gürültüleri temizlediler. Maskeleri çıkarmak için görüntü eşikleme ve morfolojik genişleme uyguladılar. Gürültüden arındırılmış görüntüleri daha sonra CNN modelini eğitmek için kullanmışlardır. Sonuçlar önerilen yöntemin OKT görüntülerini otomatik olarak sınıflandırmak için %95,09 doğruluk elde etmişlerdir.

Elsharkawy ve diğ. (2022) çalışmalarında, yapısal 3 boyutlu retina taramaları kullanılarak DR'yi erken tespit etmek için OKT tabanlı bilgisayar destekli tanı yöntemini önermişlerdir. Bu sistemde görünüm tabanlı bir yöntem kullanarak 3B-OKT taramalarının tüm retina katmanlarını otomatik olarak bölümlere ayırmak için önceki şekil bilgisini kullanmışlardır. Bölümleme adımından sonra, DR teşhisi için OKT B-tarama bölümlenmiş katmanlarından yeni doku özellikleri çıkarmışlardır. Her katmanda özellikleri çıkarmak için Markov–Gibbs rastgele alan modeli kullanmışlardır. Çıkarılan görüntüden özellikleri temsil etmek için kümülatif dağılım fonksiyonu tanımlayıcılarını kullanmışlardır. Katman bazında sınıflandırma için Gibbs enerji özelliği kullanılarak çıkarılan öznitelikleri YSA ile eğitmişlerdir. 100 sağlıklı ve 88 DR OKT görüntüsü için en iyi performansı 10-kat çapraz doğrulama kullanılarak %96,88 olarak elde etmişlerdir.

Kermany ve diğ. (2018) DÖ yapısına dayalı bir teşhis aracı oluşturdular. Sinir ağını eğitmek için transfer öğrenimini kullandılar. Bu yaklaşımı OKT görüntülerinden oluşan bir veri kümesine uygulayarak normal, KNV, drusen ve DMÖ'yü tespit ettiler. KNV, DMÖ, drusen ve normal arasındaki çok sınıflı bir karşılaştırmada, %97,8 duyarlılık, %97,4 özgüllük ve %96,6'lık bir doğruluk elde etmişlerdir.

Das ve diğ. (2019) çalışmalarında sağlıklı OKT görüntülerinden DMÖ ve YBMD'nin iki aşaması olan drusen (erken aşama) ile KNV (geç aşama) sınıflandırılması için yeni bir yöntem sunmuşlardır. Önerdikleri yöntemde, teşhis için ESA kullanan çok ölçekli bir derin çok ölçekli füzyon tabanlı sınıflandırma yaklaşımı sunmuşlardır. Yöntem, farklı sınıf dağılımlarına sahip 84.484 görüntü içeren bir OKT veri seti üzerinde değerlendirmişlerdir. Önerdikleri yöntem, test setinde ortalama %99,6 doğruluk elde etmişlerdir.

Feng Li ve diğ. (2019) DMÖ, drusen, KNV ile sağlıklı gözleri sınıflandırmak için UCSD veri seti kullanmışlardır. VGG-16 ağına ince ayar yaparak için derin transfer öğrenme yöntemini kullanmışlardır. Deneysel sonuçlara göre önerilen yaklaşımın, %98,6 tahmin doğruluğu elde etmişlerdir.

L. Huang ve diğ. (2019), normal retina ile üç yaygın retina hastalığı olan DMÖ, drusen ve KNV sınıflandırmak için katman kılavuzlu evrişimli sinir ağı önermişlerdir. Bölütleme haritalarını oluşturmak için ilk olarak etkili bir bölütleme ağı kullanmışlardır. Ardından önerdikleri ağı, OKT sınıflandırması için eğitmişlerdir. Ağın performansını %88,4 olarak elde etmişlerdir.

Fang ve diğ. (2019), retina OKT görüntüsünün otomatik olarak sınıflandırılması için yinelemeli bir füzyon ESA yöntemi önermişlerdir. Önerdikleri ağda, mevcut evrişim katmanındaki özellikleri yinelemeli olarak ESA ağındaki tüm önceki katmanlarla birleştiren ve böylece OKT görüntülerinin doğru sınıflandırılmasını sağlamak için farklı evrişim katmanlarının özelliklerini birlikte kullanabilen yinelemeli bir füzyon stratejisini benimsemişlerdir. Normal, DMÖ, drusen ve KNV'yi sınıflandırırken yinelemeli bir füzyon stratejisini sunarak, transfer öğrenme ve VGG16 ağlarına kıyasla iyileştirmeler sağlamışlardır. Eğitim için OKT verilerinin onda birini kullanmalarına rağmen ortalama doğruluğu %87,3'e yükseltmişlerdir.

Y. Wang ve diğ. (2020) OKT görüntülerini ıslak YBMD, coğrafi atrofi, drusen ve sağlıklı görüntüler olarak sınıflandırmak için önceden eğitilmiş bir VGG-19 sinir ağı kullanan bir DÖ yaklaşımı önermişlerdir. Islak AMD, coğrafi atrofi, drusen ve sağlıklı görüntüler için sınıflandırma hassasiyeti sırasıyla %91,67, %88,00, %96,30 ve %100 başarı oranları elde etmişlerdir.

AM. Alqudah (2020) çalışmasında, OKT'ye dayalı çok sınıflı bir sınıflandırma sistemi için yeni bir otomatik ESA mimarisi önermiştir. YBMD, KNV, DMÖ ve drusen retina hastalıkları ile normal gözleri sınıflandırmıştır. Softmax sınıflandırıcı kullanan ESA mimarisi, YBMD vakalarının %100'ünü, KNV'li vakaların %98,86'sını, DMÖ'lü vakaların %99,17'sini, drusen vakalarının %98,97'sini ve normal vakaların %99,15'ini genel olarak da tüm vakaların %95,30'nu doğru bir şekilde sınıflandırmıştır.

A. Alqudah ve diğ. (2021), OKT görüntülerinden, gelişmiş OKT mimarisine (AOCTNet) dayalı olarak çıkarılan otomatik özellikler kullanılarak, göz retina hastalıklarının çok sınıflı sınıflandırması için hibrit bir YZ sistemi önermişlerdir. Önerdikleri metodoloji retina

hastalıklarını normal ve dört anormal sınıfa (YBMD, KNV, DMÖ ve Drusen) sınıflandırmak için kullanmışlardır. Önerdikleri sistemi, sekiz makine öğrenme algoritması (LSVM, RBF SVM, YSA, KNN, RF, LDA, QDA ve NB) kullanılarak oluşturmuşlardır. Sınıflandırıcılar yüksek performans elde etmişlerdir. KNN ve RF sınıflandırıcıları ile sırasıyla %99,44 ve %99,12 doğruluk elde etmişlerdir.

AP ve diğ. (2021) retina OKT görüntülerinin sınıflandırılması için 6 evrişim bloğuna sahip derin ESA önermişlerdir. Modelin eğitimi ve doğrulaması, sağlıklı retina görüntüsünün yanı sıra KNV, DMÖ ve drusen 83.484 görüntüden oluşan bir veri kümesi üzerinde yapmışlardır. Önerdikleri yöntemde %99,69 doğruluk elde etmişlerdir.

Anam ve diğ. (2021) çalışmalarında, EfficientNet mimarisine sahip ESA kullanan OKT retina görüntülerine dayalı genelleştirilmiş maküler retinal patoloji için otomatik bir sınıflandırma sistemi önermişlerdir. Ön işleme aşamasında, görüntü üzerinde Gauss Filtresi, Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE) ve Gabor Filtresi olmak üzere üç tür filtre işlemi uygulamışlardır. Adaptive Moment (Adam) ve Stokastik Gradient Decent (SGD) olmak üzere iki farklı optimizasyon yöntemini kullanmışlardır. Deneysel sonuçlara göre önerilen modelin CLAHE ön işleme ve Adam optimizasyon yönteminin dört retina makula patoloji sınıfını sınıflandırabildiğini göstermişlerdir. Drusen, KNV, DMÖ ve Normal sınıflarını %90,60 doğrulukla sınıflandırmışlardır.

3. YÖNTEM

Bu bölümde tez kapsamında yeni veri seti oluşturma aşamaları, UCSD veri seti, uygulanan DÖ yöntemleri ve önerilen hibrit model ile ilgili bilgiler sunulmuştur.

3.1. VERİ SETİ OLUŞTURMA

3.1.1. OKT Görüntülerinin Toplanması

Tez çalışmasında kullanılmak üzere İstanbul İl Sağlık Müdürlüğü Kanuni Sultan Süleyman Eğitim ve Araştırma Hastanesi'ne 23.03.2021 tarihinde OKT görüntülerini almak için talepte bulunulmuştur. Hastane tarafından OKT görüntülerini toplama talebi uygun görülmüştür. Ayrıca Mardin Artuklu Üniversitesi Etik Kurulu'ndan çalışma için etik kurul izni alınmıştır. 2022 yılında uzman bir göz doktoru rehberliğinde görüntüler ".pdf" formatında YBMD, DR ve NORMAL şeklinde gruplanarak toplanmıştır. Toplanan OKT görüntüleri Şekil 3.1'deki ZEISS CIRRUS HD-OCT cihazıyla çekilmiştir.



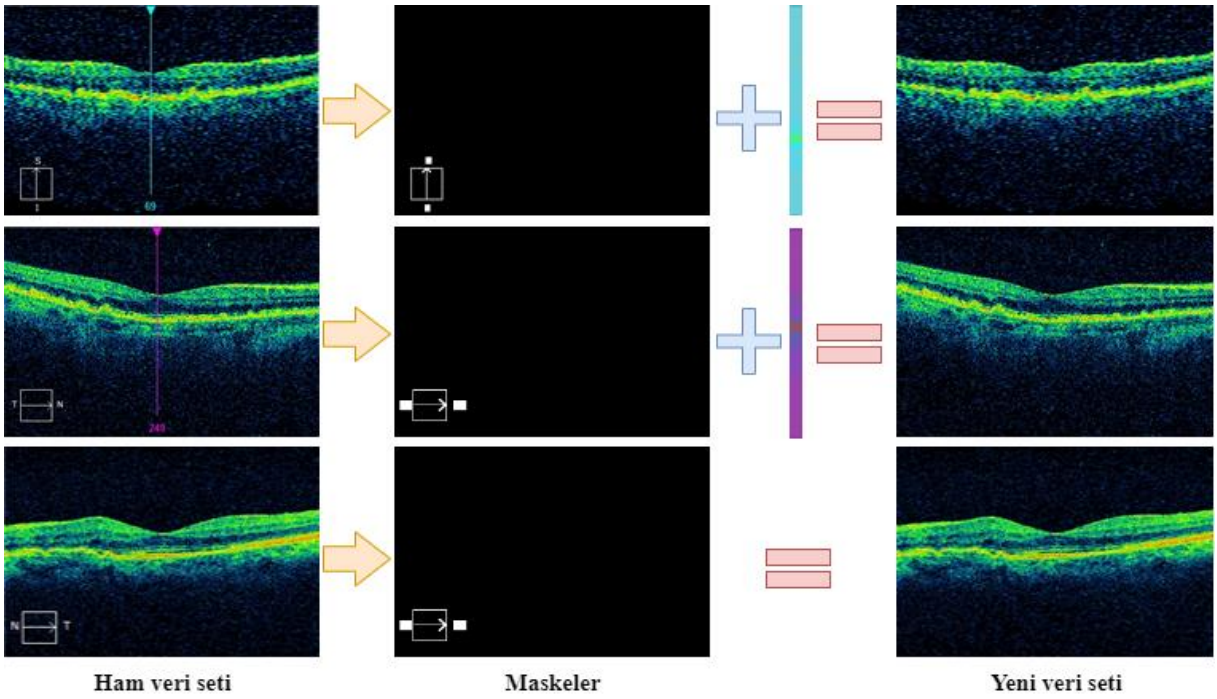
Şekil 3.1: ZEISS CIRRUS HD-OCT.

Çalışma kapsamında ".pdf" formatındaki görüntüler masaüstü uygulamalar kullanılarak 2.010 YBMD, 2.263 DR ve 38 NORMAL görüntü olmak üzere toplam 4.311 adet OKT görüntüsü

elde edilmiştir. Elde edilen görüntüler göz doktoru rehberliğinde teşhiste kullanılamayacak olan 67 görüntü silinmiştir. En sonda 2.009 YBMD, 2.197 DR ve 38 NORMAL görüntü olmak üzere toplam 4.244 adet OKT görüntüsü geriye kalmıştır.

3.1.2. Veri Önişleme

Veri seti OKT görüntülerinin bazıları Şekil 3.2'de gösterilmiştir. Görüntülerde SI, TN, NT şekilleri ile turkuaz veya pembe dikey çizgiler yer almaktadır. Görüntülerden bu gürültüler, Adobe Photoshop'ta oluşturulan maskeler ve OpenCV inpaint yöntemleri kullanılarak temizlenmiştir.



Şekil 3.2: Ham veri setine uygulanan maskeler sonrasında oluşan yeni veri seti örnekleri.

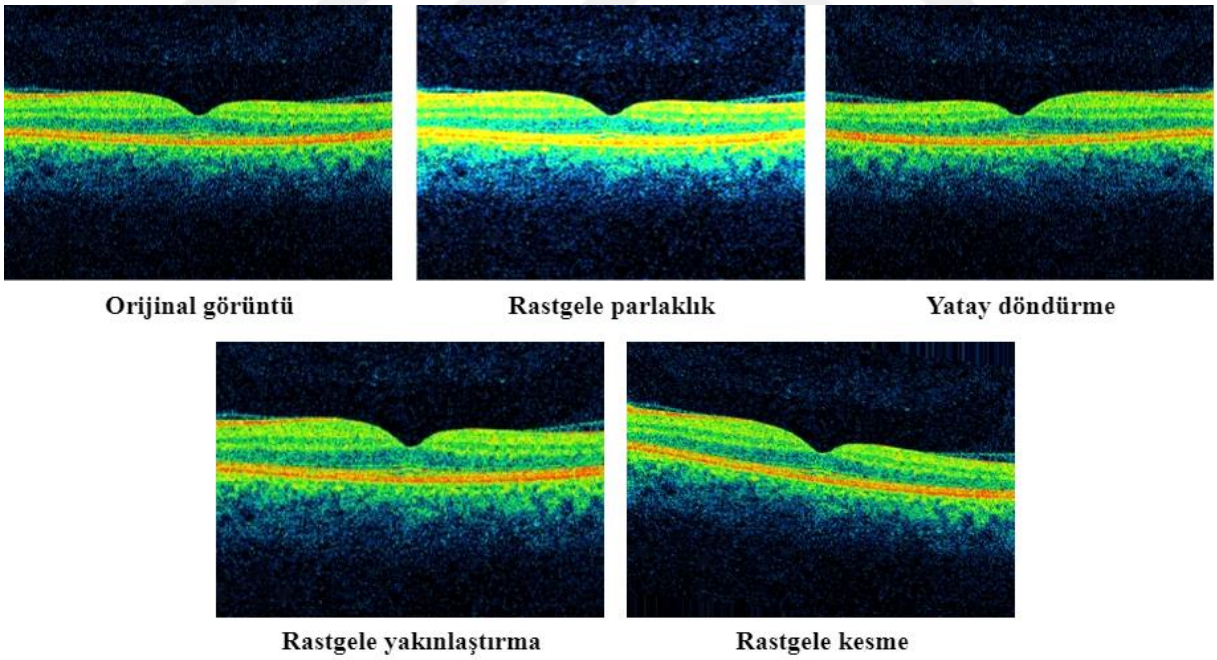
3.1.3. Veri Arttırma

Bir veri kümesinde sınıf dengesizliği, çoğunluk sınıfı örnekleri azınlık sınıfı örneklerine oranla önemli ölçüde yüksek olmasından kaynaklanmaktadır. Bu durum makine öğrenimindeki en zorlu sorunlardan biri olarak kabul edilmektedir (Taherkhani ve diğ., 2020). Standart makine öğrenimi algoritmalarının çoğu bu tür veri kümelerinde düşük performans göstermektedir. Çünkü algoritma çoğunluk sınıfı örneklerini tercih etme eğilimindedir, bu da azınlık sınıfına göre düşük tahmin doğruluğuna neden olmaktadır (Batista ve diğ., 2004).

Dengesiz veri kümeleri, sağlık, bankacılık, güvenlik ve diğerleri gibi farklı alanlarda yaygındır. Veri artırma, azınlık sınıfı örneklerinden daha fazla veri örneği eklenerek bir veri kümesini

yeniden dengelemeyi amaçlayan yaygın bir yaklaşımdır (Ali-Gombe ve Elyan, 2019). Veri kümesi arttırma, sınıflandırma için derin ağların performansını iyileştirmek için özellikle etkili bir teknik olmuştur. Eğitim görüntülerini her yönde birkaç piksel döndürme veya ölçekleme gibi işlemlerin ağ eğitimi için etkili olduğu kanıtlanmıştır (Goodfellow ve diğ., 2016).

Veri seti NORMAL OKT görüntülerinin sayısı DR ve YBMD OKT görüntülerine oranla çok az olduğundan dolayı veri setimiz dengesiz bir veri kümesinden oluşmaktadır. NORMAL OKT görüntülerini artırmak için rastgele parlaklık, yatay döndürme, rastgele yakınlaştırma ve rastgele kesme görüntü işleme yöntemleri kullanılmıştır. Görüntü işleme yöntemleri sonucunda 38 NORMAL OKT görüntüsü 2.163 NORMAL OKT görüntüsüne yükseltilmiştir. Bir OKT görüntüsünün görüntü işleme yöntemleri kullanılarak yeni oluşturulan görüntüler Şekil 3.3'te gösterilmiştir. Rastgele parlaklık, görüntünün parlaklığını rastgele değiştirmektedir. Çoğu zaman görüntülerin istenilen aydınlatma koşulları olmadığı için faydalı bir tekniktir. Yatay döndürme, görüntüyü yatay eksende döndürmektedir. Rastgele yakınlaştırma, görüntüyü rastgele yakınlaştırmakta veya uzaklaştırmaktadır. Rastgele kesme, görüntünün şeklini belirli bir eksen boyunca geometrik büyütüp değiştirmektedir.



Şekil 3.3: Bir OKT görüntüsünün veri artırmadan sonra oluşan yeni görüntüleri.

Tablo 3.1 incelendiğinde veri seti üzerinden yapılan görüntü işleme ve veri arttırma işlemlerinden sonra oluşan veri setinin dağılımı gösterilmiştir. Veri seti 2.197 DR, 2.163

NORMAL ve 2.009 YBMD OKT görüntüsü olmak üzere toplam 6.369 OKT görüntüsünden oluşmaktadır.

Tablo 3.1: Veri arttırmadan sonra veri seti OKT görüntülerinin dağılımı.

Veri Seti Sınıfları	Toplanan OKT Görüntü Sayısı	Görüntü İşlemeden Sonra OKT Görüntü Sayısı	Veri Arttırmadan Sonra OKT Görüntü Sayısı
DR	2.263	2.197	2.197
NORMAL	38	38	2.163
YBMD	2.010	2.009	2.009
Toplam	4.311	4.244	6.369

3.2. UCSD OKT VERİ SETİ

Bu tez kapsamında geliştirilen hibrit model ve dokuz DÖ modelinin performansı, oluşturulan veri seti ve literatürde çok kullanılan UCSD veri seti üzerinde test edilmiştir.

UCSD OKT veri seti, California San Diego Üniversitesi'nde Kermany ve arkadaşları (2018) tarafından oluşturmuşlardır. Görüntüler, Temmuz 2013 ile Mart 2017 arasında California San Diego Üniversitesi Shiley Göz Enstitüsü, California Retina Araştırma Vakfı, Medical Center Ophthalmology Associates, Shanghai First People's Hastanesi ve Beijing Tongren Göz Merkezi'den toplamışlardır. KNV, DMÖ ve drusen olmak üzere üç çeşit retina bozukluğu ve normal vakaları teşhisinde kullanmışlardır. UCSD eğitim veri setinde 26.315 normal, 37.205 KNV, 11.348 DMÖ ve 8.616 drusen olmak üzere toplam 83.484 OKT görüntüsü bulunmaktadır. Ayrıca test veri setinde, modeli değerlendirmek için her bir sınıftan 250 görüntü olmak üzere toplam 1.000 OKT görüntüsü bulunmaktadır.

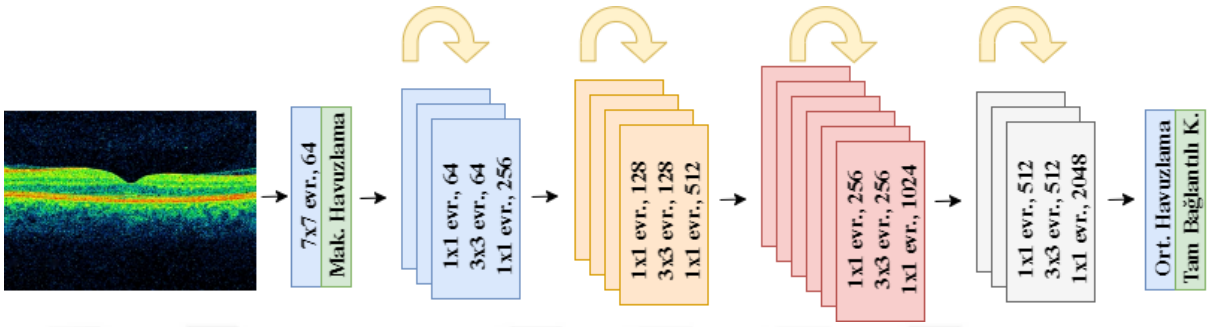
3.3. DERİN ÖĞRENME MODELLERİ

Tez çalışmasında kullanılan; ResNet-50, DenseNet-201, Inception-V3, InceptionResNet-V2, Xception, MobileNet ve EfficientNet DÖ modelleri açıklanmıştır.

3.3.1. ResNet-50 Modeli

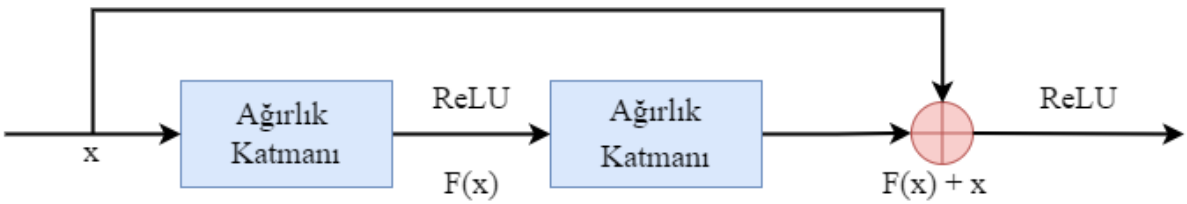
He ve diğ. (2016) tarafından "Deep Residual Learning for Image Recognition (Görüntü Tanıma İçin Derin Artık Öğrenme)" başlıklı araştırma makalesinde yenilikçi sinir ağını tanıtmışlardır. Artık ağların (Residual Networks) kısaltması olan ResNet ağını, artık bağlantıları kullanarak evrişim katman bloklarını atlama fikrine dayanarak performansı iyileştirmek üzere daha derin

ESA yapısı oluşturmaya yardımcı olabilecek kaybolan gradyanlar probleminden kaçınmak için geri yayılımda eğitilebilir parametreleri optimize etmek için kullanmışlardır. ResNet-50 mimarisini, iki havuzlama ve 50 evrişim katmanından oluşturmuşlardır. ResNet-50 mimarisinin blok diyagramı Şekil 3.4'te gösterilmektedir.



Şekil 3.4: ResNet-50 mimarisinin blok diyagramı.

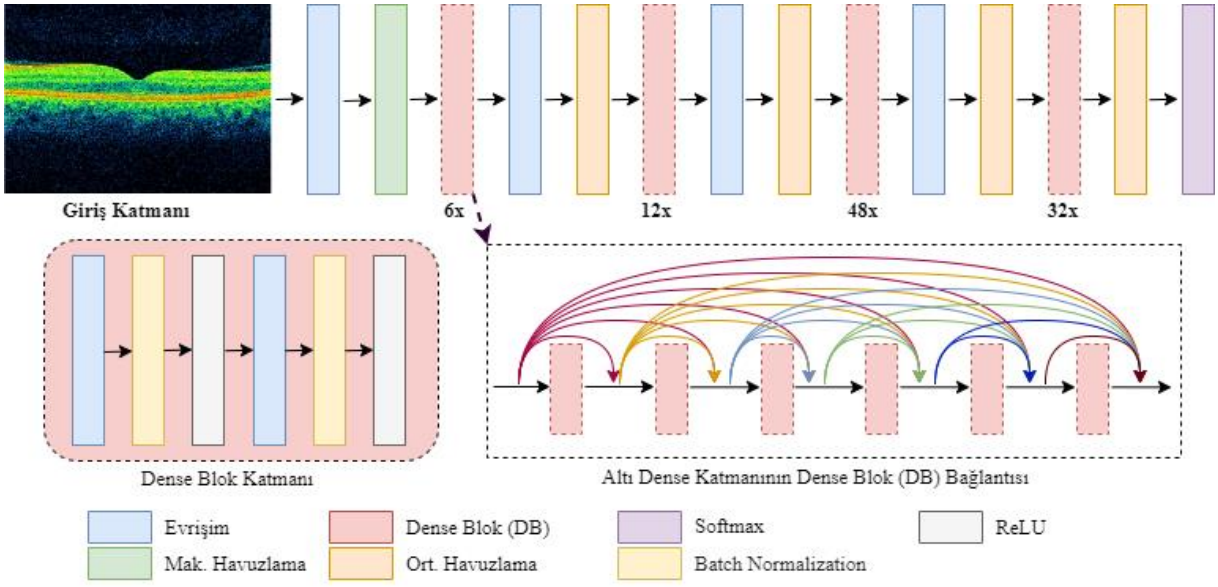
ResNet mimarisi ile Şekil 3.5'te gösterildiği gibi önceki katmandan sonraki katmana çıktı ekleyen bir atlama bağlantısı özelliğine sahip bir artık blok sunmuşlardır. Ağın tipik ESA'dan çok daha fazla katmanla bile kararlılığı koruyabildiğini göstermişlerdir.



Şekil 3.5: Artık ağ blok yapısı.

3.3.2. DenseNet-201 Modeli

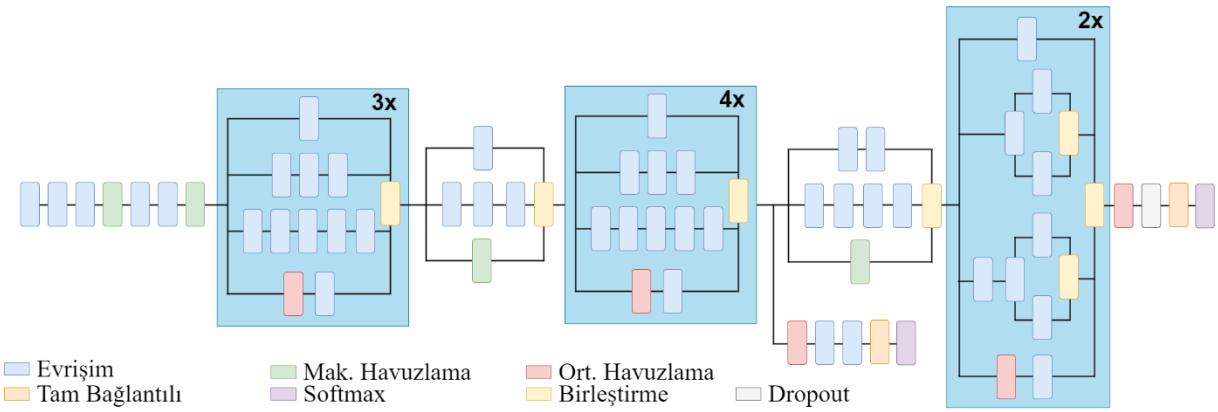
DenseNet, Huang ve diğ. (2017) tarafından önerilmiştir. CIFAR-100 ve ImageNet gibi nesne tanıma veri setlerinde çok iyi performanslar elde etmişlerdir. Ağdaki katmanlar arasındaki bilgi akışını en üst düzeye çıkarmak için, tüm katmanları ileri beslemeli bir şekilde doğrudan birbirine bağlayan bir bağlantı modeli kullanmışlardır. Her katmanda, önceki tüm katmanlardan gelen girdileri almışlar ve bu katmandan sonra gelen katmanlara özellik haritalarını aktarmışlardır. DenseNet mimarisi ile kaybolan gradyan sorununu azaltmayı, özelliklerin yeniden kullanımını, yüksek hesaplama verimliliği ve bellek verimliliği sağlama gibi birçok avantaj elde etmişlerdir. DenseNet-201 bloğunun diyagramı Şekil 3.6'da gösterilmektedir.



Şekil 3.6: DenseNet-201 mimarisinin blok diyagramı.

3.3.3. Inception-V3 Modeli

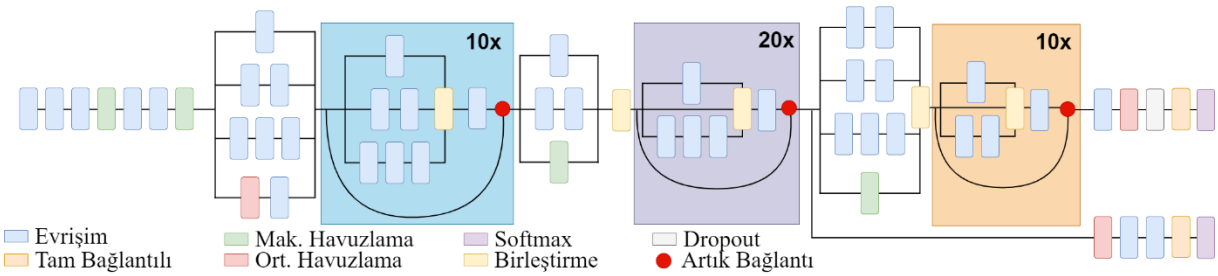
Szegedy, Vanhoucke ve diğ. (2016) tarafından derin bir ESA mimarisi temelli Inception-V3 modelini önermişlerdir. Inception-V3 modelini temel evrişim bloğu, gelişmiş Inception modülü ve sınıflandırıcı olmak üzere üç bölümden oluşturmuşlardır. Temel evrişim bloğunda özellik çıkarımı için evrişim ve maksimum havuzlama katmanlarını değiştirmişlerdir. Gelişmiş Inception modülünde, evrişim katmanlarını paralel olarak bağlamışlar ve sonuçları birleştirmişlerdir. Sınıflandırıcı sayesinde daha kararlı eğitim sonuçları elde etmişler ve kaybolan gradyan ile aşırı öğrenme sorunlarını azaltmışlardır. Inception-V3'te, 1*1 evrişim çekirdeklerini kullanıp parametre sayısını azaltarak ağın eğitim hızını arttırmışlardır (C. Lin ve diğ., 2019). Inception-V3 bloğunun diyagramı Şekil 3.7'de gösterilmektedir.



Şekil 3.7: Inception-V3 mimarisinin blok diyagramı.

3.3.4. InceptionResNet-V2 Modeli

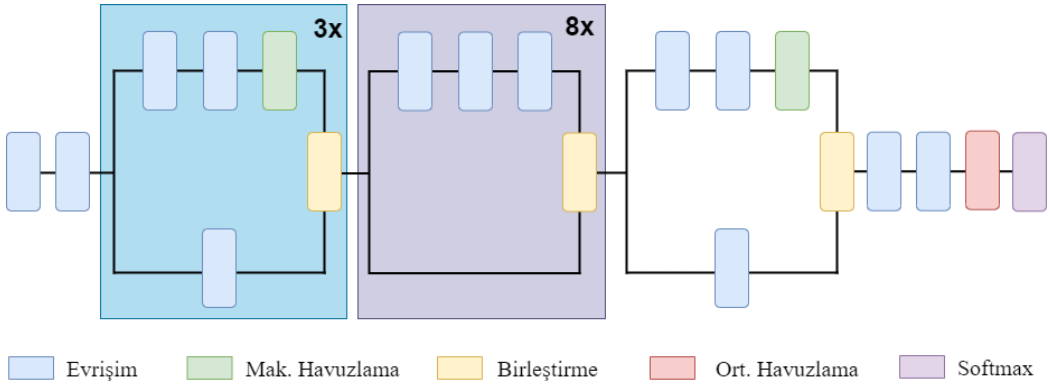
Artık ağını (He ve diğ., 2016) ve Inception mimarisini birleştirerek (Szegedy, Vanhoucke, ve diğ., 2016) InceptionResNet-V2 ağını oluşturmuşlardır (Szegedy, Ioffe, ve diğ., 2016). Şekil 3.8'de gösterilen InceptionResNet-V2 ağının ilk bölümünü sırasıyla üç evrişim, bir maksimum havuzlama, iki evrişim, bir maksimum havuzlama katmanından oluşturmuşlardır. Ağın sonraki bölümlerini, farklı boyutlarda filtreler kullanarak girdileri eşzamanlı olarak yürüten sonra birleştiren ve bu sonuçları sonraki modüllere ileten Inception evrişim katmanlarından oluşturmuşlardır. Bu modüllerin bazılarını birçok kez tekrar ettirerek kullanmışlardır. Ağın sonuna, sonuçları tahmin etmek için softmax katmanı yerleştirmişlerdir (Bhatia ve diğ., 2019).



Şekil 3.8: InceptionResNet-V2 mimarisinin blok diyagramı.

3.3.5. Xception Modeli

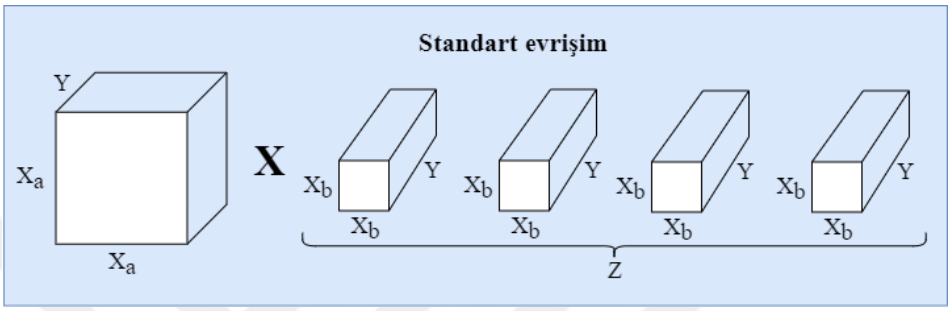
François Chollet (2017), Inception-V3 mimarisinin gelişmiş bir versiyonu olan Xception mimarisini sunmuşlardır. Inception-V3'teki sıradan evrişim işleminin yerine hesaplama maliyetini ve bellek ihtiyaçlarını azaltmak için derinlemesine ayrılabilir evrişim kullanmışlardır. Derinlemesine ayrılabilir evrişim, standart evrişim işlemini derinlemesine evrişim ve noktasal evrişim olmak üzere iki bölüme ayırmışlardır.



Şekil 3.9: Xception mimarisinin blok diyagramı.

Şekil 3.9'da gösterildiği gibi, Xception modelini 3 ortak evrişim katmanı ve 33 derinlemesine ayrılabilir evrişim katmanı olmak üzere 14 bloktan oluşturmuşlardır. İlk ve son modüller dışında diğer modülleri doğrusal artık bağlantılar ile bağlamışlardır.

Şekil 3.10'da standart bir evrişim blok diyagramı gösterilmiştir. X_a, bir kare giriş özellik haritasının yüksekliğini ve genişliği, Y giriş kanallarının sayısını, Z çıkış kanalı ve X_b ise filtrenin boyutunu ifade etmektedir.

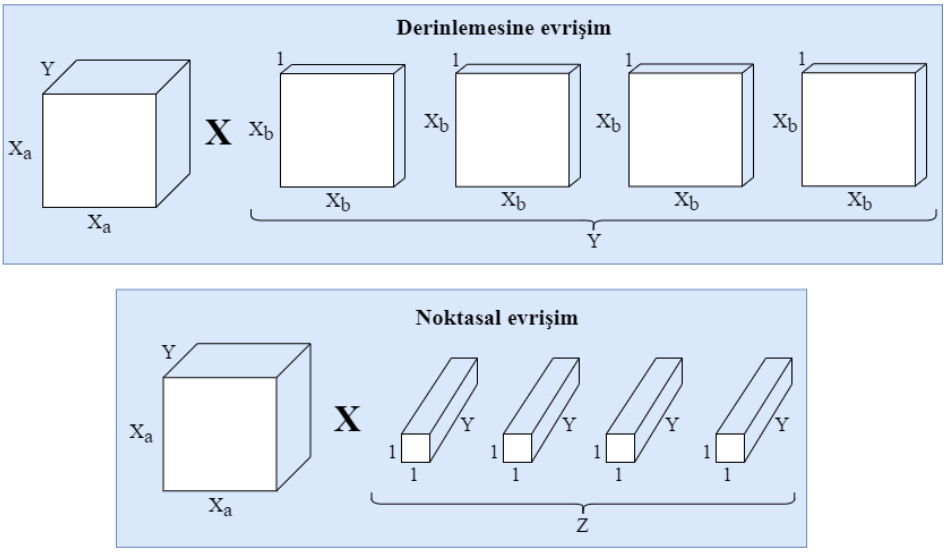


Şekil 3.10: Standart evrişim blok diyagramı.

Standart evrişimin hesaplama maliyeti Denklem 3.1 ile hesaplanmaktadır.

$$X_b * X_b * Y * Z * X_a * X_a \tag{3.1}$$

Şekil 3.11'de derinlemesine evrişim ve noktasal evrişim blok diyagramları gösterilmektedir. Noktasal evrişimde Y giriş özelliğini Z çıkış özelliğine dönüştüren 1*1 evrişimler kullanılmıştır.



Şekil 3.11: Derinlemesine evrişim ve noktasal evrişim blok diyagramları.

Derinlemesine evrişimin hesaplama maliyeti Denklem 3.2 ve noktasal evrişimin hesaplama maliyeti Denklem 3.3 ile hesaplanmaktadır.

$$X_b * X_b * Y * X_a * X_a \tag{3.2}$$

$$Y * Z * X_a * X_a \tag{3.3}$$

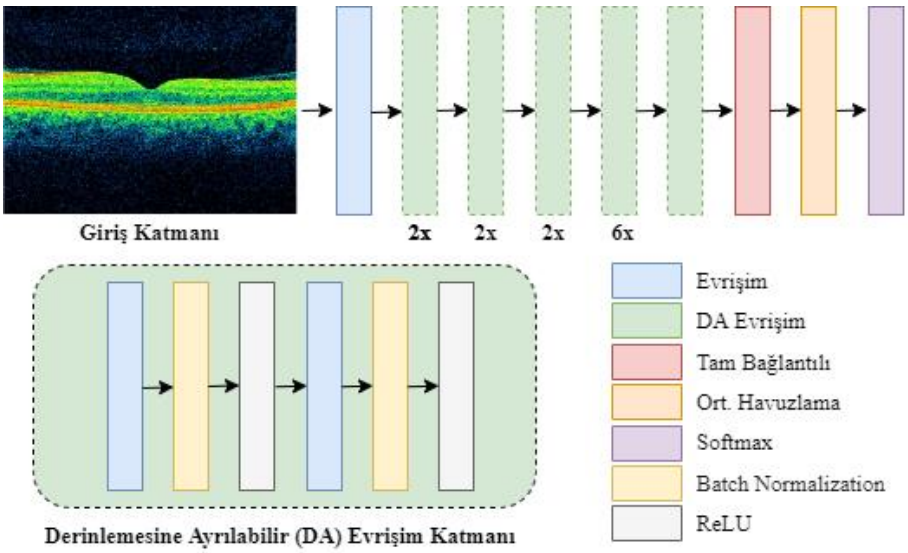
Derinlemesine ayrılabilir evrişimin hesaplama maliyetinin standart hesaplama maliyetine oranı Denklem 3.4 ile hesaplanmaktadır.

$$\frac{D.Evr.}{S.Evr.} = \frac{X_b * X_b * Y * X_a * X_a + Y * Z * X_a * X_a}{X_b * X_b * Y * Z * X_a * X_a} = \frac{1}{Z} + \frac{1}{X_b^2} \tag{3.4}$$

Örneğin Z=1024 ve X_b=4 aldığımızda denklem 3.4'e göre sonuç 0,06 olarak elde edilir. Bu sonuç standart evrişimin derinlemesine ayrılabilir evrişime göre yaklaşık 17 kat daha fazla çarpma yaptığı anlamına gelmektedir.

3.3.6. MobileNet Modeli

Howard ve diğ. (2017), MobileNet ağını sınırlı kaynakları göz önünde bulundurarak DÖ'nin gerçek zamanlı performansını iyileştirmek için geliştirmişlerdir. Bu ağ ile doğruluk performansını değiştirmeden parametre sayısını azaltmışlardır.



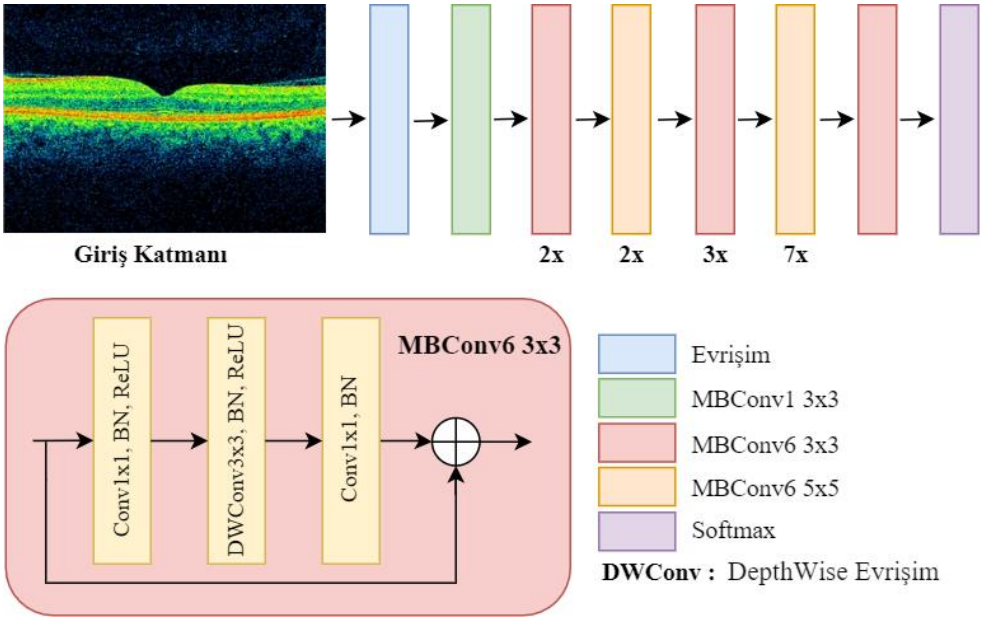
Şekil 3.12: MobileNet mimarisinin blok diyagramı.

Şekil 3.12'de MobileNet'in derinlemesine ayrılabilir evrişim yapısı gösterilmektedir. Derinlemesine ayrılabilir evrişim, derinlemesine evrişim katmanlardan ve noktasal evrişim

katmanlardan oluşmaktadır. Derinlemesine evrişim, her bir giriş kanalında tek bir evrişim gerçekleştirmektedir ve nokta evrişim filtresi derinlemesine evrişimin çıktısını doğrusal olarak 1∗1 evrişimle birleştirmektedir. Her DA evrişim sonunda, toplu normalleştirme (batch normalization) algoritması ve ReLU aktivasyon fonksiyonu yer almaktadır.

3.3.7. EfficientNet Modeli

Tan ve Le (2019), EfficientNet ile diğer son teknoloji modellerin aksine, modeli küçültürken derinliği, genişliği ve çözünürlüğü eşit şekilde ölçeklendirerek daha verimli sonuçlar elde etmişlerdir. Ağ derinliğini, genişliğini ve çözünürlüğünü dengeleyerek daha iyi bir performans elde edilebileceği gözlemine dayanan EfficientNet ailesi, hem hesaplama performansını hem de doğruluğu artırmaya yardımcı olan üç boyutun tümü için sabit oranlara sahip bir bileşik ölçeklendirme yönteminden yararlanmışlardır. EfficientNet grubu B0 ile B7 arasında 8 modelden oluşmaktadır ve model numarası büyüdükçe hesaplanan parametre sayısı fazla artmazken doğruluğu arttırmışlardır. Diğer ESA modellerinden farklı olarak EfficientNet'te, Swish isimli yeni bir aktivasyon fonksiyonu kullanmışlardır. EfficientNet'in ana yapı taşı olan ve ilk MobileNetV2'de tanıtılan MBConv (Sandler ve diğ., 2018) blokları önce kanalları genişleten, sonra bunları sıkıştıran bir katmandan oluşmaktadır. Böylece daha az kanala sahip katmanlar atlayarak bağlamışlardır. EfficientNet-B0, 230 katmana ve 7 MBConv bloktan oluşturmuşlardır (M. Tan ve Le, 2019). EfficientNet-B0 modelinin blok şeması Şekil 3.13'te gösterilmektedir.



Şekil 3.13: EfficientNet-B0 mimarisinin blok diyagramı.

Çalışmada EfficientNet ailesinin EfficientNet-B4, EfficientNet-B7 ve EfficientNet-V2S modelleri kullanılmıştır.

3.4. HİPERPARAMETRE AYARI

Etkili bir makine öğrenmesi modeli oluşturmak için karmaşık ve zaman alıcı bir süreç olan uygun algoritmanın belirlenmesi gerekmektedir. Makine öğrenmesi modellerinde, eğitim sürecinde güncellenen model parametreleri ve modeli eğitmeden önce veri bilimcisi tarafından manuel olarak ayarlanması gereken hiperparametreler olmak üzere iki tür parametre bulunmaktadır. ESA modellerinde, en iyi sonuçları elde etmek için gizli katman sayısı, aktivasyon fonksiyonu, optimizasyon algoritması, öğrenme oranı, küme boyutu (batch size) ve eğitim sayısı gibi hiperparametreler ayarlanmaktadır.

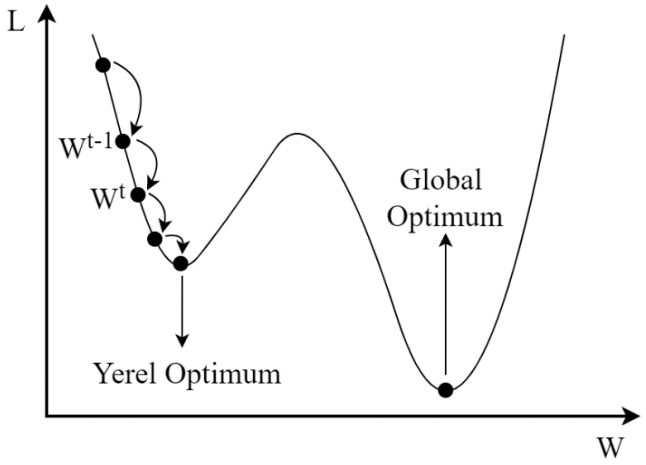
Hem önerilen hibrit modelde hem de bu çalışmada kullanılan diğer DÖ modellerinde öğrenme oranı eğitim boyunca değiştirilerek hiperparametre ayarlaması yapılmıştır. Bengio (2012) öğrenme oranının, genellikle en önemli hiperparametre olduğunu ve her zaman ayarlanması gerektiğini belirtmiştir.

Derin sinir ağlarında ağırlıklar (W) Denklem 3.5 ile güncellenmektedir.

$$W^t = W^{t-1} - \alpha \frac{\partial L}{\partial W^{t-1}} \tag{3.5}$$

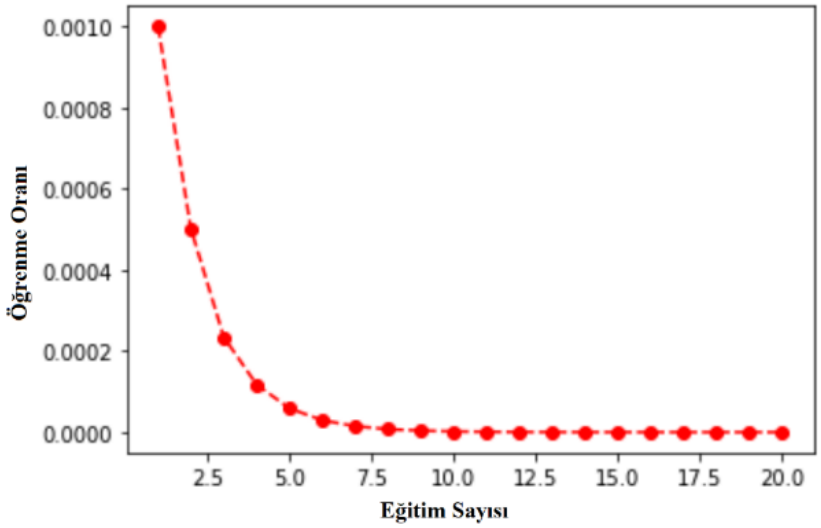
Burada L kayıp fonksiyonunu ve α öğrenme oranını göstermektedir.

DÖ'de geriye yayılım ile geriye doğru ağırlık parametresine göre kayıp fonksiyonunun kısmi türevi alınarak bulunan değerin öğrenme oranı parametresiyle çarpılması ile çıkan sonucun ağırlık değerinden çıkarılması ile yeni ağırlık değerinin güncellenmesi yapılmaktadır. Şekil 3.14'te görüldüğü gibi öğrenme oranının başlangıçta çok küçük olması eğitimin çok uzun sürmesine, yerel optimum değere takılmasına ve global optimum değere hiç ulaşılamamasına neden olabilmektedir. Çok yüksek öğrenme oranı ise salınıma neden olacağından global optimum değere ulaşılamamasına sebep olabilmektedir.



Şekil 3.14: Gradyan iniş.

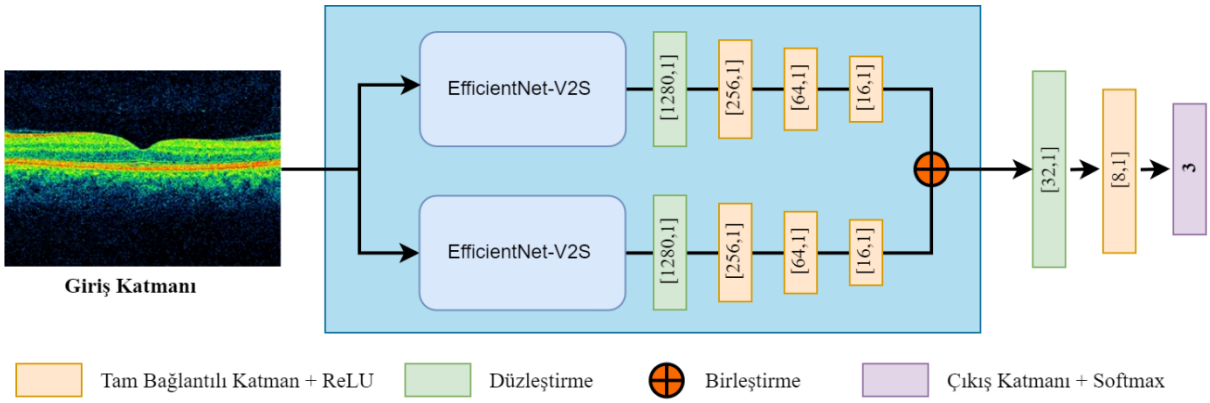
Şekil 3.15'de eğitim başlangıcında öğrenme oranı 0,001 iken eğitim sayısı arttıkça öğrenme oranı yarıya düşürülmüştür. Bunun amacı öğrenme oranını büyükten başlatıp ilk başlarda öğrenme hızının artmasını sağlamaktır. Ancak global optimum değerine ulaşılamaması riskine karşı öğrenme oranı eğitim boyunca düşürülmüştür.



Şekil 3.15: Modelin eğitim boyunca öğrenme oranı.

3.5. ÖNERİLEN HİBRİT MODEL

Bu tez çalışmasında, OKT görüntülerinden retina hastalıklarını tespit etmek ve sınıflandırmak için DÖ tabanlı yeni bir hibrit model geliştirilmiştir. Şekil 3.16'da, geliştirilen hibrit DÖ mimarisi gösterilmiştir.



Şekil 3.16: Önerilen hibrit model.

Önerilen model iki EfficientNet-V2S ESA modeli, üç düzleştirme katmanı, yedi tam bağlantılı katman ve bir çıktı katmanının birleşiminden oluşmaktadır. Her iki transfer öğrenme modelinden sonra gelen bir düzleştirme katmanı ve üç tam bağlantılı katman çıktıları birleştirilmiştir. Birleştirilen çıktılardan sonra bir tam bağlantılı katman yerleştirilmiştir. Tamamen bağlantılı katmanlarda ReLU aktivasyon fonksiyonu kullanılmıştır. Önerilen mimarinin son katmanında kullanılan softmax fonksiyonu, eğitilmiş ağdaki üç sınıf için girdi görüntüsünün olasılıksal dağılımını hesaplanmıştır.

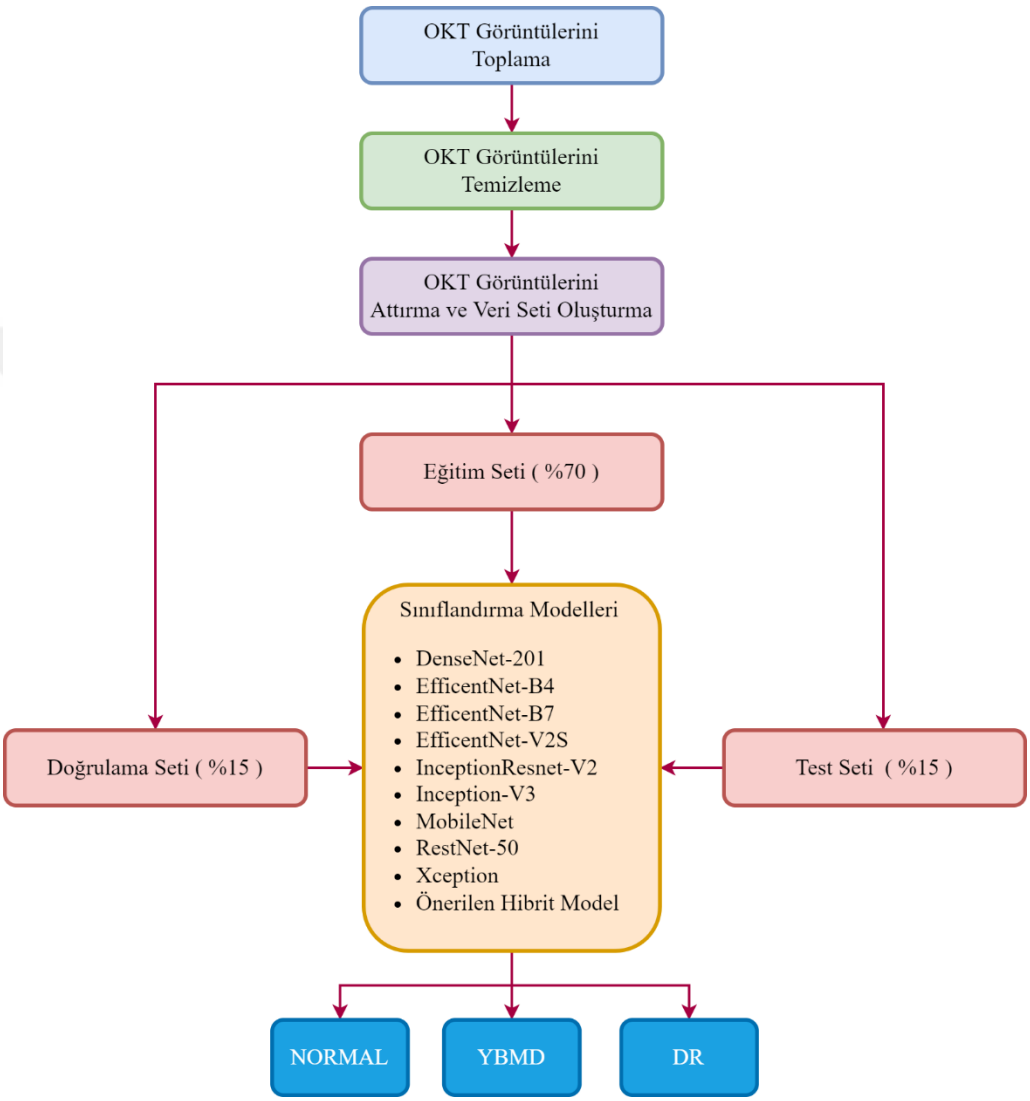
Hiperparametre ayarlı DÖ modellerinin ve önerilen hibrit modelinin parametre değerleri Tablo 3.2'de gösterilmektedir.

Tablo 3.2: Hiperparametre ayarlı derin öğrenme modellerinin ve önerilen hibrit modelinin parametre değerleri.

Parametre	**Değeri**
Giriş katmanı görüntü boyutu	150px * 150px
Aktivasyon fonksiyonu	ReLU, Softmax (Çıkış katmanı)
Optimizasyon algoritması	Adamax
Eğitim sayısı	200
Küme boyutu (batch size)	8
Eğitimi erken durdurma kuralı	Eğitim doğruluk oranı > %99
Öğrenme oranı	0.001 (Her eğitimde yarıya indirilmiştir.)

DÖ ağlarının eğitiminde kullanılacak eğitim sayısının seçimi büyük bir önem taşımaktadır. Çünkü bu sayının çok fazla olması, eğitim veri setinden aşırı öğrenmeye yol açarken, çok az

olması ise yetersiz öğrenme ile sebep olmaktadır. Hiperparametre ayarlı DÖ modelleri ve önerilen hibrit model eğitirken, eğitim doğruluğu %99'a ulaştığında model eğitimi durdurulmuştur. Optimal model ağırlıkları bulunduğu için kaynak israfı (zaman ve hesaplama maliyeti) önlenmiştir.



Şekil 3.17: Tez çalışmasının yol haritası.

Bu çalışma için izlenen adımlar Şekil 3.17'de gösterilmiştir. Çalışma için İstanbul İl Sağlık Müdürlüğü Kanuni Sultan Süleyman Eğitim ve Araştırma Hastanesi'nde ZEISS CIRRUS HD-OCT cihazıyla çekilen OKT görüntüleri uzman bir göz doktoru (Uzm. Dr. Mehmet Masum Taş) rehberliğinde YBMD, DR ve NORMAL şeklinde gruplanarak toplanmıştır. 2.009 YBMD, 2.197 DR ve 38 NORMAL görüntü olmak üzere toplanan 4.244 adet OKT görüntüsü üzerinde yer alan; SI, TN, NT şekilleri ile turkuaz veya pembe dikey çizgileri oluşturulan maskeler ve görüntü işleme yöntemleri kullanılarak temizlenmiştir. Veri setindeki 38 NORMAL OKT

görüntüsü veri arttırma yöntemleri kullanılarak 2.163 NORMAL OKT görüntüsüne çıkarılarak veri seti 6.369 OKT görüntüsüne ulaşmıştır. Veri seti; eğitim seti, doğrulama seti ve test seti şeklinde bölünmüştür.

Eğitim ve doğrulama setleri üzerinde derin modellerinin hem orijinal hem de hiperparametre ayarlaması yapılmış versiyonları ve önerilen hibrit model eğitilmiş ve test veri seti üzerinde performanslarına bakılmıştır. Ayrıca hiperparametre ayarlamalı DÖ modellerinin ve önerilen hibrit modelin performansını, literatürdeki çalışmalarda karşılaştırmak için literatürde çok kullanılan ve OKT görüntülerinden oluşan UCSD veri seti üzerinde bu modeller eğitilmiştir.

4. BULGULAR

Bu çalışmada oluşturulan veri setinin ham, ön işlenmiş ve gri tonlamalı halleri üzerinde DÖ yöntemlerinin hem orijinal hem de hiperparametre ayarlı modelleri ile eğitimler yapılmıştır. Ayrıca, DÖ yöntemlerinin hem orijinal hem de hiperparametre ayarlı modelleri literatürde çok kullanılan UCSD veri seti üzerinde eğitilmiştir. Bu bölümde, eğitimler için elde edilen sınıflandırma sonuçları gösterilmektedir.

Bu bölüm, 4 alt bölüme ayrılmaktadır. Birinci alt bölümde, veri setinin ham hali üzerinde eğitilen modellerinden elde edilen sonuçlar gösterilmektedir. İkinci alt bölümde, veri setinin ön işlenmiş hali üzerinde eğitilen modellerinden elde edilen sonuçlar gösterilmektedir. Üçüncü alt bölümde, veri setinin gri tonlamalı hali üzerinde eğitilen modellerinden elde edilen sonuçlar gösterilmektedir. Dördüncü alt bölümde, UCSD veri seti üzerinde eğitilen modellerinden elde edilen sonuçlar gösterilmektedir.

4.1. PERFORMANS METRİKLERİ

Çalışmamızda modellerin başarısını değerlendirmek için karışıklık matrisinden faydalanılmıştır. Doğruluk, hatırlama, kesinlik ve F1 Puanı metrikleri performans ölçütleri olarak kullanılmıştır.

Tablo 4.1: Karışıklık matrisi.

		Tahmin Edilen Sınıf	
		Hastalık Var	**Hastalık Yok**
Gerçek Sınıf	**Hastalık Var**	Gerçek Pozitif (GP)	Yanlış Negatif (YN)
	Hastalık Yok	Yanlış Pozitif (YP)	Gerçek Negatif (GN)

Performans metriklerinin hesaplanmasında Yanlış Negatif (YN), Yanlış Pozitif (YP), Gerçek Negatif (GN) ve Gerçek Pozitif (GP) endeksleri kullanılmıştır. GP, pozitif bir durumun sınıflandırıcı tarafından pozitif olarak tahmin edilen örnekleri ifade etmektedir. YP, negatif bir durumun sınıflandırıcı tarafından pozitif olarak tahmin edilen örnekleri ifade etmektedir. YN,

negatif bir durumun sınıflandırıcı tarafından pozitif olarak tahmin edilen örnekleri ifade etmektedir. GN, negatif bir durumun ve sınıflandırıcı tarafından negatif olarak tahmin edilen örnekleri belirtmektedir (Çalışkan, 2023).

Doğruluk, sınıflandırıcının doğru olarak tahmin ettiği hastalık olan ve hastalık olmayan görüntü sayısının toplam görüntü sayısına oranıdır.

$$Doğruluk = \frac{GP + GN}{GP + GN + YP + YN} \tag{4.1}$$

Hassasiyet, hastalık olan görüntü sayısının doğru tahmin edilme oranıdır.

$$Hassasiyet = \frac{GP}{GP + YN} \tag{4.2}$$

Kesinlik, sınıflandırıcının tahmin ettiği gerçekte hastalık olan görüntü sayısının sınıflandırıcının hastalıklı olarak tahmin ettiği görüntü sayısına oranıdır.

$$Kesinlik = \frac{GP}{GP + YP} \tag{4.3}$$

F1 puanı, bir modelin veri kümesindeki doğruluğunun ölçüsüdür. F1 puanı, kesinlik ve hassasiyet oranlarının harmonik ortalaması ilehesaplanmaktadır.

$$F1\ Puanı = 2 * \frac{Kesinlik * Hassasiyet}{Kesinlik + Hassasiyet} \tag{4.4}$$

4.2. VERİ SETİ SINIFLANDIRMA SONUÇLARI

Bu bölümde, oluşturulan veri seti üzerinde DÖ modellerinin sınıflandırma sonuçları karşılaştırılmaktadır. Bu karşılaştırmada; DenseNet-201, EfficentNet-B4, EfficentNet-B7, EfficentNet-V2S, InceptionResnet-V2, Inception-V3, MobileNet, RestNet-50, Xception ve önerilen hibrit model yöntemleri kullanılmıştır. Bu modellerin parametreleri Tablo 3.2'de ayrıntılı bir şekilde gösterilmektedir. Sınıflandırma işlemi için dokuz DÖ modelinin hem orijinal hem de hiperparametre ayarı yapılan versiyonları kullanılmıştır. Veri setindeki eğitim seti, doğrulama seti ve test seti dağılımları Tablo 4.2'de gösterilmektedir.

Tablo 4.2: Veri seti OKT görüntülerinin dağılımı.

Veri Seti Sınıfları	Eğitim Seti	Doğrulama Seti	Test Seti	Toplam
DR	1.597	300	300	2.197
NORMAL	1.563	300	300	2.163
YBMD	1.409	300	300	2.009
Toplam	**4.569**	**900**	**900**	**6.369**

4.2.1. Veri Seti İçin Derin Öğrenme Modellerinin Sınıflandırma Sonuçları

Tablo 4.3'te oluşturulan veri seti üzerinde eğitilen DÖ modellerinin ve önerilen hibrit modelinin sınıflandırma sonuçları gösterilmektedir. Buna göre, EfficentNet-V2S modeli ve Xception modeli doğruluk oranlarının en yüksek olduğu görülmektedir.

Tablo 4.3: Veri seti için derin öğrenme modellerinin sınıflandırma sonuçları.

Derin Öğrenme Modeli	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Puanı
DenseNet-201	84,89	84,89	84,89	0,85
EfficentNet-B4	92,89	92,89	92,89	0,93
EfficentNet-B7	86,55	86,55	86,55	0,87
EfficentNet-V2S	98,44	98,44	98,44	0,98
InceptionResnet-V2	94,11	94,11	94,11	0,94
Inception-V3	91,67	91,67	91,67	0,92
MobileNet	96,44	96,44	96,44	0,96
RestNet-50	94,00	93,99	93,99	0,94
Xception	97,78	97,78	97,67	0,98
Önerilen Hibrit Model	**96,89**	**96,89**	**96,89**	**0,97**

Tablo 4.4'te oluşturulan veri seti üzerinde eğitilen DÖ modellerinin ve önerilen hibrit modelinin karışıklık matrisleri gösterilmektedir.

Tablo 4.4: Veri seti için derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli	Gerçek Sınıf	Tahmini Sınıf		
		DR	NORMAL	YBMD
DenseNet-201	DR	164	-	136
	NORMAL	-	300	-
	YBMD	-	-	300
EfficentNet-B4	DR	268	1	31
	NORMAL	-	300	-
	YBMD	15	17	268
EfficentNet-B7	DR	179	-	121
	NORMAL	-	300	-
	YBMD	-	-	300
EfficentNet-V2S	DR	287	-	13
	NORMAL	-	300	-
	YBMD	1	-	299
InceptionResnet-V2	DR	248	-	52
	NORMAL	-	300	-
	YBMD	1	-	299
Inception-V3	DR	225	-	75
	NORMAL	-	300	-
	YBMD	-	-	300
MobileNet	DR	268	-	32
	NORMAL	-	300	-
	YBMD	-	-	300
RestNet-50	DR	250	-	50
	NORMAL	-	296	4
	YBMD	-	-	300
Xception	DR	293	-	7
	NORMAL	-	300	-
	YBMD	13	-	287
Önerilen Hibrit Model	DR	273	-	27
	NORMAL	-	300	-
	YBMD	-	1	299

4.2.2. Veri Seti Üzerinde Hiperparametre Ayarlı Derin Öğrenme Modellerinin Sınıflandırma Sonuçları

Tablo 4.5'te oluşturulan veri seti üzerinde eğitilen hiperparametre ayarlı DÖ modellerinin ve önerilen hibrit modelinin sınıflandırma sonuçları gösterilmektedir. Buna göre, EfficentNet-V2S modeli ve hibrit modeli doğruluk oranlarının en yüksek olduğu görülmektedir.

Tablo 4.5: Veri seti üzerinde hiperparametre ayarlı derin öğrenme modellerinin sınıflandırma sonuçları.

Derin Öğrenme Modeli	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Puanı
DenseNet-201	98,56	98,56	98,56	0,99
EfficentNet-B4	98,00	98,00	98,00	0,98
EfficentNet-B7	97,11	97,11	97,11	0,97
EfficentNet-V2S	98,78	98,89	98,78	0,99
InceptionResnet-V2	96,00	96,21	95,89	0,96
Inception-V3	94,22	94,31	94,00	0,94
MobileNet	98,00	98,00	98,00	0,98
RestNet-50	97,56	97,56	97,56	0,98
Xception	98,56	98,56	98,56	0,99
Önerilen Hibrit Model	**99,11**	**99,11**	**99,11**	**0,99**

Tablo 4.6'da oluşturulan veri seti üzerinde eğitilen hiperparametre ayarlı DÖ modellerinin ve önerilen hibrit modelinin karışıklık matrisleri gösterilmektedir. Tablo 4.4'teki karmaşıklık matrislerine göre daha iyi sonuçlar elde edildiği görülmektedir.

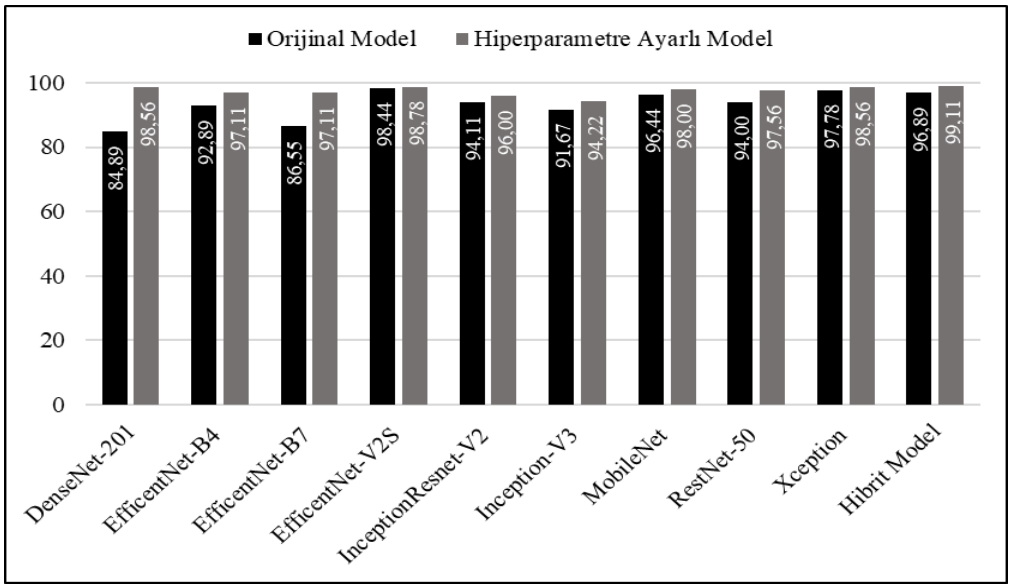
Tablo 4.6: Veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli		Tahmini Sınıf		
	Gerçek Sınıf	DR	NORMAL	YBMD
DenseNet-201	DR	291	-	9
	NORMAL	-	300	-
	YBMD	4	-	296
EfficentNet-B4	DR	274	-	26
	NORMAL	-	300	-
	YBMD	-	-	300
EfficentNet-B7	DR	274	-	26
	NORMAL	-	300	-
	YBMD	-	-	300
EfficentNet-V2S	DR	293	-	7
	NORMAL	-	300	-
	YBMD	4	-	296

Tablo 4.6 (devam): Veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli	Gerçek Sınıf	Tahmini Sınıf		
		DR	NORMAL	YBMD
InceptionResnet-V2	**DR**	**269**	**2**	**29**
	NORMAL	-	295	5
	YBMD	-	-	300
Inception-V3	DR	257	2	41
	NORMAL	-	291	9
	YBMD	-	-	300
MobileNet	DR	288	-	12
	NORMAL	-	300	-
	YBMD	6	-	294
RestNet-50	DR	281	-	19
	NORMAL	-	298	2
	YBMD	1	-	299
Xception	DR	288	1	11
	NORMAL	-	300	-
	YBMD	-	1	299
Önerilen Hibrit Model	DR	293	-	7
	NORMAL	-	300	-
	YBMD	1	-	299

Şekil 4.1'de veri seti ham hali üzerinde sınıflandırma modellerinin doğruluk oranı grafiği gösterilmektedir.



Şekil 4.1: Veri kümesi için sınıflandırma modellerinin doğruluk oranları.

4.3. ÖN İŞLENMİŞ VERİ SETİ SINIFLANDIRMA SONUÇLARI

Bu bölümde, ön işlenmiş yapılmış veri seti üzerinde DÖ modellerinin sınıflandırma sonuçları karşılaştırılmaktadır. Bu karşılaştırmada; DenseNet-201, EfficentNet-B4, EfficentNet-B7, EfficentNet-V2S, InceptionResnet-V2, Inception-V3, MobileNet, RestNet-50, Xception ve önerilen hibrit model yöntemleri kullanılmıştır. Bu modellerin parametreleri Tablo 3.2'de ayrıntılı bir şekilde gösterilmektedir.

Sınıflandırma işlemi için dokuz DÖ modelinin hem orijinal hem de hiperparametre ayarı yapılan versiyonları kullanılmıştır. Veri setindeki eğitim seti, doğrulama seti ve test seti dağılımları Tablo 4.2'de gösterilmektedir.

4.3.1. Ön İşlenmiş Veri Seti İçin Derin Öğrenme Modellerinin Sınıflandırma Sonuçları

Tablo 4.7'de ön işlenmiş veri seti üzerinde eğitilen DÖ modellerinin ve önerilen hibrit modelinin sınıflandırma sonuçları gösterilmektedir. Buna göre, EfficentNet-V2S modeli ve hibrit modeli doğruluk oranlarının en yüksek olduğu görülmektedir.

Tablo 4.7: Ön işlenmiş veri seti için derin öğrenme modellerinin sınıflandırma sonuçları.

Derin Öğrenme Modeli	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Puanı
DenseNet-201	84,89	84,89	84,89	0,85
EfficentNet-B4	94,67	95,25	93,67	0,94
EfficentNet-B7	94,89	95,18	94,89	0,95
EfficentNet-V2S	99,00	99,00	98,89	0,99
InceptionResnet-V2	97,56	97,56	97,56	0,98
Inception-V3	92,56	92,95	92,22	0,93
MobileNet	98,11	98,11	98,11	0,98
RestNet-50	90,33	90,40	90,00	0,90
Xception	98,89	99,00	98,89	0,99
Önerilen Hibrit Model	**99,56**	**99,56**	**99,56**	**1,00**

Tablo 4.8'de ön işlenmiş veri seti üzerinde eğitilen DÖ modellerinin ve önerilen hibrit modelinin karışıklık matrisleri gösterilmektedir.

Tablo 4.8: Ön işlenmiş veri seti için derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli		**Tahmini Sınıf**		
	Gerçek Sınıf	DR	NORMAL	YBMD
DenseNet-201	DR	164	-	136
	NORMAL	-	300	-
	YBMD	-	-	300
EfficentNet-B4	DR	285	11	4
	NORMAL	-	300	-
	YBMD	1	32	267
EfficentNet-B7	DR	256	18	26
	NORMAL	-	300	-
	YBMD	2	-	298
EfficentNet-V2S	DR	295	-	5
	NORMAL	-	300	-
	YBMD	2	-	298
InceptionResnet-V2	DR	281	-	19
	NORMAL	-	297	3
	YBMD	-	-	300
Inception-V3	DR	258	-	42
	NORMAL	18	276	6
	YBMD	1	-	299
MobileNet	DR	297	-	3
	NORMAL	2	287	11
	YBMD	1	-	299
RestNet-50	DR	279	-	21
	NORMAL	32	238	30
	YBMD	3	1	296
Xception	DR	291	1	8
	NORMAL	-	300	-
	YBMD	1	-	299
Önerilen Hibrit Model	DR	296	-	4
	NORMAL	-	300	-
	YBMD	-	-	300

4.3.2. Ön İşlenmiş Veri Seti İçin Hiperparametre Ayarlı Derin Öğrenme Modellerinin Sınıflandırma Sonuçları

Tablo 4.9'da ön işlenmiş veri seti üzerinde eğitilen hiperparametre ayarlı DÖ modellerinin ve önerilen hibrit modelinin sınıflandırma sonuçları gösterilmektedir. Buna göre, EfficentNet-V2S modeli ve hibrit modeli doğruluk oranlarının en yüksek olduğu görülmektedir.

Tablo 4.9: Ön işlenmiş veri seti için hiperparametre ayarlı derin öğrenme modellerinin sınıflandırma sonuçları.

Derin Öğrenme Modeli	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Puanı
DenseNet-201	99,11	99,11	99,11	0,99
EfficentNet-B4	98,78	98,78	98,78	0,99
EfficentNet-B7	98,44	98,55	98,44	0,98
EfficentNet-V2S	99,22	99,22	99,11	0,99
InceptionResnet-V2	99,00	99,11	99,00	0,99
Inception-V3	94,89	95,08	94,44	0,95
MobileNet	98,22	98,33	98,22	0,98
RestNet-50	96,89	97,10	96,78	0,97
Xception	99,11	99,11	99,11	0,99
Önerilen Hibrit Model	**99,89**	**99,89**	**99,89**	**1,00**

Tablo 4.10'da ön işlenmiş veri seti üzerinde eğitilen hiperparametre ayarlı DÖ modellerinin ve önerilen hibrit modelinin karışıklık matrisleri gösterilmektedir. Tablo 4.8'deki karmaşıklık matrislerine göre daha iyi sonuçlar elde edildiği görülmektedir.

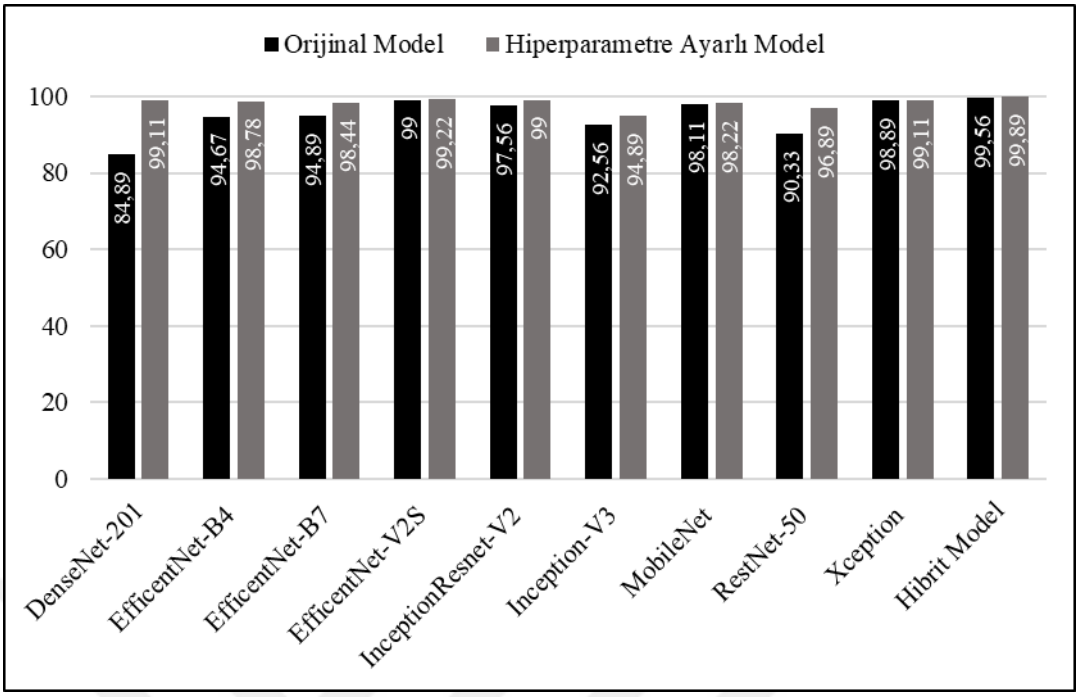
Tablo 4.10: Ön işlenmiş veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli		Tahmini Sınıf		
	Gerçek Sınıf	DR	NORMAL	YBMD
DenseNet-201	DR	297	3	-
	NORMAL	-	300	-
	YBMD	-	5	295
EfficentNet-B4	DR	297	-	3
	NORMAL	-	299	1
	YBMD	7	-	293

Tablo 4.10 (devam): Ön işlenmiş veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli	Gerçek Sınıf	Tahmini Sınıf		
		DR	NORMAL	YBMD
EfficentNet-B7	DR	290	-	10
	NORMAL	-	300	-
	YBMD	3	1	296
EfficentNet-V2S	DR	294	3	3
	NORMAL	-	300	-
	YBMD	-	1	299
InceptionResnet-V2	DR	294	2	4
	NORMAL	-	297	3
	YBMD	2	1	297
Inception-V3	DR	286	2	12
	NORMAL	-	270	30
	YBMD	2	-	298
MobileNet	DR	296	-	4
	NORMAL	4	295	1
	YBMD	5	2	293
RestNet-50	DR	279	3	18
	NORMAL	-	298	2
	YBMD	5	-	295
Xception	DR	294	-	6
	NORMAL	-	300	-
	YBMD	2	-	298
Önerilen Hibrit Model	DR	299	1	-
	NORMAL	-	300	-
	YBMD	-	-	300

Şekil 4.2’de veri seti işlenmiş hali üzerinde sınıflandırma modellerinin doğruluk oranı grafiği gösterilmektedir.



Şekil 4.2: Ön işlenmiş veri kümesi için sınıflandırma modellerinin doğruluk oranları.

4.4. GRİ TONLAMALI VERİ SETİ SINIFLANDIRMA SONUÇLARI

Bu bölümde, ön işlenmiş yapılan veri setinin gri tonlamalı versiyonu üzerinde DÖ modellerinin sınıflandırma sonuçları karşılaştırılmaktadır. Bu karşılaştırmada; DenseNet-201, EfficentNet-B4, EfficentNet-B7, EfficentNet-V2S, InceptionResnet-V2, Inception-V3, MobileNet, RestNet-50, Xception ve önerilen hibrit model yöntemleri kullanılmıştır. Bu modellerin parametreleri Tablo 3.2'de ayrıntılı bir şekilde gösterilmektedir.

Sınıflandırma işlemi için dokuz DÖ modelinin hem orijinal hem de hiperparametre ayarı yapılan versiyonları kullanılmıştır. Veri setindeki eğitim seti, doğrulama seti ve test seti dağılımları Tablo 4.2'de gösterilmektedir.

4.4.1. Gri Tonlamalı Veri Seti İçin Derin Öğrenme Modellerinin Sınıflandırma Sonuçları

Tablo 4.11'de gri tonlamalı veri seti üzerinde eğitilen DÖ modellerinin ve önerilen hibrit modelinin sınıflandırma sonuçları gösterilmektedir. Buna göre, EfficentNet-V2S modeli ve hibrit modeli doğruluk oranlarının en yüksek olduğu görülmektedir.

Tablo 4.11: Gri tonlamalı veri seti için derin öğrenme modellerinin sınıflandırma sonuçları.

Derin Öğrenme Modeli	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Puanı
DenseNet-201	96,78	97,10	96,67	0,97
EfficentNet-B4	90,11	90,39	89,89	0,90
EfficentNet-B7	85,44	86,52	84,89	0,86
EfficentNet-V2S	99,22	99,22	99,22	0,99
InceptionResnet-V2	88,33	88,33	88,33	0,88
Inception-V3	97,33	97,44	97,22	0,97
MobileNet	92,78	92,78	92,78	0,93
RestNet-50	94,22	94,30	93,78	0,94
Xception	97,00	97,00	97,00	0,97
Önerilen Hibrit Model	**99,33**	**99,44**	**99,33**	**0,99**

Tablo 4.12'de gri tonlamalı veri seti üzerinde eğitilen DÖ modellerinin ve önerilen hibrit modelinin karışıklık matrisleri gösterilmektedir.

Tablo 4.12: Gri tonlamalı veri seti için derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli		Tahmini Sınıf		
	Gerçek Sınıf	DR	NORMAL	YBMD
DenseNet-201	DR	276	17	7
	NORMAL	-	300	-
	YBMD	-	5	295
EfficentNet-B4	DR	297	-	3
	NORMAL	73	255	2
	YBMD	11	-	289
EfficentNet-B7	DR	188	109	3
	NORMAL	-	300	-
	YBMD	1	18	281
EfficentNet-V2S	DR	295	3	2
	NORMAL	-	300	-
	YBMD	2	-	298

Tablo 4.12 (devam): Gri tonlamalı veri seti için derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli	Gerçek Sınıf	Tahmini Sınıf		
		DR	NORMAL	YBMD
InceptionResnet-V2	DR	297	2	1
	NORMAL	-	201	99
	YBMD	-	3	297
Inception-V3	DR	286	13	1
	NORMAL	-	300	-
	YBMD	9	1	290
MobileNet	DR	248	50	2
	NORMAL	-	300	-
	YBMD	-	13	287
RestNet-50	DR	251	40	9
	NORMAL	-	300	-
	YBMD	-	3	297
Xception	DR	295	3	2
	NORMAL	-	300	-
	YBMD	1	21	278
Önerilen Hibrit Model	DR	295	1	4
	NORMAL	-	300	-
	YBMD	1	-	299

4.4.2. Gri Tonlamalı Veri Seti İçin Hiperparametre Ayarlı Derin Öğrenme Modellerinin Sınıflandırma Sonuçları

Tablo 4.13'te gri tonlamalı veri seti üzerinde eğitilen hiperparametre ayarlı DÖ modellerinin ve önerilen hibrit modelinin sınıflandırma sonuçları gösterilmektedir. Buna göre, EfficentNet-V2S modeli ve hibrit modeli doğruluk oranlarının en yüksek olduğu görülmektedir.

Tablo 4.13: Gri tonlamalı veri seti için hiperparametre ayarlı derin öğrenme modellerinin sınıflandırma sonuçları.

Derin Öğrenme Modeli	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Puanı
DenseNet-201	98,67	98,67	98,67	0,99
EfficentNet-B4	98,00	98,00	97,89	0,98
EfficentNet-B7	98,00	98,00	98,00	0,98
EfficentNet-V2S	99,67	99,78	99,67	1,00
InceptionResnet-V2	94,22	94,22	94,22	0,94

Tablo 4.13 (devam): Gri tonlamalı veri seti için hiperparametre ayarlı derin öğrenme modellerinin sınıflandırma sonuçları.

Derin Öğrenme Modeli	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Puanı
Inception-V3	98,33	98,33	98,11	0,98
MobileNet	95,78	95,77	95,67	0,96
RestNet-50	94,67	94,77	94,67	0,95
Xception	98,33	98,33	98,33	0,98
Önerilen Hibrit Model	**99,78**	**99,78**	**99,78**	**1,00**

Tablo 4.14'te gri tonlamalı veri seti üzerinde eğitilen hiperparametre ayarlı DÖ modellerinin ve önerilen hibrit modelinin karışıklık matrisleri gösterilmektedir. Tablo 4.12'deki karmaşıklık matrislerine göre daha iyi sonuçlar elde edildiği görülmektedir.

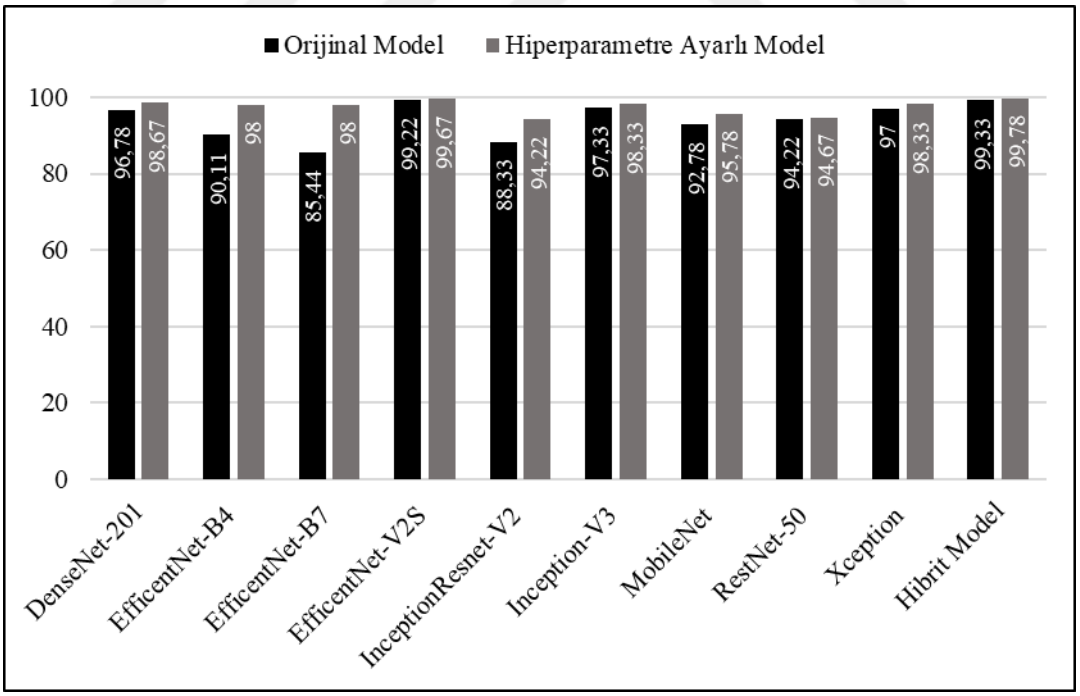
Tablo 4.14: Gri tonlamalı veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli		Tahmini Sınıf		
	Gerçek Sınıf	DR	NORMAL	YBMD
DenseNet-201	DR	290	10	-
	NORMAL	-	300	-
	YBMD	-	2	298
EfficentNet-B4	DR	294	6	-
	NORMAL	-	300	-
	YBMD	3	9	288
EfficentNet-B7	DR	291	6	3
	NORMAL	-	300	-
	YBMD	2	7	291
EfficentNet-V2S	DR	300	-	–
	NORMAL	-	300	-
	YBMD	2	1	297
InceptionResnet-V2	DR	250	2	48
	NORMAL	-	300	-
	YBMD	-	2	298
Inception-V3	DR	293	7	-
	NORMAL	-	300	-
	YBMD	-	8	292

Tablo 4.14 (devam): Gri tonlamalı veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli	Gerçek Sınıf	Tahmini Sınıf		
		DR	NORMAL	YBMD
MobileNet	DR	280	18	2
	NORMAL	-	300	-
	YBMD	4	14	282
RestNet-50	DR	266	29	5
	NORMAL	-	300	-
	YBMD	-	14	286
Xception	DR	286	11	3
	NORMAL	-	300	-
	YBMD	-	1	299
Önerilen Hibrit Model	DR	299	1	-
	NORMAL	-	300	-
	YBMD	-	1	299

Şekil 4.3'te veri seti gri tonlamalı hali üzerinde sınıflandırma modellerinin doğruluk oranı grafiği gösterilmektedir.



Şekil 4.3: Gri tonlamalı veri kümesi için sınıflandırma modellerinin doğruluk oranları.

4.5. UCSD VERİ SETİ SINIFLANDIRMA SONUÇLARI

Bu bölümde, UCSD veri seti üzerinde DÖ modellerinin sınıflandırma sonuçları karşılaştırılmaktadır. Bu karşılaştırmada; DenseNet-201, EfficentNet-B4, EfficentNet-B7, EfficentNet-V2S, InceptionResnet-V2, Inception-V3, MobileNet, RestNet-50, Xception ve önerilen hibrit model yöntemleri kullanılmıştır. Bu modellerin parametreleri Tablo 3.2'de ayrıntılı bir şekilde gösterilmektedir.

Sınıflandırma işlemi için dokuz DÖ modelinin hem orijinal hem de hiperparametre ayarı yapılan versiyonları kullanılmıştır. Veri setindeki eğitim seti, doğrulama seti ve test seti dağılımları Tablo 4.15'te gösterilmektedir.

Tablo 4.15: UCSD veri seti OKT görüntülerinin dağılımı.

Veri Seti Sınıfları	Eğitim Seti	Doğrulama Seti	Test Seti	Toplam
CNV	36.205	1.000	250	37.455
DME	10.348	1.000	250	11.598
DRUSEN	7.616	1.000	250	8.866
NORMAL	25.315	1.000	250	26.565
Toplam	**79.484**	**4000**	**1000**	**84.484**

4.5.1. UCSD Veri Seti İçin Derin Öğrenme Modellerinin Sınıflandırma Sonuçları

Tablo 4.16'da UCSD veri seti üzerinde eğitilen DÖ modellerinin ve önerilen hibrit modelinin sınıflandırma sonuçları gösterilmektedir. Buna göre, MobileNet modeli ve EfficentNet-B7 modeli doğruluk oranlarının en yüksek olduğu görülmektedir.

Tablo 4.16: UCSD veri seti için derin öğrenme modellerinin sınıflandırma sonuçları.

Derin Öğrenme Modeli	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Puanı
DenseNet-201	98,70	98,70	98,70	0,99
EfficentNet-B4	95,10	95,18	94,80	0,95
EfficentNet-B7	99,60	99,20	99,20	0,99
EfficentNet-V2S	99,40	99,40	99,40	0,99

Tablo 4.16 (devam): UCSD veri seti için derin öğrenme modellerinin sınıflandırma sonuçları.

Derin Öğrenme Modeli	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Puanı
InceptionResnet-V2	94,60	94,60	94,60	0,95
Inception-V3	92,40	92,40	92,40	0,92
MobileNet	99,50	99,50	99,50	1,00
RestNet-50	98,50	98,50	98,50	0,99
Xception	98,20	98,20	98,20	0,98
Önerilen Hibrit Model	**99,30**	**99,30**	**99,30**	**0,99**

Tablo 4.17'de UCSD veri seti üzerinde eğitilen DÖ modellerinin ve önerilen hibrit modelinin karışıklık matrisleri gösterilmektedir.

Tablo 4.17: UCSD veri seti için derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli	Gerçek Sınıf	Tahmini Sınıf			
		CNV	DME	DRUSEN	NORMAL
DenseNet-201	CNV	248	2	-	-
	DME	1	249	-	-
	DRUSEN	9	1	240	-
	NORMAL	-	-	-	250
EfficentNet-B4	CNV	250	-	-	-
	DME	17	233	-	-
	DRUSEN	29	1	220	-
	NORMAL	-	-	2	248
EfficentNet-B7	CNV	249	1	-	-
	DME	2	248	-	-
	DRUSEN	4	-	246	-
	NORMAL	-	-	1	249
EfficentNet-V2S	CNV	249	1	-	-
	DME	1	249	-	-
	DRUSEN	4	-	246	-
	NORMAL	-	-	-	250
InceptionResnet-V2	CNV	233	-	-	17
	DME	1	230	-	19
	DRUSEN	7	-	233	10
	NORMAL	-	-	-	250
Inception-V3	CNV	250	-	-	-
	DME	70	180	-	-
	DRUSEN	6	-	244	-
	NORMAL	-	-	-	250

Tablo 4.17 (devam): UCSD veri seti için derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli	Gerçek Sınıf	Tahmini Sınıf			
		CNV	DME	DRUSEN	NORMAL
MobileNet	CNV	250	-	-	-
	DME	1	249	-	-
	DRUSEN	2	-	248	-
	NORMAL	-	-	2	248
RestNet-50	CNV	250	-	-	-
	DME	9	241	-	-
	DRUSEN	5	-	245	-
	NORMAL	-	-	1	249
Xception	CNV	250	-	-	-
	DME	7	243	-	-
	DRUSEN	9	-	241	-
	NORMAL	2	-	-	249
Önerilen Hibrit Model	CNV	247	3	-	-
	DME	-	250	-	-
	DRUSEN	2	1	246	1
	NORMAL	-	-	-	250

4.5.2. UCSD Veri Seti İçin Hiperparametre Ayarlı Derin Öğrenme Modellerinin Sınıflandırma Sonuçları

Tablo 4.18'de UCSD veri seti üzerinde eğitilen hiperparametre ayarlı DÖ modellerinin ve önerilen hibrit modelinin sınıflandırma sonuçları gösterilmektedir. Buna göre, hibrit modeli doğruluk oranının en yüksek olduğu görülmektedir.

Tablo 4.18: UCSD veri seti üzerinde hiperparametre ayarlı derin öğrenme modellerinin sınıflandırma sonuçları.

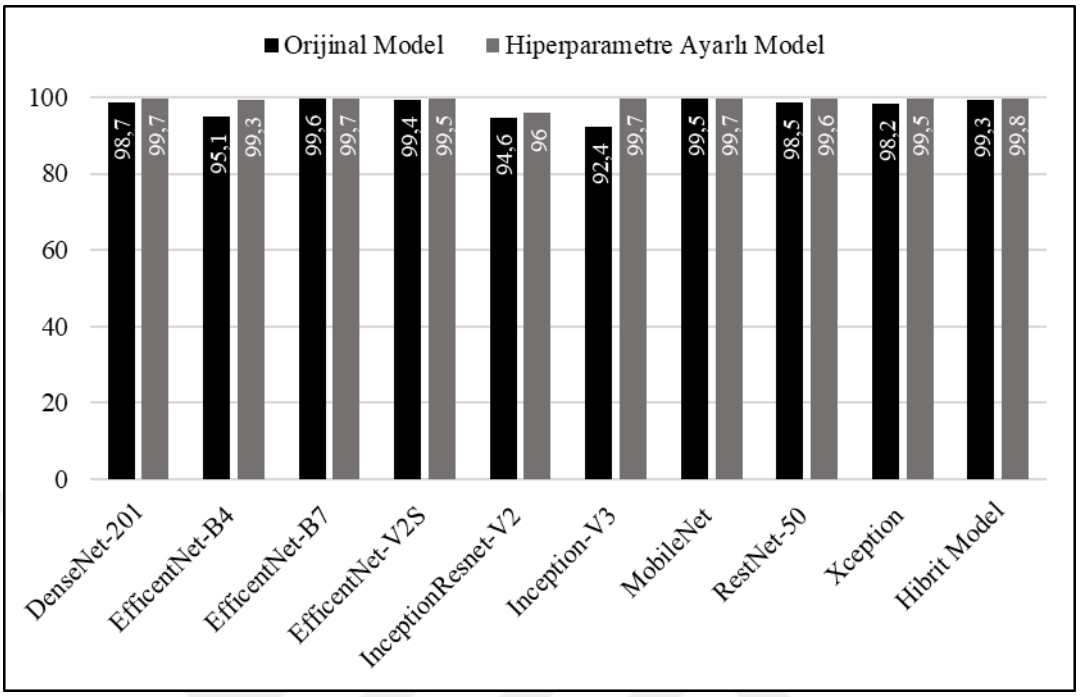
Derin Öğrenme Modeli	Doğruluk (%)	Kesinlik (%)	Hassasiyet (%)	F1 Puanı
DenseNet-201	99,70	99,70	99,70	1,00
EfficentNet-B4	99,30	99,30	99,30	0,99
EfficentNet-B7	99,70	99,70	99,70	1,00
EfficentNet-V2S	99,50	99,50	99,50	1,00
InceptionResnet-V2	96,00	96,00	96,00	0,96
Inception-V3	99,70	99,70	99,70	1,00
MobileNet	99,70	99,70	99,70	1,00
RestNet-50	99,60	99,60	99,60	1,00
Xception	99,50	99,50	99,50	1,00
Önerilen Hibrit Model	**99,80**	**99,80**	**99,80**	**1,00**

Tablo 4.19'da UCSD veri seti üzerinde eğitilen hiperparametre ayarlı DÖ modellerinin ve önerilen hibrit modelinin karışıklık matrisleri gösterilmektedir. Tablo 4.17'daki karmaşıklık matrislerine göre daha iyi sonuçlar elde edildiği görülmektedir.

Tablo 4.19: UCSD veri seti için hiperparametre ayarlı derin öğrenme modellerinin karışıklık matrisleri.

Derin Öğrenme Modeli		**Tahmini Sınıf**			
	Gerçek Sınıf	CNV	DME	DRUSEN	NORMAL
DenseNet-201	CNV	250	-	-	-
	DME	-	250	-	-
	DRUSEN	3	-	247	-
	NORMAL	-	-	-	250
EfficentNet-B4	CNV	250	-	-	-
	DME	1	249	-	-
	DRUSEN	5	-	245	-
	NORMAL	-	-	1	249
EfficentNet-B7	CNV	250	-	-	-
	DME	-	250	-	-
	DRUSEN	3	-	247	-
	NORMAL	-	-	-	250
EfficentNet-V2S	CNV	250	-	-	-
	DME	1	249	-	-
	DRUSEN	4	-	246	-
	NORMAL	-	-	-	250
InceptionResnet-V2	CNV	250	-	-	-
	DME	2	244	-	4
	DRUSEN	11	-	239	-
	NORMAL	22	-	1	227
Inception-V3	CNV	250	-	-	-
	DME	1	249	-	-
	DRUSEN	2	-	248	-
	NORMAL	-	-	-	250
MobileNet	CNV	250	-	-	-
	DME	-	250	-	-
	DRUSEN	2	-	248	-
	NORMAL	-	-	1	249
RestNet-50	CNV	250	-	-	-
	DME	1	249	-	-
	DRUSEN	3	-	247	-
	NORMAL	-	-	-	250
Xception	CNV	250	-	-	-
	DME	-	250	-	-
	DRUSEN	5	-	245	-
	NORMAL	-	-	-	250
Önerilen Hibrit Model	CNV	250	-	-	-
	DME	-	250	-	-
	DRUSEN	2	-	248	-
	NORMAL	-	-	-	250

Şekil 4.4'te UCSD veri seti sınıflandırma modellerinin doğruluk oranı grafiği gösterilmektedir.



Şekil 4.4: UCSD veri kümesi için sınıflandırma modellerinin doğruluk oranları.

Tablo 4.20'de UCSD veri seti için önerilen hibrit model ve literatürdeki diğer çalışmaların sınıflandırma performans sonuçları gösterilmiştir.

Tablo 4.20: Önerilen hibrit model ve literatürdeki çalışmaların UCSD veri seti için sınıflandırma performans sonuçları.

Çalışma	Yöntem	Veri Seti	Doğruluk
Kermany ve diğ. (2018)	InceptionV3	UCSD	%96,60
F. Li ve diğ. (2019)	VGG16	UCSD	%98,60
Kaymak ve Serener (2018)	AlexNet	UCSD	%97,10
Hwang ve diğ. (2019)	VGG16, InceptionV3, ResNet50	UCSD	VGG16 %91,20 InceptionV3 %96,93 ResNet50 %95,87
Fang ve diğ. (2019)	Iterative fusion CNN (IFCNN)	UCSD	%87,30
Huang ve diğ. (2019)	Layer guided CNN (LGCNN)	UCSD	%88,40
Das ve diğ. (2019)	Multi-scale deep feature fusion (MDFF)	UCSD	%99,60
Fang ve diğ. (2019)	Lesion-aware CNN (LACNN)	UCSD	%90,10
Paul ve diğ. (2020)	OCTx	UCSD	%98,53

Tablo 4.20 (devam): Önerilen hibrit model ve literatürdeki çalışmaların UCSD veri seti için sınıflandırma performans sonuçları.

Çalışma	Yöntem	Veri Seti	Doğruluk
Kim ve Tran (2020)	ResNet152	UCSD	%98,90
Sunjia ve diğ. (2021)	DCNN	UCSD	%99,69
Ai ve diğ. (2022)	FN-OCT	UCSD	%98,70
Diao ve diğ. (2023)	CM-CNN	UCSD	%96,93
Önerilen Hibrit Model		**UCSD**	**%99,80**
Önerilen Hibrit Model		Ham Veri Seti	%99,11
Önerilen Hibrit Model		Gri Tonlamalı Veri Seti	%99,78
Önerilen Hibrit Model		**Ön İşlenmiş Veri Seti**	**%99,89**

5. TARTIŞMA VE SONUÇ

Bu çalışmada, retina hastalıklarının sınıflandırması için yeni bir veri seti oluşturulmuş ve hibrit bir DÖ modeli önerilmiştir. İlk önce yeni veri setinin ham, ön işlenmiş ve gri tonlamalı versiyonları oluşturulmuştur. Ardından bu veri setleri üzerinde dokuz DÖ modeli ve bu modellerin hiperparametre ayarı değiştirilmiş versiyonları ile eğitimler gerçekleştirilmiştir. Bu modeller UCSD veri seti üzerinde de eğitilmiştir. Bu modellerin oluşturulan veri setleri ve UCSD veri seti üzerindeki sınıflandırma performans sonuçları deneysel olarak elde edilerek karşılaştırılmıştır.

Veri setinin ham halinin sınıflandırma modelleri ile sınıflandırma performans ölçütleri değerlendirildiğinde veri setinin ham hali üzerinde hiperparametre ayarlı DÖ modellerinin doğruluk oranlarının bu modellerin orijinal versiyonlarına göre daha yüksek olduğu görülmüştür.

Veri setinin ön işlenmiş halinin sınıflandırma modelleri ile sınıflandırma performans ölçütleri değerlendirildiğinde veri seti işlenmiş hali üzerinde hiperparametre ayarlı DÖ modellerinin doğruluk oranlarının bu modellerin orijinal versiyonlarına göre daha yüksek olduğu görülmüştür.

Veri setinin gri tonlamalı halinin sınıflandırma modelleri ile sınıflandırma performans ölçütleri değerlendirildiğinde veri seti gri tonlamalı hali üzerinde hiperparametre ayarlı DÖ modellerinin doğruluk oranlarının bu modellerin orijinal versiyonlarına göre daha yüksek olduğu görülmüştür.

UCSD veri setinin sınıflandırma modelleri ile sınıflandırma performans ölçütleri değerlendirildiğinde UCSD veri seti üzerinde hiperparametre ayarlı DÖ modellerinin doğruluk oranlarının bu modellerin orijinal versiyonlarına göre daha yüksek olduğu görülmüştür.

Çalışmamızda kullanılan bütün veri setleri üzerinde eğitilen DÖ modelleri arasında en başarılı sonuçların önerilen hibrit model ile elde edildiği görülmüştür. Ayrıca, UCSD veri seti için önerilen hibrit model literatürdeki diğer çalışmalara göre daha iyi performans göstermiştir. Bunların yanında, geliştirilen hibrit model, bu çalışma kapsamında oluşturulan veri setleri

arasında ön işlenmiş veri seti üzerinde %99,89 doğruluk oranı ile etkin bir performans göstermiştir.

Bu tez çalışmasının oftalmolojide YZ uygulamalarına katkı sağlanması hedeflenmiştir. Çalışma kapsamında OKT görüntülerinin sınıflandırılması için hem yeni bir hibrit DÖ modeli geliştirilmiş hem de OKT görüntülerinden oluşan yeni bir veri seti oluşturulmuştur. Sunulan hibrit modelin YBMD ve DR hastalarının OKT görüntülerini normal OKT görüntülerinden ayırmada oldukça etkili olduğu görülmüştür. Retina OKT görüntülerinden YBMD ve DR'yi teşhis etmede yüksek performans gösteren hibrit model, oftalmologların teşhis kararı vermelerine yardımcı olmak için tıp merkezlerinde uzmanlar tarafından kullanılabilecek bir sisteme dönüştürülebilir.

Çalışmada DÖ modelleri sadece DR ve YBMD hastalarının görüntüleri üzerinde eğitilmiştir. Ayrıca bu modeller tek bir merkezden alınan görüntüler kullanılarak eğitilmiştir. Gelecekteki çalışmalarda, farklı merkezlerden toplanan OKT görüntüleri dahil edilerek daha fazla retina hastalığı sınıflandırılması yapılabilir.

KAYNAKLAR

A P, S. Kar, S. S, G. Gopi, V.P. ve Palanisamy, P., 2021, OctNET: A Lightweight CNN for Retinal Disease Classification from Optical Coherence Tomography Images, *Computer Methods and Programs in Biomedicine*, 200 . https://doi.org/10.1016/J.CMPB.2020.105877

Abraham, A., 2005, Artificial Neural Networks, *Handbook of Measuring System Design*. https://doi.org/10.1002/0471497398.MM421

Abramoff, M.D. Garvin, M.K. ve Sonka, M., 2010, Retinal imaging and image analysis, *IEEE Reviews in Biomedical Engineering*, 3 , 169–208. https://doi.org/10.1109/RBME.2010.2084567

Addo, E. Bamiro, O.A. ve Siwale, R., 2016, Anatomy of the eye and common diseases affecting the eye, *Ocular Drug Delivery: Advances, Challenges and Applications*, 11–25. https://doi.org/10.1007/978-3-319-47691-9_2/COVER

Adiga, S. V, 2019, *Retinal Image Quality Improvement via Learning* [International Institute of Information Technology]. https://cdn.iiit.ac.in/cdn/cvit.iiit.ac.in/images/Thesis/MS/Sukesh_Adiga_V/Sukesh_thesis_1.pdf

Agarwal, A., 2008, *Fundus fluorescein and indocyanine green angiography : a textbook and atlas*, 263. https://books.google.com/books/about/Fundus_Fluorescein_and_Indocyanine_Green.html?hl=tr&id=YGfUBRWDaPgC

Aggarwal, K. Mijwil, M.M. Al-Mistarehi, A.-H. Alomari, S. Gök, M. Zein Alaabdin, A.M. ve Abdulrhman, S.H., 2022, *Has the Future Started? The Current Growth of Artificial Intelligence, Machine Learning, and Deep Learning*. https://doi.org/10.52866/ijcsm.2022.01.01.013

Ai, Z. Huang, X. Feng, J. Wang, H. Tao, Y. Zeng, F. ve Lu, Y., 2022, FN-OCT: Disease Detection Algorithm for Retinal Optical Coherence Tomography Based on a Fusion Network, *Frontiers in Neuroinformatics*, 16 , 876927. https://doi.org/10.3389/FNINF.2022.876927/BIBTEX

Albert, D.M. ve Gamm, D.M., 2023, *Britannica, eye anatomy | pupil*. https://www.britannica.com/science/pupil-eye

Ali-Gombe, A. ve Elyan, E., 2019, MFC-GAN: Class-imbalanced dataset classification using Multiple Fake Class Generative Adversarial Network, *Neurocomputing*, 361 , 212–221. https://doi.org/10.1016/J.NEUCOM.2019.06.043

Alqudah, A. Alqudah, A.M. ve Altantawi, M., 2021, Artificial Intelligence Hybrid System for

Enhancing Retinal Diseases Classification Using Automated Deep Features Extracted from OCT Images, *International Journal of Intelligent Systems and Applications in Engineering*, 9 (3), 91–100. https://doi.org/10.18201/ijisae.2021.236

Alqudah, A.M., 2020, AOCT-NET: a convolutional network automated classification of multiclass retinal diseases using spectral-domain optical coherence tomography images, *Medical and Biological Engineering and Computing*, 58 (1), 41–53. https://doi.org/10.1007/S11517-019-02066-Y/TABLES/5

Alyoubi, W.L. Abulkhair, M.F. ve Shalash, W.M., 2021, Diabetic Retinopathy Fundus Image Classification and Lesions Localization System Using Deep Learning, *Sensors 2021, Vol. 21, Page 3704*, 21 (11), 3704. https://doi.org/10.3390/S21113704

American Diabetes, A., 2011, Diagnosis and Classification of Diabetes Mellitus, *Diabetes Care*, 34 (Supplement_1), S62–S69. https://doi.org/10.2337/DC11-S062

Amin, J. Sharif, M. ve Yasmin, M., 2016, A Review on Recent Developments for Detection of Diabetic Retinopathy, *Scientifica*, 2016 . https://doi.org/10.1155/2016/6838976

An, G. Yokota, H. Motozawa, N. Takagi, S. Mandai, M. Kitahata, S. Hirami, Y. Takahashi, M. Kurimoto, Y. ve Akiba, M., 2019, Deep Learning Classification Models Built with Two-step Transfer Learning for Age Related Macular Degeneration Diagnosis, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2049–2052. https://doi.org/10.1109/EMBC.2019.8857468

Anam, D.A. Novamizanti, L. ve Rizal, S., 2021, Classification of Retinal Pathology via OCT Images using Convolutional Neural Network, *2021 International Conference on Computer System, Information Technology, and Electrical Engineering, COSITE 2021*, 12–17. https://doi.org/10.1109/COSITE52651.2021.9649630

Aykat, S. ve Senan, S., 2022, Deep Learning in Retinal Diseases Diagnosis: A Review, Içinde *Machine Learning and AI Techniques in Interactive Medical Image Analysis* (2023. baskı, ss. 1–34), IGI Global. https://doi.org/10.4018/978-1-6684-4671-3.CH001

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. https://doi.org/10.46387/BJESR.1332567

AYKAT, Ş. ve SENAN, S., 2023, Using Machine Learning to Detect Different Eye Diseases from OCT Images, *International Journal of Computational and Experimental Science and Engineering*, 9 (2), 62–67. https://doi.org/10.22399/IJCESEN.1297655

Badar, M. Haris, M. ve Fatima, A., 2020, Application of deep learning for retinal image analysis: A review, *Computer Science Review*, 35 , 100203. https://doi.org/10.1016/J.COSREV.2019.100203

Baharlouei, Z. Rabbani, H. ve Plonka, G., 2022, Detection of Retinal Abnormalities in OCT Images Using Wavelet Scattering Network, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2022-July , 3862–3865. https://doi.org/10.1109/EMBC48229.2022.9871989

Banerjee, I. de Sisternes, L. Hallak, J. Leng, T. Osborne, A. Durbin, M. ve Rubin, D., 2019, *A Deep-learning Approach for Prognosis of Age-Related Macular Degeneration Disease using SD-OCT Imaging Biomarkers*. https://arxiv.org/abs/1902.10700v1

Batista, G.E.A.P.A. Prati, R.C. ve Monard, M.C., 2004, A study of the behavior of several methods for balancing machine learning training data, *ACM SIGKDD Explorations Newsletter*, 6 (1), 20–29. https://doi.org/10.1145/1007730.1007735

Behl, T. Kaur, I. Goel, H. ve Pandey, R., 2014, *DIABETIC NEPHROPATHY AND DIABETIC RETINOPATHY AS MAJOR HEALTH BURDENS IN MODERN ERA*.

Bengio, Y., 2012, Practical recommendations for gradient-based training of deep architectures, *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 7700 LECTURE NO , 437–478. https://doi.org/10.1007/978-3-642-35289-8_26

Bennett, T.J. ve Barry, C.J., 2009, Ophthalmic imaging today: an ophthalmic photographer's viewpoint – a review, *Clinical & Experimental Ophthalmology*, 37 (1), 2–13. https://doi.org/10.1111/J.1442-9071.2008.01812.X

Bhatia, Y. Bajpayee, A. Raghuvanshi, D. ve Mittal, H., 2019, Image Captioning using Google's Inception-resnet-v2 and Recurrent Neural Network, *2019 12th International Conference on Contemporary Computing, IC3 2019*. https://doi.org/10.1109/IC3.2019.8844921

Bird, A.C. Bressler, N.M. Bressler, S.B. Chisholm, I.H. Coscas, G. Davis, M.D. de Jong, P.T.V.M. Klaver, C.C.W. Klein, B.E.K. Klein, R. Mitchell, P. Sarks, J.P. Sarks, S.H. Soubrane, G. Taylor, H.R. ve Vingerling, J.R., 1995, An international classification and grading system for age-related maculopathy and age-related macular degeneration. The International ARM Epidemiological Study Group, *Survey of ophthalmology*, 39 (5), 367–374. https://doi.org/10.1016/S0039-6257(05)80092-X

Bourne, R.R.A. Jonas, J.B. Bron, A.M. Cicinelli, M.V. Das, A. Flaxman, S.R. Friedman, D.S. Keeffe, J.E. Kempen, J.H. Leasher, J. Limburg, H. Naidoo, K. Pesudovs, K. Peto, T. Saadine, J. Silvester, A.J. Tahhan, N. Taylor, H.R. Varma, R. … Resnikoff, S., 2018, Prevalence and causes of vision loss in high-income countries and in Eastern and Central Europe in 2015: Magnitude, temporal trends and projections, *British Journal of Ophthalmology*, 102 (5), 575–585. https://doi.org/10.1136/BJOPHTHALMOL-2017-311258

Bressler, N.M., 2004, Age-Related Macular Degeneration Is the Leading Cause of Blindness..., *JAMA*, 291 (15), 1900–1901. https://doi.org/10.1001/JAMA.291.15.1900

Çalışkan, A., 2023, Finding complement of inefficient feature clusters obtained by metaheuristic optimization algorithms to detect rock mineral types, *Transactions of the Institute of Measurement and Control*, 45 (10), 1815–1828. https://doi.org/10.1177/01423312231160819

Chakravarthy, U. Evans, J. ve Rosenfeld, P.J., 2010, Age related macular degeneration, *BMJ*, 340 (7745), 526–530. https://doi.org/10.1136/BMJ.C981

Chauhan, N.K. ve Singh, K., 2019, A review on conventional machine learning vs deep

learning, *2018 International Conference on Computing, Power and Communication Technologies, GUCON 2018*, 347–352. https://doi.org/10.1109/GUCON.2018.8675097

Cheung, N. ve Wong, T.Y., 2008, Diabetic retinopathy and systemic vascular complications, *Progress in Retinal and Eye Research*, 27 (2), 161–176. https://doi.org/10.1016/J.PRETEYERES.2007.12.001

Chew, E. Clemons, T. Agrón, E. Sperduto, R.D. Sangiovanni, J.P. Kurinij, N. ve Davis, M.D., 2013, Long-term effects of vitamins C and E, β-carotene, and zinc on age-related macular degeneration: AREDS report no. 35, *Ophthalmology*, 120 (8). https://doi.org/10.1016/J.OPHTHA.2013.01.021

Chollet, F., 2017, *Xception: Deep Learning with Depthwise Separable Convolutions*. https://doi.org/10.1109/CVPR.2017.195

Coleman, D.J. Lizzi, F.L. ve Jack, R.L., 1977, *Ultrasonography of the eye and orbit*, Lea \& Febiger.

Coleman, H.R. Chan, C.C. Ferris, F.L. ve Chew, E.Y., 2008, Age-related macular degeneration, *Lancet (London, England)*, 372 (9652), 1835–1845. https://doi.org/10.1016/S0140-6736(08)61759-6

Connolly, E. Rhatigan, M. O'Halloran, A.M. Muldrew, K.A. Chakravarthy, U. Cahill, M. Kenny, R.A. ve Doyle, S.L., 2018, Prevalence of age-related macular degeneration associated genetic risk factors and 4-year progression data in the Irish population, *The British journal of ophthalmology*, 102 (12), 1691–1695. https://doi.org/10.1136/BJOPHTHALMOL-2017-311673

Das, V. Dandapat, S. ve Bora, P.K., 2019, Multi-scale deep feature fusion for automated classification of macular pathologies from OCT images, *Biomedical Signal Processing and Control*, 54 , 101605. https://doi.org/10.1016/J.BSPC.2019.101605

Davis, M.D. Gangnon, R.E. Lee, L.Y. Hubbard, L.D. Klein, B.E.K. Klein, R. Ferris, F.L. Bressler, S.B. ve Milton, R.C., 2005, The Age-Related Eye Disease Study severity scale for age-related macular degeneration: AREDS Report No. 17, *Archives of ophthalmology (Chicago, Ill. : 1960)*, 123 (11), 1484–1498. https://doi.org/10.1001/ARCHOPHT.123.11.1484

Diao, S. Su, J. Yang, C. Zhu, W. Xiang, D. Chen, X. Peng, Q. ve Shi, F., 2023, Classification and segmentation of OCT images for age-related macular degeneration based on dual guidance networks, *Biomedical Signal Processing and Control*, 84 , 104810. https://doi.org/10.1016/J.BSPC.2023.104810

Dong, S. Wang, P. ve Abbas, K., 2021, A survey on deep learning and its applications, *Computer Science Review*, 40 , 100379. https://doi.org/10.1016/J.COSREV.2021.100379

Dubow, M. Pinhas, A. Shah, N. Cooper, R.F. Gan, A. Gentile, R.C. Hendrix, V. Sulai, Y.N. Carroll, J. Chui, T.Y.P. Walsh, J.B. Weitz, R. Dubra, A. ve Rosen, R.B., 2014, Classification of Human Retinal Microaneurysms Using Adaptive Optics Scanning Light Ophthalmoscope Fluorescein Angiography, *Investigative Ophthalmology & Visual Science*, 55 (3), 1299. https://doi.org/10.1167/IOVS.13-13122

e. V., B. der A.D. Gesellschaft, D.O. ve e. V., R.G., 2017, Qualitätssicherung der optischen Kohärenztomographie für die Diagnostik des Augenhintergrunds, *Der Ophthalmologe*, 114 (7), 617–624. https://doi.org/10.1007/s00347-017-0508-9

Elgafi, M. Sharafeldeen, A. Elnakib, A. Elgarayhi, A. Alghamdi, N.S. Sallah, M. ve El-Baz, A., 2022, Detection of Diabetic Retinopathy Using Extracted 3D Features from OCT Images, *Sensors 2022, Vol. 22, Page 7833*, 22 (20), 7833. https://doi.org/10.3390/S22207833

Elsharkawy, M. Sharafeldeen, A. Soliman, A. Khalifa, F. Ghazal, M. El-Daydamony, E. Atwan, A. Sandhu, H.S. ve El-Baz, A., 2022, A Novel Computer-Aided Diagnostic System for Early Detection of Diabetic Retinopathy Using 3D-OCT Higher-Order Spatial Appearance Model, *Diagnostics 2022, Vol. 12, Page 461*, 12 (2), 461. https://doi.org/10.3390/DIAGNOSTICS12020461

Eltanboly, A. Ghazaf, M. Khalil, A. Shalaby, A. Mahmoud, A. Switala, A. El-Azab, M. Schaal, S. ve El-Baz, A., 2018, An integrated framework for automatic clinical assessment of diabetic retinopathy grade using spectral domain OCT images, *Proceedings - International Symposium on Biomedical Imaging*, 2018-April , 1431–1435. https://doi.org/10.1109/ISBI.2018.8363841

Esfahani, E.N. Daneshmand, P.G. Rabbani, H. ve Plonka, G., 2022, Automatic Classification of Macular Diseases from OCT Images Using CNN Guided with Edge Convolutional Layer, *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*, 2022-July , 3858–3861. https://doi.org/10.1109/EMBC48229.2022.9871322

ETDRS, 1987, Treatment Techniques and Clinical Guidelines for Photocoagulation of Diabetic Macular Edema: Early Treatment Diabetic Retinopathy Study Report Number 2, *Ophthalmology*, 94 (7), 761–774. https://doi.org/10.1016/S0161-6420(87)33527-4

Fang, L. Jin, Y. Huang, L. Guo, S. Zhao, G. ve Chen, X., 2019, Iterative fusion convolutional neural networks for classification of optical coherence tomography images, *Journal of Visual Communication and Image Representation*, 59 , 327–333. https://doi.org/10.1016/J.JVCIR.2019.01.022

Fang, L. Wang, C. Li, S. Rabbani, H. Chen, X. ve Liu, Z., 2019, Attention to lesion: Lesion-Aware convolutional neural network for retinal optical coherence tomography image classification, *IEEE Transactions on Medical Imaging*, 38 (8), 1959–1970. https://doi.org/10.1109/TMI.2019.2898414

Farsiu, S. Chiu, S.J. O'Connell, R. V. Folgar, F.A. Yuan, E. Izatt, J.A. ve Toth, C.A., 2014, Quantitative Classification of Eyes with and without Intermediate Age-related Macular Degeneration Using Optical Coherence Tomography, *Ophthalmology*, 121 (1), 162. https://doi.org/10.1016/J.OPHTHA.2013.07.013

Ferris, F.L. Davis, M.D. Clemons, T.E. Lee, L.Y. Chew, E.Y. Lindblad, A.S. Milton, R.C. Bressler, S.B. ve Klein, R., 2005, A simplified severity scale for age-related macular degeneration: AREDS Report No. 18, *Archives of ophthalmology (Chicago, Ill. : 1960)*, 123 (11), 1570–1574. https://doi.org/10.1001/ARCHOPHT.123.11.1570

Ferris, F.L. Fine, S.L. ve Hyman, L., 1984, Age-Related Macular Degeneration and Blindness due to Neovascular Maculopathy, *Archives of Ophthalmology*, 102 (11), 1640–1642. https://doi.org/10.1001/ARCHOPHT.1984.01040031330019

Ferris, F.L. Wilkinson, C.P. Bird, A. Chakravarthy, U. Chew, E. Csaky, K. ve Sadda, S.R., 2013, Clinical classification of age-related macular degeneration, *Ophthalmology*, 120 (4), 844–851. https://doi.org/10.1016/j.ophtha.2012.10.036

Fong, R.C. Scheirer, W.J. ve Cox, D.D., 2018, Using human brain activity to guide machine learning, *Scientific Reports 2018 8:1*, 8 (1), 1–10. https://doi.org/10.1038/s41598-018-23618-6

Fukushima, K., 1980, Neocognitron: A self-organizing neural network model for a mechanism of pattern recognition unaffected by shift in position, *Biological Cybernetics*, 36 (4), 193–202. https://doi.org/10.1007/BF00344251/METRICS

Gabriele, M.L. Wollstein, G. Ishikawa, H. Kagemann, L. Xu, J. Folio, L.S. ve Schuman, J.S., 2011, Optical Coherence Tomography: History, Current Status, and Laboratory Work, *Investigative Ophthalmology & Visual Science*, 52 (5), 2425. https://doi.org/10.1167/IOVS.10-6312

Giampani, A.S.B.- ve Junior, J.G., 2013, Anatomy of Ciliary Body, Ciliary Processes, Anterior Chamber Angle and Collector Vessels, *Glaucoma - Basic and Clinical Aspects*. https://doi.org/10.5772/52780

Goodfellow, I. Bengio, Y. ve Courville, A., 2016, *Deep learning*, MIT press.

Gulshan, V. Peng, L. Coram, M. Stumpe, M.C. Wu, D. Narayanaswamy, A. Venugopalan, S. Widner, K. Madams, T. Cuadros, J. Kim, R. Raman, R. Nelson, P.C. Mega, J.L. 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. https://doi.org/10.1001/JAMA.2016.17216

Gündoğan, F.Ç., 2023, *Gözün Yapısı - Doç. Dr. Fatih Çakır Gündoğan - Kayseri*. https://gozdoktor.net/gozun-yapisi/

Hallak, J.A. De Sisternes, L. Osborne, A. Yaspan, B. Rubin, D.L. ve Leng, T., 2019, Imaging, Genetic, and Demographic Factors Associated With Conversion to Neovascular Age-Related Macular Degeneration: Secondary Analysis of a Randomized Clinical Trial, *JAMA ophthalmology*, 137 (7), 738–744. https://doi.org/10.1001/JAMAOPHTHALMOL.2019.0868

Häner, N.U. Dysli, C. ve Munk, M.R., 2023, Imaging in retinal vascular disease: A review, *Clinical and Experimental Ophthalmology*. https://doi.org/10.1111/CEO.14203

Hassan, B. Qin, S. ve Ahmed, R., 2020, RRI-Net: Classification of Multi-class Retinal Diseases with Deep Recurrent Residual Inception Network using OCT Scans, *2020 IEEE International Symposium on Signal Processing and Information Technology, ISSPIT 2020*. https://doi.org/10.1109/ISSPIT51521.2020.9408820

Hassani, H. Silva, E.S. Unger, S. TajMazinani, M. ve Feely, S. Mac, 2020, Artificial

Intelligence (AI) or Intelligence Augmentation (IA): What Is the Future?, *AI 2020, Vol. 1, Pages 143-155*, 1 (2), 143–155. https://doi.org/10.3390/AI1020008

He, K. Zhang, X. Ren, S. ve Sun, J., 2016, Deep Residual Learning for Image Recognition, *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770–778. http://image-net.org/challenges/LSVRC/2015/

Hebb, D., 1993, *The organization of behavior*.

Heesterbeek, T.J. de Jong, E.K. Acar, I.E. Groenewoud, J.M.M. Liefers, B. Sánchez, C.I. Peto, T. Hoyng, C.B. Pauleikhoff, D. Hense, H.W. ve den Hollander, A.I., 2019, Genetic risk score has added value over initial clinical grading stage in predicting disease progression in age-related macular degeneration, *Scientific Reports 2019 9:1*, 9 (1), 1–8. https://doi.org/10.1038/s41598-019-43144-3

Heesterbeek, T.J. Lorés-Motta, L. Hoyng, C.B. Lechanteur, Y.T.E. ve den Hollander, A.I., 2020, Risk factors for progression of age-related macular degeneration, *Ophthalmic and Physiological Optics*, 40 (2), 140–170. https://doi.org/10.1111/OPO.12675

Herculano-Houzel, S., 2009, The human brain in numbers: A linearly scaled-up primate brain, *Frontiers in Human Neuroscience*, 3 (NOV), 31. https://doi.org/10.3389/NEURO.09.031.2009/BIBTEX

Howard, A.G. Zhu, M. Chen, B. Kalenichenko, D. Wang, W. Weyand, T. ve Andreetto, M., 2017, *MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications*.

Huang, D. Swanson, E.A. Lin, C.P. Schuman, J.S. Stinson, W.G. Chang, W. Hee, M.R. Flotte, T. Gregory, K. Puliafito, C.A. ve Fujimoto, J.G., 1991, Optical Coherence Tomography, *Science (New York, N.Y.)*, 254 (5035), 1178. https://doi.org/10.1126/SCIENCE.1957169

Huang, G. Liu, Z. Van Der Maaten, L. ve Weinberger, K.Q., 2017, Densely Connected Convolutional Networks, *Conference on Computer Vision and Pattern Recognition (CVPR)*, 4700–4708. https://github.com/liuzhuang13/DenseNet.

Huang, L. He, X. Fang, L. Rabbani, H. ve Chen, X., 2019, Automatic Classification of Retinal Optical Coherence Tomography Images with Layer Guided Convolutional Neural Network, *IEEE Signal Processing Letters*, 26 (7), 1026–1030. https://doi.org/10.1109/LSP.2019.2917779

Hubel, D.H. ve Wiesel, T.N., 1968, Receptive fields and functional architecture of monkey striate cortex, *The Journal of Physiology*, 195 (1), 215–243. https://doi.org/10.1113/JPHYSIOL.1968.SP008455

Hwang, D.K. Hsu, C.C. Chang, K.J. Chao, D. Sun, C.H. Jheng, Y.C. Yarmishyn, A.A. Wu, J.C. Tsai, C.Y. Wang, M.L. Peng, C.H. Chien, K.H. Kao, C.L. Lin, T.C. Woung, L.C. Chen, S.J. ve Chiou, S.H., 2019, Artificial intelligence-based decision-making for age-related macular degeneration, *Theranostics*, 9 (1), 232. https://doi.org/10.7150/THNO.28447

IDF, 2023, *IDF, Diabetes Atlas 2021*. https://diabetesatlas.org/atlas/tenth-edition/

Jackman, W.T. ve Webster, J.D., 1886, On photographing the retina of the living human eye, *Philadelphia photographer*, 23 (275), 275–276.

Jager, R.D. Mieler, W.F. ve Miller, J.W., 2008, Age-Related Macular Degeneration, *https://doi.org/10.1056/NEJMra0801537*, 358 (24), 2606–2617. https://doi.org/10.1056/NEJMRA0801537

Ji, Q. He, W. Huang, J. ve Sun, Y., 2018, Efficient Deep Learning-Based Automated Pathology Identification in Retinal Optical Coherence Tomography Images, *Algorithms 2018, Vol. 11, Page 88*, 11 (6), 88. https://doi.org/10.3390/A11060088

Jo, B.W. Lee, Y.S. Jo, J.H. ve Khan, R.M.A., 2018, Computer Vision-Based Bridge Displacement Measurements Using Rotation-Invariant Image Processing Technique, *Sustainability 2018, Vol. 10, Page 1785*, 10 (6), 1785. https://doi.org/10.3390/SU10061785

Joachim, N. Mitchell, P. Kifley, A. Rochtchina, E. Hong, T. ve Wang, J.J., 2013, Incidence and progression of geographic atrophy: observations from a population-based cohort, *Ophthalmology*, 120 (10), 2042–2050. https://doi.org/10.1016/J.OPHTHA.2013.03.029

Joshi, A. V, 2020, *Machine Learning and Artificial Intelligence*, Springer International Publishing. https://doi.org/10.1007/978-3-030-26622-6

Kao, Y.F. ve Venkatachalam, R., 2021, Human and Machine Learning, *Computational Economics*, 57 (3), 889–909. https://doi.org/10.1007/S10614-018-9803-Z/METRICS

Karri, S.P.K. Chakraborty, D. ve Chatterjee, J., 2017, Transfer learning based classification of optical coherence tomography images with diabetic macular edema and dry age-related macular degeneration, *Biomedical Optics Express*, 8 (2), 579. https://doi.org/10.1364/BOE.8.000579

Kassoff, A. Kassoff, J. Buehler, J. Eglow, M. Kaufman, F. Mehu, M. Kieval, S. Mairs, M. Graig, B. Quattrocchi, A. Jones, D. Locatelli, J. Ruby, A. Capon A., J. Garretson, B. Hassan, T. Trese, M.T. Williams, G.A. Regan, V. … Crouse, V.D., 2001, A Randomized, Placebo-Controlled, Clinical Trial of High-Dose Supplementation With Vitamins C and E, Beta Carotene, and Zinc for Age-Related Macular Degeneration and Vision Loss: AREDS Report No. 8, *Archives of Ophthalmology*, 119 (10), 1417–1436. https://doi.org/10.1001/ARCHOPHT.119.10.1417

Kaymak, S. ve Serener, A., 2018, Automated age-related macular degeneration and diabetic macular edema detection on OCT images using deep learning, *Proceedings - 2018 IEEE 14th International Conference on Intelligent Computer Communication and Processing, ICCP 2018*, 265–269. https://doi.org/10.1109/ICCP.2018.8516635

Keel, S. Wu, J. Lee, P.Y. Scheetz, J. ve He, M., 2019, Visualizing Deep Learning Models for the Detection of Referable Diabetic Retinopathy and Glaucoma, *JAMA Ophthalmology*, 137 (3), 288–292. https://doi.org/10.1001/JAMAOPHTHALMOL.2018.6035

Kermany, D.S. Goldbaum, M. Cai, W. Valentim, C.C.S. Liang, H. Baxter, S.L. McKeown, A. Yang, G. Wu, X. Yan, F. Dong, J. Prasadha, M.K. Pei, J. Ting, M. Zhu, J. Li, C. Hewett, S. Dong, J. Ziyar, I. … Zhang, K., 2018, Identifying Medical Diagnoses and Treatable

Diseases by Image-Based Deep Learning, *Cell*, 172 (5), 1122-1131.e9. https://doi.org/10.1016/J.CELL.2018.02.010

Khalilipour, E. ve Hajizadeh, F., 2023, Fluorescein Angiography, *Diagnostics in Ocular Imaging: Cornea, Retina, Glaucoma and Orbit*, 429–438. https://doi.org/10.1007/978-3-030-54863-6_14

Khan, K.N. Mahroo, O.A. Khan, R.S. Mohamed, M.D. McKibbin, M. Bird, A. Michaelides, M. Tufail, A. ve Moore, A.T., 2016, Differentiating drusen: Drusen and drusen-like appearances associated with ageing, age-related macular degeneration, inherited eye disease and other pathological processes, *Progress in retinal and eye research*, 53 , 70–106. https://doi.org/10.1016/J.PRETEYERES.2016.04.008

Kharroubi, A.T. ve Darwish, H.M., 2015, Diabetes mellitus: The epidemic of the century, *World Journal of Diabetes*, 6 (6), 850. https://doi.org/10.4239/WJD.V6.I6.850

Kim, J. ve Tran, L., 2020, Ensemble learning based on convolutional neural networks for the classification of retinal diseases from optical coherence tomography images, *Proceedings - IEEE Symposium on Computer-Based Medical Systems*, 2020-July , 532–537. https://doi.org/10.1109/CBMS49503.2020.00106

Klein, R. Klein, B.E.K. ve Linton, K.L.P., 1992, Prevalence of age-related maculopathy. The Beaver Dam Eye Study, *Ophthalmology*, 99 (6), 933–943. https://doi.org/10.1016/S0161-6420(92)31871-8

Klein, R. Meuer, S.M. Myers, C.E. Buitendijk, G.H.S. Rochtchina, E. Choudhury, F. De Jong, P.T.V.M. McKean-Cowdin, R. Iyengar, S.K. Gao, X. Lee, K.E. Vingerling, J.R. Mitchell, P. Klaver, C.C.W. Wang, J.J. ve Klein, B.E.K., 2014, Harmonizing the classification of age-related macular degeneration in the three-continent AMD consortium, *Ophthalmic epidemiology*, 21 (1), 14–23. https://doi.org/10.3109/09286586.2013.867512

Kohavi, R. ve Provost, F., 1998, Glossary of Terms, *Machine Learning*.

Krause, J. Gulshan, V. Rahimy, E. Karth, P. Widner, K. Corrado, G.S. Peng, L. ve Webster, D.R., 2018, Grader Variability and the Importance of Reference Standards for Evaluating Machine Learning Models for Diabetic Retinopathy, *Ophthalmology*, 125 (8), 1264–1272. https://doi.org/10.1016/J.OPHTHA.2018.01.034

Krogh, A., 2008, What are artificial neural networks?, *Nature Biotechnology 2008 26:2*, 26 (2), 195–197. https://doi.org/10.1038/nbt1386

Kwiterovich, K.A. Maguire, M.G. Murphy, R.P. Schachat, A.P. Bressler, N.M. Bressler, S.B. ve Fine, S.L., 1991, Frequency of adverse systemic reactions after fluorescein angiography. Results of a prospective study, *Ophthalmology*, 98 (7), 1139–1142. https://doi.org/10.1016/S0161-6420(91)32165-1

Lake, B.M. Ullman, T.D. Tenenbaum, J.B. ve Gershman, S.J., 2016, Building Machines That Learn and Think Like People, *Behavioral and Brain Sciences*, 40 . https://doi.org/10.1017/S0140525X16001837

Lee, C.S. Baughman, D.M. ve Lee, A.Y., 2017, Deep Learning Is Effective for Classifying

Normal versus Age-Related Macular Degeneration OCT Images, *Ophthalmology Retina*, 1 (4), 322–327. https://doi.org/10.1016/j.oret.2016.12.009

Lee, R. Wong, T.Y. ve Sabanayagam, C., 2015, Epidemiology of diabetic retinopathy, diabetic macular edema and related vision loss, *Eye and vision (London, England)*, 2 (1). https://doi.org/10.1186/S40662-015-0026-2

Lee, T.-H.H., 2017, *Wavelet Analysis for Image Processing*.

Lei, J. Balasubramanian, S. Abdelfattah, N.S. Nittala, M.G. ve Sadda, S.R., 2017, Proposal of a simple optical coherence tomography-based scoring system for progression of age-related macular degeneration, *Graefe's archive for clinical and experimental ophthalmology = Albrecht von Graefes Archiv fur klinische und experimentelle Ophthalmologie*, 255 (8), 1551–1558. https://doi.org/10.1007/S00417-017-3693-Y

Lens, A. Coyne Nemeth, S. ve K. Ledford, J., 2009, Ocular Anatomy and Physiology (2nd ed.), *Optometry and Vision Science*, 86 (10), 1208. https://doi.org/10.1097/OPX.0B013E3181BAFCA3

Li, F. Chen, H. Liu, Z. Zhang, X. ve Wu, Z., 2019, Fully automated detection of retinal disorders by image-based deep learning, *Graefe's Archive for Clinical and Experimental Ophthalmology*, 257 (3), 495–505. https://doi.org/10.1007/S00417-018-04224-8/FIGURES/8

Li, X. Shen, L. Shen, M. Tan, F. ve Qiu, C.S., 2019, Deep learning based early stage diabetic retinopathy detection using optical coherence tomography, *Neurocomputing*, 369 , 134–144. https://doi.org/10.1016/J.NEUCOM.2019.08.079

Liew, G. Michaelides, M. ve Bunce, C., 2014, A comparison of the causes of blindness certifications in England and Wales in working age adults (16–64 years), 1999–2000 with 2009–2010, *BMJ Open*, 4 (2), e004015. https://doi.org/10.1136/BMJOPEN-2013-004015

Lim, L.S. Mitchell, P. Seddon, J.M. Holz, F.G. ve Wong, T.Y., 2012, Age-related macular degeneration, *Lancet (London, England)*, 379 (9827), 1728–1738. https://doi.org/10.1016/S0140-6736(12)60282-7

Lin, C. Li, L. Luo, W. Wang, K.C.P. ve Guo, J., 2019, Transfer Learning Based Traffic Sign Recognition Using Inception-v3 Model, *Periodica Polytechnica Transportation Engineering*, 47 (3), 242–250. https://doi.org/10.3311/PPTR.11480

Lin, S. Ramulu, P. Lamoureux, E.L. ve Sabanayagam, C., 2016, Addressing risk factors, screening, and preventative treatment for diabetic retinopathy in developing countries: a review, *Clinical & experimental ophthalmology*, 44 (4), 300–320. https://doi.org/10.1111/CEO.12745

Lopez Pinaya, W.H. Vieira, S. Garcia-Dias, R. ve Mechelli, A., 2020, Convolutional neural networks, *Machine Learning: Methods and Applications to Brain Disorders*, 173–191. https://doi.org/10.1016/B978-0-12-815739-8.00010-9

Luger, G.F. ve Stubblefield, W.A., 1993, *Artificial intelligence : structures and strategies for complex problem solving*, 740.

https://books.google.com/books/about/Artificial_Intelligence.html?hl=tr&id=UHVQAAAAMAAJ

Mafee, M.F. Ainbinder, D. Afshani, E. ve Mafee, R.F., 1996, The eye., *Neuroimaging Clinics of North America*, 6 (1), 29–59. https://doi.org/10.1201/b13471-23

Maller, J. George, S. Purcell, S. Fagerness, J. Altshuler, D. Daly, M.J. ve Seddon, J.M., 2006, Common variation in three genes, including a noncoding variant in CFH, strongly influences risk of age-related macular degeneration, *Nature genetics*, 38 (9), 1055–1059. https://doi.org/10.1038/NG1873

Mamtora, S. Wong, Y. Bell, D. ve Sandinha, T., 2017, Bilateral Birdshot Retinochoroiditis and Retinal Astrocytoma, *Case Reports in Ophthalmological Medicine*, 2017 , 1–4. https://doi.org/10.1155/2017/6586157

Marmor, M.F. ve Ravin, J.G., 2011, Fluorescein angiography: insight and serendipity a half century ago, *Archives of ophthalmology (Chicago, Ill. : 1960)*, 129 (7), 943–948. https://doi.org/10.1001/ARCHOPHTHALMOL.2011.160

McCarty, C.A. Mukesh, B.N. Fu, C.L. Mitchell, P. Jie Jin Wang ve Taylor, H.R., 2001, Risk factors for age-related maculopathy: the Visual Impairment Project, *Archives of ophthalmology (Chicago, Ill. : 1960)*, 119 (10), 1455–1462. https://doi.org/10.1001/ARCHOPHT.119.10.1455

McLeod, D. ve Restori, M., 1979, Ultrasonic examination in severe diabetic eye disease, *The British journal of ophthalmology*, 63 (8), 533–538. https://doi.org/10.1136/BJO.63.8.533

Meng, T. Wu, C. Jia, T. Jiang, Y. ve Jia, Z., 2018, Recombined Convolutional Neural Network for Recognition of Macular Disorders in SD-OCT Images, *Chinese Control Conference, CCC*, 2018-July , 9362–9367. https://doi.org/10.23919/CHICC.2018.8483036

Minsky, M.L. ve Papert, S., 1969, Perceptrons, Expanded Edition An Introduction to Computational Geometry, Içinde *MIT Press*. https://mitpressbookstore.mit.edu/book/9780262534772

Mitchell, P. Liew, G. Gopinath, B. ve Wong, T.Y., 2018, Age-related macular degeneration, *The Lancet*, 392 (10153), 1147–1159. https://doi.org/10.1016/S0140-6736(18)31550-2

Motozawa, N. An, G. Takagi, S. Kitahata, S. Mandai, M. Hirami, Y. Yokota, H. Akiba, M. Tsujikawa, A. Takahashi, M. ve Kurimoto, Y., 2019, Optical Coherence Tomography-Based Deep-Learning Models for Classifying Normal and Age-Related Macular Degeneration and Exudative and Non-Exudative Age-Related Macular Degeneration Changes, *Ophthalmology and Therapy*, 8 (4), 527–539. https://doi.org/10.1007/S40123-019-00207-Y/FIGURES/5

Mullins, R.F. Russell, S.R. Anderson, D.H. ve Hageman, G.S., 2000, Drusen associated with aging and age-related macular degeneration contain proteins common to extracellular deposits associated with atherosclerosis, elastosis, amyloidosis, and dense deposit disease, *The FASEB Journal*, 14 (7), 835–846. https://doi.org/10.1096/FASEBJ.14.7.835

Muñoz, A., 2012, *Machine Learning and Optimization*.

Murugesan, N. Üstunkaya, T. ve Feener, E.P., 2015, Thrombosis and Hemorrhage in Diabetic Retinopathy: A Perspective from an Inflammatory Standpoint, *Seminars in thrombosis and hemostasis*, 41 (6), 659–664. https://doi.org/10.1055/S-0035-1556731

Mustafa, N.B.A. Zaki, W.M.D.W. ve Hussain, A., 2015, A review on the diabetic retinopathy assessment based on retinal vascular tortuosity, *Proceedings - 2015 IEEE 11th International Colloquium on Signal Processing and Its Applications, CSPA 2015*, 127–130. https://doi.org/10.1109/CSPA.2015.7225631

Nabijiang, M. Wan, X. Huang, S. Liu, Q. Wei, B. Zhu, J. ve Xie, X., 2022, BAM: Block attention mechanism for OCT image classification, *IET Image Processing*, 16 (5), 1376–1388. https://doi.org/10.1049/IPR2.12415

Nickla, D.L. ve Wallman, J., 2010, The multifunctional choroid, *Progress in retinal and eye research*, 29 (2), 144–168. https://doi.org/10.1016/J.PRETEYERES.2009.12.002

Nielsen, M., 2015, *Neural networks and deep learning*. https://www.ise.ncsu.edu/fuzzy-neural/wp-content/uploads/sites/9/2022/08/neuralnetworksanddeeplearning.pdf

Niemeijer, M. Abràmoff, M.D. ve Van Ginneken, B., 2009, Information fusion for diabetic retinopathy CAD in digital color fundus photographs, *IEEE transactions on medical imaging*, 28 (5), 775–785. https://doi.org/10.1109/TMI.2008.2012029

Novotny, H.R. ve Alvis, D.L., 1961, A method of photographing fluorescence in circulating blood in the human retina, *Circulation*, 24 , 82–86. https://doi.org/10.1161/01.CIR.24.1.82

Ongsulee, P., 2018, Artificial intelligence, machine learning and deep learning, *International Conference on ICT and Knowledge Engineering*, 1–6. https://doi.org/10.1109/ICTKE.2017.8259629

Osareh, A. Mirmehdi, M. Thomas, B. ve Markham, R., 2003, Automated identification of diabetic retinal exudates in digital colour images, *The British Journal of Ophthalmology*, 87 (10), 1220. https://doi.org/10.1136/BJO.87.10.1220

Panch, T. Szolovits, P. ve Atun, R., 2018, Artificial intelligence, machine learning and health systems, *Journal of Global Health*, 8 (2), 20303. https://doi.org/10.7189/JOGH.08.020303

Paul, D. Tewari, A. Ghosh, S. ve Santosh, K.C., 2020, OCTx: Ensembled deep learning model to detect retinal disorders, *Proceedings - IEEE Symposium on Computer-Based Medical Systems*, 2020-July , 526–531. https://doi.org/10.1109/CBMS49503.2020.00105

Pekala, M. Joshi, N. Liu, T.Y.A. Bressler, N.M. DeBuc, D.C. ve Burlina, P., 2019, Deep learning based retinal OCT segmentation, *Computers in Biology and Medicine*, 114 , 103445. https://doi.org/10.1016/J.COMPBIOMED.2019.103445

Peng, Y. Dharssi, S. Chen, Q. Keenan, T.D. Agrón, E. Wong, W.T. Chew, E.Y. ve Lu, Z., 2019, DeepSeeNet: A deep learning model for automated classification of patient-based age-related macular degeneration severity from color fundus photographs, *Ophthalmology*, 126 (4), 565. https://doi.org/10.1016/J.OPHTHA.2018.11.015

Pennington, K.L. ve DeAngelis, M.M., 2016, Epidemiology of age-related macular

degeneration (AMD): associations with cardiovascular disease phenotypes and lipid factors, *Eye and vision (London, England)*, 3 (1). https://doi.org/10.1186/S40662-016-0063-5

Perdomo, O. Rios, H. Rodríguez, F.J. Otálora, S. Meriaudeau, F. Müller, H. ve González, F.A., 2019, Classification of diabetes-related retinal diseases using a deep learning approach in optical coherence tomography, *Computer Methods and Programs in Biomedicine*, 178 , 181–189. https://doi.org/10.1016/J.CMPB.2019.06.016

Poole, D. Mackworth, A.K. ve Goebel, R., 1998, Computational intelligence : a logical approach, Içinde *Computational intelligence : a logical approach*.

Qureshi, I. Sharif, M. Yasmin, M. Raza, M. ve Javed, M., 2015, Computer Aided Systems for Diabetic Retinopathy Detection Using Digital Fundus Images: A Survey, *Current Medical Imaging Reviews*, 12 (4), 234–241. https://doi.org/10.2174/1573405611666150929234644

Rasti, R. Rabbani, H. Mehridehnavi, A. ve Hajizadeh, F., 2018, Macular OCT Classification Using a Multi-Scale Convolutional Neural Network Ensemble, *IEEE Transactions on Medical Imaging*, 37 (4), 1024–1034. https://doi.org/10.1109/TMI.2017.2780115

Richards, B.A. Lillicrap, T.P. Beaudoin, P. Bengio, Y. Bogacz, R. Christensen, A. Clopath, C. Costa, R.P. de Berker, A. Ganguli, S. Gillon, C.J. Hafner, D. Kepecs, A. Kriegeskorte, N. Latham, P. Lindsay, G.W. Miller, K.D. Naud, R. Pack, C.C. … Kording, K.P., 2019, A deep learning framework for neuroscience, *Nature Neuroscience 2019 22:11*, 22 (11), 1761–1770. https://doi.org/10.1038/s41593-019-0520-2

Rizwan I Haque, I. ve Neubert, J., 2020, Deep learning approaches to biomedical image segmentation, *Informatics in Medicine Unlocked*, 18 , 100297. https://doi.org/10.1016/J.IMU.2020.100297

Rong, Y. Xiang, D. Zhu, W. Yu, K. Shi, F. Fan, Z. ve Chen, X., 2019, Surrogate-assisted retinal OCT image classification based on convolutional neural networks, *IEEE Journal of Biomedical and Health Informatics*, 23 (1), 253–263. https://doi.org/10.1109/JBHI.2018.2795545

Rosenblatt, F., 1958, The perceptron: A probabilistic model for information storage and organization in the brain, *Psychological Review*, 65 (6), 386–408. https://doi.org/10.1037/H0042519

Rumelhart, D.E. Hinton, G.E. ve Williams, R.J., 1986, Learning representations by back-propagating errors, *Nature 1986 323:6088*, 323 (6088), 533–536. https://doi.org/10.1038/323533a0

Russell, S. ve Norvig, P., 2003, Artificial intelligence: A modern approach, *Pretence artificial Hall series in intelligence, Chapter Intelligent Agent*, 31–52.

Saha, S. Nassisi, M. Wang, M. Lindenberg, S. kanagasingam, Y. Sadda, S. ve Hu, Z.J., 2019, Automated detection and classification of early AMD biomarkers using deep learning, *Scientific Reports 2019 9:1*, 9 (1), 1–9. https://doi.org/10.1038/s41598-019-47390-3

Sandhu, H.S. Eltanboly, A. Shalaby, A. Keynton, R.S. Schaal, S. ve El-Baz, A., 2018, Automated Diagnosis and Grading of Diabetic Retinopathy Using Optical Coherence Tomography, *Investigative Ophthalmology & Visual Science*, 59 (7), 3155–3160. https://doi.org/10.1167/IOVS.17-23677

Sandler, M. Howard, A. Zhu, M. Zhmoginov, A. ve Chen, L.C., 2018, MobileNetV2: Inverted Residuals and Linear Bottlenecks, *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 4510–4520. https://doi.org/10.48550/arxiv.1801.04381

Sankar, M. Batri, K. ve Parvathi, R., 2016, Earliest diabetic retinopathy classification using deep convolution neural networks. pdf, *Int. J. Adv. Eng. Technol*, 10 , M9.

Schaefer, M. Michelin, L. ve Kepner, J., 2021, *Naming Schema for a Human Brain-Scale Neural Network*. https://doi.org/10.1002/cne.21974

Schlanitz, F.G. Baumann, B. Kundi, M. Sacu, S. Baratsits, M. Scheschy, U. Shahlaee, A. Mittermüller, T.J. Montuoro, A. Roberts, P. Pircher, M. Hitzenberger, C.K. ve Schmidt-Erfurth, U., 2017, Drusen volume development over time and its relevance to the course of age-related macular degeneration, *The British journal of ophthalmology*, 101 (2), 198–203. https://doi.org/10.1136/BJOPHTHALMOL-2016-308422

Schmidt-Erfurth, U. Sadeghipour, A. Gerendas, B.S. Waldstein, S.M. ve Bogunović, H., 2018, Artificial intelligence in retina, *Progress in Retinal and Eye Research*, 67 , 1–29. https://doi.org/10.1016/J.PRETEYERES.2018.07.004

Schmidt, R.M., 2019, *Recurrent Neural Networks (RNNs): A gentle Introduction and Overview*. https://arxiv.org/abs/1912.05911v1

Serener, A. ve Serte, S., 2019, Dry and wet age-related macular degeneration classification using OCT images and deep learning, *2019 Scientific Meeting on Electrical-Electronics and Biomedical Engineering and Computer Science, EBBT 2019*. https://doi.org/10.1109/EBBT.2019.8741768

Serra, J., 1982, Image analysis and mathematical morphology, *Academic Press*.

Sherstinsky, A., 2020, Fundamentals of Recurrent Neural Network (RNN) and Long Short-Term Memory (LSTM) network, *Physica D: Nonlinear Phenomena*, 404 , 132306. https://doi.org/10.1016/J.PHYSD.2019.132306

Shim, S.H. Kim, S.G. Bae, J.H. Yu, H.G. ve Song, S.J., 2016, Risk Factors for Progression of Early Age-Related Macular Degeneration in Koreans, *Ophthalmic epidemiology*, 23 (2), 80–87. https://doi.org/10.3109/09286586.2015.1129425

Signorelli, C.M., 2018, Can computers become conscious and overcome humans?, *Frontiers Robotics AI*, 5 (OCT), 121. https://doi.org/10.3389/FROBT.2018.00121/BIBTEX

Smith, W. Assink, J. Klein, R. Mitchell, P. Klaver, C.C.W. Klein, B.E.K. Hofman, A. Jensen, S. Wang, J.J. ve De Jong, P.T.V.M., 2001, Risk factors for age-related macular degeneration: Pooled findings from three continents, *Ophthalmology*, 108 (4), 697–704. https://doi.org/10.1016/S0161-6420(00)00580-7

Sotoudeh-Paima, S. Jodeiri, A. Hajizadeh, F. ve Soltanian-Zadeh, H., 2022, Multi-scale convolutional neural network for automated AMD classification using retinal OCT images, *Computers in Biology and Medicine*, 144 , 105368. https://doi.org/10.1016/J.COMPBIOMED.2022.105368

Subramanian, M. Shanmugavadivel, K. Naren, O.S. Premkumar, K. ve Rankish, K., 2022, Classification of Retinal OCT Images Using Deep Learning, *2022 International Conference on Computer Communication and Informatics, ICCCI 2022*. https://doi.org/10.1109/ICCCI54379.2022.9740985

Szegedy, C. Ioffe, S. Vanhoucke, V. ve Alemi, A.A., 2016, Inception-v4, Inception-ResNet and the Impact of Residual Connections on Learning, *31st AAAI Conference on Artificial Intelligence, AAAI 2017*, 4278–4284. https://doi.org/10.1609/aaai.v31i1.11231

Szegedy, C. Vanhoucke, V. Ioffe, S. ve Shlens, J., 2016, Rethinking the Inception Architecture for Computer Vision; Rethinking the Inception Architecture for Computer Vision, *2016 IEEE Conference on Computer Vision and Pattern Recognition*, 2818–2826. https://doi.org/10.1109/CVPR.2016.308

Taherkhani, A. Cosma, G. ve McGinnity, T.M., 2020, AdaBoost-CNN: An adaptive boosting algorithm for convolutional neural networks to classify multi-class imbalanced datasets using transfer learning, *Neurocomputing*, 404 , 351–366. https://doi.org/10.1016/J.NEUCOM.2020.03.064

Tan, J.S.L. Wang, J.J. Flood, V. Rochtchina, E. Smith, W. ve Mitchell, P., 2008, Dietary Antioxidants and the Long-term Incidence of Age-Related Macular Degeneration: The Blue Mountains Eye Study, *Ophthalmology*, 115 (2), 334–341. https://doi.org/10.1016/J.OPHTHA.2007.03.083

Tan, M. ve Le, Q. V., 2019, EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks, *36th International Conference on Machine Learning, ICML 2019*, 2019-June , 10691–10700. https://doi.org/10.48550/arxiv.1905.11946

Taylor, R. ve Batey, D., 2012, *Handbook of Retinal Screening in Diabetes Diagnosis and Management*. https://www.wiley.com/en-gb/Handbook+of+Retinal+Screening+in+Diabetes%3A+Diagnosis+and+Management%2C+2nd+Edition-p-9781119968559

Thomas, A. Harikrishnan, P.M. Krishna, A.K. Palanisamy, P. ve Gopi, V.P., 2021, Automated Detection of Age-Related Macular Degeneration from OCT Images Using Multipath CNN, *Journal of Computing Science and Engineering*, 15 (1), 34–46. https://doi.org/10.5626/JCSE.2021.15.1.34

Thomas, A. Harikrishnan, P.M. Ramachandran Ramachandran, S. Manoj, R. Palanisamy, P. ve Gopi, V.P., 2021, A novel multiscale and multipath convolutional neural network based age-related macular degeneration detection using OCT images, *Computer methods and programs in biomedicine*, 209 . https://doi.org/10.1016/J.CMPB.2021.106294

Thomas, C.J. Mirza, R.G. ve Gill, M.K., 2021, Age-Related Macular Degeneration, *Medical Clinics of North America*, 105 (3), 473–491. https://doi.org/10.1016/j.mcna.2021.01.003

Tikellis, G. Robman, L.D. Dimitrov, P. Nicolas, C. McCarty, C.A. ve Guymer, R.H., 2006, Characteristics of progression of early Age-related macular degeneration: the Cardiovascular Health and Age-related maculopathy Study, *Eye 2007 21:2*, 21 (2), 169–176. https://doi.org/10.1038/sj.eye.6702151

Treder, M. Lauermann, J.L. ve Eter, N., 2018, Automated detection of exudative age-related macular degeneration in spectral domain optical coherence tomography using deep learning, *Graefe's Archive for Clinical and Experimental Ophthalmology*, 256 (2), 259–265. https://doi.org/10.1007/S00417-017-3850-3/FIGURES/5

Vaishya, R.D. Khurana, V. Patel, S. ve Mitra, A.K., 2014, Controlled Ocular Drug Delivery with Nanomicelles, *Wiley interdisciplinary reviews. Nanomedicine and nanobiotechnology*, 6 (5), 422. https://doi.org/10.1002/WNAN.1272

Van Leeuwen, R. Boekhoorn, S. Vingerling, J.R. Witteman, J.C.M. Klaver, C.C.W. Hofman, A. ve De Jong, P.T.V.M., 2005, Dietary Intake of Antioxidants and Risk of Age-Related Macular Degeneration, *JAMA*, 294 (24), 3101–3107. https://doi.org/10.1001/JAMA.294.24.3101

Wang, D. ve Wang, L., 2019, On OCT image classification via deep learning, *IEEE Photonics Journal*, 11 (5). https://doi.org/10.1109/JPHOT.2019.2934484

Wang, L. Clark, M.E. Crossman, D.K. Kojima, K. Messinger, J.D. Mobley, J.A. ve Curcio, C.A., 2010, Abundant Lipid and Protein Components of Drusen, *PLOS ONE*, 5 (4), e10329. https://doi.org/10.1371/JOURNAL.PONE.0010329

Wang, Y. Lucas, M. Furst, J. Fawzi, A.A. ve Raicu, D., 2020, Explainable Deep Learning for Biomarker Classification of OCT Images, *Proceedings - IEEE 20th International Conference on Bioinformatics and Bioengineering, BIBE 2020*, 204–210. https://doi.org/10.1109/BIBE50027.2020.00041

WH, S., 1985, Ophthalmic Pathology, *An Atlas and Textbook*, 395–400. https://cir.nii.ac.jp/crid/1571135651013357696

WHO, 2019, World report on vision, *World health Organisation*, 214 (14), 180–235. https://www.who.int/publications-detail/world-report-on-vision

Wong, W.L. Su, X. Li, X. Cheung, C.M.G. Klein, R. Cheng, C.Y. ve Wong, T.Y., 2014, Global prevalence of age-related macular degeneration and disease burden projection for 2020 and 2040: a systematic review and meta-analysis, *The Lancet. Global health*, 2 (2). https://doi.org/10.1016/S2214-109X(13)70145-1

Yadav, P. ve Singh, N.P., 2019, Classification of normal and abnormal retinal images by using feature-based machine learning approach, *Lecture Notes in Electrical Engineering*, 524 , 387–396. https://doi.org/10.1007/978-981-13-2685-1_37/COVER

Yamashita, R. Nishio, M. Do, R.K.G. ve Togashi, K., 2018, Convolutional neural networks: an overview and application in radiology, *Insights into Imaging*, 9 (4), 611–629. https://doi.org/10.1007/S13244-018-0639-9/FIGURES/15

Yau, J.W.Y. Rogers, S.L. Kawasaki, R. Lamoureux, E.L. Kowalski, J.W. Bek, T. Chen, S.J.

Dekker, J.M. Fletcher, A. Grauslund, J. Haffner, S. Hamman, R.F. Ikram, M.K. Kayama, T. Klein, B.E.K. Klein, R. Krishnaiah, S. Mayurasakorn, K. O'Hare, J.P. … Wong, T.Y., 2012, Global Prevalence and Major Risk Factors of Diabetic Retinopathy, *Diabetes Care*, 35 (3), 556–564. https://doi.org/10.2337/DC11-1909

Yavuz, Z. İkibaş, C. Şevik, U. ve Köse, C., 2009, Retinal Görüntülerde Optik Diskin Otomatik Olarak Çıkartılması için Bir yöntem, *5. Uluslararası İleri Teknolojiler Sempozyumu, IATS'09*.

Zabihollahy, F. Lochbihler, A. Ukwatta, E. Zabihollahy, F. Lochbihler, A. ve Ukwatta, E., 2019, Deep learning based approach for fully automated detection and segmentation of hard exudate from retinal images, *SPIE*, 10953 , 1095308. https://doi.org/10.1117/12.2513034

Zhou, S. Yu, D. Cai, Y. Zhang, Y. Li, B. ve Li, W., 2022, TCAM-Resnet: A convolutional neural network for screening DR and AMD based on OCT images, *Proceedings - 2022 IEEE International Conference on Bioinformatics and Biomedicine, BIBM 2022*, 1830–1835. https://doi.org/10.1109/BIBM55620.2022.9995218

Zou, J. Han, Y. ve So, S.S., 2008, Overview of artificial neural networks, *Methods in Molecular Biology*, 458 , 15–23. https://doi.org/10.1007/978-1-60327-101-1_2/COVER

İNTİHAL RAPORU İLK SAYFASI

Şükrü AYKAT

ORİJİNALLİK RAPORU

%9	%8	%1	%4
BENZERLİK ENDEKSİ	İNTERNET KAYNAKLARI	YAYINLAR	ÖĞRENCİ ÖDEVLERİ

BİRİNCİL KAYNAKLAR

1	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	%2
2	acikbilim.yok.gov.tr İnternet Kaynağı	%1
3	www.sas.com İnternet Kaynağı	%1
4	acikerisim.aku.edu.tr İnternet Kaynağı	<%1
5	dergipark.org.tr İnternet Kaynağı	<%1
6	www.researchgate.net İnternet Kaynağı	<%1
7	tr.thomatts.org İnternet Kaynağı	<%1
8	acikerisim.baskent.edu.tr İnternet Kaynağı	<%1
9	hakan.io İnternet Kaynağı	<%1