



T.C.
NECMETTİN ERBAKAN
ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



**OPTİK KOHERANS TOMOGRAFİ
GÖRÜNTÜLERİ İLE RETİNAL
HASTALIKLARIN EVRİŞİMSEL SİNİR AĞI
KULLANILARAK TEŞHİS EDİLMESİ**

Hafıza Esra URMAMEN

YÜKSEK LİSANS TEZİ

Bilgisayar Mühendisliği Anabilim Dalı

Haziran-2023
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Hafiza Esra Urmamen tarafından hazırlanan “Optik Koherans Tomografi Görüntüleri ile Retinal Hastalıkların Evrışimsel Sinir Ağı Kullanılarak Teşhis Edilmesi” adlı tez çalışması 23/06/2023 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Başkan

Dr.Öğr.Üyesi Alper KILIÇ

Danışman

Prof.Dr. Sabri KOÇER

Üye

Dr.Öğr.Üyesi Murat KARAKOYUN

İmza

.....

.....

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun/.../20.. gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Şerife Yurdagül KUMCU
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Hafiza Esra URMAMEN

Tarih:

ÖZET

YÜKSEK LİSANS TEZİ

OPTİK KOHERANS TOMOGRAFİ GÖRÜNTÜLERİ İLE RETİNAL HASTALIKLARIN EVRİŞİMSEL SINIR AĞI KULLANILARAK TEŞHİS EDİLMESİ

Hafiza Esra URMAMEN

Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. Sabri KOÇER

2023, 67 Sayfa

Jüri

Prof.Dr. Sabri KOÇER

Dr.Öğr.Üyesi Alper KILIÇ

Dr.Öğr.Üyesi Murat KARAKOYUN

Retina, görmeyi sağlayan ışığa ve renklere duyarlı ağ tabakasıdır. Retinadaki bozulmalar insanların yaşam kalitesini olumsuz etkilemektedir. Retinal hastalıkların tedavisinde gelişen teknolojiyle birlikte bilgisayarlı tanı sistemlerinin kullanımı oldukça yaygınlaşmıştır. Retinada meydana gelen bozulmalar körlüğe varan ciddi sorunlara sebep olabilmekte ve retinada kalıcı hasarlar meydana gelebilmektedir. Retinal hastalıklar aniden veya yavaş yavaş görme kaybına, perdeli görüntüye, görüş alanında karanlık ve lekeli görüntüler oluşmasına neden olabilmektedir. Retinal hastalıklara erken teşhis konulması ve tedavi edilmesi büyük önem taşımaktadır. Retina tomografi görüntüleri, oftalmologlar tarafından retinal hastalıkları teşhis etmek ve gözde oluşabilecek kalıcı hasarların önlenmesi için kullanılmaktadır. Böylece erken teşhis ile yapılan tedaviyi kolaylaştırmış ve daha iyi klinik sonuçlar elde edilmesi sağlanmış olmaktadır. Bu çalışmada, retinal hastalıkların erken tespit edilmesi ve uygun tedavi yöntemlerinin uygulanabilmesi için Konvolüsyonel Sinir Ağları (CNN) kullanılarak bir derin öğrenme modeli önerilmektedir. Önerilen model ODIR-5K veri seti üzerinde uygulanmıştır. ODIR-5K veri seti üzerinde önerilen model veri ön işlemlerinden geçirilerek öncelikle görüntülerde farklı çözünürlük ve boyutlardaki görüntüler eşitlenmiş ardından çeşitli ön işlemlerden geçirilmiştir. Miyop, Hipertansiyon, Glokom, Yaşa Bağlı Maküler Dejenerasyon (YBMD), Diyabetik Retinopati (DR), Katarakt, normal ve diğer anormallikleri içeren sekiz farklı retinal hastalık verisi sınıflandırılmıştır. Ayrıca transfer öğrenme yöntemlerinin doğruluk (accuracy) oranı VGG19 (%98.16), ResNet50 (%98.86), Xception (%95.36), InceptionV3 (%98.2) ve önerilen evrişimli sinir ağı modeli için (%97.51) olarak elde edilmiştir. Önerilen model önceden eğitilmiş transfer öğrenme metotları ile karşılaştırıldığında Xception mimarisine kıyasla daha yüksek doğruluk değerine ulaşmıştır. VGG19, ResNet50 ve InceptionV3 mimarileriyle hastalık bazında kıyaslandığında katarakt, normal görüntüler ve diğer hastalıklara ait görüntülerin sınıflandırılmasında daha başarılı sonuçlar elde edilmiştir. Önerilen derin öğrenme tabanlı ESA modeli retinal hastalıkların erken teşhis edilmesinde umut verici sonuçlara ulaşmıştır ve retinal hastalıkların sınıflandırılmasında kullanılabilir.

Anahtar Kelimeler: Derin öğrenme, Evrişimli Sinir Ağları, Fundus Görüntüleri, Optik Koherans Tomografi, Retinal Hastalıklar

ABSTRACT

MS THESIS

DIAGNOSIS OF RETINAL DISEASES USING OPTICAL COHERENCE TOMOGRAPHY IMAGES WITH CONVOLUTIONAL NEURAL NETWORKS

Hafiza Esra URMAMEN

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN COMPUTER ENGINEERING**

Advisor: Prof. Dr. Sabri KOÇER

2023, 67 Pages

Jury

Advisor Prof.Dr. Sabri KOÇER

Asst. Prof. Dr. Alper KILIÇ

Asst. Prof.Dr. Murat KARAKOYUN

The retina is a light-sensitive layer that enables vision and perception of colors. Disturbances in the retina negatively affect people's quality of life. With the advancement of technology in the treatment of retinal diseases, the use of computer-aided diagnostic systems has become widespread. Disturbances occurring in the retina can lead to serious problems, including blindness and permanent damage to the retina. Retinal diseases can result in sudden or gradual vision loss, blurred vision, dark and blotchy images in the field of view. Early diagnosis and treatment of retinal diseases are of great importance. Retinal tomography images are used by ophthalmologists to diagnose retinal diseases and prevent possible permanent damage in the eye. Thus, early diagnosis facilitates treatment and ensures better clinical outcomes.

In this study, a deep learning model using Convolutional Neural Networks (CNNs) is proposed for the early detection of retinal diseases and the application of appropriate treatment methods. The proposed model is applied on the ODIR-5K dataset. The ODIR-5K dataset contains retinal images of eight different types of diseases, including Myopia, Hypertension, Glaucoma, Age-related Macular Degeneration (ARMD), Diabetic Retinopathy (DR), Cataract, Other abnormalities, and normal individuals. The images in the ODIR-5K dataset were first equalized to have consistent resolution and dimensions, and then underwent preprocessing steps including histogram equalization using the clahe method. Scaling operations were also performed. Furthermore, the accuracy rates of transfer learning methods were obtained as follows: VGG19 (98.16%), ResNet50 (98.86%), Xception (95.36%), InceptionV3 (98.2%) and the proposed convolutional neural network model (97.51%). The proposed model achieved better classification results for images of cataracts and normal retinas compared to pre-trained transfer learning methods. The proposed deep learning-based CNN model can be used for the early detection of retinal diseases.

Keywords: Deep Learning, Convolutional Neural Network, OCT, Fundus Images, Retinal Diseases

ÖNSÖZ

Lisans ve Yüksek Lisans eğitim hayatım boyunca yardımlarını esirgemeyen saygıdeğer Danışman Hocam Prof. Dr. Sabri KOÇER'e teşekkürlerimi sunarım.

Her zaman desteklerini hissettiğim Konya Teknik Üniversitesi Bilgisayar Mühendisliği değerli Hocam Dr. Öğr. Üyesi Alper KILIÇ ve mesai arkadaşlarıma sonsuz teşekkürlerimi sunarım. Son olarak bugünlere gelmemde büyük emekleri olan annem ve babam; Emine ve Mehmet URMAMEN'e minnet ve şükranlarımı sunarım.

Hafıza Esra URMAMEN
KONYA-2023

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	v
ÖNSÖZ	vi
İÇİNDEKİLER.....	vii
SİMGELER VE KISALTMALAR.....	ix
1.GİRİŞ	1
2. KAYNAK ARAŞTIRMASI	3
3. MATERYAL VE YÖNTEM.....	8
3.1. Gözün Yapısı ve Retinal Hastalıklar	8
3.1.1. Retina Anatomisi	10
3.2. Tomografi Cihazları.....	11
3.3.Retinal Hastalıklar	12
3.3.1. Maküler Epiretinal Membran.....	12
3.3.2. Epiretinal Membran	12
3.3.3. Drusen.....	13
3.3.4. Diyabetik Retinopati	14
3.3.5. Glokom	15
3.3.6. Katarakt.....	15
3.3.7. Yaşa Bağlı Maküler Dejenerasyon	16
3.3.8. Hipertansiyon.....	16
3.3.9. Miyop.....	17
3.3.10. Diğer Hastalıklar	17
3.4. Derin Öğrenme	18
3.4.1. Derin Öğrenme Eğitim Metotları.....	19
3.5. Yapay Sinir Ağları (Artificial Neural Network).....	20
3.5.1. Evrimsel (Konvolüsyonel) Sinir Ağları	22
3.6. Ön Eğitimli Ağlar	30
3.6.1. ResNet.....	31
3.6.2. VGG-Net.....	32
3.6.3. EfficientNet.....	33
3.6.4. InceptionNet.....	34
3.6.5. Xception.....	35
3.6.6. LeNet-5 Ağ Mimarisi.....	37
3.7. Önerilen Evrimsel Sinir Ağı Modeli	37
3.8. ODIR-5K Veri Seti	41
3.9.Verİ Ön İşleme.....	47
3.9.1. Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE)	47
3.10. Veri Artırma (Data Augmentation).....	50

3.11. Veri setinin Eğitim, Doğrulama ve Test olarak Bölünmesi.....	51
3.12. Çalışmada Kullanılan Donanım ve Yazılımlar	51
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	52
4.1. Performans Metrikleri.....	52
4.1.1. Karışıklık Matrisi.....	52
4.1.2. Duyarlılık (Recall) :	54
4.1.3. Hassasiyet (Precision):.....	54
4.1.4. Kesinlik (Recall):.....	54
4.1.5. F-1 Puanı (F-1-Score):	55
4.2. MODELLERİN TEST SONUÇLARI	56
4.2.1.VGG19 Modeli	56
4.2.2.XceptionV3 Modeli	58
4.2.3 InceptionV3 Modeli	59
4.2.4. ResNet50 Modeli	61
4.2.5. Önerilen ESA Modeli	63
5. SONUÇLAR VE ÖNERİLER.....	66
5.1 Sonuçlar	66
5.2 Öneriler	66
6. KAYNAKLAR	68
EKLER	72

SİMGELER VE KISALTMALAR

Kısaltmalar

OCT	Optical Coherens Tomography
ESA	Evrişimli Sinir Ağı
CNN	Convolutional Neural Network
YBMÖ	Yaşa Bağlı Maküler Ödem
DR	Diyabetik Retinopati
AMD	Age-related Macular Degeneration
DME	Diyabetik Maküler Ödem
FFA	Fundus Floresein Anjiyografi
RELU	Rectified Linear Unit – Doğrultulmuş lineer birim
CLAHE	Contrast Limited Adaptive Histogram Equalization
FED	Funchs Endotelyal Distrofi
DES	Dry Eyes Syndrome
CDR	Cup to Disc Ratio
OD	Optic Disk
OC	Optic Cup
SE	Squeeze and Excitation
RPE	Retina Pigment Epiteli
GAN	Generative Adversarial Networks

ŞEKİLLER TABLOSU

Şekil 3.1. Gözün Anatomik Yapısı	9
Şekil 3.2. Retinanın Anatomik Yapısı (S.C., 2023).....	10
Şekil 3.3. Optik Koherans Tomografi Cihazı (Akman, 2023).	11
Şekil 3.4. Maküler Epiretinal Membran Fotoğrafı.....	12
Şekil 3.5. Epiretinal Membran Fundus Fotoğrafı	13
Şekil 3.6. Soft Drusen Fundus Fotoğrafı	13
Şekil 3.7. Diyabetik Retinopati Fundus Fotoğrafı	14
Şekil 3.8. Glokom Fundus Fotoğrafı	15
Şekil 3.9. Katarakt Fundus Fotoğrafı.....	15
Şekil 3.10.Yaşa Bağlı Maküler Dejenerasyon Fundus Fotoğrafı.....	16
Şekil 3.11. Hipertansiyon Fundus Fotoğrafı.....	16
Şekil 3.12. Miyop Fundus Fotoğrafı.....	17
Şekil 3.13. Diğer Hastalıklar ve Anormallikleri İçeren Fundus Fotoğrafları.....	18
Şekil 3.14.Transfer Öğrenme ve Sıfırdan Öğrenme (Gudikandula, 2019).	20
Şekil 3.15. Nöronun Temel Yapısı (Neuron, 2023).....	21
Şekil 3.16.Yapay Sinir Ağı Hücresi	21
Şekil 3.17. Evrişimli Sinir Ağı Yapısı (Mathworks, 2023).	22
Şekil 3.18. Evrişim Katmanı Özellik Çıkarımı (Kuchera Et Al., 2019).	23
Şekil 3.19. Sigmoid Aktivasyon Fonksiyonu ve Türevi Grafiği.....	25
Şekil 3.20. Tanh Aktivasyon Fonksiyonu ve Türevi	26
Şekil 3.21. Relu Aktivasyon Fonksiyonu ve Türevi.....	26
Şekil 3.22. Leaky Relu Aktivasyon Fonksiyonu ve Türevi	27
Şekil 3.23. 2x2 Maksimum Havuzlama , Ortalama Havuzlama (Yani, Irawan, & Setianingsih, 2019). ...	28
Şekil 3.24. Tam Bağlantı Katmanı	29
Şekil 3.25. Dropout Uygulanan ve Uygulanmayan Katmanlar(Srivastava, Hinton, Krizhevsky, Sutskever, & Salakhutdinov, 2014).	29
Şekil 3.26. Düzleştirme Katmanı.....	30
Şekil 3.27. Resnet Artık İnşa Bloğu	31
Şekil 3.28. Resnet Mimarisi (Techs, 2023).	32
Şekil 3.29. VGG16 Mimarisi(Varshney, 2023).....	33
Şekil 3.30. Efficientnet Mimarisi (Ahmed, 2023).	33
Şekil 3.31. Inception Modül Yapısı (Szegedy Et Al., 2015).	35
Şekil 3.32. Xception Mimarisi Derinleştirilmiş Evrişim Modeli (Chollet, 2017).....	36
Şekil 3.33. Xception Ağının Mimarisi (Chollet, 2017).....	36
Şekil 3.34. Lenet-5 Mimarisi(Yann Lecun, 2015).	37
Şekil 3.35. Önerilen Model Akış Diyagramı	38
Şekil 3.36. Önerilen Esa Mimarisinin Yapısı	39
Şekil 3.37. Odır-5k Veri Seti Hastalıkların Dağılım Grafiği	42
Şekil 3.38. Normal Tomografi Fotoğrafları.....	43
Şekil 3.39. Diyabetik Retinopati Tomografi Fotoğrafları.....	44
Şekil 3.40. Katarakt Tomografi Fotoğrafları	44
Şekil 3.41. Hipertansiyon Tomografi Fotoğrafları	45
Şekil 3.42. Diğer Hastalıklar Ve Anormallikler İçeren Tomografi Fotoğrafları.....	45
Şekil 3.43.YBMD Tomografi Fotoğraflar	46
Şekil 3.44. Miyop Tomografi Fotoğrafları	46
Şekil 3.45. Glokom Tomografi Fotoğrafları	47
Şekil 3.46. Glokom Retinal Görüntüsü(A), Gri Filtre Uygulanmış(B), Clahe Uygulanmış Görüntüsü(C) 48	
Şekil 3.47. AMD Retinal Görüntüsü(A), Gri Filtre Uygulanmış(B), Clahe Uygulanmış Görüntüsü(C)... 48	
Şekil 3.48. Diğer Hastalıklar Retinal Görüntüsü(A), Gri Filtre Uygulanmış(B), Clahe Uygulanmış Görüntüsü(C).....	49
Şekil 3.49. Glokom Görüntüsüne Gri Filtre ve Clahe Uygulanmış Histogram Grafikleri.....	49
Şekil 3.50. AMD Görüntüsüne Gri Filtre ve Clahe Uygulanmış Histogram Grafikleri	49
Şekil 3.51. Miyop Görüntüsüne Gri Filtre ve Clahe Uygulanmış Histogram Grafikleri	50
Şekil 4.1. Karışıklık (Hata) Matrisi	53
Şekil 4.2. VGG19 Doğruluk Ve Kayıp Grafikleri	56
Şekil 4.3. VGG19 Hata Matrisi	57

Şekil 4.4. Xceptionv3 Doğruluk Ve Kayıp Grafikleri	58
Şekil 4.5. Xceptionv3 Hata Matrisi	59
Şekil 4.6. Doğruluk ve Kayıp Grafikleri.....	60
Şekil 4.7. Inceptionv3 Hata Matrisi	60
Şekil 4.8. Doğruluk Ve Kayıp Grafikleri.....	61
Şekil 4.9. Resnet50 Hata Matrisi	62
Şekil 4.10. Doğruluk Ve Kayıp Grafikleri.....	63
Şekil 4.11. Önerilen Esa Hata Matrisi	64



ÇİZELGELER LİSTESİ

Çizelge 3.1. Hiper-Parametre Ayarları	38
Çizelge 3.2. Esa Mimarisinin Yapısı	41
Çizelge 3.3. Veri Setindeki Hastalıkların Dağılımı	43
Çizelge 3.4. Veri Artırma İçin Kullanılan Parametre Değerleri	51
Çizelge 3.5. Veri Seti Artırma Uygulandıktan Sonra Veri Dağılımı	51
Çizelge 4.1. Vgg19 Modeli İle Test Verilerinden Elde Edilen Sınıflandırma Sonuçları	57
Çizelge 4.2. Xceptionv3 Modeli Test Verileri İle Elde Edilen Sınıflandırma Sonuçları	59
Çizelge 4.3. Inceptionv3 Modeli Test Verileri İle Elde Edilen Sınıflandırma Sonuçları	61
Çizelge 4.4. Resnet50 Modeli Test Verileri İle Elde Edilen Sınıflandırma Sonuçları	62
Çizelge 4.5. Önerilen Esa Modeli Test Verileri İle Elde Edilen Sınıflandırma Sonuçları	64
Çizelge 4.6. Modellerin Performans Analizi Karşılaştırılması	65



1.GİRİŞ

Retina, göz küresinin iç yüzeyinde bulunan ışığa duyarlı hücreleri yapısında barındıran optik sinir dokusu ve damar tabakasından oluşmaktadır. Kalınlığı yaklaşık olarak 0.1 ile 0.5 mm aralığında olan yarı saydam yapıdaki duyusal ağ katmanıdır. Bu katman, odaklanan ışığı mercek yardımıyla alarak nöral sinyallere dönüştürür ve bu sinyallerin beyne iletilmesini sağlar (Keremany et al., 2018). Makula, göze gelen ışığın odaklandığı, nesneleri detaylı, keskin ve renkli görmemize yardımcı olan yapısında özel fotoreseptör hücrelerin bulunduğu retina üzerinde yer alan merkezdir (Keremany et al., 2018). Retina da göze gelen ışığı algılayan çubuk ve koni hücreleri olmak üzere 2 tür fotoreseptör hücre bulunmaktadır. Çubuk hücreleri, siyah-beyaz görmemizi sağlar, ışığa duyarlı yapıdaki bu hücreler gece net görüş sağlar ve retina bölgesinde yoğun olarak bulunmaktadır. Koni hücreler, renkli görmeyi sağlar, keskin ve net görüşe yardımcı olmaktadır ve sarı benek bölgesinde yoğun bir şekilde bulunmaktadır. Çubuk ve koni hücrelerinde oluşan bozulmalar sonucunda miyop ve hipermetrop göz kusurları meydana gelebilmektedir.

Retina bölgesinde meydana gelen sorunlar karakteristik özellikler gösterebilmektedir. Retinal dokunun çevresel faktörlerden kaynaklı zarar görmesi, kalıtsal, göz içi tümörler, retina yırtıkları ve damar sistemindeki bozulmalar sebebiyle meydana gelebilmektedir. Bu sebeple görüş alanında çeşitli sorunlar oluşan bireylerin kalıcı görme sorunları yaşamamaları için vakit kaybetmeden alanında uzman kişilere başvurmaları büyük önem taşımaktadır.

Miyop, Hipermetrop, Glokom, Yaşa bağlı Maküler Dejenerasyon (YBMD), Drusen, Diyabetik Maküler Ödem (DME), Diyabetik Retinopati (DR), Sarı Nokta Hastalığı, Makula Deliği, Retina yırtığı, Hipertansiyon ve diğer retinada oluşan birçok göz travmaları ve retina hastalıkları mevcuttur. Bu hastalıklara sahip bireylerde görme kalitesinde azalma, geçici veya kısa süreli görme kayıpları, perdeli görüntü, gözün ön tarafında uçuşan cisimler gibi belirtileri mevcut olabilmektedir. Bazen de hiçbir belirti göstermeden görme kayıpları ile sonuçlanabilen retinal hastalıklarda mevcuttur. Gözün retinasında oluşan belirtiler hastanın görme işlevini etkileyen, müdahale edilmediğinde geri dönüşü olmayan hasarlar bırakabilmektedir (Schmidt-Erfurth, Sadeghipour, Gerendas, Waldstein, & Bogunović, 2018). Bu nedenle erken teşhis ve tedavi son derece önemli ve hassasiyet gösterilmesi gereken bir konudur. Teknolojinin ilerlemesiyle birlikte

bilgisayar destekli tanı sistemleri ile retinal hastalıkların teşhis ve tedavisinde umut verici sonuçlar elde edilmektedir.

Uzmanlar tarafından retina muayeneleri sonrasında son teknoloji ile geliştirilmiş retinayı detaylı şekilde incelemek için kullanılan ultrasonik cihazlar, Optik Koherans Tomografisi (OCT) ve Fundus Floresein Anjigografisi (FFA) teknolojileri kullanarak elde edilen görüntüler üzerinden retinal hastalıklara erken tanı konulabilmesi uzmanların teşhisini oldukça kolaylaştırmaktadır. Uzmanlar tarafından teşhis edilen hastalıklar gerekli tedavi işlemleri tamamlandıktan sonra hasta hayatına devam edebilmektedir bu açıdan önerilen derin öğrenme tabanlı otomatik hastalık tanı sistemi uzmanların oküler retinal hastalıkları teşhis etmesinde işlerini kolaylaştırmaktadır. Retinal hastalıkların teşhis edilmesinde uzman sayısının yetersizliği ve yeterli zamanın olmaması gibi faktörlerin önüne geçerek daha hızlı şekilde müdahale edilmesini, hastalıkların teşhisini kolaylaştıracak derin öğrenme tabanlı Evrişimli Sinir Ağı (ESA) önerilmiştir.

Bu çalışma kapsamında retinal hastalıkların teşhisini kolaylaştırmak için transfer öğrenme mimarileri ve evrişimli sinir ağları kullanılmıştır. Optik Koherans Tomografi görüntülerinden oluşan ODIR-5K veri seti tercih edilmiş olup, tomografi görüntüleri farklı çözünürlüklerde ve boyutlarda olması dolayısıyla görüntüler 224x224 boyutlarına indirgenerek ölçeklendirilmiştir. OCT görüntüleri gri filtreleme ve kontrast histogram eşitleme veri ön işlemlerinden geçirilmiştir. Veri setinde bulunan verilerde dengesiz dağılımlar sebebiyle veri artırma işlemleri uygulanarak veri setindeki dengesizlik giderilmeye çalışılmıştır. ImageNet yarışmasında başarılı olan transfer öğrenme yöntemlerinden VGG19, InceptionV3, Xception ve ResNet50 transfer öğrenme yöntemleri ve önerilen ESA uygulanan derin öğrenme modelleri uygulanarak sınıflandırma işlemi tamamlanmıştır. Elde edilen sonuçlar karşılaştırıldığında önerilen ESA mimarisinin transfer öğrenme metotlarına yakın doğruluk değerlerine ulaştığı ayrıca normal ve katarakt görüntülerinde diğer yöntemlere kıyasla yüksek başarı oranına ulaştığı görülmüştür.

Bu tez çalışması 5 temel bölümden oluşmaktadır. Birinci bölümde giriş ve çalışmanın amacından bahsedilmiştir, ikinci bölümde kaynak araştırması yapılmıştır ve daha önce uygulanan derin öğrenme metotları ve transfer öğrenme metotları incelenmiştir. Üçüncü bölümde kullanılan materyal ve metotlara değinilmiştir. Dördüncü bölümde, çalışmadan elde edilen araştırma sonuçları ve elde edilen sonuçlar tablolar halinde verilerek değerlendirilmiştir. Son olarak beşinci bölümde sonuçlar ve önerilere yer verilmiştir.

2. KAYNAK ARAŞTIRMASI

Retinal hastalıkların sınıflandırılması ile ilgili yapılan uygulamalar incelendiğinde literatüre katkısı olan birçok farklı yöntem kullanılmıştır. Son zamanlarda yapılan çalışmalarda derin öğrenme mimarileri, transfer öğrenme yöntemleri oldukça sık kullanılmaktadır. Bu alanda literatürde yapılan çalışmalar ve kullanılan yöntemler incelenmiştir.

2014 yılında Srinivasan ve ark. Yönlendirilmiş gradyan (HOG) ve destek vektör makinesine (SVM) dayalı bir sistem önermişlerdir. Yönlendirilmiş gradyan , yaşa bağlı maküler dejenerasyon (AMD) ve diyabetik maküler ödem (DME) gibi retinal hastalıkların tespit edilmesi için kullanılmıştır. Açık kaynak olarak sunulan Optik Koherans Tomografi (OCT) veri setinde bulunan görüntüler yetişkin hastaların retinalarından seçilmiş görüntülerden oluşmaktadır. OCT setinde veriler Normal, CNV, Drusen ve DME olmak üzere dört sınıfa ayrılmıştır. DME için %100, AMD için %100 ve normal olarak sınıflandırılmış sağlıklı retina da %86,76 gibi yüksek bir doğruluk oranı elde etmiştir (Srinivasan et al., 2014).

2016 yılında Gulshan ve ark. OCT fundus görüntülerinden diyabetik retinopati ve diyabetik maküler ödemin belirlenebilmesi için Inception mimarisi kullanarak önerdikleri modeli EyePACS-1 veri seti ve Messidor-2 veri setleri üzerinde eğitmişlerdir. EyePACS-1 için duyarlılık %90,3 ve özgüllük %98,1 değerleri elde etmiştir. Messidor-2 veri seti için duyarlılık %87,0 ve özgüllük %98,5 olarak bulunmuştur (Gulshan et al., 2016).

2017 yılında Gargeya ve ark. diyabetik hastalardan alınan toplamda 75.137 adet halka açık fundus görüntülerini, sağlıklı ve Diyabetik Retinopati (DR) hastası olarak sınıflandırmak için ağaç tabanlı bir sınıflandırma modeli geliştirmişlerdir. Messidor 2 ve E-Ophtha veri setleri üzerinde geliştirdikleri modeli eğitim ve test aşamalarını gerçekleştirmişlerdir. Geliştirdikleri otomatik derin öğrenme yönteminde öğrenilen bilgiler, otomatik olarak oluşturulmuş bir anormallik ısı haritası aracılığıyla kolaylıkla görselleştirilmiştir ve 5 kat çapraz doğrulamada sırasıyla %94 ve %98 hassasiyet ve özgüllük ile AUC değerini 0.97 olarak elde etmişlerdir (Gargeya & Leng, 2017).

2018 yılında Najeeb ve ark. tarafından retinal anormalliklerin otomatik olarak tespit edilebilmesi için Optik Koherans Tomografi (OCT) tarama görüntülerinden oluşturulan içerisinde çeşitli hastalıklardan oluşan 83.484 veri içeren OCT veri setini kullanarak retinal rahatsızlıkların sınıflandırması için tek katmanlı ağ yapısı kullandıkları

modeli önermişlerdir. Önerilen model %95.66 oranında doğruluk oranına sahip ve açık kaynak olarak kullanıma sunulmuştur (Najeeb et al., 2018).

2019 yılında Das ve ark. yaptıkları çalışmada OCT görüntülerinden patolojilerin tespit edilebilmesi için çok ölçek içeren yeni bir derin özellik füzyonu (MDFF) içeren yöntem önermişlerdir. Kullanılan veri setinde 84.484 retinal görüntü içeren ve Diyabetik Maküler Ödem (DME), Yaşa Bağlı Maküler Dejenerasyon (AMD), Drusen, Koroidal Neovaskularizasyon(CNV) hastalıklarının bulunduğu veri seti üzerinde test edildiğinde sırasıyla %99.6, %99.87, %99.6 hassasiyet, özgüllük ve doğruluk değerleri elde edilmiştir. Önerilen yöntem çok fazla uzmanın bulunmadığı sağlık merkezlerinde, göz kliniklerinde retinal patolojilerin otomatik teşhisi için kullanım ve erken tedavisi için oldukça umut vaat eden doğruluk sonuçları sağlamıştır (V. Das, Dandapat, & Bora, 2019).

2020 yılında Berrimi ve ark. CNV, Drusen, DME ve AMD gibi ağırlıklı olarak retinanın zarar görmesinden kaynaklanan ve retinada kalıcı hasarlara neden olabilecek hastalıkların tespit edilmesi için Optik Koherans Tomografisi ile gelişmiş tarama yapabilen cihazdan aldıkları göze ait retinanın kesitsel görüntülerini barındıran veri setinde geliştirdikleri modeli doğrulamışlardır. Geliştirilen modelde transfer öğrenmeden yola çıkarak derin bir CNN mimarisi önerilmiştir ve elde edilen sonuçları Inception V3 ve VGG-16 mimarisine daha fazla evrişim katmanı ekleyerek önceden eğitilmiş transfer öğrenme modelleriyle karşılaştırmışlardır. Önerilen model de test setinde %98.5'lik doğruluğa ulaşılmış, InceptionV3 ve VGG16 modellerinde ise sırasıyla %99.27' ve %93.5'e varan doğruluk değerlerine ulaşılmıştır (Berrimi & Moussaoui, 2020).

2021 yılında Sridha ve ark. Gözün Fundus Fotoğrafı taramalarını içeren retinal görüntüleri ön işleme tabi tuttukten sonra kan damarların dallanan yapılarını çıkartmak için hessian matrisinin maksimum eğrilik tekniği uygulanmıştır. Sınıflandırma işlemi için oluşturulan evrişimli sinir ağı, her bir sınıf için bir sıkıştırma, uyarma ve darboğaz katmanlarının bir kombinasyonunu ve ikili sınıflandırma için bir evrişim ve havuzlama katmanı mimarisini içerir. Önerilen modelin değerlendirmesi için Diabetdb1 veri setinde ve bir tıp kurumu tarafından sağlanan hem diyabet hem de normal retinaların fundus fotoğraflarından oluşan veri seti üzerinde uygulanmıştır. Veri setleri üzerinde uygulanan deneysel sonuçlar değerlendirildiğinde %98,7 doğruluk ve %97,2 kesinlik oranlarına ulaşılmıştır, bu da geleneksel derin öğrenme yöntemlerine kıyasla önerilen yöntemin umut vaat ettiği görülmektedir(S. Das, Kharbanda, M, Raman, & D, 2021).

2021 yılında Elsayy ve ark. ön segment optik koherans tomografi (AS-OCT) görüntülerinin kullanılarak yaygın kornea hastalıkları: Kuru göz sendromu (DES), Funchs Endotelyal Distrofi (FED) ve Keratokonus(KCN) ile ilgili çok hastalıklı bir derin öğrenme modeli (MDDN) önerilmektedir. Bu çalışmada sinir ağını geliştirmek ve doğrulamak için 478 hastanın gözünden alınan toplamda 158.220 AS-OCT görüntüsü 45.900 sağlıklı, 16.740 FED, 90.780 DES hastalıklarına ait OCT görüntüleri kullanılarak model eğitilmiştir ve 134.460 görüntü ile model doğrulanmıştır. MDDN, DES, FED için %95 CI :0,90 olarak bulunmuştur (Elsawy et al., 2021).

2021 yılında Shanmugam P. ark. tarafından fundus görüntülerinde glokom hastalığının tespit edilebilmesi için derin öğrenme ve rastgele orman sınıflandırma algoritmasını kullanarak otomatik bir sistem önermişlerdir. Bu çalışmada fundus fotoğraflarından CDR (Cup to Disc Ratio) tahmin edilerek, glokomun varlığının ayırt edilebilmesi için optik diskin boyutu kullanılmaktadır. Önerilen glokom tanıma tekniği, özellik çıkarma aşaması ve glokom değerlendirme aşamalarını içerir. Optik Disk (OD) ve Optik Kup (OC) sınırları belirlenirken Au-Net kullanılmıştır. Glokom hastalığı bulunan görüntüleri sınıflandırmak için de Rastgele Orman Sınıflandırıcısı kullanılmıştır. Önerilen yöntemin performansına bakıldığında Deformable U-Net, Full-Deformable U-Net ve U-Net gibi farklı tekniklerle karşılaştırıldığında önerilen yöntemin sınıflandırma doğruluğu %99 oranında daha iyi performans verdiği ve U-Net ile karşılaştırıldığında %14 oranında segmentasyon doğruluğuna sahip olduğu ortaya konmuştur (P, J, & R, 2021).

2022 yılında Gupta ve ark. retinal fundus görüntüleri ile çeşitli göz hastalıklarını tespitini otomatik olarak sağlayan (ODCNN-RFIC) derin öğrenme modeli için Optimal Derin Konvolüsyonel Sinir Ağı geliştirmişlerdir. Geliştirdikleri derin öğrenme modelini Aria ve Stare veri setleri üzerinde uygulamışlardır. Geliştirilen modelde, iki aşamadan oluşan veri ön işleme uygulanmaktadır, ilki Kılavuzlu Filtre (Guided Filter) diğeri de Adaptif Medyan filtre kullanılmaktadır. Ayrıca görüntü bölütleme işlemi için U-Net kullanarak enfekte olan bölgelerin uygun şekilde tespit edilmesine olanak sağlanmıştır. Sınıflandırma modeli olarak çekirdek aşırı öğrenme makinesi (MFO-KELM) modeli ve Mayfly optimizasyonu uygulanmıştır. Elde edilen deneysel sonuçlar, Aria ve Stare veri setleri ile sırasıyla %97.62, %98.82 oranında doğruluk değerlerini elde etmiştir. Önerilen ODCNN-RFIC modelinin fundus görüntülerinde sınıflandırma sonuçları mevcut güncel yöntemlerle karşılaştırıldığında doğruluk değerlerindeki üstün performansını göstermektedir (Gupta, Choubey, & Choubey, 2022).

2022 yılında Rajan ve ark. optik koherans tomoğrafi görüntülerinin sınıflandırılması için yeni bir derin öğrenme mimarisi olan OCT Deep-Net2'yi önermişlerdir. Bu çalışmada dört sınıflı hastalık sınıflandırılması yapılmıştır ve önerilen model OCT Deep-Net2 30 katmandan oluşmaktadır. Performans ölçütlerine bakıldığında OCT Deep-Net2 mimarisinin %98 doğruluk değeri ile verimliliği büyük ölçüde ortaya konulmaktadır (Rajan & Kumar, 2022).

2023 yılında Batha ve ark. çalışmalarında Diyabetik Retinopati (DR) tespit edilebilmesi için derin öğrenme yaklaşımına sahip bir hibrit model önermişlerdir. Başlangıç olarak görüntülerdeki gürültüleri giderebilmek için çapraz kılavuzlu ikili filtre (CGBF) uygulanmıştır. Ön işleme işlemleri uygulandıktan sonra özneteliklerin belirlenebilmesi için dalgacık tabanlı bir Chimp Optimizasyon Algoritması (WBCOA) tasarlanmıştır. Öznetelik çıkarımından sonra, açık kapalı havza yöntemiyle optik disk (OD) ve kan damarı (BV) segmentasyonu yapılmıştır. Son olarak sınıflandırma işlemi için Siyam tabanlı AlexNet ve GoogleNet ile SVM modeli önerilmiştir. Çıkarılan görüntüler Destek Vektör Makinesi (SVM) kullanılarak sınıflandırmıştır ve önerilen yöntem Python dilinde kodlanarak uygulanmış ve DIARETDB0 (DB0) ve DIARETDB1 (DB1) veri setleri üzerinde test edilmiştir. Veri setleri üzerinde önerilen hibrit derin öğrenme ağı, DB0, DB1 veri setleri sırasıyla %94 ve %94,83 doğruluk elde edilmiştir. Önerilen hibrit derin öğrenme modelinin erken Diyabetik Retinopati (DR) tespiti için doğru sonuçlar elde ettiği ve diyabetin etkili tedavisine katkı sağlayacağını kanıtlamaktadır (Venkaiahpalaswamy, Prasad Reddy, & Batha, 2023).

2023 yılında Lu ve ark. Oftalmologların hastaların tedavilerini geliştirmek için DR ve DME hastalıklarını otomatik olarak derecelendirmek için transfer öğrenmeye dayalı beş katmanlı evrişimli sinir ağı modeli geliştirmişlerdir. Geliştirdikleri beş katmanlı çapraz doğrulama modelini MobileNetV2 ve ResNet50 ile karşılaştırmışlardır. Önerilen modelin doğruluk oranı %99.71, MobileNetV2 %99.43 ve ResNet50 modelinde %99.73 olarak elde edilmiştir. Bu sonuçlar geliştirdikleri modelin klinik deneylerde retinal hastalıkların teşhisinde umut verici sonuçlar elde ettiği ve MobileNetV2 den daha başarılı olduğu görülmektedir (Lu et al., 2023).

2023 yılında Bhati ve ark. tarafından dengesiz fundus görüntü veri setinde çok etiketli sınıflandırılmış ve retinal hastalıkların tespiti için bir evrişim ağı önermişlerdir. Kullandıkları veri seti Oküler Hastalık Tanıma (ODIR-5K) bu veri seti araştırmacılar tarafından fundus tomografi görüntüleri sekiz farklı sınıftan oluşmaktadır. Bu çalışma, ekstra hesaplama maliyetine gerek kalmadan ayrımcı bölge doğrultusunda konvolüsyon

sinir ağı (DKCNet) önermişlerdir. DKCNet, bir SE (Squeeze and Excitation) bloğu tarafından takip edilen bir dikkat bloğundan oluşmaktadır. SE bloğu ayırt edici özellik haritaları alarak kanalların bağımlılıklarını geliştirir. Çalışma kapsamında elde edilen sonuçlar 94.28 F1 skoru, 96.08 AUC skoru ve 0.81 kappa skoru ile ODIR-5K veri seti üzerinde çok etiketli görüntülerin sınıflandırılması için Inception, ResNet ile DKCNet modelinin daha iyi performans gösterdiği görülmektedir. Önerilen modelin halka açık üç veri seti üzerinde test edilmiştir ve test verilerinde kullanılan verilerde çok etiketli sınıflandırma için kullanılacak yüksek doğruluk değerlerine sahip sonuçlar elde edilmiştir (Bhati, Gour, Khanna, & Ojha, 2023).

Literatür incelendiğinde VGG19, ResNet50, InceptionV3 ve Xception modellerinin bir arada bulunduğu ve sonuçların karşılaştırıldığı retinal hastalıkların teşhisine yönelik çalışmanın bulunmadığı görülmüştür. Bu sebeple önerilen derin öğrenme tabanlı ESA modeli ile önceden eğitilmiş transfer öğrenme modelleri kıyaslanmıştır. Karşılaştırılan modellerde doğruluk, kesinlik, duyarlılık, kayıp değeri ve F-1 puanı gibi performans ölçütlerine göre değerlendirme işlemleri yapılmıştır.

3. MATERYAL VE YÖNTEM

Tez çalışmasının bu bölümünde, retinal hastalıkların sınıflandırılması için, optik koherans tomografi cihazından elde edilen fundus görüntüleri kullanılmıştır. Kullanılan veri setine dair bilgiler eklenmiştir. Veri seti üzerinde ön işleme teknikleri, veri artırma işlemleri uygulanmıştır. Çalışma yapısal olarak iki adımdan oluşmaktadır veri setinde bulunan veri dağılımlarının eşitsizliği nedeniyle veri artırma işlemi ardından yüksek çözünürlük ve farklı boyutlarda bulunan veriler 224x224 boyutlarında yeniden ölçeklendirilmiştir. Ölçeklendirilmiş görüntülere gri filtre ardından Konstrast Sınırlı Adaptif Histogram Eşitleme (CLAHE) işlemleri gerçekleştirilmiştir. Veri ön işleme işlemlerinin ardından önerilen ESA mimarisi kullanılarak eğitilmiştir.


ODIR-5K veri seti üzerinde önerilen ESA ve ImageNet veri tabanı üzerinde önceden eğitilmiş transfer öğrenme yöntemleri kullanılmaktadır. ODIR-5K veri seti Çin’de Shangong Medikal Teknoloji tarafından sağlık kuruluşlarından alınan renkli fundus fotoğraflarını içermektedir. Dünya genelinde oldukça sık görülen retinal hastalıklardan oluşmaktadır. Önerilen yöntem transfer öğrenme yöntemleri ile karşılaştırılarak elde edilen sonuçlar karşılaştırılmıştır.

3.1. Gözün Yapısı ve Retinal Hastalıklar

Göz, insanın dış dünyaya açılan etrafımızdaki nesneleri algılamamıza yardımcı, benzersiz bir yapıya sahip beş temel duyu organımızdan en hassas ve en karmaşık olanlarından biridir. Göz küresi yaklaşık 2,5 cm çapında olup yapısında bulunan fotoreseptörler sayesinde ışık uyarılarını algılayabilmekte ve nesneleri görebilmektedir. Orbita denilen göz çukuru olarak da bilinen armut şeklinde kemiksi bir yapı içerisinde bulunur ve yaklaşık 7.5 gr. ağırlığında ve küresel bir yapıya sahiptir. Şekil 3.1 incelendiğinde göz yapısında dıştan içe doğru destekleyici (sert) tabaka, vasküler (damar) tabaka ve ağ tabaka olmak üzere birbirini saran üç temel segmentten oluşmaktadır (Karalezli & Kaderli, 2021). Sert tabaka, kornea ve skleradan oluşmaktadır. Gözün şekli ve yapısını sklera tarafından korunmaktadır, sklera gözü iç ve dış etkenlere karşı koruyan beyaz bir bağ dokusu tabakasından oluşmaktadır. Kornea ise iris ile göz bebeğinin ön kısmında yer alan şeffaf bir tabakadır, görüntülerdeki ince detayların fark edilmesi ve nesnelere odaklanabilmemiz kornea tarafından sağlanmaktadır (Ita, 2022). Gözümüzün orta kısmında siliyer cisim, iris ve koroid bulunmaktadır. İris gözün renkli kısmıdır ve

retinaya ulaşan ışık miktarını kontrol eder. Siliyer cisim ise göz bebeğinin arkasında bulunmaktadır ve göz içi sıvısının üretildiği yerdir (Willoughby et al., 2010).

Ağ tabaka, gözün en iç kısmında bulunan ve tamamen damarlardan oluşan bir yapıdır. İçerisinde bulunan makula tabakasındaki fotoreseptör hücreleri sayesinde beyin görüntü oluşturmalarını sağlamak amacıyla beyne sinyaller gönderir ve beyinde bulunan görme merkezi bu sinyalleri işleyerek görüntüyü algılamaktadır Retinada iki çeşit fotoreseptör bulunmaktadır bunlar koni ve çomak hücreleri olarak bilinmektedir. Çomak hücreleri düşük ışık dalga boyuna karşı duyarlıdır bu nedenle gece görüşümüzde ve karanlıkta görmemize yardımcı olmaktadırlar. Koni hücreleri ise daha büyük dalga boylarına sahip ışıktaki nesneleri net, keskin ve renkli görmemize yardımcı hücrelerdir (Foster et al., 1991).



Şekil 3.1. Gözün Anatomik Yapısı


Görme eylemi, ışık kaynağından alınan ışık ilk olarak kornea da kırılıp sonrasında göz bebeği de gelen ışık miktarının fazlalığına göre küçülüp, büyüyerek ışığın göz merceğinde ikinci kez kırılmasını sağlar ardından camsı cisim aracılığıyla görüntü sarı benek denilen “makula” üzerine olduğundan küçük ve ters şekilde düşmektedir. Şekil 3.1.’de gösterilen sarı cisimden (fovea) sonra optik sinirler aracılığıyla talamusa ve uç beyine giderek görüntü düz şekilde algılanması sağlanmaktadır. Tüm göz sistemi birbiri ile ve beyinde bulunan görme merkezi ile senkronize şekilde görme eylemini gerçekleştirmektedir. Görme eyleminde sorun yaşayan bireylerin retinal fundus tomografi cihazlarında çekilen görüntüler uzmanlar tarafından incelenerek

değerlendirilmektedir. Göz küresini detaylı bir şekilde görüntülemek için oftalmoskolojik adı verilen cihaz kullanılmaktadır (Hayati et al., 2023). Bu cihaz sayesinde göz dibi muayenesi yapılabilir ve oluşan hastalığın teşhisi, tedavisi vakit kaybetmeden gerçekleştirilebilmektedir. Bireyler ilerde oluşabilecek ciddi sorunların ve görme kaybının önüne bu sayede geçilebilmektedir.

3.1.1. Retina Anatomisi

Retina, göz küresinin arka tabakasında yer alan yaklaşık 0.5 mm genişliğinde ışığı algılayan ağ dokudur (Kolb, 2012). Yapısında bulunan reseptör hücreler sayesinde ışık enerjisi ile algıladığı bilgiyi beyne iletmektedir. Reseptör hücreler karanlıkta görmeye yardımcı olanları basil ve aydınlık ortamlarda görmeye yardımcı olanları koni hücreleri olmak üzere iki çeşit fotoreseptör hücre bulunmaktadır. Retinanın yapısında dıştan içe doğru 10 katman bulunmaktadır.

- Retina pigment epiteli (RPE)
- Fotoreseptör tabaka: Basil ve koni hücrelerini içermektedir (Snell RS, 1998).
- Dış limitan membran
- İç pleksiform tabaka
- Gangliyon hücreleri tabakası
- İç limitan membran
- Dış nükleer tabaka
- İç nükleer tabaka
- Dış pleksiform tabaka




Şekil 3.2. Retinanın Anatomik Yapısı (S.C., 2023).

Şekil 3.2’de retinada bulunan temel yapılar gösterilmiştir. Retinanın tam ortasında yer alan “Makula” ışığın odaklandığı ve ortasında “fovea” denilen sarı nokta olarak da bilinen keskin görme merkezini oluşturmaktadır. Fovea yapısında oldukça fazla konik hücre barındırmaktadır ve bu sayede keskin, renkli ve detaylı görme merkezini oluşturur.

3.2. Tomografi Cihazları

Optik Koherans Tomografi (OCT) tekniği fizik profesörü Dr. Fujimoto ve ark. tarafından tanımlanmıştır (Huang et al., 1991). Oftalmolojide ilk kez kullanılması da İngiltere Göz Merkezinde, cihazın bir biyomikroskop üzerinde konumlandırılması sonucunda geliştirilen model ile Dr. Schuman ve Dr. Puliafito tarafından ön segment, retinal hastalıklar ve göz tansiyonu uygulanmasıyla sonuçlar elde edilmiştir. Kullanılan çalışmalara ait OKT modeli 1996’da Carl Zeiss firması aracılığıyla piyasaya sunulmuştur (Puliafito et al., 1995). Şekil 3.3’de OCT cihazları örneği verilmiştir.



Şekil 3.3. Optik Koherans Tomografi cihazı (Akman, 2023).

Son yıllarda oldukça sık kullanılan Göz Tomografisi olarak da bilinen Optik Koherans Tomografi (OCT) cihazları radyasyona maruz kalmadan kullandığı kızılötesi ışık (~ 800 nm) teknolojisi sayesinde dokuların kesitlerini alan cihazlardır. 1991 yılında David Huang ve ark. tarafından geliştirilen teknoloji ile birlikte göze gönderilen ışık dalgaları sayesinde göz dokularından geri yansıyan ışık değerlerini ölçerek gözün 3 boyutlu görsel haritalarını ayrıntılı bir şekilde çıkarmaktadır (Huang et al., 1991). Bu sayede birçok göz rahatsızlığı tespit edilebilmekte ve teşhis konulması oldukça kolaylaştırılmıştır. OCT birçok göz rahatsızlığının ve anormalliklerin tespitinde kullanılmaktadır. Diyabetik Retinopati, Sarı Nokta Hastalığı, Göz Tansiyonu, Miyopi, Yaşa Bağlı Maküler Dejenerasyon, Koroidal Nörovaskulasyon ve Sarı Nokta gibi birçok

hastalığı teşhis etmede oldukça başarılı bir görüntüleme yöntemidir. Tomografi cihazları geçmişten günümüze teknolojinin de gelişmesiyle birlikte uzmanların hastalığın teşhis edilmesi, tedavisinde oldukça önemlidir.

3.3.Retinal Hastalıklar

3.3.1. Maküler Epiretinal Membran

Makula, retinanın merkezinde yer alan göze gelen ışıkların odaklandığı merkez bölgesidir. Görme fonksiyonumuzun en kuvvetli ve en keskin olduğu kısımdır. Epiretinal membran ise diğer adıyla makula zarı olarak da bilinmektedir. Bu yapı makulanın merkezinde veya yüzey bölgesinde oluşmaktadır. Bu zar, altındaki makula bölgesinde çekintilere ve makulanın yapısında bozulmalara sebep olmaktadır. Şekil 3.4’de Maküler Epiretinal Membran hastalığına ait fotoğraf görülmektedir.



Şekil 3.4. Maküler Epiretinal Membran Fotoğrafı

Makula zarına herhangi bir sorun olması durumunda ise görmede bulanıklık, cisimleri eğilmiş, çarpık görüş bozuklukları meydana gelebilmektedir genelde ilerleyen yaşlarda ortaya çıkan Maküler Epiretinal Membran hastalığının 40 yaşından sonra görülme sıklığı %4-12 oranları arasında değişim göstermektedir (Totan, 2023). Epiretinal Membran görme kaybına neden olduğunda uzman doktorlar tarafından cerrahi müdahalede bulunulması gerekmektedir.

3.3.2. Epiretinal Membran

Epiretinal Membran gözün ön kısmında zar tabakası oluşmasına denilmektedir. Görmede azalma makula denilen retinanın 3-4 mm’lik merkezinde bulunan bölgede

oluşması durumunda görme fonksiyonlarında azalmalar meydana gelebilmektedir. Şekil 3.5 'de Epiretinal Membran hastalığına ait retinal fotoğraf bulunmaktadır.



Şekil 3.5. Epiretinal Membran Fundus Fotoğrafı

Genelde hastalığın görülmesi herhangi bir nedene bağlanamamaktadır. İlerlemesi durumunda cerrahi müdahale edilebilmektedir (Mitchell, Smith, Attebo, & Wang, 1995).

3.3.3. Drusen

Retinanın altında bulunan yağlardan ve proteinlerden oluşan sarı veya beyaz renge sahip olan bulutsu parlak noktalar drusen olarak adlandırılmaktadır (Silvestri et al., 2012). Belirgin drusen ve soft drusen şeklinde kategorize edilebilmektedir (Mitchell et al., 1995). Belirgin drusen, soft drusen ile karşılaştırıldığında daha keskin ve sınırları daha belirgin şekilde ayırt edilebilmektedir. Şekil 3.6'da soft drusene ait retinal fotoğraf bulunmaktadır.




Şekil 3.6. Soft Drusen Fundus Fotoğrafı

Yaşa Bağlı Maküler Dejenerasyon (YBMD) hastalığının tespit edilmesinde drusenler büyük önem taşımakta ve hastalığın teşhisini kolaylaştırmaktadır (Mittal & Kumari, 2015).

3.3.4. Diyabetik Retinopati

Diyabetik Retinopati (DR), retina damarlarında meydana gelen mikrovasküler bozulmalar sonucunda oluşan ve ciddi görme kaybına ve körlüğe sebep olabilen hastalıklardan biridir. DR, retinada bulunan kılcal damarlarda membranların kalınlaşması, kılcal zayıflama, artan kılcal damarlardaki geçirgenlik, epitel hücrelerde bağlantı kayıpları gibi normal olmayan alışılmamış değişikliklerden kaynaklanabilmektedir (Scanlon, 2022). Genellikle DR, Diyabet (Diabetes Mellitus) halk arasında şeker hastalığı olarak bilinen diyabet hastalığına sahip olan bireylerde DR hastalığının görülme olasılığı daha yüksektir. Diyabet, pankreas tarafından üretilen insülin hormonunun vücudumuzda etkin bir şekilde kullanılamamasından veya insülin hormonunun üretilmemesinden kaynaklanan rahatsızlıktır.



Şekil 3.7. Diyabetik Retinopati Fundus Fotoğrafı

Dünya genelinde diyabet hastalığının 1995 yılında %4,0 olduğu ve 2025 yılında %5,4'e çıkacağı tahmin edilmektedir (King, Aubert, & Herman, 1998).). DR sahip bireyler hastalığın farkında olmayabilir veya aniden oluşabilen görme kaybına maruz kalabilirler. Şekil 3.7'de DR ait retinal görüntü bulunmaktadır. DR, İkili görme, flu görme nesneleri tam olarak ayırt edememe gibi zamanla ortaya çıkabilen sorunların yaşanmasına sebep olabilir. DR ilerleyerek kalıcı hasarlara da sebep olabilmektedir. Bu nedenle düzenli bir şekilde göz muayenesi yaptırılmalıdır ve fundus tomografi görüntüleri alanında uzmanlaşmış hekimler tarafından teşhis edilmelidir.

3.3.5. Glokom

Glokom, dünya genelinde insanlarda en sıklıkla görülen retinal hastalıklar arasında ikinci retinal hastalıktır (Quigley, 1996). Doğru ve zamanında teşhisi yapılmadığında retinada kalıcı hasarlara ve geri dönüşü olmayan körlüğe sebep olabilmektedir. Şekil 3.8’de Glokoma ait fotoğraf bulunmaktadır.




Şekil 3.8. Glokom Fundus Fotoğrafi

Erken teşhis edildiği takdirde tedavi edilebilir optik sinirlerde veya sinir liflerindeki hasarlara müdahale edilebilmektedir. Yüksek göz içi basıncı, ilerleyen yaş faktörü glokomun görülme olasılığını artırmaktadır (Coleman & Brigatti, 2001).

3.3.6. Katarakt

Katarakt, şeffaf göz merceğinde meydana gelen opaklık, sisli veya mercekteki görüntünün buğulu hale gelmesi olarak tanımlanmaktadır (Matthews, 2004). Göz merceğinde meydana gelen bozulmalar göze gelen ışık miktarının da retinaya daha az şiddetli şekilde düşmesine sebep olabilmekte ve devam ettiği sürece görme eylemi azalmaktadır.



Şekil 3.9. Katarakt Fundus Fotoğrafi

3.3.7. Yaş a Bağ lı Maküler Dejenerasyon

Yaş a Bağ lı Makula Dejenerasyonu (YBMD), retina epitel dokusunda oluş an normal olmayan madde birikintileri sarıms ı, parlak şekilde görülen drusenlerin hücre dışında birikmesi sonucunda YBMD hastalığı için teş his yapılabilir (Mullins, Russell, Anderson, & Hageman, 2000).



Ş ekil 3.10.Yaş a Bağ lı Maküler Dejenerasyon Fundus Fotoğ rafı

3.3.8. Hipertansiyon


Oküler hipertansiyon, retinal damarlardaki kan basıncının ani olarak değ iş imleri ve yüks elmesi durumunda göz iç i basıncının normal basınçtan yüksek olduğ u durumlarda ortaya çıkan patolojiye denilmektedir. Retinal fundus tomografi görüntüleri ile tespit edilebilmektedir.



Ş ekil 3.11. Hipertansiyon Fundus Fotoğ rafı

3.3.9. Miyop

Miyop, dünya genelinde görülme sıklığı en fazla olan retinal hastalıklardan birisidir. Miyop rahatsızlığı görülen hastalar arasında ortalama %20 sinde optik kırılma gücü 6 ve daha üstünde numaraya sahip olabilmektedir bu şekilde olan hastalara yüksek miyopi denilmektedir (Wu, Huang, Yu, Fang, & Chen, 2016).




Şekil 3.12.Miyop Fundus Fotoğrafı

Nesneleri net görebilmemiz ışık kaynağından gelen ışığın retina üzerinde odaklanarak nesnelerin algılanması ile sağlamaktadır fakat miyopi de bu durum göze gelen ışınların retinanın ön tarafında odaklanması sonucunda oluşmaktadır. Bu nedenle uzakta bulunan nesneleri tespit etmekte, işaretleri okumada ve yazıları okumakta bu hastalığa sahip bireyler zorluk çekmektedir.

3.3.10. Diğer Hastalıklar

En sık görülen retinal hastalıklardan farklı olarak retinada çevresel faktörlerden veya genetik faktörlerden kaynaklanan retinal hastalıklarda meydana gelebilmektedir. Bunlar retina yırtığı, optik disk ödemi, retina dekolmanı, retinal ven ve retinal arter tıkanıklıkları, makula deliği, sarı nokta ve göz travmaları gibi sorunlar ortaya çıkabilmektedir.



Şekil 3.13. Diğer Hastalıklar ve Anormallikleri içeren Fundus Fotoğrafları

3.4. Derin Öğrenme

Derin öğrenme, insan beyninin karar verme mekanizmasından etkilenecek geliştirilen çok katmanlı yapay sinir ağlarını kullanan makine öğrenmesinin alt disiplini. Derin öğrenmeyi makine öğrenmesinden ayıran en temel fark makine öğrenmesinde bulunan özellik çıkarımı gibi kodlanmış kurallar yerine verilerden otomatik olarak öğrenme işlemini gerçekleştirilmesidir. Derin öğrenme günümüze gelene kadar birçok farklı şekilde adlandırılmıştır ve son zamanlarda oldukça popüler şekilde kullanılmasına rağmen geçmişi 1940'lı yıllara dayanmaktadır. Derin öğrenmenin tarihi gelişim dönemi incelendiğinde, üç gelişim döneminden oluşan bir tarihi bulunmaktadır. Derin öğrenmenin tarihçesine bakıldığında, gelişiminin üç dönemde incelenmesi gerekmektedir. Bunlar sırasıyla 'sibernetik' adıyla bilinen 1940'lı yıllardan 1960'lı yıllara kadar olan gelişmeleri kapsayan dönemi, 1980'li yıllardan 1990'lı yıllara kadar olan gelişmeleri 'bağlantıcılık' adıyla bilinmektedir ve 2006'da ortaya çıkan ve son zamanlarda oldukça popüler hale gelen 'derin öğrenme' olarak karşımıza çıkmaktadır (Ian , Yoshua, & Aaron 2018). Derin öğrenmenin temelleri 1943 yılında McCulloch ve Pitts tarafından sinir sisteminin temel birimi olan nöronlar taklit edilerek oluşturulan yeni bir matematiksel model tanımlamaları ile başlamıştır (McCulloch & Pitts, 1943). İnsan beyninin öğrenmesine benzer şekilde tasarlanan sinir hücreleri modellenerek makinelerde bu matematiksel modeli kullanmak amaçlanmıştır. 1958 yılında Franck Rosenblatt tarafından perceptron tek katmandan oluşan basit sinir hücreleri ağıdır. McCulloch ve

Pitts tarafından geliştirilen matematiksel modelin yetersiz kaldığı yerleri tamamlamak için geliştirilmiştir. 1965 yılında Alexey Grigorevich tarafından ilk derin öğrenme mimarisi her katmanda en iyi özelliklerin belirlenerek diğer katmana iletilmesini sağlamıştır. Ancak katman sayısının artırılması modelin iyileştirilmesini sağlamadığı için modelin devamlılığı sağlanmamıştır (Dettmers, 2015). Minsky ve Papert klasik modelde bulunmayan aktivasyon fonksiyonunu modele ekleyerek günümüzde kullanılan perceptron mimarisini geliştirmişlerdir.


Makine öğrenmesinde veri miktarının artması kullanılan donanımların grafik işleme birimlerinin(GPU) yetersizliği, karmaşık veri kümelerinin olduğu durumlarda öz niteliklerin belirlenmesi için ilgili alanda uzman kişilere ihtiyaç duyulması gibi sorunlar makine öğrenmesine alternatif yöntemler arayışında derin öğrenmenin ortaya çıkmasına neden olmuştur (Özkan & Ülker, 2017). Derin öğrenmede makine öğrenmesinden farklı olarak öz nitelik ve model parametrelerinin belirlenmesi derin öğrenme katmanlarından evrişim katmanları içerisinde otomatik şekilde yapılmaktadır. Derin öğrenmede kullanılabilir veri seti artmasıyla ve karmaşık problemleri çözebilmesi açısından daha çok tercih edilmektedir. Derin öğrenmede, geri yayılım algoritması kullanılarak bir önceki katmandan alınan en iyi özelliklerin seçilerek diğer katmanlara iletimini sağlayarak büyük verilerdeki karmaşık yapıyı minimize edilmesi ve makine öğrenmesinde yaşanan zorlukların çözümlenmesi amaçlanmıştır. Son zamanlarda çeşitli alanlarda sıkça kullanılmaktadır bu alanlara örnek olarak nesne tanıma, sınıflandırma, ses tanıma, ilaç keşfi, biyomedikal, tıp alanında hastalık teşhisi, sürücüsüz araçlar ve doğal dil işleme gibi birçok alanda yaygın bir şekilde derin öğrenme yöntemleri kullanılmaktadır (LeCun, Bengio, & Hinton, 2015).

3.4.1. Derin Öğrenme Eğitim Metotları

Derin öğrenme kullanarak bir model eğitmek istendiğinde iki yöntem karşımıza çıkmaktadır. Bunlar transfer öğrenme yöntemleri diğeri ise katmanlarını, yapısını kendi belirlediğimiz, inşa ettiğimiz modelleri kullanarak derin öğrenme modelleri geliştirilebilmektedir.

Sıfırdan eğitilen modelde KSA katmanları modeli geliştiren kişi tarafından belirlenmektedir. Transfer öğrenme metodunda ImageNet veri tabanı üzerinde eğitilmiş 14 milyondan fazla görüntü bulunmaktadır (Li et al., 2010). Bu sayede daha öncesinde hafızasında sakladığı verileri tekrar kullanılabilir ve öğrenme aktarımı ile yüksek başarı


ve daha hızlı öğrenebilen modellerdir oluşturulur. Transfer öğrenme modellerine LeNet-5, AlexNet, VGG16, VGG19, InceptionV3, ResNet, MobileNetV2, Xception ve EfficientNet örnek olarak verilebilir.



Şekil 3.14. Transfer Öğrenme ve Sıfırdan Öğrenme (Gudikandula, 2019).


3.5. Yapay Sinir Ağları (Artificial Neural Network)

Yapay sinir ağları, insan beyninin işleyişinden etkilenilerek geliştirilen ve verilerden öğrenmeyi sağlayan bir modelleme tekniğidir. İnsanlardaki biyolojik sinir sistemine benzer şekilde geliştirilmiştir. Öğrenmenin beyinde nasıl gerçekleştiği gibi sorular sonucunda insan ve hayvan beyinlerini incelemişlerdir. İnsan beyinde bulunan karar verme mekanizması ve nesneleri algılama mekanizmasını makineler de entegre edilmesi düşüncesiyle biyolojik beyinlerin bilgiyi nasıl işlediği araştırılmıştır. Beyinde bulunan nöronların gelen bilgileri doğrusal bir şekilde işlediği ortaya konmuştur. İnsan beyninin aldığı verileri işleyişinden, öğrenme özelliğinden ve karar verme mekanizmasından esinlenilerek Yapay Sinir Ağları (YSA) modelini geliştirmişlerdir (Şen, 2004).



Şekil 3.15. Nöronun temel yapısı (Neuron, 2023).

Şekil 3.15.'de nöronun temel yapısı gösterilmiştir. Nöronlarda 3 temel bölüm bulunmaktadır. Bu bölümler dendritler, hücre gövdesi ve aksonlardır. Dendritler diğer nöronlardan gelen mesajları hücre gövdesine iletilmesini yani sistemin girişini sağlayan yapılardır. Dendritlerden gelen sinyal verileri merkezde bulunan çekirdekte ağırlandırılarak akson boyunca iletilmektedir. Hücre çekirdeği ise nöronda enerji üretilmesinden sorumludur. Miyelin kılıf, nöronun ortasında bulunur ve yayılma hızını etkileyen bölgedir. Schwann hücresi, miyelinlerden oluşur yapısında lipitler ve proteinler bulunmaktadır. Nörona büyümesinde eşlik etmektedir.



Şekil 3.16. Yapay Sinir Ağı Hücresi

Yapay sinir ağı hücreleri, matematiksel formülü Denklem 3.1'de verildiği gibi ifade edilir: w ağırlık değerlerini, dendritler x değerini ve b bias değerini göstermektedir.


$$\sum_i w_i x_i + b \quad (3.1)$$

Şekil 3.16 'da yapay sinir hücresinin matematiksel modellemesi bulunmaktadır. Nörona gelen dentritler x_1 , x_2 olarak belirtilmektedir ve dentritlere ait ağırlıklar w_1 , w_2 olarak gösterilmektedir. Biyolojik sinir sisteminde bulunan dentritler toplama fonksiyonuna karşılık gelmektedir. Sinapslar ağırlık değerlerini karşılamaktadır. Sinir hücresinin gövdesi transfer fonksiyonunu, yapay nöronların çıkışını aksonlar temsil etmektedirler (Öztürk & Şahin, 2018).

3.5.1. Evrişimsel (Konvolüsyonel) Sinir Ağları

Evrişimli Sinir Ağları (CNN) özel tasarlanmış sinir ağlarıdır Çok boyutlu matris veri dizisini girdi verisi olarak kullanır. Evrişimli sinir ağı mimarileri derin öğrenme yöntemlerinden biridir. Görüntü sınıflandırma, nesne tespiti ve sınıflandırması, bilgisayarlı görü sistemleri, hastalık tespiti gibi birçok alanda oldukça sık kullanılmaktadır. Evrişim işlemi bir matris çarpım işlemi olarak da tanımlanabilmektedir. Kernel matrisi girdi matrisi üzerinden dolaşarak evrişim işlemi yapılması sağlanır (Ian et al., 2018).

Evrişimli sinir ağları mimarisini özellik çıkarımı ve sınıflandırma bölümleri olarak 2 temel kısımda incelenebilir. Özellik çıkarımı konvolüsyon, havuzlama katmanları içerisinde girdi verimizden elde edilen özelliklere ait bir özellik matrisi çıkarılmasıdır. İkinci aşama olan sınıflandırma da ise düzleştirme, tam bağlantı katmanı ve aktivasyon fonksiyonu uygulanmakta ve sınıflandırma işlemi tamamlanmaktadır. Evrişimli sinir ağlarını yapay sinir ağlarından ayıran en önemli katman evrişim işleminin yapıldığı konvolüsyon katmanıdır.




Şekil 3.17. Evrişimli Sinir Ağı Yapısı (Mathworks, 2023).

3.5.1.1. Giriş(Input) katmanı

Giriş katmanı, modelde kullanılacak verinin giriş işlemi olarak bilinmektedir. Kullanılan ağı mimari yapısına göre girdi değerimiz ayarlanmalıdır. Modelin eğitimi için kullanacağımız girdi değerleri bir araya gelerek veri seti oluşturmaktadırlar.

3.5.1.2. Konvolüsyon katmanı

Konvolüsyon katmanı, evrişimli sinir ağlarının temelini oluşturmaktadır. Rastgele değerlere sahip girdi verimizi mevcut bir filtreden geçirerek öz nitelik matrisi çıkarılmış ve girdi üzerindeki özelliklerin çıkarılması sağlanır. Konvolüsyon katmanı sayesinde görüntüde bulunan detayların çıkarılması sağlanır. Öğrenme adımı konvolüsyon katmanında gerçekleşmektedir.



Şekil 3.18. Evrişim Katmanı Özellik Çıkarımı (Kuchera et al., 2019).

Şekil 3.18'de verilen 5x5 boyutlarındaki girdi verisi matrisine 3x3 boyutlu filtre uygulanmıştır. Matrislerde bulunan her bir değer birbiri ile çarpılarak toplama işlemi

yapılmıştır. 3x3 lük filtre görüntü boyunca kaydırılarak aynı aşamalar tekrar edilir ve özellik haritası çıkarılır. Elde edilen özellik haritası sayesinde görüntüde bulunan ağırlık değerleri belirlenmiş olur. Evrişim katmanı bir veya birden fazla olabilmektedir.

3.5.1.3. Aktivasyon fonksiyonu

Evrişimli sinir ağlarında en temel işlemlerden biri de aktivasyon fonksiyonunun ESA'ya uygulanmasıdır. Aktivasyon fonksiyonları temel olarak giriş sinyallerini çeşitli matematiksel işlemler uyguladıktan sonra bulunan negatif değerleri temizleyerek bir çıkış sinyaline çevirir. Aktivasyon fonksiyonundan elde edilen değer tam bağlantı katmanına girdi verisi olarak kullanılır. Aktivasyon fonksiyonu, matematiksel işlemler kullanarak nöronun ağı girişinin önemli olup olmadığına yani nöronun aktive edilmesine karar veren mekanizmadır (Glorot, Bordes, & Bengio, 2011). Aktivasyon katmanı, sinir ağı içeren verilerin hazırlanmasını sağlamaktadır. Aktivasyon fonksiyonlarının diğer işlevi ise nöronların çıktı değerlerini belirli aralık değerlerine indirgemektedir. Bu katmanda yaygın olarak kullanılan aktivasyon fonksiyonlarına doğrusal, ReLu, Sigmoid, Hiperbolik Tanjant, Leaky ReLu, Swish ve Softmax fonksiyonları örnek olarak verilebilir. Modelimize yüksek doğruluk değerlerini elde edebilmek için uygun aktivasyon fonksiyonu seçerken problemin çözümüne göre belirlenmesine dikkat edilmesi gerekmektedir. Seçilen aktivasyon fonksiyonunun türevinin alınabilir olmasına, hassasiyet değerinin fazla olmasına, doğrusal veya sabit olmamasına, belirli aralıklar içinde olmasına dikkat edilmelidir. Aktivasyon fonksiyonunun hassasiyet değerinin fazla olmasına özellikle dikkat edilmesinin nedeni, görüntüler üzerinde matris işlemlerinin uygulanacak olmasıdır. Aksi halde aktivasyon fonksiyonunun öğrenme oranı düşük olmaktadır.

Aşağıda ESA ve derin öğrenme mimarisinde kullanılan aktivasyon fonksiyonlarına ait matematiksel denklemleri ve grafikleri verilmiştir.

- Doğrusal aktivasyon fonksiyonu: Lineer fonksiyonu, nöronlardan gelen ağırlıklı toplamla orantılı olan bir düz çizgi fonksiyonu olarak da ifade edilebilir. Sabit bir çıktı değerine sahiptir bu da bize geri yayılım kullanımı sırasında hata oranının sabit olacağını için istenilen çıktıyı almayı ve geri yayılımın kullanımını bozabilmektedir. Matematiksel ifadesi Denklem 3.2'de gösterilmektedir.


Denklemden gösterilen a değeri herhangi sabit bir sayı değeri olabilir, seçimi opsiyoneldir.

$$f(x) = ax \quad (3.2)$$

Sigmoid aktivasyon fonksiyonu: Koordinat sisteminde gösterildiğinde S harfine benzeyen, doğrusal olmayan bir aktivasyon fonksiyonudur. Oldukça sık kullanılan aktivasyon fonksiyonlarından biridir. Matematiksel olarak ifade edilmesi Denklem 3.3 ile belirtilmektedir. 0-1 aralığında çıktı değerlerine sahip olmaktadır. Aynı zamanda türevlenebilir. (Sharma, Sharma, & Athaiya, 2017).

- Şekil 3.19’da Sigmoid fonksiyonunun türevlenebilir bir aktivasyon fonksiyonu olduğu gösterilmektedir. Bu sayede öğrenme işlemini daha efektif gerçekleştirebilmektedir.

$$f(x)_{sigm} = \frac{1}{(1+e^x)} \quad (3.3)$$



Şekil 3.19.Sigmoid Aktivasyon Fonksiyonu ve Türevi Grafiği

- Hiperbolik Tanjant (Tanh): Hiperbolik tanjant, -1 ile 1 aralığında değerler alabilmektedir ve 0 merkezinden geçmektedir. Sigmoid fonksiyonuna göre daha simetrik yapıya sahiptir. Denklemi 3.4 ile ifade edilmiştir. Her x değeri için bir çıktı üreten hiperbolik tanjant fonksiyonu bu özelliği ile bir sürekli fonksiyondur. Bu aktivasyon fonksiyonu $[-1, +1]$ arasında çıktı üretir. Sigmoid fonksiyonuna oldukça benzer ve ikili sınıflandırma problemlerinde kullanılır. Sigmoid fonksiyonuna göre daha çok değer alabilir. Böylece bu durum sinir ağının daha hızlı öğrenmesine sebep olur ve verimliliği arttırmaktadır.


$$f(x)_{\tanh} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.4)$$



Şekil 3.20.Tanh Aktivasyon Fonksiyonu ve Türevi

- ReLU : Doğrultulmuş doğrusal birim olarak bilinen ve doğrusal olmayan bir fonksiyondur. Sinir ağlarında en sık kullanılan aktivasyon fonksiyonlarından biridir. 0'dan küçük tüm değerler için 0 değerini almaktadır, x pozitif değeri için de x değerini almaktadır. Denklem 3.5 de fonksiyonun matematiksel ifadesi gösterilmiş olup, Şekil 3.21'de bulunan grafik incelendiğinde türevinin 0 dan küçük olan değerlerde 0 da sabit kaldığı görülmektedir.


$$ReLU(x) = (x)^+ = \max(0, x) \quad (3.5)$$



Şekil 3.21.ReLU Aktivasyon Fonksiyonu ve Türevi

- Leaky ReLu : ReLU aktivasyon fonksiyonuna göre öğrenme oranı ve işlem yükü daha fazladır. Şekil 3.21’de bulunan ReLu fonksiyonun türevi incelendiğinde negatif değerlerde 0 sabit değerine sahiptir. Leaky ReLu ise 0 değerine yakınsandığı görülmektedir.

$$f(x)_{LeakyReLU(x)} = f(x) = \begin{cases} x, & x \geq 0 \\ mx, & x \leq 0 \end{cases} \quad (3.6)$$



Şekil 3.22. Leaky ReLU Aktivasyon Fonksiyonu ve Türevi


- Swish (A Self-Gated) : Negatif bölgelerde de değer almaktadır. Bu bölgelerde aldığı değerler doğrusal değildir. Diğer tüm aktivasyon fonksiyonları monotondur. Swish fonksiyonun çıktısının girdi arttığında bile düşmeyecektir. Bu swishe özgü bir özelliktir.

$$f(x)_{Swish} = 2x\sigma(\beta x) = \begin{cases} \beta = 0 \text{ için } f(x) = x \\ \beta \rightarrow \infty \text{ için } f(x) = 2 \max(0, x) \end{cases} \quad (3.7)$$

3.5.1.4. Havuzlama (Pooling) katmanı

Havuzlama katmanı, büyük veri kümesinin daha minimize edilmesi ve ağırlık sayısını azaltarak uygun hale getirilmesini sağlayan katmandır. Bu sayede öğrenme işleminin daha hızlı ve daha az maliyetle gerçekleşmesi sağlanır. Bu katmanda herhangi bir öğrenme işlemi gerçekleştirilmez ve özelliklerin korunması devam etmektedir. Evrişim katmanından sonra uygulanmaktadır. Havuzlama katmanı eğitim süresini

kısaltmakla birlikte zamandan tasarruf etmemizi sağlamaktadır. Maksimum havuzlama veya ortalama havuzlama olmak üzere 2 şekilde uygulanabilir. Uygulanan filtrenin ortalamasının alınmasıyla ortalama havuzlama, maksimum değerinin alınması ile de maksimum havuzlama denilmektedir. 2x2 lik boyutta maksimum ve minimum havuzlama katmanları görüntü matrisinde bulunan max değeri veya ortalama değeri olarak hem görüntü matrisinin boyutunun küçülmesini sağlamakta hem de işlem maliyetini düşürülmesine yardımcı olmaktadır. Havuzlama katmanında kaydırma (stride) sayısı yani girdi verisi üzerinde uygulanacak filtrenin kaç birim kaydırılarak uygulanacağı ve havuzlama katmanının boyutu parametrelerinin ayarlanması gerekmektedir. Bu katmanda öğrenme gerçekleşmemektedir.




Şekil 3.23. 2x2 Maksimum Havuzlama , Ortalama Havuzlama (Yani, Irawan, & Setianingsih, 2019).

Şekil 3.23’de maksimum havuzlama ve ortalama havuzlama yöntemleri gösterilmiş olup, veri matrisinde bulunan indisler üzerinde 2x2 havuzlama uyguladığımızda matris verisinde bulunan maksimum değerleri olarak boyutu indirgemekte ve işlem yükünü azaltmaktadır. Ortalama havuzlama yönteminde ise 2x2 boyutunda matris uygulanan girdi verisinde bulunan değerlerin ortalamasını alarak yeni bir matris oluşturmaktadır. Bu yöntem de ortalama havuzlama olarak isimlendirilmektedir.

3.5.1.5. Tam bağlantılı katman (FC)

Tam bağlantılı katman da evrişim ve havuzlama katmanlarından elde edilen girdilerin matris değerleri düzleştirme işleminden geçirilerek vektör haline getirilmektedir. Şekil 3.24’de tam bağlantılı katmana ait görsel bulunmaktadır.




Şekil 3.24. Tam Bağlantı Katmanı

Havuzlama katmanından sonra tam bağlantılı katman bulunmaktadır ve sınıflandırma işleminde aktivasyon fonksiyonu kullanılmadan önceki son katmandır.

3.5.1.6. Dropout katmanı

Dropout katmanı, rastgele şekilde bazı düğümleri iptal ederek işleme alınmamasını sağlamaktadır. Genellikle veri seti az veriye sahip olduğunda veya eğitim süresi uzun olduğu zamanlarda aşırı öğrenme meydana gelebilmektedir. Modelin eğitilen veri setinde bulunan verileri ezberlemesini engellemek için kullanılmaktadır.




Şekil 3.25. Dropout Uygulanan ve Uygulanmayan Katmanlar(Srivastava, Hinton, Krizhevsky, Sutskever, & Salakhutdinov, 2014).

Şekil 3.25’de standart bir sinir ağı ve rastgele bazı düğümleri silinen ağa ait görseller bulunmaktadır. Dropout katmanı sayesinde modelin aşırı öğrenme(overfitting) durumu önlenir. Dropout katmanı modelin performansının iyileşmesini sağlamaktadır.

3.5.1.7. Düzleştirme katmanı

ESA’da son havuzlama katmanından sonra özellik haritası oluşmaktadır. Oluşturulan öznelik haritaları birleştirilerek düzleştirme işlemi uygulanarak vektör haline getirilmektedir.



Şekil 3.26. Düzleştirme Katmanı

Şekil 3.26’da düzleştirilmiş matris tek boyuta indirgenmiştir. Oluşan matris tam bağlı katmanda işlenerek istenilen boyuta getirilmektedir. Çıktı olarak sınıf sayısı kadar boyuta indirgenir.

3.6. Ön Eğitilmiş Ağlar

Ön Eğitilmiş Ağlar, ImageNet veri tabanı üzerinde bulunan görüntüler üzerinde önceden eğitilmiş verileri yapısında bulunduran, birçok farklı çeşit ve yapıda mimarileri içeren derin öğrenme yöntemleridir. Evrişimli Sinir Ağı modellerinde öğrenmenin daha hızlı gerçekleşmesi için Ön eğitilmiş ağlar oldukça önem kazanmıştır. Benzer problemlerin çözümü için geliştirilen mimariler yüksek doğruluk değerleri elde edilmiştir ve zamanla kullanımı popülerlik kazanmıştır. Her problem için uygun çözüm ve doğruluk oranlarına ulaşılmasada geliştirilen mimariler sayesinde birçok problemin çözümünde


doğruluklarını kanıtlayan sonuçlar elde etmişlerdir. Bu çalışmada ön-eğitimli mimariler arasında ResNet50, InceptionV3, Xception ve VGG19 ağları kullanılmıştır.

3.6.1. ResNet

ResNet mimarisi, 2015 yılında Microsoft araştırma grubu Xiangyu Zhang ve arkadaşları tarafından sunulmuş olan daha derin olan ağların eğitimini kolaylaştırmak için geliştirilmiş 152 katmanlı evrişimli sinir ağıdır. ILSVRC yarışmasında %3,57 top-5 hata değeri ile birincilik almıştır (He, Zhang, Ren, & Sun, 2016). ResNet, Residual Network kelimelerinin birleştirilmesi ile artık blokların (residual block) modele eklenmesi ile oluşturulmuştur. Her iki ağırlık katmanında bir ReLU aktivasyon fonksiyonu eklenerek geriye yayılımda gerçekleşebilecek vanishing gradyan problemi önlenmektedir.

ResNet, VGG mimarisinde karşılaşılan bazı sorunları çözmek için geliştirilmiştir. VGG ağı yapısı düz şekilde geliştirilmiş olup, VGG ağında düzenlemeler yapmak ve derinleştirmek için katman sayısını artırmak ağın yapısında bozulmalara sebep olmaktadır. Bu bozulmalar sonucunda eğitim hata değerleri yüksek çıkmaktadır. ResNet mimarisine derin artık ağlar yöntemi kullanılır bu sayede artık bağlantı katmanı kullanarak ağlar birleştirilir.


$$\text{Çıkış} = F(x) + x \quad (3.8)$$



Şekil 3.27. ResNet artık inşa bloğu

Şekil 3.27’de verilen artık bloklar üzerinden öğrenme ileri yönde beslenir, artık katman çıkışına eklenir ve çıkış denklemi (Denklem 3.8) ifade edilmektedir.


ResNet mimarisinin 152 katmana kadar derinliği artırılabilir. Diğer ön eğitimli evrişimli sinir ağlarına göre daha derindir fakat daha az karmaşıklığa sahiptir. Artık bloklar üzerinden daha hızlı yayılma sağlanmaktadır (He et al., 2016). ResNet18, ResNet34, ResNet50, ResNet101, ResNet152 gibi içerdiği katman sayısına göre çeşitleri bulunmaktadır.



Şekil 3.28. ResNET Mimarisi (Techs, 2023).

3.6.2. VGG-Net

2014 yılında Simonyan K. ve arkadaşları tarafından Oxford üniversitesinde geliştirilmiş derin öğrenme modelidir. AlexNet de bulunan katman sayısı artırılıp derinleştirilerek geliştirilen Evrişimli Sinir Ağı (ESA) modelidir. (Simonyan & Zisserman, 2014). Katıldıkları ImageNet yarışmasında top-5 hata oranında %7,3 değeri ile diğer modeller arasında varlığını kanıtlamıştır (Simonyan & Zisserman, 2014). Girdi verisi olarak 3 x 224 x 224 boyutundaki 3 kanallı RGB girdi verilerini girdi verisi olarak almaktadır. 16 ve 19 katmandan oluşan oldukça sık kullanılan VGGNet mimarileri bulunmaktadır (Simonyan & Zisserman, 2014).




Şekil 3.29.VGG 16 Mimarisi(Varshney, 2023).

Şekil 3.29’da bulunan VGG-16 ağı mimarisi yapısında 13 evrişim katmanı, 3 tane tam bağlı katmandan oluşmaktadır. İlk konvolüsyon işleminden sonra 224 x 224 x 64 boyutlarında daha derinleşmektedir.

3.6.3. EfficientNet

EfficientNet, Mingxing Tan ve Quoc V.Le tarafından son derece yüksek doğruluk değerleri sağlayan, minimal ve daha hızlı bir görüntü sınıflandırma modelidir. Bir grup evrişimli sinir ağı mimarisi yapısına sahip transfer öğrenme yöntemlerinden daha etkili ve verimli bir yapıya sahiptir ve 66 milyon parametresi bulunmaktadır. Etkili ve efektif model oluşturabilmek birleşik bir katsayı kullanarak ağ genişliği, derinlik ve çözünürlük değerlerinin hepsini eşit şekilde ölçekleyen evrişimli sinir ağı mimarisi ve ölçekleme yöntemidir(Kızrak, 2019).




Şekil 3.30. EfficientNet Mimarisi (Ahmed, 2023).

Şekil 3.30’da EfficientNet yapısı verilmektedir. Derinlemesine evrişim ve noktasal evrişim ile hesaplama maliyetinin minimum seviyede doğruluk kaybıyla azaltmak için orijinal evrişimi iki aşamaya bölmektedir. B0 ve B7 değerleri arasında toplamda 8 tip EfficientNet modeli bulunmaktadır.

3.6.4. InceptionNet

2015 yılında Christian Szegedy ve arkadaşları tarafından geliştirilmiş evrişimli sinir ağının optimize edilmiş hali olarak sunulan derin öğrenme ağıdır (Szegedy, Vanhoucke, Ioffe, Shlens, & Wojna, 2016). Derin sinir ağlarında katmanları peş peşe sıralanması ile oluşturulan modellerde evrişim katmanları ağın aşırı öğrenmesine neden olabilmektedir. Evrişim katmanlarının sayısının fazla olması işlem karmaşıklığına, eğitim maliyetini artırmasına, hafıza gereksinimi oluşmasına ve çıkış veri miktarının artması gibi dezavantajlara neden olmuştur. Ayrıca kaybolan gradyan problemi gibi bazı sorunları da beraberinde getirmektedir. Bu sorunlara çözüm olarak geliştirilen mimariyi katman olarak derinleşmektense, ağı genişletmek mantığıyla modelleme yapılmıştır. Mimaride toplamda 22 katmandan oluşmakta olan ağ ImageNet veri yarışmasında %6,67 lık top-5 hata oranına ulaşarak birincilik almıştır. (Szegedy et al., 2015).

Başlangıç katmanında 1x1 boyutlarındaki evrişim katmanı boyutu indirmek için kullanılmaktadır. Böylelikle ağın parametre sayısı indirgenmiş ve yüksek performans değerleri içeren bir yapı geliştirilmesi amaçlanmıştır. Diğer transfer öğrenme yöntemlerinden farklı olarak evrişim katmanlarının boyutları farklılık göstermektedir. Evrişim katmanlarının 1x1, 3x3, 5x5 boyutlarındaki filtreler ve 3x3 havuzlama katmanı girdi verisine eş zamanlı uygulanarak elde edilen sonuçlar birleştirilmiştir.




Şekil 3.31. Inception Modül Yapısı (Szegedy et al., 2015).

Şekil 3.31’de InceptionNet mimari modellenmesi gösterilmiştir. Girdi verisine uygulanan farklı boyutları içeren filtreler sayesinde farklı değere sahip özellik haritaları elde edilmektedir. Özellik haritaları birleştirme işlemi uygulandıktan sonra bir diğer modülün giriş değerini oluşturmaktadır.

InceptionV1 üzerinde yapılan bazı yeniliklerle birlikte InceptionV2, InceptionV3, InceptionV4 gibi yeni Inception versiyonları geliştirilmiştir. Bu tez çalışmasında InceptionV3 tercih edilmiştir.


3.6.5. Xception

Xception, Chollet tarafından geliştirilen temel yapı olarak InceptionV3 ağ mimarisinden ilham alınarak inşa edilmiştir. “Aşırı Başlangıç (Extreme Inception)” olarak da bilinen Derin Sinir Ağı (DNN) mimarisidir (Chollet, 2017). Inception mimarisi yeniden yapılandırılmış, derinlemesine ayrılabilir evrişim katmanları ile değiştirilerek formüle edilmiştir (Chollet, 2017). Inception mimarisine göre daha verimli sonuçlar elde etmiştir.



Şekil 3.32. Xception Mimarisi Derinleştirilmiş Evrişim Modeli (Chollet, 2017).

Şekil 3.32’de Xception mimarisinde uygulanan derinlemesine evrişim yapısı gösterilmiştir. Xception mimarisi, toplamda 14 tane modülden oluşan evrişim katmanlarının her biri artık bağlar ile birbirine bağlantılıdır. Özellik çıkarımı işlemi için 36 evrişim katmanı, tam bağlı ve çıkışında bulunan sınıflandırma katmanlarından oluşmaktadır.




Şekil 3.33. Xception Ağının Mimarisi (Chollet, 2017).

Şekil 3.33’de veriler öncelikle giriş akışından, sonrasında 8 kez yinelenen orta akıştan son olarak çıkış akışından geçirilmektedir ve ağı eğitimi tamamlanmaktadır.

3.6.6. LeNet-5 Ağ Mimarisi

LeNet, Yan Lecun ve ekibi tarafından el yazısı ve makine baskılı karakterleri tanımak için özel olarak geliştirdikleri ilk evrişimli sinir ağı modelidir (LeCun, 2015). MNIST (Modified National Institute of Standards and Technology) veri seti üzerinde bulunan rakamları tanımak için yapılan deneylerde başarılı sonuçlar elde edilmiştir. Bilinen en eski CNN mimarisidir. LeNet modelinde girişte 5 evrişim katmanı, 2 tam bağlı gizli katman ve son olarak tam bağlı çıktı katmanı olmak üzere toplam 8 katman içermektedir. Eğitim boyunca matrisin genişliği ve yüksekliği azalırken, derinlik değeri ters orantılı şekilde artmaktadır.



Şekil 3.34. Lenet-5 Mimarisi(Yann LeCun, 2015).

LeNet-5 mimarisi yaklaşık 60.000 parametre içermektedir (Kızrak, 2018). LeNet mimarisi Şekil 3.34 'de verilmiştir.

3.7. Önerilen Evrişimli Sinir Ağı Modeli


Şekil 3.35'de gösterilen OCT cihazı ile elde edilen ODIR-5K veri seti görüntülerinden retinal hastalıkların tespit edilmesi için önerilen ESA modelinin akış diyagramı bulunmaktadır.

Önerilen ESA modeline çeşitli veri ön işleme teknikleri uygulanmış, veri seti eğitim, doğrulama ve test veri seti olmak üzere üçe ayrılmıştır. Önerilen model uygulanarak sekiz farklı sınıfın bulunduğu veri seti üzerinde eğitim ve test işlemi tamamlanmıştır. Uygulanmakta olan adımlar aşağıda detaylı bir şekilde anlatılmıştır.


Çizelge 3.1. Hiper-parametre ayarları

İsim	Değer
Epoch	50
Batch Size	32
Loss	Categorical Crossentropy
Optimizer	ADAM
Learning Rate	0.0001

Çizelge 3.1’de her modelin eğitiminde kullanılan hiper-parametrelere yer verilmiştir. Önerilen ESA modeli, transfer öğrenme yöntemleri için uygulanan ön işleme yöntemleri ve hiper-parametre ayarları her model için aynı şekilde uygulanmıştır.

**Şekil 3.35.**Önerilen Model Akış Diyagramı

Veri seti %16 doğrulama, %64 eğitim ve %20 si test olmak üzere ayrılmıştır. Şekil 3.36’da önerilen ESA mimarisinin katmanları detaylı şekilde gösterilmektedir.



Şekil 3.36.Önerilen ESA Mimarisinin Yapısı

Önerilen ESA mimarisi katmanları

Geliştirilen derin öğrenme modelinde katmanlara göre yapılan işlemler sırasıyla aşağıdaki gibidir.

- **Giriş katmanı:** Veri setinde bulunan veriler yeniden boyutlandırılarak 224 x 224 boyutlarına getirilerek evrişim katmanına gönderilmiştir.
- **Birinci evrişim katmanı:** 224 x 224 piksel boyutundaki resimlere 3x3 boyutlu 32 adet filtre uygulanmıştır.
- **İkinci evrişim katmanı:** 3x3 boyutlarında 32 adet filtre uygulanmıştır. 2x2 boyutlarında maksimum havuzlama katmanından sonra dropout uygulanmıştır.
- **Üçüncü evrişim katmanı:** 3x3 boyutlarında 64 adet filtre uygulanmıştır.
- **Dördüncü evrişim katmanı:** 3x3 boyutlarında 64 adet filtre uygulanmıştır. 2x2 boyutlarında maksimum havuzlama uygulandıktan sonra dropout uygulanmıştır.

- **Beşinci evrişim katmanı:** 3x3 boyutlarında 128adet filtre uygulanmıştır.
- **Altıncı evrişim katmanı:** 3x3 boyutlarında 128 adet filtre uygulanmıştır. 2x2 boyutlarında maksimum havuzlama uygulandıktan sonra dropout uygulanmıştır.
- **Yedinci evrişim katmanı:** 3x3 boyutlarında 128 adet filtre uygulanmıştır.
- **Sekizinci evrişim katmanı:** 3x3 boyutlarında 128 adet filtre uygulanmıştır. 2x2 boyutlarında maksimum havuzlama uygulandıktan sonra dropout uygulanmıştır.
- **Dokuzuncu evrişim katmanı:** 3x3 boyutlarında 256 adet filtre uygulanmıştır.
- **Onuncu evrişim katmanı:** 3x3 boyutlarında 256 adet filtre uygulanmıştır. 2x2 boyutlarında maksimum havuzlama uygulandıktan sonra dropout uygulanmıştır. On katmandan oluşan konvolüsyonel sinir ağının son katmanı hariç tamamında aktivasyon fonksiyonu olarak ReLu tercih edilmiştir. Her katmanın ardından batch normalizasyon eklenmiştir. Onuncu evrişim katmanından 2x2 maksimum havuzlama ve dropout katmanından sonra flatten (düzleştirme) uygulanarak matris boyutundaki veriyi tek boyutlu dizi haline getirmektedir. Evrişim katmanlarının ardından tam bağlı katmanlarda ağ eğitime devam etmiştir. 512,256,128,64,8 boyutlarındaki dense katmanları ile nöronların diğer katmana girdi olarak verilmesi sağlanmıştır.
- **Çıktı katmanı:** Sınıf sayısı 8 nörondan oluşmaktadır. Bu katmanında Sigmoid aktivasyon fonksiyonu tercih edilmiştir.

Uygulanan ESA mimarisi katman sayısı az tutularak aşırı öğrenmenin engellenmesi amaçlanmaktadır. Her konvolüsyon katmanından sonra batch normalizasyon katmanı eklenerek yığın normalleştirme işlemi yapılmıştır. Bu sayede ağ eğilirken diğer katmanların öğrenmesini beklemek zorunda kalmadan eş zamanlı şekilde eğitim işleminin gerçekleştirilmesi amaçlanmaktadır. Çizelge 3.2’de detaylı şekilde katmanlar, boyutları, kullanılan aktivasyon fonksiyonları hakkında bilgilere yer verilmiştir.

Çizelge 3.2. ESA mimarisinin yapısı

	Katman	Boyut	Filtre boyutu	Parametre	Aktivasyon fonksiyonu
Giriş	Görüntü	224x224 x1	-	1	-
1	Konvolüsyon	224x224 x32	3x3	896	ReLu
2	Konvolüsyon	222x222 x32	3x3	9248	ReLu
3	Mak.Hav.	111x111x32	2x2	0	ReLu
4	Dropout	111x111x32	-	0	-
5	Konvolüsyon	109x109 x64	3x3	18496	ReLu
6	Konvolüsyon	107x107x64	3x3	36928	ReLu
7	Mak.Hav.	53x53x64	2x2	0	ReLu
8	Dropout	53x53x64	-	0	-
9	Konvolüsyon	51x51x128	3x3	73856	ReLu
10	Konvolüsyon	49x49x128	3x3	1147584	ReLu
11	Mak.Hav.	24x24x128	2x2	0	ReLu
12	Dropout	24x24x128	-	0	-
13	Konvolüsyon	22x22 x256	3x3	295168	ReLu
14	Konvolüsyon	20x20x256	3x3	590080	ReLu
15	Mak.Hav.	10x10x256	2x2	0	ReLu
16	Dropout	10x10x256	-	0	-
17	Konvolüsyon	8x8x512	3x3	1180160	ReLu
18	Konvolüsyon	6x6x512	3x3	2359808	ReLu
19	Mak.Hav.	3x3x512	2x2	0	ReLu
20	Dropout	3x3x512	-	0	-
21	Düzleştirme	4608	-	0	-
22	Dense	512	-	2359808	ReLu
23	Dense	256	-	131328	ReLu
24	Dense	128	-	32896	ReLu
25	Dense	64	-	8256	ReLu
Çıkış	Dense	8	-	520	Sigmoid

3.8. ODIR-5K Veri Seti


Bu çalışmada, retinal hastalıkları sınıflandırılması için Optik Koherans Tomografi (OCT) cihazı ile kayıt altına alınan renkli sağ ve sol göz dibi tomografi verilerinden yararlanılmıştır. Bu veri seti halka açık Kaggle web sitesi üzerinden Çin’de bulunan Shangong Medikal Teknoloji tarafından çeşitli sağlık kuruluşlarından alınan verilerle oluşturulmuştur (Larxel, 2020). Retinal hastalara ve sağlıklı bireylere ait tomografi görüntülerini içermektedir Oküler Hastalık Tanıma (ODIR), retinal hastalıkları içerisinde bulunduran ODIR-5K veri seti olarak adlandırılmıştır. ODIR-5K veri setinde yaş, sol ve sağ gözlerden elde edilen yüksek çözünürlükte bulunan fundus görüntüleri ve uzmanlar

tarafından etiketlenmiş hastalıklara ait veriler bulunmaktadır. Veri setinde 5.000 hastadan alınan 6.392 fundus görüntüsü bulunmaktadır. ODIR-5K veri setinde 8 farklı sınıfa ait patolojik veri bulunmaktadır. Bu veri sınıfından yedisi retinal hastalıklara sahip bireylere ait tomografi görüntülerini diğeri ise normal retinaya sahip bireylerden alınan tomografi görüntülerini barındırmaktadır.

Veri setinde kullanılan retinal hastalıklar şu şekilde sıralanmaktadır:

- Miyop
- Diyabetik Retinopati
- Hipertansiyon
- Glokom
- Drusen
- Katarakt
- Yaşa Bağlı Maküler Dejenerasyon
- Diğer hastalıklar ve anormallikler

Hastalıklarını içeren çok sayıda yüksek çözünürlükte retinal tomografi fotoğraflarını içermektedir. Veri setine ait sınıflandırılmış hastalıklara ait dağılım grafiği Şekil 3.37’de verilmiştir.





Şekil 3.37. ODIR-5K Veri Seti Hastalıkların Dağılım Grafiği

Çizelge 3.3. Veri setindeki Hastalıkların Dağılımı


Hastalık	Sayısal dağılımı
AMD	262
Katarakt	293
Diyabet	1608
Glokom	284
Hipertansiyon	128
Normal	2873
Patolojik Miyop	232
Diğer Hastalıklar ve Anormallikler	708

Veri setinde bulunan sınıflara ait dağılım Çizelge 3.3’de verilmiştir. Çizelge 3.3 incelendiğinde Veri setinde bulunan hastalıkların dağılımları arasında oldukça dengesizlikler bulunmaktadır. Veri dağılımı arasındaki dengelenmenin sağlanması için veri artırma işlemi gerçekleştirilmiştir. Optik koherans tomografi görüntüleri döndürme, kırpma ve yakınlaştırma işlemleri gibi çeşitli veri artırma yöntemleri uygulanarak, veride bulunan dengesizlikler giderilmiş ve veri seti eğitim için uygun hale getirilerek transfer öğrenme modellerinde ve önerilen Evrişimli Sinir Ağı (ESA) modelinde kullanılmıştır. Aşağıda ODIR-5K veri setinde bulunan 8 tip hastalığa ait retinal tomografi fotoğraflarına yer verilmiştir.


**Şekil 3.38.** Normal Tomografi Fotoğrafları




Şekil 3.39. Diyabetik Retinopati Tomografi Fotoğrafları




Şekil 3.40. Katarakt Tomografi Fotoğrafları




Şekil 3.41. Hipertansiyon tomografi Fotoğrafları




Şekil 3.42. Diğer Hastalıklar ve Anormallikler İçeren Tomografi Fotoğrafları



Şekil 3.43.YBMD tomografi Fotoğraflar



Şekil 3.44. Miyop Tomografi Fotoğrafları



Şekil 3.45. Glokom Tomografi Fotoğrafları

3.9. Veri Ön İşleme


Veri ön işleme, veri setlerinde kullandığımız veriler dağınık, tekrarlı, alakasız, gürültülü ve eksik veriler bulunabilmektedir. Elde edilen veriye bir model uygulanmadan önce bir takım ön işleme teknikleri uygulayarak veriyi elde ederken oluşan sorunların teknik veya çevresel sorunların önüne geçmek gerekmektedir. Bu sayede modelimizi eğitirken yüksek başarı oranları elde edilebilmektedir. Tez çalışması için kullanılan veri集中的 görüntüler farklı boyutlarda ve çözünürlüktedir öncelikle görüntüler 224x224 olarak boyutlandırılmıştır. Sonrasında görüntüler gri filtre uygulanarak ardından CLAHE veri ön işleme uygulanmıştır.

3.9.1. Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE)


CLAHE, piksel değerlerini yeniden dağıtarak bir görüntüdeki kontrastı ve ayrıntılarını geliştirmek için kullanılan bir görüntü işleme tekniğidir. Histogram Eşitleme (HE), görüntü verisinin parlaklık ve kontrast değerlerini ayarlamak için kullanılan görüntü ön işleme tekniklerinden biridir. Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (CLAHE) işlemi ise HE işlemi sırasında oluşan aşırı parlaklığı önlemek

amacıyla geliştirilmiştir (Smith, 2023). CLAHE uygulanırken görüntü bloklar adı verilen daha küçük bölgelere bölünür. Histogram eşitleme daha sonra her bloğa ayrı ayrı uygulanır. Uygulanan her bloğun piksel değerlerinin dağılımını değiştirerek kontrastı artırılır. Elde edilen bloklarda aşırı kontrast artışı olabilmektedir. Bu durumun önüne geçebilmek için histogram sınırlama adımı uygulanarak bloklardaki piksel değerleri sınır değerine göre kırılır. Kırılan bu bloklar birleştirilerek kontrastı iyileştirilmiş görüntüler elde edilir. CLAHE özellikle bölgesel kontrastı artırmak için kullanılan etkili bir görüntü işleme tekniğidir. Renk dağılımları eşit olmayan görüntüler için kullanımı uygun bir görüntü işleme metodudur.




Şekil 3.46, 3.47 ve 3.48’de ODIR-5K veri seti görüntülerine gri filtre ve CLAHE uygulanmış retinal görüntüler ve görüntülerden elde edilen histogram grafiklerine yer verilmiştir.




Şekil 3.46. Glokom Retinal Görüntüsü(A), Gri Filtre Uygulanmış(B), CLAHE Uygulanmış Görüntüsü(C)



Şekil 3.47. AMD Retinal Görüntüsü(A), Gri Filtre Uygulanmış(B), CLAHE Uygulanmış Görüntüsü(C)





Şekil 3.51.Miyop Görüntüsüne Gri Filtre ve CLAHE Uygulanmış Histogram Grafikleri

Şekil 3.49, 3.50 ve 3.51’de histogram eşitleme grafiklerine yer verilmiştir. Grafikler incelendiğinde mavi renkte belirtilen gri filtreye ait histogram dağılımlarının bulunduğu çizgisel gösterimdir. Grafikte turuncu renkte belirtilen çizgiler de görüntülere CLAHE uygulandıktan sonra oluşan sayısal dağılımı göstermektedir. Gri filtre ve CLAHE uygulandıktan sonra renk dağılımlarının sayısal olarak dengelenmeye çalışıldığı görülmektedir.

3.10. Veri Artırma (Data Augmentation)

Derin öğrenme uygulamalarında modelin performansının başarısında büyük veri setleri oldukça önemlidir. Veri setinde bulunan veriler yetersiz kaldığında modelin eğitimi sırasında overfitting (aşırı öğrenme) problemi ortaya çıkabilir. Aşırı öğrenmeyi minimum seviyeye indirmek için veri artırma yöntemleri kullanılmaktadır (Shorten & Khoshgoftaar, 2019). Çizelge 4.1’de veri çoğaltma yöntemlerini uygulamak için kullanılan parametrelere yer verilmiştir. Çizelge 4.2’de veri çoğaltma işlemleri uygulandıktan sonra veri setindeki hastalıkların dağılımları verilmektedir.

Çizelge 3.4. Veri Artırma İçin Kullanılan Parametre Değerleri

Parametre	Açıklama	Değer
RESCALE	Pikselleri yeniden ölçeklendirme	1./255
ZOOM_RANGE (°C)	Görüntü yaklaştırma	[.99, 1.01]
BRIGHT_RANGE	Parlaklık ayarı	[0.8, 1.2]
HORIZONTAL_FLIP	Görüntüyü yatay yönde döndürme	True
VERTICAL_FLIP	Görüntüyü dikey yönde döndürme	True
FILL_MODE	Girişin sınırları dışında bulunan noktalar verilen moda göre doldurulur	Constant

Çizelge 3.5.Veri Seti Artırma Uygulandıktan Sonra Veri Dağılımı

Sınıf	Veri değeri
AMD	2888
Diyabet	3048
Glokom	2901
Katarakt	2769
Miyop	2928
Normal	2816
Diğer anormallikler	2592
Hipertansiyon	2856

3.11. Veri setinin Eğitim, Doğrulama ve Test olarak Bölünmesi

Makine öğrenimi modellerinin eğitilmesi için kullanılan ilk veri seti eğitim verileridir. Eğitim verileri, tahminlerini nasıl bu veriler üzerinde yapacaklarını veya istenilen görevi nasıl uygulamalarını öğretmek için kullanılan makine öğrenimi algoritmalarına verilmektedir. Doğrulama verileri, eğitim esnasında modelin performansının değerlendirilmesi için kullanılan eğitim setinden ayrı olarak belirlenen veri setidir. Modelin doğrulanması süresinde hiper parametrelerinin modele uygun seçilmesi aşırı öğrenme (overfitting) durumunun önlenmesi açısından oldukça önemlidir.

3.12. Çalışmada Kullanılan Donanım ve Yazılımlar

Tez çalışmasında NVIDIA GeForce RTX-3050 ekran kartı 16 GB RAM kullanılmıştır. Programlama dili olarak python tercih edilmiş olup, geliştirilen derin öğrenme tabanlı evrişimli sinir ağı modeli Jupyter notebook kullanılarak gerçekleştirilmiştir. Keras kütüphanesi kullanılarak derin öğrenme modelinin eğitimi ve test işlemi gerçekleştirilmiştir.

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

Önerilen ESA modelinde veri ön işleme teknikleri ve derin öğrenme tabanlı evrişimsel sinir ağı kullanılmıştır. Önerilen model transfer öğrenme metotları ile karşılaştırılmıştır. Retinal hastalıkların teşhis edilebilmesi için uygulanan transfer öğrenme yöntemlerinden VGG19, ResNet50, InceptionV3, Xception ve önerilen evrişimli sinir ağına ait doğruluk ve kayıp grafiklerine yer verilmektedir. Modelin performansının detaylı şekilde analiz edilebilmesi için kullanılan transfer öğrenme yöntemleri için karmaşıklık matrisleri oluşturulup, incelenmiştir. Elde edilen karmaşıklık matrisleri, hastalıkların sınıflandırılması sonucunda elde edilen doğru veya yanlış tahmin değerlerini detaylı şekilde göstermektedir.

Performans metrikleri alanında tez çalışmasında kullanılan değerlendirme metriklerine yer verilmiştir. Bu metrikler sırasıyla karışıklık matrisi, doğruluk oranı, duyarlılık, hassasiyet, kesinlik, F-1 puanıdır.

4.1. Performans Metrikleri

Derin öğrenme modellerinin sınıflandırıcı performanslarının değerlendirilmesi için performans metrikleri kullanılmaktadır. Birçok değerlendirme metriği bulunmaktadır. Bu metriklerdeki performans değerleri bazılarında güçlü, bazılarında ise düşük değerde çıkabilmektedir. Modeller bu metrikler sayesinde tahmin edilen ve gerçek değerleri karşılaştırılır. Bu tez çalışmasında uygulanan performans metrikleri kesinlik (precision), doğruluk (accuracy), karmaşıklık matrisi ve F1 puanı olmak üzere 4 performans metriği kullanılmıştır.

4.1.1. Karışıklık Matrisi

Karışıklık matrisi, derin öğrenme ve makine öğrenmesinde uygulanan Doğruluk değerlerinin bilindiği test veri seti üzerinde, modellerin performansının değerlendirilmesi için hedef ve tahmin değerlerinin karşılaştırıldığı karışıklık matrisi (Confusion Matrix) sıklıkla kullanılmaktadır.

		GERÇEK	
		Pozitif	Negatif
TAHMİN	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 4.1.Karışıklık (Hata) Matrisi

Şekil 4.1’de verilen hata matrisi, sınıflandırma modelinin, gerçek değerlerin bilindiği belirli bir test kümesinde nasıl performans gösterdiği ölçmek amacıyla kullanılan bir yöntemdir.

True Positive – TP

TP, sınıflandırıcının pozitif değerdeki sınıfı pozitif olarak doğru tahmin ettiği değerlerin sayısını ifade etmektedir.

True Negative – TN

TN, sınıflandırıcının negatif değerdeki sınıfı negatif olarak doğru tahmin ettiği değerlerin sayısını ifade etmektedir.

False Positive – FP

FP, sınıflandırıcının negatif sınıfa ait veriyi pozitif olarak yanlış tahmin ettiği değerlerin sayısını ifade etmektedir.

False Negative – FN

FN, sınıflandırıcının pozitif sınıfa ait veriyi negatif olarak yanlış tahmin ettiği değerlerin sayısını ifade etmektedir.

$$\text{TOPLAM} = TP + FP + TN + FN$$

$$\text{Gerçek Pozitif Değerler} = TP + FN$$

$$\text{Gerçek Negatif Değerler} = TN + FP$$

(4.1)

Doğruluk Oranı (Accuracy Rate): Sınıflayıcının hangi sıklıkta doğru tahmin değerlerini elde ettiğinin ölçütüdür şeklinde ifade edilmektedir. Denklem 4.2’de belirttiği gibi TP ve TN değerlerinin toplamının toplam değere bölünmesi ile hesaplanmaktadır.

$$DOĞRULUK = \frac{TP+TN}{TOPLAM} \quad (4.2)$$

4.1.2. Duyarlılık (Recall) :

Sınıflandırıcının hangi oranda gerçek pozitif ya da gerçek negatif değeri doğru tahminde bulunduğu ölçütüdür. İsabet oranı veya hatırlama oranı olarak da isimlendirilmektedir. Bu değerlerin mümkün olduğunca yüksek çıkması beklenir. Denklem 4.3’de Duyarlılık değerinin matematiksel gösterimi bulunmaktadır.

$$DUYARLILIK = \frac{TP}{GERÇEK POZİTİF DEĞERLER} \quad (4.3)$$

4.1.3. Hassasiyet (Precision):

Hassasiyet tüm sınıflar içerisinde yapılan doğru pozitif tahminlerin, toplam pozitif tahminlere bölünmesiyle elde edilir. Hassasiyet ile doğru olarak ne kadar tahmin yapıldığı ölçülmektedir. Hassasiyet aynı zamanda pozitif tahmin edici değer olarak da isimlendirilmektedir. Hassasiyet denklem 4.4’de gösterildiği gibi hesaplanmaktadır.

$$HASSASİYET = \frac{TP}{TP+FP} \quad (4.4)$$

4.1.4. Kesinlik (Recall):

Kesinlik doğru pozitif tahmin sayısının, doğru pozitif tahmin sayısı ile doğru negatif tahmin sayısına bölünmesiyle hesaplanan bir ölçüdür. Kesinlik denklem 4.5’de gösterildiği şekilde hesaplanmaktadır.

$$KESİNLİK = \frac{TP}{TP+TN} \quad (4.5)$$

4.1.5. F-1 Puanı (F-1-Score):

F puanı, gerçek pozitif değerlerin oranını ifade eden kesinlik (recall) ve hassasiyetin harmonik ortalamasıdır. F puanı bir sınıflandırıcının gösterdiği performansın ne kadar iyi olduğunun bir ölçüsüdür. F-1score literatürde sınıflandırıcıların başarısını karşılaştırmak için sıklıkla kullanılmaktadır. F-1 puanı denklem 4.6’da gösterildiği şekilde hesaplanmaktadır.

$$F1 \text{ PUANI} = 2 * \frac{HASSASIYET \times DUYARLILIK}{HASSASIYET + DUYARLILIK} \quad (4.6)$$




4.2. MODELLERİN TEST SONUÇLARI

4.2.1.VGG19 Modeli

VGG19 modeli ön eğitimli ağırlar başlığı altında detaylı şekilde açıklanmıştır. Önceden eğitilmiş bu modelin Kaggle web sayfası üzerinden erişilen ODIR-5K veri seti üzerindeki başarısının ölçülmesi için transfer öğrenme yöntemi kullanılmıştır. Eğitim esnasında adım sayısı (epoch) 50 olarak, öğrenme oranı 0.0001 ve batch size değeri 32 olarak belirlenmiştir. Optimizasyon yöntemi olarak Adam kullanılmış olup kayıp fonksiyonu olarak Categorical Cross Entropy tercih edilmiştir.

VGG19 modelinin eğitim süreci ile alakalı Şekil 4.2’de doğruluk değerleri ve kayıp değerlerinin bulunduğu grafikler verilmiştir. Model tüm hastalık sınıfları için (YBMÖ, Katarakt, Diyabet, Glokom, Hipertansiyon, Miyop, normal ve diğer) ortalama doğruluk değeri %98.16 eğitim doğruluğuna ve %88.24 oranında doğrulama doğruluğuna ulaşmıştır.



Şekil 4.2.VGG19 Doğruluk ve Kayıp Grafikleri

Gerçek değer	YBMÖ	554	0	2	0	0	1	6	1
	Katarakt	0	536	0	0	0	0	1	0
	Diyabet	7	2	420	9	3	1	141	30
	Glokom	0	0	1	564	0	1	11	3
	Hipertansiyon	0	0	0	0	605	0	0	0
	Miyop	1	2	0	0	0	579	0	0
	Normal	13	9	106	32	9	3	340	43
	Diğer	5	5	27	2	2	0	48	424
		YBMÖ	Katarakt	Diyabet	Glokom	Hipertansiyon	Miyop	Normal	Diğer
		Tahmin edilen değer							

Şekil 4.3.VGG19 Hata Matrisi

Şekil 4.3 'de verilen hata matrisi, test verilerinden elde edilen modelin performans değerlerini göstermektedir. Hesaplama, YBMÖ 564 veri görüntüsü, Katarakta 537, Diyabete 613 görüntü, Glokoma 581, Hipertansiyona 605, Miyop 582, normal 555 ve diğer anormallikler için 521 görüntü ile yapılmıştır.

VGG19 için eğitilen model YBMÖ %98.22, Katarakt %99.81, Diyabet %68.51, Glokom %97.07, Hipertansiyon %100, Miyop %99.48, normal %61.26 ve diğer hastalıklar için %81.38 doğruluk değerine ulaşmıştır.


Çizelge 4.1'de VGG19 modeli test edildikten sonra oluşan sınıflandırma değerlendirme metriklerine yer verilmiştir.

Çizelge 4.1. VGG19 Modeli İle Test Verilerinden Elde Edilen Sınıflandırma Sonuçları

Sınıf	Precision	Recall	F1-score	Support
YBMÖ	0.96	0.98	0.97	564
Katarakt	0.97	1.00	0.98	537
Diyabet	0.75	0.69	0.72	613
Glokom	0.93	0.97	0.95	581
Hipertansiyon	0.98	1.00	0.99	605
Miyop	0.98	0.99	0.99	582
Normal	0.62	0.61	0.62	555
Diğer	0.85	0.81	0.83	521

4.2.2.XceptionV3 Modeli

XceptionV3 modeli ön eğitilmiş ağırlar başlığı altında detaylı şekilde açıklanmış ve mimari yapıları hakkında bilgiler verilmiştir. XceptionV3 modelinin eğitim süreci ile alakalı Şekil 4.4’de doğruluk değerleri ve kayıp değerlerinin bulunduğu grafikler verilmiştir. Model tüm hastalık sınıfları için (YBMÖ, Katarakt, Diyabet, Glokom, Hipertansiyon, Miyop, normal ve diğer) ortalama %95.36 eğitim doğruluğuna ve %82.49 oranında doğrulama doğruluğuna ulaşmıştır.



Şekil 4.4. XceptionV3 Doğruluk ve Kayıp Grafikleri

Şekil 4.5’de XceptionV3 modeline ait hata matrisi verilmiştir. Test edilen model, YBMÖ etiketli olan görüntülerin 7’sini Diyabet, 11’ini normal, 9’unu diğer ve 1’er tanesini de Glokom, Hipertansiyon ve Miyop olarak tahmin etmiştir. XceptionV3 kullanılarak oluşturulan model Hipertansiyon, Glokom ve Miyop hastalıklarında yüksek doğruluk değerlerine ulaşmıştır.

YBMÖ	534	0	7	1	1	1	11	9
Katarakt	0	529	0	1	0	1	5	1
Diyabet	0	4	360	15	33	3	132	58
Glokom	2	1	3	552	2	0	20	1
Hipertansiyon	0	0	6	1	595	0	1	2
Miyop	1	1	0	1	0	577	0	2
Normal	16	9	106	37	20	3	300	64
Diğer	28	14	43	11	5	15	88	313

Tahmin edilen değer

Şekil 4.5. XceptionV3 Hata Matrisi

XceptionV3 için eğitilen model YBMÖ %94.68, Katarakt %98.51, Diyabet %58.72, Glokom %97.41, Hipertansiyon %98.34, Miyop %99.14, Normal %54.04 ve diğer hastalıklar için %60 doğruluk değerine ulaşmıştır. Çizelge 4.2’de XceptionV3 modeli test edildikten sonra oluşan sınıflandırma değerlendirme metriklerine yer verilmiştir.


Çizelge 4.2. Xceptionv3 Modeli Test Verileri İle Elde Edilen Sınıflandırma Sonuçları

Sınıf	Precision	Recall	F1-score	Support
YBMÖ	0.91	0.95	0.93	564
Katarakt	0.95	0.99	0.97	537
Diyabet	0.69	0.59	0.63	613
Glokom	0.89	0.95	0.92	581
Hipertansiyon	0.90	0.98	0.94	605
Miyop	0.96	0.99	0.98	582
Normal	0.54	0.54	0.54	555
Diğer	0.70	0.60	0.64	521

4.2.3 InceptionV3 Modeli

InceptionV3 modeli ön eğitilmiş ağırlar başlığı altında detaylı şekilde açıklanmış ve mimari yapıları hakkında bilgiler verilmiştir. InceptionV3 modelinin eğitim süreci ile alakalı Şekil 4.6 ‘da doğruluk değerleri ve kayıp değerlerinin bulunduğu grafikler verilmiştir. Model tüm hastalık sınıfları için (YBMÖ, Katarakt, Diyabet, Glokom,

Hipertansiyon, Miyop, normal ve diğer) ortalama %98.2 eğitim doğruluğuna ve %86.83 oranında doğrulama doğruluğuna ulaşmıştır.



Şekil 4.6. Doğruluk ve Kayıp Grafikleri

Gerçek değer	YBMÖ	555	0	0	1	0	0	7	1
	Katarakt	0	537	0	0	0	0	0	0
	Diyabet	8	0	393	12	26	2	122	50
	Glokom	0	1	3	566	0	0	10	1
	Hipertansiyon	1	0	1	0	601	0	1	1
	Miyop	0	0	0	0	0	582	0	0
	Normal	14	10	119	32	13	4	323	40
	Diğer	15	4	23	5	5	8	60	401
		Tahmin edilen değer							
		YBMÖ	Katarakt	Diyabet	Glokom	Hipertansiyon	Miyop	Normal	Diğer

Şekil 4.7. InceptionV3 Hata Matrisi

InceptionV3 için eğitilen model YBMÖ %94.40, Katarakt %100, Diyabet %64.11, Glokom %97.41, Hipertansiyon %99.33, Miyop %100, Normal %58.18 ve diğer hastalıklar için %76.96 doğruluk değerine ulaşmıştır.


Çizelge 4.3'de InceptionV3 modeli test edildikten sonra oluşan sınıflandırma değerlendirme metriklerine yer verilmiştir.

Çizelge 4.3. Inceptionv3 Modeli Test Verileri İle Elde Edilen Sınıflandırma Sonuçları

Sınıf	Precision	Recall	F1-score	Support
YBMÖ	0.94	0.98	0.96	564
Katarakt	0.97	1.00	0.99	537
Diyabet	0.73	0.64	0.68	613
Glokom	0.92	0.97	0.95	581
Hipertansiyon	0.93	0.99	0.96	605
Miyop	0.98	1.00	0.99	582
Normal	0.62	0.58	0.60	555
Diğer	0.81	0.77	0.79	521

4.2.4. ResNet50 Modeli

ResNet50 modeli ön eğitilmiş ağırlar başlığı altında detaylı şekilde açıklanmış ve mimari yapıları hakkında bilgiler verilmiştir. ResNet50 modelinin eğitim süreci ile alakalı Şekil 4.8’de doğruluk değerleri ve kayıp değerlerinin bulunduğu grafikler verilmiştir. Model tüm hastalık sınıfları için (YBMÖ, Katarakt, Diyabet, Glokom, Hipertansiyon, Miyop, normal ve diğer) ortalama %98.86 eğitim doğruluğuna ve %86.83 oranında doğrulama doğruluğuna ulaşmıştır.

**Şekil 4.8.** Doğruluk ve Kayıp Grafikleri

Şekil 4.9’da ResNet50 modeline ait hata matrisi verilmiştir. Test edilen model Katarakt hastalığına ait 537 görüntünün 535’ini Katarakt olarak 1’ini normal ve diğer hastalıklara ait sınıflandırmıştır. Uygulanan model Hipertansiyon, Katarakt ve Miyop hastalıkları için başarısı diğer sınıflara göre yüksek tahmin oranında çıkmıştır. Diyabet, normal ve diğer hastalıklar için düşük tahmin oranında sonuç vermiştir.

Gerçek değer	YBMÖ	550	0	4	1	0	0	6	4
	Katarakt	0	535	0	0	0	0	1	1
	Diyabet	10	2	399	6	18	0	131	47
	Glokom	0	2	0	564	0	0	13	2
	Hipertansiyon	0	0	1	0	603	0	1	1
	Miyop	1	0	0	0	0	581	0	0
	Normal	11	7	106	37	16	4	327	47
	Diğer	15	1	26	9	3	14	54	399
		Tahmin edilen değer							
		YBMÖ	Katarakt	Diyabet	Glokom	Hipertansiyon	Miyop	Normal	Diğer

Şekil 4.9. ResNet50 Hata Matrisi

ResNet50 mimarisi için eğitilen model YBMÖ %97.51, Katarakt %99.62, Diyabet %65.08, Glokom %97.07, Hipertansiyon %99.66, Miyop %99.82, Normal %58.91 ve diğer hastalıklar için %76.58 doğruluk değerlerine ulaşmıştır.


Çizelge 4.4. Resnet50 Modeli Test Verileri İle Elde Edilen Sınıflandırma Sonuçları

Sınıf	Precision	Recall	F1-score	Support
YBMÖ	0.94	0.98	0.96	564
Katarakt	0.98	1.00	0.99	537
Diyabet	0.74	0.65	0.69	613
Glokom	0.92	0.97	0.94	581
Hipertansiyon	0.94	1.00	0.97	605
Miyop	0.97	1.00	0.98	582
Normal	0.61	0.59	0.60	555
Diğer	0.80	0.77	0.78	521

Çizelge 4.4’de ResNet50 modeli test edildikten sonra oluşan sınıflandırma değerlendirme metriklerine yer verilmiştir.

4.2.5. Önerilen ESA Modeli

Önerilen ESA modeli Şekil 3.36’da detaylı şekilde açıklanmış ve mimari yapıları hakkında bilgiler verilmiştir. ESA modelinin eğitim süreci ile ilgili Şekil 4.10 ‘da doğruluk değerleri ve kayıp değerlerine ait grafikler verilmiştir. Model tüm hastalık sınıfları için (YBMÖ, Katarakt, Diyabet, Glokom, Hipertansiyon, Miyop, normal ve diğer) ortalama %97.51 eğitim doğruluğuna ve %89.22 oranında doğrulama doğruluğuna ulaşmıştır.



Şekil 4.10. Doğruluk ve Kayıp Grafikleri

Şekil 4.10’da önerilen ESA modeline ait hata matrisi verilmiştir. Katarakt hastalığına ait test için kullanılan 537 görüntünün tamamını doğru şekilde tahmin ederek %100 oranında doğruluk oranına ulaşmıştır. Miyop hastalığının testi için bulunan 582 görüntünün 581’ini doğru tahmin ederek %99.82 oranında doğruluk elde etmiştir. Diğer mimariler ile kıyaslandığında normal ve diğer hastalıklara ait başarı oranları sırasıyla %64.5 ve %83.49 olarak hesaplanmıştır.

Gerçek değer	YBMO	559	0	0	0	0	0	3	2
	Katarakt	0	537	0	0	0	0	0	0
	Diyabet	2	3	429	5	9	0	138	27
	Glokom	0	0	0	566	0	0	15	0
	Hipertansiyon	0	1	1	0	602	0	1	0
	Miyop	0	0	0	0	0	581	0	1
	Normal	8	5	107	23	4	3	358	47
	Diğer	7	4	23	3	2	7	40	435
		YBMO	Katarakt	Diyabet	Glokom	Hipertansiyon	Miyop	Normal	Diğer
		Tahmin edilen değer							

Şekil 4.11. Önerilen ESA Hata Matrisi

Çizelge 4.5’de ESA modeli test edildikten sonra oluşan sınıflandırma değerlendirme metriklerine yer verilmiştir.

ESA mimarisi için eğitilen model YBMÖ %99.11, Katarakt %100, Diyabet %69.98, Glokom %97.74, Hipertansiyon %99.50, Miyop %99.82, Normal %64.50 ve diğer hastalıklar için %83.49 doğruluk değerine ulaşmıştır.

Çizelge 4.5. Önerilen ESA Modeli Test Verileri İle Elde Edilen Sınıflandırma Sonuçları

Sınıf	Precision	Recall	F1-score	Support
YBMÖ	0.97	0.99	0.98	564
Katarakt	0.98	1.00	0.99	537
Diyabet	0.77	0.70	0.73	613
Glokom	0.95	0.97	0.96	581
Hipertansiyon	0.98	1.00	0.99	605
Miyop	0.98	1.00	0.99	582
Normal	0.65	0.65	0.65	555
Diğer	0.85	0.83	0.84	521

Çizelge 4.6. Modellerin Performans Analizi Karşılaştırılması

Model	Eğitim Doğruluğu	Doğrulama Doğruluğu	Test Doğruluğu
VGG19	%98.16	%88.24	%88.21
InceptionV3	%98.2	%86.83	%86.29
Xception	%95.36	%82.49	%88.60
ResNet50	%98.86	%86.83	%86.78
Önerilen ESA	%97.51	%89.22	%89.26

Çizelge 4.6 incelendiğinde önerilen ESA mimarisinin %97.51 oranında eğitim başarısına, %89.22 doğrulama doğruluğuna ve %89.26 oranında test başarısı elde ettiği görülmektedir. Önerilen model önceden eğitilmiş Xception modelinden eğitim ve doğrulama değerlerinde yüksek başarıya ulaşmıştır. Sınıf bazında değerlendirildiğinde diğer sınıflardan normal, katarakt ve diğer hastalıklar sınıflarında önceden eğitilmiş modellerden başarı oranı daha yüksek çıkmıştır.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Yapılan yüksek lisans tez çalışmasında, yaygın şekilde görülen çeşitli retinal hastalıkların sınıflandırılması, retinal hastalıkların erken teşhis ve tedavi edilmesi açısından oldukça önemlidir. Çalışmada 8 farklı retinal hastalığa ait tomografi görüntülerini içeren ODIR-5K veri seti kullanılmıştır. ODIR-5K veri seti çeşitli ön işlemlere tabii tutulmuştur. Boyutlandırma, gri filtre ve CLAHE veri ön işlemleri uygulanarak veri seti eğitim için hazır hale getirilmeye çalışılmıştır. Veri seti %16 doğrulama, %64 eğitim ve %20 test olmak üzere ayrılmıştır.

Transfer öğrenme metotlarından VGG19, InceptionV3, Xception ve ResNet50 mimarileri tercih edilmiştir. Elde edilen sonuçlar karşılaştırıldığında en yüksek doğruluk oranına %98.86 ile ResNet50 mimarisinin ulaştığı görülmektedir. VGG19 da bu oran %98.16, InceptionV3 mimarisinde %98.2, Xception mimarisinde %95.36 ve önerilen ESA mimarisinde %97.51 doğruluk olarak elde edilmiştir.

Sonuç olarak, yapılan tez çalışmasında, retinal tomografi görüntülerinden ESA derin öğrenme modeli kullanılarak sınıflandırılmasıyla, hastalıkların teşhisinde doktorlara yardımcı olabilecek nitelikte ve ilk aşamada kullanılabilecek bir sistem önerilmiştir. Uygulanan model retinal hastalıklar içerisinde YBMÖ %99.11, Katarakt %100, Diyabet %69.98, Glokom %97.74, Hipertansiyon %99.50, Miyop %99.82, Normal %64.50 ve diğer hastalıklar için %83.49 doğruluk değerlerine ulaşmıştır. Doğruluk değerleri incelendiğinde önerilen derin öğrenme tabanlı sistemin 8 farklı hastalık arasında YBMÖ, Hipertansiyon, Katarakt, Glokom ve Miyop hastalıklarının teşhisi için yüksek doğruluk değerlerine ulaştığı görülmektedir.

5.2 Öneriler

Bu tez çalışmasında, bilgisayar destekli tanı sistemleri ile sağlık alanında yapılan çalışmalara katkıda bulunarak sağlık sorunlarının erken teşhis edilebilmesi için bir

çalışma yapılmıştır. Uzman sayısındaki yetersizlikler ve dünyadaki birçok ülkede sağlık sistemlerindeki erken teşhis problemi, bu çalışmanın temel hedefini oluşturmaktadır.

Bu çalışmada CNN modelleri ile retinal tomografi görüntüleri üzerinde çalışılmıştır ve elde edilen sonuçlar incelenmiştir. Çalışmada kullanılan ODIR-5K veri setinin dağınık ve gelişime açık bir veri seti olması ve derin öğrenme yöntemlerinin gelişerek daha da iyi sonuçlar verebileceği bir gerçektir. Transfer öğrenme metotlarının kullanıldığı mimarilere farklı parametreler ile iyileştirilerek en iyi sonucu verecek parametrelerin tespit edilmesi için ince ayarlama (fine tuning) işlemi yapılabilir.

Veri artırım yöntemlerinden Çekişmeli Üretici Ağlar (GAN) kullanılabilir ve böylece daha iyi sonuçlar elde edilebilir. İleriki çalışmalarda yeni metotlar, hibrit sistemler geliştirilerek başarımın arttırılması hedeflenmektedir. Elde edilen sonuçlar bazı hastalık sınıfları için umut verici olsa da bazı sınıflarda düşük doğruluk değerleri elde edilmiştir. Oluşturulan modellerin hiper-parametre değerlerinde değişiklikler yapılabilir.

İlerleyen çalışmalarımızda retinal hastalıkları içeren veri setlerinin oldukça dağınık yapıda olması sebebiyle Necmettin Erbakan Üniversitesi Meram Tıp Fakültesi Göz hastalıkları Anabilim Dalı tarafından etik kurul onayıyla elde edilen tomografi görüntüleri ile veri setindeki dağınıklık giderilmeye çalışılarak yüksek başarı oranlarına ulaşılması hedeflenmektedir. Etik kuruldan alınan sonuç raporu Ek-1 olarak verilmiştir.

Bu tez çalışmasından elde edilen sonuçlar doğrultusunda çalışma genişletilerek farklı birçok hastalık tespiti için kullanılan yeni derin öğrenme modellerinin kullanımı mümkün görünmektedir.

6. KAYNAKLAR

- Ahmed, T. (2023). Classification and understanding of cloud structures via satellite images with EfficientUNet. In.
- Akman, A. (2023). Glokom Tanısı (OCT Göz Tomografisi). Retrieved from <https://www.drahmetakman.com/tr/glokom-tanisi>
- Berrimi, M., & Moussaoui, A. (2020, 13-15 Oct. 2020). *Deep learning for identifying and classifying retinal diseases*. Paper presented at the 2020 2nd International Conference on Computer and Information Sciences (ICCIS).
- Bhati, A., Gour, N., Khanna, P., & Ojha, A. (2023). Discriminative kernel convolution network for multi-label ophthalmic disease detection on imbalanced fundus image dataset. *Computers in Biology and Medicine*, 153, 106519. doi:<https://doi.org/10.1016/j.combiomed.2022.106519>
- Chollet, F. (2017). *Xception: Deep Learning with Depthwise Separable Convolutions*.
- Coleman, A. L., & Brigatti, L. (2001). The glaucomas. *Minerva Med*, 92(5), 365-379.
- Das, S., Kharbanda, K., M, S., Raman, R., & D, E. D. (2021). Deep learning architecture based on segmented fundus image features for classification of diabetic retinopathy. *Biomedical Signal Processing and Control*, 68, 102600. doi:<https://doi.org/10.1016/j.bspc.2021.102600>
- Das, V., Dandapat, S., & 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. doi:<https://doi.org/10.1016/j.bspc.2019.101605>
- Dettmers, T. (2015). Deep Learning in a Nutshell: History and Training. Retrieved from <https://developer.nvidia.com/blog/deep-learning-nutshell-history-training/>
- Elsawy, A., Eleiwa, T., Chase, C., Ozcan, E., Tolba, M., Feuer, W., . . . Abou Shousha, M. (2021). Multidisease Deep Learning Neural Network for the Diagnosis of Corneal Diseases. *American Journal of Ophthalmology*, 226, 252-261. doi:<https://doi.org/10.1016/j.ajo.2021.01.018>
- Foster, R. G., Provencio, I., Hudson, D., Fiske, S., De Grip, W., & Menaker, M. (1991). Circadian photoreception in the retinally degenerate mouse (rd/rd). *Journal of Comparative Physiology A*, 169(1), 39-50. doi:10.1007/BF00198171
- Gargeya, R., & Leng, T. (2017). Automated Identification of Diabetic Retinopathy Using Deep Learning. *Ophthalmology*, 124(7), 962-969. doi:<https://doi.org/10.1016/j.ophtha.2017.02.008>
- Glorot, X., Bordes, A., & Bengio, Y. (2011). *Deep Sparse Rectifier Neural Networks*. Paper presented at the Proceedings of the Fourteenth International Conference on Artificial Intelligence and Statistics, Proceedings of Machine Learning Research. <https://proceedings.mlr.press/v15/glorot11a.html>
- Gudikandula, P. (2019). Deep view on transfer learning with image classification pytorch. Retrieved from <https://purnasai.github.io/Deep-view-on-Transfer-learning-with-lamge-classification-Pytorch/>
- Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., . . . 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. doi:10.1001/jama.2016.17216
- Gupta, I. K., Choubey, A., & Choubey, S. (2022). Artificial intelligence with optimal deep learning enabled automated retinal fundus image classification model. *Expert Systems*, 39(10), e13028.

- Hayati, M., Muchtar, K., Roslidar, Maulina, N., Syamsuddin, I., Elwirehardja, G. N., & Pardamean, B. (2023). Impact of CLAHE-based image enhancement for diabetic retinopathy classification through deep learning. *Procedia Computer Science*, 216, 57-66. doi:<https://doi.org/10.1016/j.procs.2022.12.111>
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). *Deep residual learning for image recognition*. Paper presented at the Proceedings of the IEEE conference on computer vision and pattern recognition.
- Huang, D., Swanson, E. A., Lin, C. P., Schuman, J. S., Stinson, W. G., Chang, W., . . . et al. (1991). Optical coherence tomography. *Science*, 254(5035), 1178-1181. doi:10.1126/science.1957169
- Ian, G., Yoshua, B., & Aaron, C. (2018). *Derin Öğrenme*.
- Ita, K. (2022). Chapter 4 - Anatomy and physiology of the eye. In K. Ita (Ed.), *Microneedles* (pp. 73-92): Academic Press.
- Karalezli, A., & Kaderli, A. (2021). TIP FAKÜLTESİ ÖĞRENCİLERİ İÇİN GÖZ HASTALIKLARI. 1-3.
- Kermany, D. S., Goldbaum, M., Cai, W., Valentim, C. C. S., Liang, H., Baxter, S. L., . . . Zhang, K. (2018). Identifying Medical Diagnoses and Treatable Diseases by Image-Based Deep Learning. *Cell*, 172(5), 1122-1131.e1129. doi:<https://doi.org/10.1016/j.cell.2018.02.010>
- King, H., Aubert, R. E., & Herman, W. H. (1998). Global burden of diabetes, 1995-2025: prevalence, numerical estimates, and projections. *Diabetes Care*, 21(9), 1414-1431. doi:10.2337/diacare.21.9.1414
- Kızrak, A. (2018). DERİNE DAHA DERİNE: Evrişimli Sinir Ağları. Retrieved from <https://ayyucekizrak.medium.com/deri%CC%87ne-daha-deri%CC%87ne-evri%CC%87simli-sinir-aglari%CC%87-2813a2c8b2a9>
- Kızrak, A. (2019). Ölçeklendirme ile CNN Modelinin Doğruluk ve Verimliliğini Artırma: EfficientNet.
- Kolb, H. (2012). Simple anatomy of the retina.
- Kuchera, M., Ramanujan, R., Taylor, J. Z., Strauss, R. R., Bazin, D., Bradt, J., & Chen, R. (2019). Machine learning methods for track classification in the AT-TPC. *Nuclear Instruments and Methods in Physics Research Section A: Accelerators, Spectrometers, Detectors and Associated Equipment*, 940. doi:10.1016/j.nima.2019.05.097
- Larxel. (2020). "Ocular Disease Recognition". Retrieved from <https://www.kaggle.com/datasets/andrewmvd/ocular-disease-recognition-odir5k>
- LeCun, Y. (2015). LeNet-5, convolutional neural networks. URL: <http://yann.lecun.com/exdb/lenet>, 20(5), 14.
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436-444. doi:10.1038/nature14539
- Li, F., Kai, L., Olga, R., Jonathan, K., Jia, D., & Alex, B. (2010). ImageNet. Retrieved from <https://web.archive.org/web/20190705151244/http://www.image-net.org/about-stats>
- Lu, Z., Miao, J., Dong, J., Zhu, S., Wang, X., & Feng, J. (2023). Automatic classification of retinal diseases with transfer learning-based lightweight convolutional neural network. *Biomedical Signal Processing and Control*, 81, 104365. doi:<https://doi.org/10.1016/j.bspc.2022.104365>
- Mathworks. (2023). Convolutional Neural Network. Retrieved from <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html>

- Matthews, A. G. (2004). The lens and cataracts. *Vet Clin North Am Equine Pract*, 20(2), 393-415, vii. doi:10.1016/j.cveq.2004.04.009
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5, 115-133.
- Mitchell, P., Smith, W., Attebo, K., & Wang, J. J. (1995). Prevalence of Age-related Maculopathy in Australia: The Blue Mountains Eye Study. *Ophthalmology*, 102(10), 1450-1460. doi:[https://doi.org/10.1016/S0161-6420\(95\)30846-9](https://doi.org/10.1016/S0161-6420(95)30846-9)
- Mittal, D., & Kumari, K. (2015). Automated detection and segmentation of drusen in retinal fundus images. *Computers & Electrical Engineering*, 47, 82-95. doi:<https://doi.org/10.1016/j.compeleceng.2015.08.014>
- Mullins, R. F., Russell, S. R., Anderson, D. H., & 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. *Faseb j*, 14(7), 835-846.
- Najeeb, S., Sharmile, N., Khan, M. S., Sahin, I., Islam, M. T., & Bhuiyan, M. I. H. (2018, 20-22 Dec. 2018). *Classification of Retinal Diseases from OCT scans using Convolutional Neural Networks*. Paper presented at the 2018 10th International Conference on Electrical and Computer Engineering (ICECE).
- Neuron. (2023). Neuron Definition. Retrieved from <https://byjus.com/biology/neurons/>
- Özkan, İ., & Ülker, E. J. G. B. A. D. (2017). Derin öğrenme ve görüntü analizinde kullanılan derin öğrenme modelleri. 6(3), 85-104.
- Öztürk, K., & Şahin, M. E. (2018). Yapay sinir ağları ve yapay zekâ'ya genel bir bakış. *Takvim-i Vekayi*, 6(2), 25-36.
- P, S., J, R., & R, P. (2021). An automatic recognition of glaucoma in fundus images using deep learning and random forest classifier. *Applied Soft Computing*, 109, 107512. doi:<https://doi.org/10.1016/j.asoc.2021.107512>
- Puliafito, C. A., Hee, M. R., Lin, C. P., Reichel, E., Schuman, J. S., Duker, J. S., . . . Fujimoto, J. G. (1995). Imaging of macular diseases with optical coherence tomography. *Ophthalmology*, 102(2), 217-229. doi:10.1016/s0161-6420(95)31032-9
- Quigley, H. A. (1996). Number of people with glaucoma worldwide. *Br J Ophthalmol*, 80(5), 389-393. doi:10.1136/bjo.80.5.389
- Rajan, R., & Kumar, S. N. (2022). IoT based optical coherence tomography retinal images classification using OCT Deep Net2. *Measurement: Sensors*, 100652. doi:<https://doi.org/10.1016/j.measen.2022.100652>
- S.C., E. P. A. (2023). Retina. Retrieved from <https://www.epawi.com/comprehensive-eye-care-milwaukee/retina/>
- Scanlon, P. H. (2022). Diabetic retinopathy. *Medicine*, 50(11), 696-703. doi:<https://doi.org/10.1016/j.mpmmed.2022.08.013>
- Schmidt-Erfurth, U., Sadeghipour, A., Gerendas, B. S., Waldstein, S. M., & Bogunović, H. (2018). Artificial intelligence in retina. *Progress in retinal and eye research*, 67, 1-29.
- Sharma, S., Sharma, S., & Athaiya, A. (2017). Activation functions in neural networks. *Towards Data Sci*, 6(12), 310-316.
- Shorten, C., & Khoshgoftaar, T. (2019). A survey on Image Data Augmentation for Deep Learning. *Journal of Big Data*, 6. doi:10.1186/s40537-019-0197-0
- Silvestri, G., Williams, M. A., McAuley, C., Oakes, K., Sillery, E., Henderson, D. C., . . . Muldrew, K. A. (2012). Drusen prevalence and pigmentary changes in Caucasians aged 18–54 years. *Eye*, 26(10), 1357-1362. doi:10.1038/eye.2012.165

- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Smith, L. (2023). Retrieved from <https://www.mathworks.com/matlabcentral/fileexchange/22182-contrast-limited-adaptive-histogram-equalization-clahe>
- Snell RS, L. M. (1998). Clinical anatomy of the eye. *The eye ball. 2nd Edition, Malden, Mass : Blackwell Science Inc*, 132-213.
- Srinivasan, P. P., Kim, L. A., Mettu, P. S., Cousins, S. W., Comer, G. M., Izatt, J. A., & Farsiu, S. (2014). Fully automated detection of diabetic macular edema and dry age-related macular degeneration from optical coherence tomography images. *Biomed Opt Express*, 5(10), 3568-3577. doi:10.1364/boe.5.003568
- Srivastava, N., Hinton, G. E., Krizhevsky, A., Sutskever, I., & Salakhutdinov, R. (2014). Dropout: a simple way to prevent neural networks from overfitting. *J. Mach. Learn. Res.*, 15, 1929-1958.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., & Wojna, Z. (2016, 27-30 June 2016). *Rethinking the Inception Architecture for Computer Vision*. Paper presented at the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- Szegedy, C., Wei, L., Yangqing, J., Sermanet, P., Reed, S., Anguelov, D., . . . Rabinovich, A. (2015, 7-12 June 2015). *Going deeper with convolutions*. Paper presented at the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR).
- Şen, Z. (2004). *Yapay sinir ağları: Su Vakfı*.
- Techs, A. (2023). ResNet: Understanding the Revolutionary Neural Network Architecture for Deep Learning. Retrieved from <https://anothertechs.com/programming/neural-network/resnet/>
- Totan, Y. (2023). Epiretinal Membran ve Tedavisi.
- Varshney, P. (2023). VGGNet-16 Architecture: A Complete Guide. Retrieved from <https://www.kaggle.com/code/blurredmachine/vggnet-16-architecture-a-complete-guide>
- Venkaiahpalaswamy, B., Prasad Reddy, P., & Batha, S. (2023). Hybrid deep learning approaches for the detection of diabetic retinopathy using optimized wavelet based model. *Biomedical Signal Processing and Control*, 79, 104146. doi:<https://doi.org/10.1016/j.bspc.2022.104146>
- Willoughby, C. E., Ponzin, D., Ferrari, S., Lobo, A., Landau, K., & Omid, Y. (2010). Anatomy and physiology of the human eye: effects of mucopolysaccharidoses disease on structure and function – a review. *Clinical & Experimental Ophthalmology*, 38(s1), 2-11. doi:<https://doi.org/10.1111/j.1442-9071.2010.02363.x>
- Wu, P. C., Huang, H. M., Yu, H. J., Fang, P. C., & Chen, C. T. (2016). Epidemiology of Myopia. *Asia Pac J Ophthalmol (Phila)*, 5(6), 386-393. doi:10.1097/apo.0000000000000236
- Yani, M., Irawan, S., & Setianingsih, C. (2019). Application of Transfer Learning Using Convolutional Neural Network Method for Early Detection of Terry's Nail. *Journal of Physics: Conference Series*, 1201, 012052. doi:10.1088/1742-6596/1201/1/012052
- Yann LeCun, L. B., Yoshua Bengio, and Patrick Haffner. (2015). Structure of the LeNet network.