



**T. C.
SIVAS CUMHURİYET ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**DERİN ÖĞRENME YÖNTEMLERİ İLE TOMOGRAFİ
GÖRÜNTÜLERİNDEN KAPALI AÇILI GLOKOM GÖZ
HASTALIĞININ SINIFLANDIRILMASI**

YÜKSEK LİSANS TEZİ

**Fatih TEKE
(20219258005)**

**Veri Bilimi ve Yapay Zekâ Ana Bilim Dalı
Tez Danışmanı: Prof. Dr. Oğuz Kaynar**

**SIVAS
OCAK 2024**

Fatih TEKE'nin hazırladığı ve “DERİN ÖĞRENME YÖNTEMLERİ İLE TOMOGRAFİ GÖRÜNTÜLERİNDEN KAPALI AÇILI GLOKOM GÖZ HASTALIĞININ SINIFLANDIRILMASI” adlı bu çalışma aşağıdaki jüri tarafından VERİ BİLİMİ VE YAPAY ZEKÂ ANA BİLİM DALI'nda YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Tez Danışmanı	Prof. Dr. Oğuz KAYNAR Sivas Cumhuriyet Üniversitesi
Jüri Üyesi	Prof. Dr. Metin ZONTUL Sivas Bilim ve Teknoloji Üniversitesi
Jüri Üyesi	Doç. Dr. Ahmet Gürkan YÜKSEK Sivas Cumhuriyet Üniversitesi

Bu tez, Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. Nevcihan GÜR SOY
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

Bu tez, Sivas Cumhuriyet Üniversitesi Senatosu'nun 20.08.2014 tarihli ve 7 sayılı kararı ile kabul edilen Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kılavuzu (Yönerge)'nda belirtilen kurallara uygun olarak hazırlanmıştır.





Bütün hakları saklıdır.

Kaynak göstermek koşuluyla alıntı ve gönderme yapılabilir.

© Fatih TEKE, 2023

Bu tez, bana olan inançları zaman zaman benimkini aşan kişilere ithaf edilmiştir.
Sınırsız sevgisi yolculuğumun temelini oluşturan aileme. Fedakarlıklarınız
ve cesaretiniz bilgi arayışımı körükledi.

Rehberlikleriyle hem akademik hem de kişisel gelişimimi şekillendiren akıl hocalarıma.
Bilgeliğiniz araştırma ve keşiflerin karmaşık arazisinde beni yönlendiren bir pusula
oldu.

Zorluklara göğüs gerdiğimde yanımda olan büyük ve küçük zaferleri kutlayan
arkadaşlarıma. Dostluğunuz akademinin bazen tek renkli dünyasına renk kattı.

Bu çalışma, hepinizin çabalarımca cömertçe harcadığınız kolektif zaman, enerji ve inanç
yatırımının bir kanıtıdır. Akademik arayışımın sürekli gelişen anlatımında değişmez
sabitler olduğunuz için teşekkür ederim.

Yürekten şükranlarımla,
Fatih TEKE

ETİK

Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü, Tez Yazım Kılavuzu (Yönerge)'nda belirtilen kurallara uygun olarak hazırladığım bu tez çalışmada;

- ✓ Bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- ✓ Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- ✓ Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere, bilimsel normlara uygun olarak atıfta bulunduğumu ve atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- ✓ Bütün bilgilerin doğru ve tam olduğunu, kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ✓ Tezin herhangi bir bölümünü, Sivas Cumhuriyet Üniversitesi veya bir başka üniversitede, bir başka tez çalışması olarak sunmadığımı; beyan ederim.

05.02.2024

Fatih TEKE

KATKI BELİRTME VE TEŞEKKÜR

Bu akademik çabanın doruk noktasında, bu tezin tamamlanmasında katkıları ve destekleri olan kişilere şükranlarımı sunuyorum.

Bu çalışma sadece bireysel çabalarımın değil, destekleyici bir ağı kolektif katkılarının bir sentezini içermektedir. Danışmanım ve çalışma sırasında fikir aldığım değerli hocalarımın sağladığı paha biçilmez rehberlik, bu araştırma yolculuğunun temel taşı oldu. Uzmanlıkları ve içgöruları bu keşfin gidişatını şekillendirerek bu çalışmanın ortaya çıkmasını sağladı.

İş birliği ruhuyla bu tezi farklı bakış açıları ve yapıcı eleştirilerle besleyen tez danışmanıma, meslektaşlarıma ve iş arkadaşlarıma en içten teşekkürlerimi sunuyorum. Fikir alışverişi entelektüel gelişim için bir katalizör olmuştur.

Arkadaşlarıma ve aileme, sarsılmaz cesaretiniz için teşekkür ederim. Yeteneklerime olan inancınız, bu bilimsel arayışın doğasında var olan zorlukların üstesinden gelmek için gereken duygusal desteği sağlayarak sürekli bir motivasyon kaynağı oldu.

Son olarak, bu çalışma için zamanlarını ve deneyimlerini cömertçe paylaşan deneklere ve katılımcılara, katkılarınız bu çalışmanın merkezinde yer almaktadır. Bu araştırmaya katılma isteğiniz, araştırmanın derinliğini ve önemini zenginleştirdi.

Bu tezin ardındaki yolculuğa baktığımda, tezin tamamlanmasının bilgi arayışını tanımlayan işbirlikçi ruhun bir kanıtı olduğunun farkındayım. Adı geçen her bir kişi, bu bilimsel yolculukta eşsiz ve hayati bir rol oynadı ve bunun için derinden müteşekkirim.

İçten takdirlerimle,

Fatih TEKE

ÖZET

DERİN ÖĞRENME YÖNTEMLERİ İLE TOMOGRAFİ GÖRÜNTÜLERİNDEN KAPALI AÇILI GLOKOM GÖZ HASTALIĞININ SINIFLANDIRILMASI

Fatih TEKE

Yüksek Lisans Tezi

Yapay Zekâ ve Veri Bilimi Anabilim Dalı

Danışman: Prof. Dr. Oğuz KAYNAR

2024, 61+xiv sayfa

Bu çalışmada bir derin yapay zekâ modelinin kullanılması yoluyla kapalı açılı glokomun saptanması ve sınıflandırılmasına yeni ve gelişmiş bir yaklaşım sunulmaktadır. Giriş verileri olarak Ön Segment Optik Koherens Tomografi (AS-OCT) görüntülerini kullanarak geliştirilen model, %95'lik yüksek bir genel doğruluk sergilemiştir. Metodoloji, kapalı açılı glokomun yüksek derecede hassasiyetle otomatik olarak tanımlanmasına ve sınıflandırılmasına olanak tanıyan en son teknolojiye sahip derin öğrenme tekniklerinin entegrasyonunu içermektedir. Bu araştırmanın bulguları, oftalmik teşhislerde yapay zekânın uygulanmasına ilişkin giderek artan literatüre katkıda bulunmayı ve oküler patoloji alanında daha iyi klinik karar verme ve hasta sonuçları için umut verici çıkarımlar sunmayı hedeflemektedir. Sınıflandırma için toplamda 1600 adet AS-OCT görüntüsü ile geliştirilen model performans değerleri, peripapiller OCT görüntülerinin, glokomun peripapiller tabaka haritalarında oldukça iyi bir sonuç verdiğini ve glokomun erken safhada yakalanması için kullanılmasını desteklemektedir. Geliştirilen yöntem ile AS-OCT görüntülerinin kapalı açılı glokom tespitinde ve teşhisinde doktorlara yardımcı olması amaçlanmaktadır.

Anahtar kelimeler: Glokom, Optik koherens tomografi, Peripapiller, AS-OCT

ABSTRACT

CLASSIFICATION OF CLOSED-ANGLE GLAUCOMA EYE DISEASE FROM TOMOGRAPHY IMAGES WITH DEEP LEARNING METHODS

Fatih TEKE

Master of Science Thesis

Department of Artificial Intelligence and Data Science

Supervisor: Prof. Dr. Oğuz KAYNAR

2024, 61+xiv pages

This study introduces an enhanced paradigm for the detection and classification of closed-angle glaucoma, leveraging a sophisticated deep artificial intelligence model. Notably, the model, constructed with Anterior Segment Optical Coherence Tomography (AS-OCT) images, attains an high overall accuracy of 95%. The methodology encompasses the incorporation of cutting-edge deep learning techniques, enabling the automated and precise identification and classification of closed-angle glaucoma. The research findings aims to contribute substantively to the burgeoning literature on the application of artificial intelligence in ophthalmic diagnostics, holding promise for improved clinical decision-making and enhanced patient outcomes in ocular pathology. The model's exemplary performance, evaluated with a dataset of 1600 AS-OCT images, particularly underscores the efficacy of peripapillary OCT images in generating robust peripapillary layer maps for glaucoma classification, thereby advocating for its utility in early-stage glaucoma detection. Ultimately, the developed methodology aspires to facilitate clinicians in the timely and accurate detection and diagnosis of closed-angle glaucoma utilizing AS-OCT images.

Key Words: Glaucoma, Optic coherence tomography, Peripapillary, AS-OCT

İÇİNDEKİLER

Sayfa

ETİK	vi
KATKI BELİRTME VE TEŞEKKÜR.....	vii
ÖZET	viii
ABSTRACT.....	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ.....	xii
SİMGELER DİZİNİ.....	xiii
KISALTMALAR DİZİNİ	xiv
1. GİRİŞ	1
1.1 Literatür Çalışması.....	3
1.2 Amaç ve Kapsam	6
2. MATERYAL VE METHOD	8
2.1 Glokom	8
2.1.1 Teşhis.....	13
2.1.2 Tedavi	15
2.1.3 Glokom Türleri.....	16
2.2 Yapay Zekâ ve Derin Öğrenme	17
2.2.1 Yapay Zekâ ve Görüntü İşleme Çalışmaları	20
2.2.2 Evrişimli Sinir Ağları (CNN)	23
2.2.3 Performans Metrikleri	28
3. UYGULAMALAR VE DENEYSEL ÇALIŞMALAR.....	31
3.1 Veri Seti	31
3.2 Deneysel Tasarım ve Uygulama	34
4. BULGULAR.....	38
4.1 Model Performans Sonuçları	38
4.1.1 Sınıf Aktivasyon Harita Sonuçları.....	43
5. TARTIŞMA VE SONUÇ	46
KAYNAKLAR	50
EKLER	60
EK-1 ‘Check Accuracy’ Algoritması.....	60

ŞEKİLLER DİZİNİ

	<u>Sayfa</u>
Şekil 2.1 Göz Yapısı.....	9
Şekil 2.2 Glokom İşleyiş Görseli.....	12
Şekil 2.3 OCT Cihazı.....	14
Şekil 2.4 Karışıklık Matrisi.....	28
Şekil 3.1 İşlem Akış Şeması.....	32
Şekil 3.2 Artırılmış AS-OCT Görüntüleri.....	34
Şekil 3.3 Model Mimarisi.....	35
Şekil 4.1 Eğitim Alıcı Karakteristik Çalışma Eğrisi.....	39
Şekil 4.2 Doğrulama Alıcı Karakteristik Çalışma Eğrisi.....	40
Şekil 4.3 Eğitim Alıcı Karakteristik Çalışma Eğrisi-2.....	41
Şekil 4.4 Doğrulama Alıcı Karakteristik Çalışma Eğrisi-2.....	42
Şekil 4.5 Sınıf Aktivasyon Harita Örneği (T0001-05.jpg).....	43
Şekil 4.6 Sınıf Aktivasyon Harita Örneği (T0022-14.jpg).....	44

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 3.1 Angle Glaucoma Challenge Eğitim Veri Seti	31
Çizelge 3.2 Görüntü Çoğaltma Yöntem ve Değerleri.....	33
Çizelge 3.3 Model Hiperparametre Değerleri.....	36
Çizelge 4.1 Model Performans Sonuçları.....	38
Çizelge 4.2 Performans Metrikleri ve Genel Başarı Tablosu.....	40
Çizelge 4.3 Düzenlenen Model Performans Sonuçları.....	41
Çizelge 4.4 Performans Metrikleri ve Genel Başarı Tablosu-2.....	43



SİMGELER DİZİNİ

p_i	Yanlış tahmin olasılık değeri
β	Hareketli ortalama parametresi
η	Öğrenme katsayısı
σ	Sigmoid aktivasyon fonksiyonu
θ_t	t zaman anı
G_t	Önceki tüm alt derecelerin dış çarpımı
g_t	t zamanındaki gradyan
ϵ	Sıfırın bölünmesi önlemek için küçük bir miktar
$s_{(i,t)}$	t zamanı boyunca toplanan i özneliği için sıfır olmayanların sayısı



KISALTMALAR DİZİNİ

AOD	: Açık Açılma Mesafesi
AIA	: Açık Girinti Alanları
GİB	: Göz İçi Basıncı
CM	: Siliyer Kas
OCT	: Optik Koherens Tomografi
MIGS	: Minimal Invaziv Glokom Ameliyatları
SLT	: Seçici Lazer Trabeküloplasti
LPI	: Lazer Periferik İridotomi
POAG	: Birincil Açık Açılı Glokom
PACG	: Birincil Açık Kapanması Glokomu
NTG	: Normal Tansiyonlu Glokom
AS-OCT	: Ön Segment Optik Koherens Tomografi
CNN	: Evrişimli Sinir Ağları
OCT-A	: Optik Koherens Tomografi Anjiyografi
RSLT	: Retina Sinir Lifi Tabakası
OSB	: Optik Sinir Başı
FD-OCT	: Fourier Alanlı Optik Koherens Tomografi
TD-OCT	: Zaman Alanlı Optik Koherens Tomografi
3D	: Üç Boyutlu
LSTM	: Uzun Kısa Süreli Bellek
AUC	: Eğri Altındaki Alan
RNFL	: Retina Sinir Lif Kalınlığı
SD-OCT	: Spektral Domain Optik Koherens Tomografi
CDR	: Kâse Disk Oranı
RDR	: Çerçeve Disk Oranı
ISNT	: Aşağı > Üstün > Nazal > Temporal
SVM	: Destek Vektör Makinesi
ACD	: Ön Oda Derinliği
ACV	: Ön Oda Hacmi
SS-OCT	: Taranan Kaynak Optik Koherens Tomografi
ROC	: Alıcı Çalışma Karakteristiği
FP	: Yanlış Pozitif
FN	: Yanlış Negatif
TP	: Doğru Pozitif
TN	: Doğru Negatif
TPR	: Doğru Pozitif Oran
FPR	: Yanlış Pozitif Oran
AUC	: Eğri Altındaki Alan
ReLU	: Düzeltilmiş Doğrusal Birim
RMSprop	: Kök Ortalama Kare Yayılım
CAM	: Sınıf Aktivasyon Haritası
D	: Kapalı Açılı Glokom Olmayan Örnekler (Diğer)
KAG	: Kapalı Açılı Glokom Olan Örnekler

1. GİRİŞ

İnsan algısının temel bir yönü olan görme, bireylerin çevrelerini yorumlamasına ve onlarla etkileşime geçmesine olanak sağlayan karmaşık bir süreçtir. Gözlerin, optik sinirlerin ve beynin karmaşık koordinasyonu, görsel uyarıyı alma, işleme ve anlamlandırma becerisiyle sonuçlanmaktadır. Bireylerin yüzleri tanımaya, çevrelerinde gezinmesine, renk ve biçim ayrıntılarını anlamlandırmasına olanak tanımaktadır. Bu karmaşık sistem bozulmalara karşı dayanıklı değildir ve çeşitli hastalıklar görüşümüzün netliğini ve keskinliğini tehlikeye atabilmektedir. Miyop ve hipermetrop gibi yaygın kırma kusurlarından, glokom ve makula¹ dejenerasyonu gibi daha karmaşık koşullara kadar bu rahatsızlıklar, günlük hayatımızdaki netliği olumsuz etkilemektedir. Bu hastalıklar yalnızca fiziksel görme eylemini tehlikeye atmakla kalmayıp, aynı zamanda duygusal ve işlevsel sonuçlar da taşımaktadır. Görme bozukluğu bulunan bireyler, sıklıkla yüksek stres, kaygı ve depresyon yaşamaktadırlar. Yaşa bağlı makula dejenerasyonu gibi durumlar göz önüne alındığında ise, kademeli merkezi görme kaybı, kişinin yüzleri tanıma, okuma veya faaliyetlere katılma yeteneğini doğrudan etkilenmektedir. Bu nedenle, görme hastalıkları, farklı demografik yapılardan milyonlarca kişiyi etkileyen önemli bir küresel sağlık sorunu olarak karşımıza çıkmaktadır. Dünya Sağlık Örgütü'ne (WHO) göre, dünya çapında tahminen 2,2 milyar insan görme bozukluğu veya körlükten rahatsız olmakta ve bunların başlıca nedeni olarak düzeltilmemiş kırma kusurları gösterilmiştir [1]. Dünya çapında 2 milyardan fazla insanı etkileyen miyobun [2,3], özellikle artan ekran süresinin ve sınırlı açık hava etkinliklerinin yaygınlığına katkıda bulunduğu kentleşmiş bölgelerde ciddi bir artış gösterdiği kaydedilmiştir [4]. Görme hastalıklarından bir diğeri olan glokom ise , yaklaşık 80 milyon insanı etkilemekte ve yaklaşık 11 milyon kişi bu durum nedeniyle kör hale gelmektedir [5,6]. Bu istatistikler, görme hastalıklarının küresel ölçekte ele alınmasının ve tedavisinin önemini göstermektedir. Bununla beraber etkilerini azaltmak ve görme sağlığını korumak için erken teşhis ve kapsamlı göz bakımı ihtiyacı da doğmuştur ve farklı tedavi yöntemleri ile bu sorunun üstesinden gelmek için çalışmalar yapılmaktadır.

¹ Gözdeki retinanın merkezine yakın bir yerde bulunan küçük ve hassas alan

Görme hastalıklarının tedavi yöntemleri, optik yardımlardan cerrahi müdahalelere kadar her biri spesifik oküler rahatsızlıklara yönelik olarak tasarlanmaktadır. Miyop, hipermetrop ve astigmat gibi yaygın görülen kırma kusurları için gözlük veya kontakt lens şeklindeki düzeltici lensler birincil invazif olmayan çözümler olarak uygulanmaktadır. Lens teknolojisindeki gelişme aynı zamanda çeşitli mesafelerde gelişmiş görsel netlik sunan, odaklı ve progresif² lenslerin de ortaya çıkmasına neden olmuştur. Glokom gibi daha karmaşık durumlarda ise, hastalığın ilerlemesini yavaşlatmak amacıyla çeşitli göz içi, basıncını düşürücü ilaçlar kullanılmaktadır. Göz içi basıncını etkili bir şekilde yönetmek için ilerlemiş vakalarda trabekülektomi³ veya drenaj⁴ implantlarının yerleştirilmesi gibi cerrahi müdahaleler önerilmektedir. Retina hastalıkları alanında ise anti-VEGF⁵ (Vasküler Endotelyal Büyüme Faktörü) enjeksiyonları gibi yenilikçi tedaviler, yaşa bağlı makula dejenerasyonu (AMD) ve diyabetik retinopati⁶ gibi durumların tedavisinde önemli gelişme kaydetmiştir. Tedavi yöntemlerindeki bu ilerlemeler, görme bakımının dinamik yapısını yansıtmakta olup, çeşitli oküler⁷ rahatsızlıklara yönelik kişiselleştirilmiş yaklaşımlara odaklanarak, sonuçta görme yetisini geliştirmeye ve korumaya çalışmaktadır. Sürekli gelişen ve değişen teknoloji ile, göz bakımı alanında yenilikçi bir yaklaşım olarak ortaya çıkan Optik Koherens Tomografi⁸ (OCT) cihazı, çeşitli göz hastalıklarının tanı ve tedavisinde önemli rol oynamaktadır. Invazif⁹ olmayan görüntüleme teknolojisini kullanan OCT, klinisyenlerin gözün iç yapılarının detaylı ayrıntılara sahip yüksek çözünürlüklü kesitsel görüntülerini elde etmelerini sağlamaktadır. Bu yeteneğin glokom, makula dejenerasyonu ve diyabetik retinopati gibi hastalıkların erken tespitinde ve izlenmesinde etkili olduğu gözlemlenmiştir. Tedavinin etkinliğini değerlendirmek için dinamik bir araç görevi görerek klinisyenlerin bilinçli kararlar almasına ve müdahalelerini bireysel hasta ihtiyaçlarına göre uyarlamasına olanak tanımaktadır. Non-invazif işleyişi ve gerçek zamanlı olarak ayrıntılı görüntüler yakalama yeteneği, modern göz bakımında bir mihenk

² Zaman içinde kademeli olarak ilerleyen veya gelişen durum ya da cisim

³ Optik sinir hasarına ve görme kaybına yol açabilen bir göz rahatsızlığı olan glokomun tedavisinde kullanılan cerrahi bir prosedür

⁴ Sıvıların gazların veya diğer maddelerin belirli bir alandan dışarı akmasına veya kaçmasına izin verme süreci

⁵ Yeni kan damarlarının oluşumu olan anjiyogenezde anahtar rol oynayan bir sinyal proteini

⁶ Gözün arkasındaki ışığa duyarlı doku olan retinanın herhangi bir hasarını veya hastalığını tanımlamak için kullanılan genel bir terim

⁷ Gözlerin anatomisi, yapısı veya işlevi ile ilgili şeyleri tanımlamak için kullanılan bir sıfat

⁸ Retinanın ve gözün diğer katmanlarının ayrıntılı, kesitsel görüntülerini yakalamak için ışık dalgalarını kullanan, invazif olmayan bir görüntüleme tekniği

⁹ Vücuda veya vücudun bir kısmına girmeyi içeren herhangi bir tıbbi prosedür veya müdahale

taşı olarak, daha iyi sonuçlara katkıda bulunmaktadır. Geliştirilen yeni araç ve yöntemlerle beraber, son yıllarda yapay zekânın oftalmoloji¹⁰ alanına entegrasyonunda, göz hastalıklarının tedavisinde yeni yöntemler ile kayda değer bir artış yaşanmıştır. Yapay zekânın bu alandaki gelişimi öncelikle erken teşhisin ve kişiselleştirilmiş tedavi stratejilerinin geliştirilmesine odaklanmıştır. Gelişmiş algoritmalar artık retina taramaları ve optik koherens tomografi (OCT) görüntüleri gibi tıbbi görüntüleme verilerindeki karmaşık ayrıntıları analiz ederek, hafif anormalliklerin belirlenmesinde oldukça yüksek bir hassasiyet sağlamaktadır. Bu artan doğruluk, yalnızca hastalığın erken tespitini kolaylaştırmakla kalmamakta, aynı zamanda kişiselleştirilmiş tedavi planlarının uyarlanması da önemli bir rol oynamaktadır. Yapay zekâ, tıbbi geçmişi, genetik bilgileri ve yaşam tarzı faktörlerini de içeren çeşitli hasta verilerini dikkate alarak, diyabetik retinopati ve yaşa bağlı makula dejenerasyonu gibi durumlar için kişiselleştirilmiş tedavilerin formüle edilmesine katkıda bulunmaktadır. Yapay zekâ ve oftalmik bakımın bu şekilde birleştirilmesi, yalnızca hasta sonuçlarının iyileştirilmesi konusunda umut vaat etmekle kalmamakta, aynı zamanda uzaktan izleme, teleoftalmoloji¹¹ ve göz hastalıklarının tedavisinde daha erişilebilir ve etkili bir yaklaşım için de yollar açmaktadır. Farklı yöntem, metot ve materyaller ile gerçekleştirilen derin öğrenme ve yapay zekâ ile ilgili çalışmalara literatür bölümünde değinilmiştir.

1.1 Literatür Çalışması

Glokom hastalığının teşhis ve tedavisinde süre gelen değişim ve yenilikler ile farklı yöntem ve metotlar geliştirilmektedir.

Karthik Gopinath ve ark. [7] 2016 yılında OCT-A görüntülerini kullanarak glokom tespiti için sundukları yöntem ile kılcac damar yoğunluğu ve RSLT¹² kalınlığını tahmin etmiştir. Ayrıca bu kalınlık hacmi, glokom olma ve glokom olmama sınıflandırması için kullanılmıştır. Kılcac damar yoğunluğu, optik sinir başını (OSB) tanımlamak için morfolojik¹³ işlemler uygulanarak elde edilmiş ve RSLT kalınlığı ve OSB yapısı birlikte kullanılarak yapılan çalışmada, %94,44 duyarlılık ve %91,67

¹⁰ Gözler ve görme sistemi ile ilgili bozuklukların ve hastalıkların incelenmesi ve tedavisine odaklanan bir tıp dalı

¹¹ Özellikle telekomünikasyon teknolojisinin kullanımı yoluyla göz rahatsızlıklarının uzaktan teşhisi ve yönetimi ve görme bakımı ile ilgilenen bir tele-tıp dalı

¹² Retinal sinir lifi katmanına gelir ve gözün arkasındaki ışığa duyarlı doku olan retinanın kritik bir bileşenidir

¹³ Organizmaların veya nesnelerin biçiminin ve yapısının incelenmesi

özgüllük değerleri ile OCT görüntüleri üzerinde kullanılan yapay zekâ yöntemlerinin potansiyeli ortaya konmuştur. Mitra Sehi ve ark. [8] yaptığı farklı bir çalışmada ise fourier alanlı optik koherens tomografi yöntemi¹⁴ (FD-OCT) ile zaman alanlı optik koherens tomografi¹⁵ (TD-OCT) yönteminin glokom tespitindeki başarı oranları incelenmiştir ve FD-OCT ile çekilen görüntülerin TD-OCT ile çekilen görüntülere göre daha kalın ölçümler içerdiğine not düşülmüştür. Bunun yanı sıra tanısız anlamda benzer performanslar elde edildiği ve önemli bir farkın gözlemlenmediği vurgulanmıştır.

Gabriel Garcia ve ark. [9] yaptığı çalışmada ise 3D spektral alanlı optik koherens tomografi görüntüleri¹⁶ (SD-OCT) kullanılarak glokom tespiti yapılmıştır. Diğer çalışmalardan farklı olarak artık ve dikkat bilgileri LSTM ağları¹⁷ ile tahminlemeye entegre edilmiştir. Sonuç olarak 3 boyutlu öğrenme modellerinin glokom tahminlemede kayda değer sonuçlar ürettiğinden (AUC = 0.8847) bahsedilmiştir.

Alireza Kamalipour ve ark. [10], spektral alanlı optik koherens tomografinin glokom tespitinde uygulama alanlarını ve glokom hastalığının erken tespitine yapabileceği katkılarından bahsederek, glokomda gözlemlenen yapısal ve fonksiyonel değişikliklerin analiz edilmesi konusunun, yapay zekâ teknikleri için önemli bir fırsat olduğu vurgulanmıştır.

Atalie ve ark. [11] yaptığı araştırmada derin öğrenmede kullanılan görüntü işleme katmanları olan CNN yapılarının görüntü üzerinden önemli özellikleri yakalayıp çıkarabilme yetisine değinmiştir. Bunun yanı sıra SD-OCT ve RSLT verilerinin birlikte kullanılması ile daha iyi sonuçlar elde edilebileceğinden ancak SD-OCT teknolojisinin pahalı ve kolay taşınmayacağı belirtilmiştir. Ayrıca görüntü işleme yöntemleri ile elde edilen sonuçların klasik OCT parametreleri ile elde edilen sonuçlardan daha iyi sonuçlar gösterdiği vurgulanmıştır.

Lisboa ve ark. [12] yaptıkları çalışmada skleral alanlı optik koherens tomografi SD-OCT, retinal sinir lifi tabakası RSLT, optik sinir başı OSB ve maküler¹⁸ ölçümlerin

¹⁴ Biyolojik dokuların kesitsel görüntülerini yakalamak için kullanılan yüksek çözünürlüklü bir görüntüleme tekniği

¹⁵ FD-OCT'nin aksine zaman alanında çalışır

¹⁶ FD-OCT gibi spectral alan kategorisinde bir görüntüleme tekniği

¹⁷ Yapay zekâ ve makine öğrenimi alanında bir tür tekrarlayan sinir ağı (RNN) mimarisi

¹⁸ Retinanın merkezi kısmı olan makula ile ilgili kantitatif ölçümler veya parametreler

preperimetrik¹⁹ glokomatöz²⁰ hasar tespit yetenekleri karşılaştırılmıştır. Elde edilen sonuçlarda SD-OCT ve RSLT ölçümlerinin glokom şüphelilerinden oluşan bir kohortta²¹ preperimetrik glokomatöz hasar tespitinde OSB ve maküler ölçümlerden daha iyi performans gösterdiğini gözlemlemişlerdir. Bu yönüyle OCT parametrik değerleri arasındaki glokom teşhisine yönelik etkinlik de gösterilmeye çalışılmıştır.

Siva ve ark. [13] yaptıkları çalışmada, daha önceki bahsedilen çalışmalardan farklı olarak klinik ölçümlerden ziyade görüntü verilerinden hastalık desenleri çıkarıp tanımlanmasını içeren çalışmalara dikkat çekmiştir. Bu doğrultuda gerçekleştirilen çalışmada, öznelik seçim aşamasının altını çizerken, fundus²² görüntüleri kullanılarak ve glokoma sebep olan görüntü bölgelerinin öznelik olarak belirlenmesini geliştirmeye yönelik bir teknik ve yöntem önerisi sunulmuştur. Farklı çalışmalardan elde edilen sonuçların karşılaştırıldığı inceleme çalışmasında, görüntü işleme yöntemlerinin glokomatöz vakaların özelliklerinin çıkarılabildiğini destekleyen vurgulara yer verilmiştir.

Bir başka çalışmada Singh ve ark. [14] glokom tahmini yapmak için optik disk görüntüleri üzerinde wavelet²³ yönteminin kullanılmasını önermiş ve OCT görüntülerinin fundus görüntülerinden glokom tahmini konusunda daha küçük örnekleri daha erken safhalarda tanımlayabildiğinden bahsedilmiştir. Bu yönüyle OCT görüntülerinden çıkarılan özneliklerin problemin tanımlanmasında ve teşhis edilmesinde etkinliği gösterilmiştir. %97'lik doğruluk oranı ve %92 fl değerinin yanı sıra, performans metrikleri arasındaki güvenilirliği ölçmek için kullanılan kappa metriği²⁴, tek kullanılan metriklerden daha etkili bir metrik olarak kullanılmıştır.

Anum ve ark. [15] yaptıkları çalışmada, glokom tahmin problemi için yapısal ve yapısal olmayan öznelik ölçümlerini beraber kullanmıştır. Elde edilen %100 hassasiyet ve %87 özgüllük değerleri ile uygulanan yöntemin umut vadecici olduğuna dikkat çekilmiştir. Raj ve ark. [16] yaptığı çalışmada, CDR²⁵ verileri ile RDR²⁶ ve ISNT²⁷ kuralları birlikte

¹⁹ Perimetri tarafından tespit edilen görme alanı kusurlarının başlangıcından önce meydana gelen bir aşama veya durum

²⁰ Glokom ile ilgili durumları, özellikleri veya süreçleri tanımlamak için kullanılan sıfat

²¹ Belirli bir zaman dilimi içinde ortak bir özelliği veya deneyimi paylaşan bireylerden oluşan grup

²² Merceğin karşısındaki gözün iç yüzeyi

²³ Farklı ölçeklerde özelliklere sahip fonksiyonları analiz ve temsil etmek için dalgacık dönüşümü kullanan matematiksel fonksiyon

²⁴ Değerlendiriciler arası güvenilirliği veya iki değerlendiriciyi veya yöntem arasındaki anlaşmayı değerlendiren istatistiksel bir ölçü olan Cohen Kappa katsayısı

²⁵ Kap-Disk Oranı (CDR), optic diskin çanak kısmının çapını optic diskin toplam çapıyla karşılaştırır.

²⁶ Optik sinir başının görünümünü değerlendirmek için kullanılan bir ölçüm

²⁷ Optik sinir başının glokom belirtileri açısından değerlendirilmesi bağlamında kullanılan klasik klavuz

uygulanmış, aynı zamanda oftalmolojistlerin bilmek isteyecekleri glokom evresi hakkında da bilgi verilmeye çalışıldığından bahsedilmiştir. Bu uygulamada önerilen yöntem ise optik kâse ve optik disk segmentasyonlarının kullanılmasıdır. Kullanılan segmentasyon yöntemi olarak OTSU²⁸ segmentasyon yöntemi belirtilmiş ve 0,3 olarak belirlenen eşik değeri ile SVM²⁹ modelinde sınıflandırma yapılmış ve fundus görüntülerinden glokom tahminlemesi için daha efektif yöntemlerin kullanılmasının gerekliliğinden bahsedilmiştir.

Madhumalini ve ark. [17] yaptıkları çalışmada kan damarı segmentasyonu ve optik disk segmentasyonu yaparak elde edilen öznelikler yardımı ile glokom sınıflandırması yapmışlardır. Uygulanan yaklaşım ile 99.64%, 97.84%, 98.75% olmak üzere hassasiyet, özgüllük ve doğruluk değerleri elde edilmiştir. Şüpheli glokom örnekleri ile ilgili olarak ise nöro-retinal³⁰ çerçeve şekli ve boyutu gibi daha hibrit özneliklerin tespit edileceğinden bahsedilen çalışmada daha geniş ve büyük veri kaynaklarının dahil edileceği not düşülmüştür.

Haitao ve ark. [18] AS-OCT görüntüleme yöntemindeki gelişmeleri inceledikleri çalışmalarında, Anterior Chamber Depth³¹ (ACD) ve Anterior Chamber Volume³² (ACV) özelliklerinin AS-OCT görüntülerinden kolay bir şekilde çıkarılabileceği belirtilmiştir. AS-OCT görüntülerinin göz yapısı hakkında birçok özelliği barındırdığından bahsedilen incelemede, genel olarak AS-OCT görüntü ve cihazlarının glokom tespitinde etkili bir yöntem olduğuna yer verilmiştir.

1.2 Amaç ve Kapsam

Bu çalışma, derin öğrenme ve yapay zekâ (AI) yöntemleriyle birlikte Ön Segment Optik Koherens Tomografi (AS-OCT) görüntülerinin potansiyelinden yararlanarak glokom teşhisine katkıda bulunmayı hedeflemiştir. Birincil amaç, tedavi edilmediği takdirde ciddi görme bozukluğuna neden olan bir durumu ifade eden kapalı açılı glokomun erken tespiti için sağlam ve doğru bir sistem geliştirmektir. Derin öğrenme ve yapay zekâ algoritmalarını kullanarak, AS-OCT görüntülerini hassasiyetle analiz etmeyi

²⁸ Otsu yöntemi, küresel bir uyarlanabilir ikileştirme eşik görüntü bölümlendirme algoritmasıdır ve eşik seçim kuralını kullanarak arka plan ile hedef görüntü arasındaki sınıflar arası maksimum varyansı alır.

²⁹ Sınıflandırma ve regresyon görevleri için kullanılan denetimli bir makine öğrenmesi algoritması

³⁰ Gözdeki retina ile ilişkili nöral veya sinir dokusu

³¹ Yerleşik bir ön segment biyometrik parametresidir. Anatomik olarak kornea endoteli ile kristal lensin ön kapsülü arasındaki mesafe

³² Kapalı açılı glokomun tespitinde duyarlılığı yüksek olan ön kamara parametresi

ve kapalı açılı glokomun göstergesi olan ince anatomik varyasyonların tanımlanması amaçlanmıştır. Görmeyi tehdit eden bu durumun erken müdahalesine ve yönetimine katkıda bulunmak, böylece hasta sonuçlarını iyileştirerek sağlık sistemleri üzerindeki yükün azaltılması planlanmıştır. Kapalı açılı glokom tespiti için derin öğrenmeye dayalı bir algoritmanın geliştirilmesinde yalnızca Ön Segment Optik Koherens Tomografi (AS-OCT) görüntüleri kullanmanın fizibilitesini ve etkinliğini değerlendirmekle kalmamış, aynı zamanda algoritmanın sağlamlığını artırmak için demografik faktörler, hastalığın ciddiyeti ve etiketleme faktörleri de dahil etmiştir. Bunu başarmak için hem kapalı açılı glokom vakalarını hem de normal kontrolleri kapsayan bir AS-OCT görüntü veri seti derlenmiştir. Ayrıca veri setinin hazırlanmasında uzman çeşitliliği de dikkate alınmıştır. AS-OCT görüntülerinin otomatik analizi için iyi sonuç verdiği kanıtlanmış derin öğrenme mimarileri bileşenlerinin uygulanması ile kapalı açılı glokomun göstergesi olan özellikleri çıkarmak için evrişimli sinir ağlarının (CNN) ve diğer ileri tekniklerin entegrasyonu organize edilmiştir. Performans değerleri olarak geliştirilen modelin duyarlılığının, özgüllüğünün ve genel teşhis doğruluğunun titizlikle değerlendirilmesi sonrasında, önerilen derin öğrenme yaklaşımının üstünlüğünü ve klinik uygunluğunu belirlemek için mevcut tanı yöntemleriyle karşılaştırılmıştır. Bunun yanında, modele olan güveni doğrulamak amacıyla, Sınıf Aktivasyon Haritaları³³ (CAM) çıkarılmış ve değerlendirmeye alınmıştır. Klinik etki bakımından, erken kapalı açılı glokom tespitinin tedavi sonuçları ve görsel prognoz³⁴ üzerindeki potansiyel etkisinin araştırılmasından sonra kişiselleştirilmiş ve zamanında yönetim stratejileri için yapay zekâ tabanlı teşhis araçlarının klinik uygulamaya entegrasyonu tartışılmıştır. Model ve çalışmada gözlemlenen eksikliklere parmak basılmış ve gelecek çalışmalar için önerilerde bulunulmuştur.

³³ Bilgisayarlı görme alanında, özellikle evrişimli sinir ağlarının yorumlanmasında kullanılan bir teknik

³⁴ Belirti ve semptomların zaman içinde iyileşip iyileşmeyeceği veya kötüleşeceği veya sabit kalacağı da dahil olmak üzere, bir hastalığın olasılığını veya beklenen gelişimini tahmin etmek için kullanılan tıbbi bir terim

2. MATERYAL VE METHOD


Bu çalışmada kullanılan materyal ve yöntemlerin araştırılmasında, sistematik ve objektif bir araştırmayı sağlamak için bilinçli bir seçim ve tekniklerin titizlikle uygulanması yapılmıştır. Glokomu kapsayan bölümler, tanısı, tedavi yöntemleri ve çeşitli glokom türleri kapsamlı bir şekilde ele alınmıştır. Ayrıca yapay zekânın ve bu alandaki uygulamalarının, evrimsel sinir ağlarına odaklanılarak derinlemesine bir analizi sistematik olarak gerçekleştirilmiştir. Derin öğrenme ve görüntü işleme izah edilerek bu metodolojilerin inceliklerini kapsayan ayrıntılar açıklanmıştır. Bu süreç ve metodolojilerin kullanıldığı çalışmalara örnekler verilmiştir.

2.1 Glokom

Genellikle görmenin sessiz hırsız [19] olarak adlandırılan glokom, optik sinire kademeli bir şekilde zarar vererek ilerleyici görme kaybına yol açan bir grup göz rahatsızlığıdır. Her birinin kendine has özellikleri ve ayrıntıları olan farklı glokom türleri vardır ancak hepsinin ortak etkisi, görme işlevinde bozulmalara sebep olmalarıdır. Erken ve orta evrelerde hiçbir bulgu vermemekle beraber, görme alanımızı kenarlardan başlayarak daraltmaya başlamakta ve kişi genellikle erken ve orta evrelerde bu kenarlardaki daralmayı fark etmemektedir. Kişinin görmesi bozulduktan sonra fark edilmesinden dolayı çoğu zaman körlüğe kadar ilerleyen çok büyük kayıplarla karşı karşıya kalınmaktadır. National Institutes of Health [20,21] 2020 verilerine göre 2020 yılında 76.600.000 olan glokom hasta sayısının, 2040 yılında 111.000.000 sayısına ulaşması beklendiği belirtilmiştir. Glokom daha çok 40 yaş ve üzerinde görülmesine rağmen, belirli bir yaş ve cinsiyet farklılığı bulunmamakta ve her bireyde görülmektedir. Bu hastalık, tüm göz hastalıkları içerisinde körlük nedeni olarak kataraktan sonra dünyada ikinci [22] sırada yer almaktadır. Körlüğe neden olabilen glokom için tanı konduğunda, durumun ciddiyeti hasta ve hasta yakınlarına tüm açıklığı ile anlatılmalıdır. Bunun nedeni bazı hastaların şikayetleri olmadığı gerekçesi ile tedaviye devam etmemesi ve nihayetinde ciddi görme kayıplarının gelişmesidir. Glokom hastalığının meydana gelmesi ve ilerlemesine birçok farklı etken neden olmaktadır. Bu etkenlerden en belirgin olanı göz tansiyonudur. Göz içi sıvısının göz çeperlerine uyguladığı basıncı ifade eder ve bu basınç, görme sinirlerinde hasar oluşturarak glokomu tetiklemektedir (Şekil 2.1). Glokom

hastalığında göz tansiyonu her zaman yüksek olmamaktadır. Normal değer, kişiden kişiye değişmekle birlikte genel olarak 21 mm civarının altı normal değer [23] olarak kabul edilmektedir. Ancak bu ilişki %100 doğru değildir. Örneğin, yüksek göz tansiyonu olan her kişide glokom gelişmezken, glokom olan bir kişide göz tansiyonu normal olabilmektedir. Bu nedenle glokom, çok faktörlü bir görme siniri hastalığı olarak karşımıza çıkmaktadır. Bu faktörlerden sadece bir tanesi göz tansiyonudur. Gözün işleyişi, tıpkı ince ayarlı bir alet gibi, optimum işlev için bileşenlerinin hassas etkileşimine dayanmaktadır.

Glokom söz konusu olduğunda, göz iris kalınlığı ve eğriliği, görme ve basınç [24,25] düzenlemesinin karmaşık etkileşiminde önemli rol oynamaktadır. İris kalınlığı, glomatöz hasara karşı hassasiyetin belirlenmesinde çok önemli bir faktör olarak hizmet etmektedir. Daha ince bir iris, göz içi basıncındaki dalgalanmalara daha uyarlı hale geldiğinden, optik siniri artan strese maruz bırakabilir. Bu koruyucu bir kalkan olarak düşünülebilir. Daha kalın irisler, glokomun gizli ilerlemesine karşı daha sağlam bir savunma sağlar. Öte yandan iris eğriliği, glokom öyküsüne başka bir karmaşıklık katmanı daha eklemektedir. Bu etmen, iris kemerlerinin göz içindeki drenaj yollarını etkileme şeklidir. Uygun olmayan şekilde kavimsel bir iris, akışkan dinamiğini bozabilir ve bu da glokomun ayırt edici özelliği olan göz içi basıncının yükselmesine neden olabilir. Bir başka önemli etken olan açı kapanma derinliği, kornea ile irisin buluştuğu drenaj açısının darlığını ifade etmektedir (Şekil 2.1).



Şekil 2.1 Göz Yapısı³⁵

Bu açı, gözün iç basıncının düzenlediği bir geçit olarak görev yapmaktadır. Bu açının çok dar olması, sıvının düzgün akışını engelleyen bir darboğaz gibi göz içi

³⁵ <https://healthjade.com/human-eye/>

basıncının artmasına neden olmaktadır. Basıncıdaki bu artış, glokomatöz hasar için bir üreme alanı haline gelmekte ve optik siniri riske atmaktadır. Açı kapanma genişliği [26] bu önemli bağlantı noktasının genişliği olarak düşünüldüğünde, daha geniş bir açı, daha verimli bir drenaj sistemine olanak tanımakta ve basınç oluşma olasılığını azaltmaktadır. Bu, görüş alanını aşındırabilecek tehlikeli dalgaları önleyerek istikrarlı bir akış sağlamak için bir nehir yatağını genişletmeye benzetilebilir. Göz sağlığının kompleks işleyişinde, açı kapanma derinliği, akışkan dinamiğinin işleyişini düzenlemek için uyum sağlamaktadır. Bu unsurlar dengede olduğunda glokom riski azalmaktadır ancak açılar çok sığ veya çok darsa, göz içi basıncı ile görme kaybına neden olmaktadır. Açı kapanması derinliğinin ve genişliğinin etkilerini anlamak, glokomun karmaşıklığını ortaya çıkarmakta ve hedefe yönelik müdahalelerin önünü açan içgörüler ve oküler sağlık konusunda daha net bir görüş sunmaktadır. Bunun yanı sıra lens kasası veya kristal lens'in [26] konumu veya kalınlığındaki değişiklikler, göz içindeki drenaj yollarını etkileyerek glokom hasarına koruma sağlayan hassas dengeyi etkileyebilmektedir. Bu optik bileşenin bitişiğinde küçük ama önemli bir anatomik yapı olan skleral çıkıntı bulunmaktadır. Bu yapı, göz mekanizmasını yerinde tutan bir çapa görevi görmektedir. Skleral çıkıntı, gözün drenaj dokularının gerginliğini etkileyerek sıvının dışarı akışını karmaşık bir şekilde düzenlemektedir. Bu küçük yapıda düzensizlik veya işlev bozukluğu meydana geldiğinde, drenaj sistemi bozulabilmekte ve göz içi basıncının artmasına neden olabilmektedir ve bu da glokomun habercisi olmaktadır. Lens kasası ve skleral mahmuz birlikte hassas bir işlevi yerine getirerek göz sağlığının durumunu şekillendirmektedir. Bu bileşenler arasındaki optimal etkileşim ile göz içinde uyumlu bir sıvı akışı sağlayarak, glokomun karakteristik özelliği olan basınçtaki olumsuz artış önlenmektedir. Ancak bu işleyişteki herhangi bir yanlış dengeyi bozabilmekte ve hastalığın gizlice ilerlemesine zemin hazırlayabilmektedir. Bu işleyiş klinisyenlere ve araştırmacılara detaylı bir bakış açısı sağlayarak, görmeyi engelleyen bu rahatsızlığın nedenlerini ortaya çıkarma ve görmeyi korumaya yönelik müdahalelerin uygulanması açısından onlara rehberlik etmektedir. Açı açılma mesafesi (AOD) ve açı girinti alanları (AIA), glokom bağlamında önemli roller oynayan [25] diğer etkenlerden bazılarıdır. Açı açılma mesafesi, iris ile trabeküler ağ³⁶ yapısı arasındaki, aköz mizah³⁷ drenajı için kritik olan boşluğu ifade etmektedir. Azalan AOD³⁸, sulu mizahın dışarı akışını engelleyebilir ve bu da glokom

³⁶ Gözün ön odasında bulunan yapı

³⁷ Gözün ön odasını, kornea ile merceğe arasındaki boşluğu dolduran, berrak ve sulu sıvı

³⁸ Glokomun tanı ve tedavisinde, gözdeki ön kamara açısının değerlendirilmesinde kullanılan bir ölçüm

için önemli bir risk faktörü olan göz içi basıncının (GİB) yükselmesine yol açabilir. Benzer şekilde, iridokorneal³⁹ açıda içbükey bölgeleri temsil eden açılı girinti alanları, sulu mizahın dışarı akışının dinamiklerini etkilemektedir. Yetersiz girinti alanları, açılı kapanmasına katkıda bulunabilmekte, drenaj yollarını kısıtlayabilmekte ve GİB yükselmesini şiddetlendirebilmektedir. AOD ve açılı girinti alanlarının etkileşimi, oküler homeostazın⁴⁰ korunmasında ve glokomatöz optik nöropatide yer alan patolojik⁴¹ süreçlerin önlenmesinde bunların önemi vurgulanmaktadır. Bu parametrelerin anlaşılması, glokom için erken teşhis ve yönetim stratejilerine yardımcı olabilmektedir bunun nedeni açılı yapılarının modülasyonunu hedef alan müdahaleler, GİB ile ilişkili optik sinir hasarını azaltabilecek ve sonuçta görme fonksiyonunu koruyabilecektir. Gözün en dış tabakası olan sklera [25-28] ise, yapısal bütünlüğün korunmasında rol oynamaktadır. Sklera kalınlığındaki değişiklikler, glokomatöz patogeneizde rol oynamaktadır ve daha ince sklera, GİB dinamiklerini etkileyen biyomekanik⁴² değişikliklere potansiyel olarak katkıda bulunmaktadır. Ayrıca iridokorneal açının önemli bir bileşeni olan trabeküler ağ, aköz mizahın dışarı akışını yönetmektedir. Yoğunluğu ve morfolojisi de dahil olmak üzere trabeküler parametrelerdeki sapmalar, aköz hüme drenaj direncini etkileyerek glokom gelişimi ve ilerlemesinde birincil risk faktörü olan GİB'in yükselmesine yol açabilmektedir. Skleral kalınlık ile trabeküler açılı parametreleri arasındaki karmaşık ilişki, bunların oküler fizyolojinin biyomekanik ve hidrodinamik⁴³ yönleri üzerindeki kolektif etkisinin altını çizmektedir. Bu faktörleri hedef alan müdahaleler, glokom hastalarında GİB ile ilişkili optik sinir hasarını hafifletmeyi amaçlayan terapötik⁴⁴ stratejiler için yollar sunabileceğinden, bu anlayış klinik açıdan anlamlı olmaktadır. Sklera ve siliyer cisim kavşağında yer alan belirgin bir anatomik dönüm noktası olan skleral mahmuz [24, 26, 29], iridokorneal açının doğru değerlendirilmesinde çok önemli bir öneme sahiptir. Glokom alanında iridokorneal açılı, aköz mizah çıkışını düzenlemedeki rolü nedeniyle dikkatin odak noktasıdır. Skleral çıkıntı hem klinisyenler hem de araştırmacılar için kritik bir referans noktası olarak

³⁹ Gözdeki iris ile kornea arasındaki ilişki veya bağlantı

⁴⁰ Göz içinde stabil ve dengeli bir iç ortamın korunması

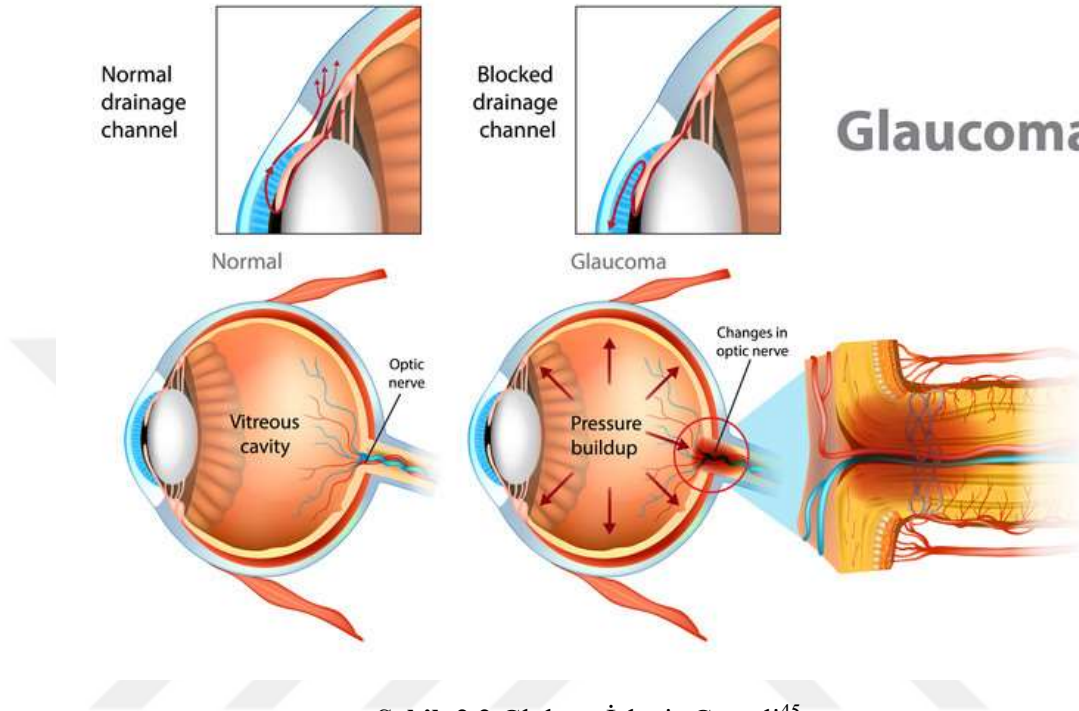
⁴¹ Bir hastalık veya patolojik süreçle ilgili veya bunların neden olduğu bir şeyi tanımlamak için kullanılan sıfat

⁴² Canlı organizmaların ve onların hareketlerinin mekanik yönlerinin incelenmesi

⁴³ Akışkanların hareketini ve katı sınırlarla etkileşimlerini belirleyen ilkelerin inceleyen bilim dalı

⁴⁴ Sağlığı ve refahı geliştirmek için bir durumun, bozukluğun veya hastalığın tedavisi, yönetimi veya hafifletilmesiyle ilgili her şey

hizmet etmekte ve aköz mizahın drenaj yollarına bütünleşmiş bir yapı olan trabeküler ağın kesin lokalizasyonunu kolaylaştırmaktadır.



Şekil 2.2 Glokom İşleyiş Görseli⁴⁵

Açı açılma mesafesi ve trabeküler ağ örgüsü morfolojisi gibi açı parametrelerinin güvenilir ölçümlerini elde etmek için skleral çıkıntının doğru tanımlanması vazgeçilmezdir. Bu ölçümler, glokomatöz optik sinir hasarında önemli bir belirleyici olan GİB dinamiklerini etkileyen faktörlerin kapsamlı bir şekilde anlaşılmasına katkıda bulunmaktadır. Klinik uygulamada skleral çıkıntıların doğru tanımlanması, iridokorneal açı konfigürasyonunun değerlendirilmesine yardımcı olur böylece tanı ve tedavi kararlarına bilgi vermektedir. Skleral çıkıntıya gösterilen dikkat, teşhis yöntemlerinin kesinliğini arttırmakta ve glokomatöz göz hastalığının karmaşık işleyişinde önemli bir anatomik dönüm noktası olarak rolünün altını çizmektedir. Son olarak schwalbe çizgisi, skleral mahmuz, siliyer kasın⁴⁶ (CM) [26] kesişimi ve iç korneada yumru benzeri yapıların varlığı arasındaki etkileşim ve görme alanı bozuklukları, bir optik nöropati olan glokom bağlamında kritik önem taşımaktadır [25]. Descemet membranının⁴⁷ [30] sonlanmasını temsil eden Schwalbe çizgisi, iridokorneal açının değerlendirilmesinde

⁴⁵ <https://www.health.harvard.edu/staying-healthy/the-facts-about-glaucoma>

⁴⁶ Gözün içinde yer alan ve merceği çevreleyen halka şeklindeki kas

⁴⁷ Gözün korneasında yer alan ince, şeffaf bir tabaka

önemli bir anatomik dönüm noktası görevi görmektedir. Skleral çıkıntıyla olan kesin ilişkisi, sulu mizahın dışarı akışını düzenleyen önemli bir yapı olan trabeküler ağ yapısının konfigürasyonunun değerlendirilmesinde etkilidir. Siliyer kas ile iç kornea sınırının kesişimi, glokomdaki anatomik değerlendirmelere başka bir zorluk katmanı daha eklemektedir. Akomodasyondan⁴⁸ [31, 32] ve aköz hümör [33, 34] dinamiklerini etkilemekten sorumlu olan siliyer kas, glokomlu gözlerdeki değişikliklere duyarlı bir bölgede kornea ile kesişmektedir. Bu kesişimin anlaşılması, GİB'i etkileyen biyomekanik ve hidrodinamik faktörlerin çözülmesine yardımcı olmaktadır. Ayrıca iç korneada yumru benzeri yapıların belirlenmesi glokomla ilişkili yapısal değişiklikleri işaret edebilmektedir. Bu anormallikler korneoskleral⁴⁹ bölgedeki patolojik değişikliklerin göstergesi olabilmekte, potansiyel olarak aköz hümör drenaj direncini etkileyebilmekte ve yüksek GİB'e katkıda bulunabilmektedir. Klinik alanda bu anatomik özelliklerin kapsamlı bir analizi tanısal öneme sahiptir. Schwalbe çizgisi, skleral mahmuz, siliyer kas kesişimi ve kornea yapıları arasındaki karmaşık ilişki, glokomatöz optik nöropatinin altında yatan mekanizmalar hakkında değerli bilgiler sağlamaktadır. Kesin anatomik karakterizasyon, tanısal yöntemlere ve terapötik müdahalelere bilgi sağlamaktadır ve glokomun, karmaşık yapısal etkileri olan bir göz hastalığı olarak çok yönlü doğasını vurgulamaktadır.

2.1.1 Teşhis

Glokomun tanısı hem klinik hem de araştırma yöntemlerini entegre eden kapsamlı ve çok yönlü bir yaklaşımı gerektirmektedir. Bu nedenle tanı süreci, hastalıkla ilişkili ince yapısal ve işlevsel değişiklikleri ayırt edecek şekilde uyarlanmıştır. Klinik muayene, optik sinir başına odaklanarak oküler yapıların kapsamlı bir değerlendirmesini kapsamaktadır. Oftalmoskopi, optik disk morfolojisinin doğrudan görselleştirilmesine olanak tanıyarak çukurlaşma, nöroretinal⁵⁰ çerçeve incelmesi ve sinir lifi tabakası defektleri⁵¹ gibi karakteristik değişikliklerin tanımlanmasına olanak tanımaktadır. GİB ölçümü glokom tanısının temel bir yönünü oluşturmakta, Goldmann aplanasyon tonometrisi⁵² [103, 104]

⁴⁸ Gözün farklı mesafelerdeki nesnelere net bir şekilde görebilmek için odağını ayarlama yeteneği

⁴⁹ Kornea ile gözün beyaz dış tabakası arasındaki geçiş bölgesi

⁵⁰ Retinanın nöral dokusu, optik sinir başı

⁵¹ Glokomatöz hasarın ayırt edici özellikleri

⁵² Goldman Aplanasyon Tonometresi Imbert-Fick yasasını temel alan bir araçtır. Göz içi basıncının ölçümünde altın standart cihaz olarak kabul edilir.

veya temassız tonometri dahil olmak üzere tonometri⁵³ yöntemleri de glokomun ilerlemesi için kritik bir risk faktörü olan normal aralıklardan sapmaları tanımlamak için GİB'in miktarını belirlemektedir. Görüntüleme teknolojilerindeki ilerlemeler tanısal araçları zenginleştirmiştir. Bu zenginliklerden biri olan OCT [105-108], optik sinir başı ve retinal sinir lifi tabakasının yüksek çözünürlüklü, kesitsel görüntülenmesini sağlayarak glokomla ilişkili yapısal değişikliklerin niceliksel değerlendirmesini kolaylaştırmaktadır (Şekil 2.3).



Şekil 2.3 OCT Cihazı⁵⁴

Genellikle Humphrey Field Analizörü⁵⁵ [109] gibi perimetri tekniklerini kullanan görme alanı testi, hastanın görme alanı içindeki çeşitli konumlardaki uyarımları algılama yeteneğini haritalandırarak görmenin işlevsel yönlerini değerlendirmektedir. Kavisli skotomlar⁵⁶ veya nazal adım paternleri⁵⁷ gibi karakteristik görme alanı kusurlarının tespiti, glokom tanısının doğrulanmasına ve hastalığın ciddiyetinin ölçülmesine yardımcı olmaktadır. Gonyoskopi⁵⁸ [110, 111] ile yapılan iridokorneal açı değerlendirmesi drenaj yollarının anatomisine ışık tutmaktadır. Trabeküler ağ yapısı ve Schwalbe çizgisi de dahil olmak üzere açı yapılarının doğrudan görselleştirilmesi, klinisyene potansiyel açı kapanması veya aköz hümör çıkışını etkileyen anormallikler hakkında bilgi vermektedir.

⁵³ Göz içindeki göz basıncını ölçmek için kullanılan tanısal bir test

⁵⁴ <https://www.zeiss.com/meditec/en/products/optical-coherence-tomography-devices.html>

⁵⁵ Oftalmoloji alanında görme alanı kusurlarını değerlendirmek ve ölçmek için kullanılan bir teşhis cihazı

⁵⁶ Görme alanında azalmış veya görme kaybı olan alanlar

⁵⁷ Görme alanının nasal (iç) kısmında meydana gelen belirli bir görme alanı kaybı türü

⁵⁸ Oftalmolojide gözün ön kamara açısının anatomisini değerlendirmek için kullanılan tanısal bir işlem

Kornea kalınlıđını ölçen kornea pakimetri⁵⁹ [112, 113] bir diđer önemli parametredir. Daha ince kornealar GİB'in olduđundan düşük deđerlendirilmesine neden olabilir ve glokom risk deđerlendirmesinde düzeltme faktörlerini gerektirebilir. Bu çeşitli teşhis yöntemlerinin entegrasyonu, glokom tanısına kapsamlı bir yaklaşım oluşturmaktadır. En son teknolojilerle desteklenen klinik zekâ, erken teşhise, doğru evrelemeye ve kişiye özel yönetim stratejilerine olanak tanıyarak sonuçta görme işlevini korumayı ve görmeyi tehdit eden bu durumun ilerlemesini hafifletmeyi amaçlamaktadır.

2.1.2 Tedavi

Glokom tedavisi, hastalığın ilerlemesi için birincil deđiştirilebilir risk faktörü olan GİB'i azaltmayı amaçlayan çok yönlü bir yaklaşımı içermektedir. Tedavi yöntemleri hem farmakolojik⁶⁰ hem de cerrahi müdahaleleri kapsamaktadır. Farmakolojik yönetim, GİB'in azaltılmasını hedefleyen topikal⁶¹ ve sistemik⁶² ilaçlara dayanmaktadır. Prostaglandin analogları⁶³ [35], beta blokerler⁶⁴ [36, 37], alfa agonistler⁶⁵ [38] ve karbonik anhidraz inhibitörleri⁶⁶ [39, 40], kullanılan ilaç sınıfları arasındadır. Optimum GİB kontrolünü sağlamak için kombinasyon tedavileri reçete edilebilmektedir. Latanoprost⁶⁷ [41] gibi prostaglandin analogları uveoskleral⁶⁸ çıkışı arttırırken, timolol⁶⁹ gibi beta blokerler aköz hümör üretimini azaltmaktadır. Apraklonidin⁷⁰ gibi alfa agonistleri ve dorzolamid⁷¹ gibi karbonik anhidraz inhibitörleri etkilerini sırasıyla sulu mizah drenajını artırarak ve üretimini inhibe ederek göstermektedirler. İlaç seçimi hastalığın şiddeti, hastanın tepkisi ve potansiyel yan etkiler gibi faktörlere göre bireyselleştirilmektedir. Farmakoterapi⁷² tek başına hedef GİB'e ulaşamadığında veya hızlı ve önemli basınç düşüşüne ihtiyaç duyulduğunda cerrahi müdahaleler zorunlu hale gelmektedir. Bir filtrasyon ameliyatı olan trabekülektomi [42, 43], sulu mizah çıkışını kolaylaştırmak için yeni bir drenaj yolunun oluşturulmasını içerir. Trabeküler mikro-

⁵⁹ Gözün şeffaf ön kısmı olan korneanın kalınlığının ölçümü

⁶⁰ Çeşitli tıbbi durumları yönetmek veya tedavi etmek için ilaçların kullanılması

⁶¹ Bir maddenin vücudun yüzeyine genellikle deriye ve mukoza zarlarına uygulanması

⁶² Tüm vücudu kapsayan müdahale veya tedaviler

⁶³ Glokom tedavisinde yaygın olarak kullanılan bir ilaç sınıfı

⁶⁴ Glokom tedavisinde yaygın olarak kullanılan bir ilaç sınıfı

⁶⁵ Glokom tedavisinde kullanılan bir ilaç sınıfı

⁶⁶ Glokom tedavisinde kullanılan bir ilaç sınıfı

⁶⁷ Glokom ve oküler hipertansiyonun tedavisinde kullanılan bir ilaç

⁶⁸ Oküler aköz mizahın ön kamaradan trabeküler ağ örgüsü dışındaki ön kamara açısına drenajı

⁶⁹ Glokom ve hipertansiyon tedavisinde kullanılan, seçici olmayan bir beta-adrenerjik ilaç

⁷⁰ Glokom tedavisinde kullanılan bir ilaçtır

⁷¹ Anhidraz ilaç sınıfına ait glokom ve hipertansiyon tedavisinde kullanılan bir ilaç

⁷² Çeşitli tıbbi durumları tedavi etmek ve yönetmek için ilaç ve ilaçların kullanımı

bypass stentleri⁷³ gibi minimal invaziv glokom ameliyatları⁷⁴ (MIGS) [44] veya seçici lazer trabeküloplasti⁷⁵ (SLT) [43] gibi lazer prosedürleri, doku bozulmasını en aza indirirken drenajı arttırmayı amaçlamaktadır. Daha ileri vakalarda, aközün harici bir rezervuara yönlendirilmesi ve GİB'in etkili bir şekilde azaltılması için tüp şant implantasyonu⁷⁶ [39] düşünülebilir. Siklofotokoagülasyon⁷⁷ [45, 46] gibi siklodestrüktif⁷⁸ prosedürler, sulu mizah üretimini azaltmak için siliyer cismin lazerle ablasyonunu⁷⁹ içermektedir. Lazer tedavisi glokom tedavisinde çok önemli bir rol oynamaktadır. MIGS ve SLT'nin yanı sıra, lazer periferik iridotomi⁸⁰ (LPI) [47, 48], periferik iriste bir delik oluşturarak ve aköz mizah akışını kolaylaştırarak açı kapanması glokomunu gidermektedir. Tıbbi, lazer veya cerrahi müdahaleler arasındaki seçim, glokom alt tipinin spesifik özelliklerine, bireysel hasta faktörlerine ve yan etkileri en aza indirirken görme fonksiyonunu korumaya yönelik genel tedavi hedefine göre yönlendirilir. GİB izleme, görme alanı testi ve yapısal değerlendirmeleri içeren düzenli takip değerlendirmeleri, devam eden yönetim stratejisinin ayrılmaz bileşenleridir ve terapötik sonuçları optimize etmek için zamanında ayarlamalar yapılmasını sağlamaktadır.

2.1.3 Glokom Türleri

Glokom, etiyojisi⁸¹, klinik prezentasyon⁸² ve anatomik hususlara göre sınıflandırılan çeşitli türleri kapsamaktadır. Bu türlerden ilki olan **Birincil Açık Açı Glokom (POAG)** [49-51], açık iridokorneal açı ve kademeli, sıklıkla asemptomatik⁸³ ilerleme ile karakterize edilen en yaygın formdur. Yüksek GİB ve bozulmuş trabeküler ağ fonksiyonu, optik sinir hasarına katkıda bulunmaktadır. Risk faktörleri ise ileri yaş,

⁷³ Sulu mizahın drenajı için bir bypass veya alternatif yol oluşturarak göz içi basıncını düşürmek üzere tasarlanmış tıbbi cihaz

⁷⁴ Göz travmasını en aza indirirken glokomda göz içi basıncını düşürmeyi amaçlayan bir grup cerrahi teknik

⁷⁵ Açık açı glokom tedavisinde kullanılan lazer bazlı bir cerrahi işlem

⁷⁶ Glokomlu hastalarda göz içi basıncını yönetmek için glokom drenaj cihazı veya tüp şantı olarak da bilinen bir drenaj tüpünün implante edildiği cerrahi bir prosedür

⁷⁷ Göz içi sıvısının, göz içi sıvısının üretimini azaltmak ve göz içi basıncını düşürmek için lazer enerjisinin kullanılmasını içeren cerrahi bir işlem

⁷⁸ Siliyer cismin fonksiyonunu yok ederek veya azaltarak glokomlu bireylerde göz içi basıncını azaltmayı amaçlayan bir grup cerrahi teknik

⁷⁹ Gözdeki dokunun çıkarılmasını veya azaltılmasını içeren, özellikle sulu mizahın üretimi veya drenajıyla ilgili yapıları hedef alan prosedür veya teknik

⁸⁰ Gözün renkli kısmı olan periferik iriste küçük bir delik oluşturmak için lazer kullanılmasını içeren cerrahi bir prosedür

⁸¹ Bir durumun altında yatan nedenler ve kökenleri

⁸² Tıbbi bir durumun klinik görünümü, bir sağlık uzmanının hasta muayenesi sırasında gözlemleyebileceği, belirti, semptom ve diğer gözlemlenebilir özellikler

⁸³ Tıbbi bir durumun gözle görülür semptomlarının veya belirtilerinin olmaması

aile öyküsü, afrika kökenli olmak ve yüksek GİB olarak gözlemlenmektedir. **Primer Açık Kapanması Glokomu (PACG)** [26, 52] ise, açık kapanmasını içerir, aköz hümör çıkışının engellenmesine ve yüksek GİB'e yol açmaktadır. Pupil bloğu⁸⁴, lense bağlı faktörler veya lensin öne doğru yer değiştirmesi açık kapanmasına neden olmaktadır. Akut açık kapanması krizleri, ani görme kaybı, ağrı ve yüksek GİB ile kendini göstermektedir. **Normal Tansiyonlu Glokom (NTG)** [53], normal GİB düzeylerine rağmen ilerleyici optik sinir hasarı ile karakterizedir. Vasküler düzensizlik⁸⁵ veya optik sinir duyarlılığı gibi GİB dışındaki faktörler optik sinir hasarına katkıda bulunmaktadır. GİB ötesinde risk faktörlerinin dikkatli bir şekilde izlenmesini ve değerlendirilmesini gerektirmektedir. **İkincil Glokomlar** altta yatan oküler veya sistemik rahatsızlıkların sonucudur. [54] Pigmenter glokom⁸⁶, psödoeksfolyasyon glokomu⁸⁷, neovasküler glokom⁸⁸ ve üveitik glokom⁸⁹ bu hastalıklara örnek olarak verilebilmektedir. **Konjenital Glokom** genellikle sulu mizah drenajını etkileyen gelişimsel anormalliklere bağlı olarak doğumda mevcuttur. Bebeklerde görülen epifora⁹⁰, fotofobi⁹¹ ve genişlemiş kornealar [55] konjenital glokom örneklerindedir. **Jüvenil Glokom** ise erişkin başlangıçlı glokomu andıran özelliklerle 40 yaşın altındaki bireylerde görülmektedir. Jüvenil açık açılı glokomun genetik bir bileşeni olabilme olasılığı bulunmaktadır [56]. Glokomun çeşitli türlerini ve sınıflandırmalarını anlamak, kişiye özel teşhis ve tedavi yaklaşımları için çok önemlidir; altta yatan patofizyolojinin⁹² ve her bir alt tip ile ilişkili risk faktörlerinin ele alınmasında kesinlik ihtiyacını vurgulamaktadır.

2.2 Yapay Zekâ ve Derin Öğrenme

Yapay Zekâ ve derin öğrenme, teknoloji ve hesaplamalı zekâ alanında en ileri alanları temsil etmektedir. Yapay zekâ genel anlamda görsel algı, konuşma, tanıma, karar verme ve dil çevirisi gibi genellikle insan zekâsı gerektiren görevleri yerine getirebilen

⁸⁴ Açık kapanması glokomu gibi belirli glokom türleri bağlamında gözde meydana gelebilecek bir durum

⁸⁵ Kan damarlarının yapısındaki veya işlevindeki anormallikler veya değişiklikler

⁸⁶ Pigment granüllerinin iristen trabeküler ağa bağlanmasıyla karakterize edilen ve sulu mizahın normal çıkışını engelleyebilen bir tür sekonder açık açılı glokom

⁸⁷ Psödoeksfolyasyon sendromu (PEX) adı verilen sistemik bir durumla ilişkili bir tür sekonder açık açılı glokom

⁸⁸ Iris üzerinde ve gözün ön kamara açısında anormal kan damarlarının büyümesiyle karakterize edilen bir tür sekonder glokom

⁸⁹ Üveitin bir komplikasyonu olarak ortaya çıkan bir tür sekonder glokom

⁹⁰ Gözlerin aşırı yırtılması veya sulanması

⁹¹ Işığa karşı artan hassasiyetle karakterize edilen durum

⁹² Hastalık sürecinin bir parçası olarak fizyolojik süreçlerde ve işlevlerde meydana gelen anormal değişiklikler

bilgisayar sistemlerinin geliştirilmesini ifade etmektedir. Yapay Zekâ 2 ana kategoriye ayrılmıştır. Dar veya zayıf yapay zekâ [57], sanal kişisel asistanlar, sohbet robotları veya görüntü tanıma sistemleri gibi belirli bir görev için tasarlanmış ve eğitilmiş yapay zekâ sistemlerini ifade etmektedir. Bu sistemler sınırlı bir alanda çalışmakta ve insan zekâsıyla ilişkili geniş bilişsel yeteneklerden yoksundur. Genel ve güçlü yapay zekâ [58] ise insan zekâsına benzer şekilde, farklı alanlardaki bilgiyi anlama, öğrenme ve uygulama becerisine sahip makineler yaratmayı amaçlamaktadır. Güçlü yapay zekâyâ ulaşmak uzun vadeli bir hedef olmaya devam etmektedir ve aktif bir araştırma alanıdır. Makine öğrenmesinin bir alt kümesi olan derin öğrenme, çok miktarda veriden kalıpları analiz etmek ve öğrenmek için çok katmanlı sinir ağlarının kullanılmasını içermektedir. Derin öğrenme, verilerin hiyerarşik temsillerini otomatik olarak öğrenmek için çok katmanlı sinir ağlarına (derin sinir ağları) [59] odaklanmaktadır "Derin" terimi, bu sinir ağlarının karmaşık özellikleri ve kalıpları öğrenmelerini sağlayan derin mimarisinden gelmektedir. Derin öğrenmenin temel unsurları olan sinir ağları, hiyerarşik özelliklerin öğrenilmesi ve büyük veri ile eğitimini içermektedir. Bu paradigma, görüntü ve konuşma tanıma, doğal dil işleme ve hatta tıbbi teşhis dahil olmak üzere çeşitli alanlarda ilerlemeye katkıda bulunmuştur. Yapay zekâ ve derin öğrenme arasındaki uyumluluk, yeniliği teşvik etmeye devam ederek makinelerin yalnızca bilgiyi işlemesine değil, aynı zamanda uyum sağlamasına ve zaman içinde performanslarını iyileştirmesine de olanak tanımıştır. Bu teknolojiler ilerledikçe, çeşitli endüstriler ve günlük yaşam üzerindeki etkileri de giderek derinleşmiştir.

Yapay zekânın kavramsal kökleri, Alan Turing gibi vizyonerlerin ufuk açıcı katkılarıyla 20. yüzyılın ortalarına kadar uzanmaktadır [60]. Ardından gelen yıllarda, Turing Testi gibi temel teoriler formüle edilmiş ve makinelere insan benzeri zekâ kazandırmaya adanmış bir disiplinin temeli atılmıştır. İlk yapay zekâ çabaları, mantıksal düşünce süreçlerini taklit etmeyi amaçlayan kural tabanlı sistemlere ve sembolik akıl yürütmeye odaklanmıştır [61]. 1960'larda ve 1970'lerde, bilgiyi temsil etmek için resmi kuralların ve mantıksal yapıların kullanımını vurgulayan sembolik yapay zekâ, baskın bir paradigma olarak ortaya çıkmıştır. Belirli alanlardaki insan uzmanlığını taklit etmek için tasarlanan uzman sistemler bu dönemde öne çıkmıştır. Ancak belirsizlik ve karmaşıklıkla başa çıkmadaki sınırlamalar, "Yapay Zekâ Kısı" [62] olarak bilinen bir şüphecilik dönemine yol açmıştır. 20. yüzyılın sonları, makine öğrenimindeki (ML) gelişmelerin de etkisiyle yapay zekâyâ olan ilginin yeniden canlanmasına tanık olmuştur. Mühendisler ve

arařtırmacılar, makinelerin verilerden kalıpları öğrenmesini sağlayacak istatistiksel yaklaşımları keřfetmeye başlamıřtır. Bu, algoritmaların zaman içinde uyum sağlaması ve performanslarını iyileřtirmesiyle, kural tabanlı sistemlerden daha çok veri odaklı metodolojilere geçiře iřaret etmiřtir. 21. yüzyılda sinir ađlarına olan ilginin yeniden canlanması ve derin öğrenmenin ortaya çıkıřıyla, veri odaklı metodolojilere geçiř sağlanmıřtır.

İnsan beyninin sinir mimarisinden ilham alan derin öğrenme yöntemleri, çok katmanlı yapay sinir ađlarından yararlanmıřtır ve bu derinlik, geniş veri kümelerinden karmařık özelliklerin çıkarılmasına olanak tanıyarak benzeri görölmemiř yetenekler sunmuřtur. Yapay zekanın sađlık, finans ve ulařım gibi çeřitli alanlara pasif entegrasyonu, verimliliđin ve karar alma süreçlerinin artmasına neden olmuřtur. Yapay zekanın geniş alanı içerisinde DL güçlü bir alt alan olarak öne çıkmıřtır. DL, insan beyninin yapısını ve iřlevini yansıtan yapay sinir ađlarının inřasını ve eđitimini içermektedir. DL modelleri, birbirine bađlı düđüm katmanları aracılıđıyla, otonom bir şekilde öğrenip geniş veri kümelerinden karmařık modelleri çıkarabilmektedir ve böylece karmařık karar alma süreçlerine olanak tanımaktadır.

DL alanında pasif öğrenme [63] mekanizmaları çok önemli bir rol oynamaktadır. Sinir ađları, eđitim süreci sırasında alınan geri bildirimlere göre iç parametrelerini pasif olarak ayarlamaktadır. Bu pasif uyarılma, DL modellerinin veriler içindeki karmařık iliřkilere iliřkin anlayıřlarını sürekli olarak iyileřtirmesine olanak tanımakta ve bu da zaman içinde performansın artmasını sağlamaktadır. Yapay zekâ ve DL'nin pasif entegrasyonu, çeřitli sektörlerde bir yenilik dalgasının ortaya çıkmasına da neden olmuřtur. Sađlık hizmetlerinde yapay zekâ, görüntü tanıma ve tahmine dayalı analitik yoluyla teřhis dođruluđuna pasif bir şekilde katkıda bulunmaktadır. Finansal kurumlar, dolandırıcılık tespiti ve risk deđerlendirmesi için DL'den yararlanarak geçmiř verilerden pasif öğrenme yoluyla güvenlik önlemleri geliřtirmiřlerdir. Derin öğrenmenin geniş alanında, çeřitli çalıřma alanları, karmařık sinir ađı mimarilerinin arařtırılması ve uygulanmasıyla aktif olarak ilgilenmektedir. Çoklu katmanlarla karakterize edilen bu mimariler, geniş veri kümelerinden karmařık modellerin otomatik olarak çıkarılmasını ve yorumlanmasını kolaylařtırmak için titizlikle tasarlanmıřtır.

Bilgisayarlı görme ve nesne tanıma ve görüntü bölümleme, evriřimli sinir ađları (CNN) aracılıđıyla gerçekteřtirilmektedir. Hacimli veri kümeleri içindeki kalıpları bađımsız olarak ayırt etmek ve yorumlamak için geliřtirilen (CNN) çeřitli uygulamalarda yaygın

olarak kullanılmaktadır. Doğal dil işlemede, yinelenen sinir ağları (RNN), dil modelleme ve dizi oluşturma gibi görevlerde çok önemli bir rol oynamaktadır. Tutarlı diziler oluşturulmasına olanak verildiği için, metin oluşturma ve duygu analizi gibi görevlerde kullanılmaktadır.

Üretken Rekabetçi Ağlar (GAN) [64] ise, yeni veri örnekleri oluşturmak için kullanılan farklı bir mimaridir. GAN'ler bir oluşturucu ile bir ayırıcı arasında rekabetçi bir öğrenme sürecine pasif olarak dahil olur ve oluşturucunun gerçekçi veriler oluşturma yeteneğini yinelenmeli olarak geliştirmektedir. Makine öğreniminin sürekli gelişen ortamında, bir dizi yenilikçi model önemli ilerlemeler kaydetmektedir. Bunlardan birisi olan 'Google Gemini' [65] dikkate değer bir örnek olarak öne çıkmaktadır. Bu yeni nesil modeller, çok sayıda gelişmiş özellik ve son teknoloji çözümler sunarak yapay zekaya yaklaşım şeklinizi değiştirmektedir. Örneğin Google Gemini, modelin çeşitli veri kümelerine uyarlanabilirliğini artıran yeni yetenekler sunmaktadır. Gelişmiş mimarisi, derin öğrenme ilkelerinden yararlanarak veriler içindeki karmaşık kalıpları ve ilişkileri özerk bir şekilde ayırt etmesine olanak tanımaktadır. Bu, özellikle büyük ve karmaşık veri kümeleriyle uğraşırken daha iyi doğruluk ve verimlilik sağlamaktadır. Bu yeni modellerin en önemli özelliklerinden biri, büyük miktarda veriyi olağanüstü bir hızla işlemelerine olanak tanıyan ölçeklenebilirlikleridir. Bu ölçeklenebilirlik, paralel bilgi işlem yetenekleriyle birleştiğinde, daha hızlı eğitim ve çıkarım sürelerini kolaylaştırarak onları gerçek zamanlı uygulamalar ve zorlu bilgi işlem görevleri için çok uygun hale getirmektedir. Bu yeni modeller, makine öğreniminde ulaşılabilirliğin sınırlarını zorlamaya devam ettikçe endüstrilerde devrim yaratma, süreçleri optimize etme ve karmaşık sorunların çözümüne katkıda bulunma potansiyelini artırmaktadır. Bu modellerin ortaya çıkışı, gelişmiş özelliklerin ve çözümlerin benzeri görülmemiş ilerlemelere ve dönüştürücü uygulamalara yol açtığı makine öğreniminde yeni bir çağın da sinyalini vermektedir. Derin öğrenme yöntemleri ile, farklı alanlardaki çeşitli mimarilerin çok yönlülüğünü ve etkinliğini gösteren çok sayıda araştırma bulunmaktadır. Özellikle tıbbi verilerin analizinde ve yorumlanmasında bu teknolojilerin yeteneklerinden yararlanmak için çeşitli yaklaşımlar ve metodolojiler kullanılmıştır.

2.2.1 Yapay Zekâ ve Görüntü İşleme Çalışmaları

Derin öğrenme algoritmaları ile görüntülerin anlamlandırılmasını kapsayan yapay zekâ ve görüntü işleme teknikleri elde ettikleri yüksek başarı oranları ile umut

vadetmektedir. Gelişen ve değişen yöntemlerin hızlı entegre edilebilmesi ile bir derin öğrenme türü olan görüntü işleme uygulamaları, farklı çözümler sunmak için kullanılmaktadır. Aşağıda bu uygulamalara örnekler verilmiştir.

Krizhevsky ve ark. [66] ve Simonyan & Zisserman [67] ile He ve ark. tarafından yapılan uyarlamalar [68], görselle ilgili görevlerde dikkate değer başarı oranları göstermiştir. Pasif analizler, bu modellerin kullandığı hiyerarşik özellik çıkarma metodolojisinin başarılarına önemli ölçüde katkıda bulunduğunu ortaya koymaktadır. Yorumlanabilirlik konusunda zorluklar devam etse de CNN'lere metodolojik güven özellikle görüntü sınıflandırmada yüksek olmuştur.

Hochreiter ve Schmidhuber'in çalışması [69], Graves'in pasif uyarlamalarıyla RNN'lerin temelleri atılmıştır [70]. Doğal dil işlemede yüksek başarı oranlarını ortaya koyulmuştur. Özellikle sıralı bağımlılık yakalamada kullanılan metodolojiler, dil modelleme ve oluşturma görevlerinde güvene katkıda bulunmuştur. RNN'ler dikkate değer bir başarı elde ederken, uzun vadeli bağımlılık modellemesindeki zorluklar da kabul edilmektedir.

Goodfellow ve ark. GAN'ları [71], pasif çekişmeli öğrenme yoluyla veri üretiminde yenilikçi bir yaklaşım geliştirmiştir. Arjovsky ve ark. gösterdiği gibi görüntü sentezindeki elde edilen başarı oranları [72] ve Gulrajani ve ark. [73], bu metodolojinin etkinliğini göstermektedir. GAN'larda metodolojik güven yüksektir, ancak eğitim istikrarı ve modun çökmesi konusundaki zorluklar devam etmektedir.

Bahdanau ve ark. [74] ve Vaswani ve ark. [75] dikkat mekanizmalarını tanıtarak modelin yorumlanabilirliğini artırmıştır ve çeşitli görevlerde başarıya ulaşmıştır. Pasif analiz, dikkat mekanizmalarının etkinliğine, özellikle de alanlar arası performansın iyileştirilmesine ilişkin yüksek bir güven düzeyini ortaya koymaktadır. Farklılık, bu modelleri benzerlerinden ayıran, ilgili bilgilere seçici olarak odaklanma yeteneğinde yatmaktadır. Sağlık hizmetleri (Esteva ve ark. [76]), finans (Deng ve ark. [77]) ve otonom sistemler (Bojarski ve ark. [78]) alanındaki çalışmalar, alana özgü zorluklara göre uyarlanmış çeşitli metodolojiler kullanılarak yüksek başarı oranları sergilemiştir. Metodolojik güven, sağlık hizmetlerindeki yorumlanabilirlik zorluklarına ve otonom sistemlerdeki etik hususlara göre değişmektedir.

Litjens ve ark. [79] ve Gulshan ve ark. [80], tıbbi görüntü sınıflandırması için CNN'lerin kullanılmasında yüksek başarı oranları elde etmişlerdir. Pasif analizler, CNN'lerin özellikle radyoloji ve patoloji görüntülerinde karmaşık desenleri yakalamadaki etkinliğini

ortaya koymuştur. Metodolojik güven oldukça yüksektir ve CNN'ler sürekli olarak geleneksel yöntemlerden daha iyi performans göstermektedir. Farklılık, CNN'lerin çeşitli görüntüleme yöntemlerine uyarlanabilirliği ve onları sahada diğerlerinden ayırmasında yatmaktadır.

Li ve ark. tarafından keşfedilen geçici tıbbi görüntü analizi [81] ve Liu ve ark. [82], RNN'lerin uygulamasından faydalanmıştır. Kardiyak görüntüleme gibi dinamik görüntüleme senaryolarındaki başarı oranları, RNN'lerin zamansal bağımlılıkları yakalamadaki etkinliğini göstermektedir. Pasif içgörüler, uzun vadeli bağımlılıkların ele alınmasında zorluklar devam etse de RNN'lerin uygulanmasına olan güvenin arttığını göstermektedir.

Wang ve arkadaşları tarafından ortaya atılan dikkat mekanizmaları [83] ve Zhang ve ark. [84], tıbbi görüntü sınıflandırmasında bölgeye özgü analizleri zenginleştirmiştir. Pasif analiz, özellikle görüntülerdeki anormalliklerin lokalizasyonunda yüksek başarı oranlarına işaret etmektedir. Metodolojik güven, dikkat mekanizmalarının sağladığı yorumlanabilirlik ile pekiştirilmekte ve bu çalışmalar diğerlerinden ayrılmaktadır. Zhang ve ark. tarafından gösterildiği gibi alanlar arası uygulamalar ve McKinney ve ark. [85], çeşitli tıbbi görüntüleme alanlarındaki başarıyı sergilemiştir. Metodolojilerin pasif olarak incelenmesi, alana özgü zorluklara göre uyarlanmış uyarlanabilir yaklaşımları ortaya çıkararak metodolojik güveni artırmaktadır. Farklılık, bu modellerin görüntüleme yöntemleri ve klinik uzmanlıklar arasındaki çok yönlülüğünde yatmaktadır.

Cheplygina ve arkadaşlarının da belirttiği gibi, veri kıtlığı, yorumlanabilirlik ve model sağlamlığı konusundaki zorluklar devam etmektedir [86] ve Esteva ve ark. [87] devam eden araştırma çabalarına ilişkin pasif içgörüler, metodolojik güveni artırmak ve bu zorlukları ele almak için gelişen stratejilere ışık tutarak tıbbi görüntü sınıflandırmasının dinamik ortamına katkıda bulunmuştur.

Veri kümelerindeki karmaşık desenler ve özellikler otomatik olarak tanımlanıp öğrenildiğinden, CNN derin öğrenme modellerinin dönüştürücü etkisi oldukça yüksektir. Bu modellerin kullanılmasıyla, çeşitli veri kümeleri genelinde tahmin doğruluğu ve genellemede önemli bir gelişme elde edilmiştir. Bu yönüyle geniş kapsamlı derin öğrenme uygulamalarında CNN derin öğrenme modelleri sıklıkla kullanılmaktadır.

2.2.2 Evrişimli Sinir Ağları (CNN)

CNN'ler, biyolojik görme sistemlerinden esinlenerek tasarlanan ve özellikle büyük ve karmaşık veri setleri üzerinde etkili olan derin öğrenme modelleridir. Temelde, CNN'ler, girdi verisinin lokal desenlerini anlama yeteneği ve özellik çıkarma kapasitesiyle öne çıkmaktadır. CNN'ler, özellikle görsel veri analizindeki başarılarıyla bilinmektedir ve temel özelliği konvolüsyon katmanlarını içermeleridir. Bu katmanlar, girdi verisi üzerinde belirli filtre veya çekirdeklerin (kernels) uygulanmasıyla lokal desenlerin öğrenilmesini sağlamaktadır. Konvolüsyon işlemi, filtrelerin girdi verisi üzerinde kaydırılması ve noktasal çarpımların alınması yoluyla gerçekleşmektedir. Bu sayede özellik haritaları elde edilmekte ve girdi verisinin önemli özellikleri vurgulanmaktadır. CNN'lerin temelinde, giriş verilerindeki yerel kalıpları yakalayan matematiksel bir işlem olan evrişim işlemi yatmaktadır. Bir giriş görüntüsünün evrişimi I filtrelili K aşağıdaki formülle temsil edilmektedir:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n) \cdot K(i - m, j - n) \quad [2.0]$$

Burada $S(i, j)$, elde edilen özellik haritasındaki (i, j) konumundaki değeri temsil etmektedir. Evrişim işleminin ardından, bir aktivasyon fonksiyonu modele doğrusal olmama durumunu getirmektedir. Düzeltilmiş Doğrusal Birim (ReLU), şu şekilde tanımlanan, yaygın olarak kullanılan bir aktivasyon fonksiyonudur:

$$f(x) = \max(0, x) \quad [2.1]$$

ReLU, çıkışın negatif girişler için sıfır ve pozitif girişler için doğrusal olmasını sağlayarak eğitim sırasında daha hızlı yakınsamayı kolaylaştırmaktadır. MaxPooling gibi havuzlama katmanları, özellik haritalarının uzamsal boyutlarını azaltarak temel bilgileri korumaktadır. MaxPooling şu şekilde tanımlanmaktadır:

$$P(i, j) = \max(I(2i, 2j), I(2i, 2j + 1), I(2i + 1, 2j), I(2i + 1, 2j + 1)) \quad [2.2]$$

Düzeltilmiş doğrusal birimler veya ReLu'lar pozitif boyutta doğrusal, ancak negatif boyutta sıfır olan bir tür aktivasyon fonksiyonu olarak göze çarpmaktadır. Yapay sinir ağlarında ReLu, her bir düğümde elde edilen argümanın pozitif kısmını tanımlamaktadır. Bir düğümün girişi olarak kabul edilen x ile ReLu aktivasyon fonksiyonu aşağıdaki gibi formülleştirilmiştir.

$$f(x) = x^+ = \max(0, x) = \frac{x+|x|}{2} = \begin{cases} x & \text{if } x > 0, \\ 0 & \text{otherwise.} \end{cases} \quad f'(x) = \begin{cases} 1 & \text{if } x > 0, \\ 0 & \text{if } x < 0. \end{cases} \quad [2.3]$$

Sigmoid aktivasyon fonksiyonu ise tüm gerçek giriş değerleri için tanımlanan ve her noktada negatif olmayan bir türevi ve tam olarak bir bükülme noktası olan sınırlı, türevlenebilir gerçek bir fonksiyon olarak aşağıda belirtilen formül ile tanımlanmıştır.

$$\sigma(x) = \frac{1}{1+e^{-x}} = \frac{e^x}{1+e^x} = 1 - \sigma(-x). \quad [2.4]$$

Kayıp fonksiyonu olarak kullanılan ve amacı, verileri iki sınıfa ayırmak olduğu ikili sınıflandırma görevlerinde yaygın olarak kullanılan ikili çapraz entropi (binary_crossentropy), tahmin edilen ikili sonuçlar ile gerçek ikili etiketler arasındaki farkı ölçmek için makine öğrenmesinde kullanılan bir kayıp fonksiyonu olmakla beraber olasılık dağılımları arasındaki farklılığı ölçerek ve yanlış tahminleri cezalandırarak geliştirilen modelin eğitilmesine yardımcı olması için kullanılmaktadır. Bu fonksiyon tahmin edilen olasılıkların her birini 0 veya 1 olabilen gerçek sınıf çıktılarıyla karşılaştırmakta, daha sonra beklenen değerden uzaklığa bağlı olarak olasılıkları cezalandıran puanı hesaplamaktadır. Bu, gerçek değer ne kadar yakın veya uzak olduğu anlamına gelmektedir. İkili çapraz doğrulama, model tahmininden elde edilen sınıf türlerini kontrol ederek yanlış tahmin edilen sınıf türleri için model tahmin olasılığını $1 - p_i$ (1-yanlış tahmin olasılık değeri) olacak şekilde yeniden düzenlemektedir. Daha sonra düzenlenen olasılık değerleri için log değerleri hesaplanmaktadır. Log değeri kullanılmasının sebebi ise log değerinin tahmin edilen olasılık ile düzeltilmiş olasılık arasındaki küçük farklar için daha az ceza sunmasıdır ve fark büyüdükçe ceza daha yüksek olmaktadır. Düzeltilmiş olasılıkların tümü 0 ile 1 arasında olduğundan tüm log değerleri negatif olmaktadır. Düzeltilmiş olasılıkları hesaplamak yerine, log kaybı aşağıdaki formül;

$$\text{Log Loss} = \frac{1}{N} \sum_{i=1}^N - (y_i * \log(p_i) + (1 - y_i) * \log(1 - p_i)) \quad [2.5]$$

kullanılarak hesaplanmaktadır. Burada, p_i 1. sınıfın olasılığı, $(1 - p_i)$ ise 0. sınıfın olasılığıdır. 1. sınıfa ait bir örnek olduğunda formülün ilk kısmı aktif hale gelmekte ve ikinci kısmı kaybolmaktadır. 0. sınıf için ise tam tersi gerçekleşmektedir. Buradan ikili çapraz entropinin, düzeltilmiş tahmin olasılıklarının logaritmik negatif ortalaması olduğu da anlaşılmaktadır. Bunun yanında öğrenme oranının problemler için uygun olsa da derin öğrenmede karşılaşılan problemler gibi dışbükey olmayan problemler için ideal olmayabileceğidir. Ancak, Adagrad⁹³'in [88] koordinat bazında uyarlanabilirliği bir

⁹³ Gradyan tabanlı optimizasyona yönelik bir algoritmadır. Öğrenme oranı, geçmiş gözlemlerin bilgisi dahil edilerek parametrelere bileşen bazında uyarlanır.

önkoşul olarak son derece arzu edilen bir durum olmaktadır. AdaGrad, öğrenme oranını parametrelere uygulayan stokastik bir optimizasyon yaklaşımıdır. Sık sık meydana gelen özelliklerle ilişkili parametreler için daha küçük güncellemeler ve seyrek olarak meydana gelen özelliklerle ilişkili parametreler için daha büyük güncellemeler gerçekleştirmektedir. Adagrad, güncelleme kuralında, θ_i 'nin geçmiş gradyanlarına dayalı olarak her θ_i parametresi için her t zaman adımında genel öğrenme oranı η 'yı değiştirmektedir. Bu işlem aşağıda belirtilen;

$$\theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii} + \epsilon}} g_{t,i} \quad [2.6]$$

formül ile gerçekleşmektedir. AdaGrad'ın faydası, öğrenme oranını manuel olarak ayarlama ihtiyacını ortadan kaldırmasıdır. Zayıflığı ise paydadaki kare gradyanların birikmesidir. Eklenen her terim pozitif olduğundan, biriken toplam eğitim sırasında büyümeye devam ederek öğrenme oranının azalmasına ve son derece küçük hale gelmesine neden olmaktadır. Tieleman ve Hilton [89], RMSProp algoritmasını, hız planlamasını koordinat uyarlamalı öğrenme hızlarından ayırmak için basit bir düzeltme olarak önermişlerdir. Buradaki sorun Adagrad'ın g_t gradyanının karelerini bir $s_t = s_{t-1} + g_t^2$ durum vektöründe biriktirmesidir. Bu sorunu çözenin bir yolu s_t/t kullanmaktır. g_t 'nin makul dağılımı için bu yakınsama göstermektedir. Ne yazık ki, prosedür değerlerinin tam yörüngesini hatırladığından, limit davranışının önem kazanmaya başlaması çok uzun zaman alabilmektedir. Başka bir alternatif de momentum yönetiminde kullandığımız gibi $s_t \leftarrow \gamma s_{t-1} + (1 - \gamma) g_t^2$ bazı parametreler için $\gamma > 0$ sızdıran bir ortalama kullanmaktır ve diğer tüm parçaları sabit tutmak RMSProp sonucunu vermektedir. Bu nedenle problem çözümünde kullanılan ve belirtilen yaklaşımın denklemsel hali;

$$s_t \leftarrow \gamma s_{t-1} + (1 - \gamma) g_t^2, \quad [2.7]$$

$$x_t \leftarrow x_{t-1} - \frac{\eta}{\sqrt{s_t + \epsilon}} \odot g_t. \quad [2.8]$$

şeklinde belirtilmiştir. Sıfıra bölünme veya aşırı büyük adım boyutlarına maruz kalmayı sağlamak için sabit $\epsilon > 0$ değeri 10^{-6} olarak ayarlanmaktadır. Bu genişleme göz önüne alındığında, artık koordinat bazında uygulanan ölçeklendirmeden bağımsız olarak öğrenme oranı η kontrol edilmekte özgür hale gelmektedir. Sızdıran ortalamalar açısından, momentum yöntemi durumunda daha önce uygulanan mantığın bir benzeri uygulanabilmektedir. s_t getirilerinin tanımının genişletilmesi;

$$s_t = (1 - \gamma)g_t^2 + \gamma s_{t-1} \quad [2.9]$$

$$= (1 - \gamma)(g_t^2 + \gamma g_{t-1}^2 + \gamma^2 g_{t-2}^2 + \dots) \quad [2.10]$$

şeklinde gerçekleştirilmektedir. RMSProp algoritmasının güncellenmiş formülü ise aşağıdaki şekilde gerçekleşmektedir;

$$E[g^2](t) = \beta E[g^2](t-1) + (1 - \beta) \left(\frac{\partial c}{\partial w} \right)^2 \quad [2.11]$$

$$w_{ij}(t) = w_{ij}(t-1) - \frac{\eta}{\sqrt{E[g^2]}} \frac{\partial c}{\partial w_{ij}} \quad [2.12]$$

Burada $E[g^2]$ kare gradyanların hareketli ortalamasını, $\delta c / \delta w$ maliyet fonksiyonunun ağırlığa göre gradyanını, η öğrenme katsayısını ve β hareketli ortalama parametresini (varsayılan değer -0.9, dokuz mini grupta varsayılan gradyan değerinin 0.1 ve onda birlerde -0.9'un toplamını yaklaşık sıfır yapmak için ve deneyime göre varsayılan η değeri 0.001'dir) ifade etmektedir.

Havuzlama, önemli özellikleri korurken daha kompakt bir temsil oluşturmaya yardımcı olmaktadır. Tam Bağlantılı (FC) katmanlar, bir katmandaki her nöronu bir sonraki katmandaki her nörona bağlamaktadır. FC katmanının çıktısı şu şekilde ifade edilebilmektedir:

$$y = f(\sum w_i \cdot x_i + b) \quad [2.13]$$

Burada w_i ağırlıkları, x_i girişleri, b önyargıyı ve $f()$ aktivasyon fonksiyonunu temsil etmektedir. Tipik bir CNN mimarisi, aktivasyon fonksiyonları ve havuzlama katmanlarının serpiştirildiği ve ardından tamamen bağlı katmanların takip ettiği birden fazla evrişimli katmandan oluşmaktadır. Mimari şu şekilde ifade edilmektedir:

$$O = f(F_2(f(P_1(F_1(I)))) \quad [2.14]$$

Burada F_1 birinci evrişim katmanını, P_1 havuzlama katmanını, F_2 ikinci evrişim katmanını ve $f()$ aktivasyon fonksiyonunu temsil etmektedir. CNN'lerin eğitimi, geri yayılım yoluyla bir kayıp fonksiyonunun en aza indirilmesini içermektedir. Ağırlık w için gradyan iniş güncelleme kuralı şu şekilde verilir:

$$w = w - a * \frac{\partial L}{\partial w} \quad [2.15]$$

Burada a öğrenme oranı, L kayıp fonksiyonu ve $\frac{\partial L}{\partial w}$ ise kaybın ağırlığa göre eğimidir. CNN'ler, verilerden özelliklerin hiyerarşik temsillerini otomatik olarak öğrenmektedir. İlk katmanlardaki basit özellikleri ayırt edebilir ve daha derin katmanlarda aşamalı olarak

karmaşık temsiller oluşturabilmektedirler. Bir dereceye kadar çeviri sabitlik sergilerler ve bu, giriş alanındaki konumlarına bakılmaksızın kalıpları tanıyabilecekleri anlamına gelmektedir. Bu özellikle görüntü tanıma gibi görevler için faydalı olmaktadır. Evrişimli katmanlarda paylaşılan ağırlıkların kullanılması, parametre sayısını azaltarak CNN'leri hesaplama açısından daha verimli hale getirmekte ve aşırı uyum riskini azaltmaktadır. Verilerdeki mekansal hiyerarşileri yakalamak için yerel alıcı alanları kullanmaktadır. Bu girdinin küçük, ilgili bölümlerine odaklanmasına olanak tanıyarak mekansal ilişkileri içeren görevlerde onları etkili kılmaktadır. Büyük veri kümeleri üzerinde önceden eğitilmiş modellerden yararlanarak transfer öğrenmeyi kolaylaştırabilmektedir. Model, bir görevden kazanılan bilgiyi diğerine uyarlayabildiğinden, sınırlı veri kümeleriyle uğraşırken bu avantajlı olabilmektedir. Bunların yanı sıra CNN'lerin, özellikle de derin mimarilerin eğitimi, hesaplama açısından yoğun olabilir ve önemli miktarda kaynak gerektirebilir. Bu, sınırlı hesaplama gücüne sahip bireyler veya kuruluşlar için bunların erişilebilirliğini sınırlayabilmektedir. Genellikle büyük ve çeşitli veri kümeleri üzerinde eğitildiklerinde en iyi performansı göstermektedirler. Bu tür veri kümelerinin edinilmesi ve hazırlanması, özellikle niş veya özel alanlar için zorlayıcı olabilmektedir. Başarılarına rağmen CNN'ler, ağ içindeki karar verme sürecini anlamının karmaşık olabileceği anlamında yorumlanabilirlikten yoksun olmaktadır. Bu "kara kutu" yapısı, özellikle yorumlanabilirliğin çok önemli olduğu kritik uygulamalarda bir dezavantaj olmaktadır. Parametre paylaşımı bir dereceye kadar aşırı uyumun önlenmesine yardımcı olsa da derin CNN'ler, özellikle veri kümesi küçükse veya model çok karmaşıkça aşırı uyum sağlamaya eğilimli olabilmektedir. CNN'ler öncelikle yerel kalıplara odaklanır ve küresel bağlamı yakalamada zorluk yaşayabilmektedir. Bu sınırlama, girdi verilerinin bütünsel olarak anlaşılmasını gerektiren görevleri etkileyebilir. Evrişimsel Sinir Ağları (CNN'ler), derin öğrenme alanında, özellikle görüntü işleme ve örüntü tanıma alanında çok önemli bir ilerleme olarak yer almaktadır. Hiyerarşik özellik çıkarma ve parametre paylaşımı ilkeleri üzerine inşa edilen CNN'ler, verilerden karmaşık gösterimleri otomatik olarak öğrenme konusunda oldukça iyi sonuçlar vermektedir. Uzamsal hiyerarşileri ayırt etme, çeviri değişmezliği sergileme ve aktarım öğrenimi için önceden eğitilmiş modellerden yararlanma yetenekleri, onları görüntü sınıflandırma, nesne algılama ve bölümlendirme gibi görevler için güçlü araçlar olarak konumlandırmaktadır. Hesaplama yoğunluğuna ve yorumlanabilirlik ile ilgili zorluklara rağmen CNN'ler, karmaşık görsel veri analizi görevlerini yerine getirme ve yapay zekanın sınırlarını zorlama konusundaki etkinliklerini sergileyerek çeşitli alanlarda etkili hale gelmektedir.

2.2.3 Performans Metrikleri

Derin öğrenme alanında, model performansının değerlendirilmesi ve ölçülmesi, çeşitli performans ölçümlerinin kapsamlı bir şekilde anlaşılmasını gerektiren en önemli hususlardır. Hassasiyet, geri çağırma ve F1 puanından, alıcı işletim karakteristik eğrisi (AUC-ROC) altındaki alan ve ortalama karesel hata gibi daha incelikli ölçümlere kadar uzanan bu ölçümler, çeşitli görevlerde derin öğrenme modellerinin etkinliğini değerlendirmede önemli kriterler olarak hizmet etmektedir. Modelin genelleme, kalıpları ayırt etme ve doğru tahminler yapma yeteneğini objektif olarak ölçmek ve böylece model performansının daha sonraki analizi ve iyileştirilmesi için sağlam bir temel oluşturmak amacıyla bu ölçümler uygulanmaktadır. Model performansını ölçmek için kullanılan ve çıktının iki veya daha fazla olabilecek sınıflandırma problemlerinde performans ölçütü olan karışıklık matrisi, tahmin edilen ve gerçek değerlerin birbiri üzerindeki performansını tanımlamaktadır (Şekil 2.4). İkili sınıflandırma problemi ele alındığında, model performansını ölçmek ve değerlendirmek bakımından daha adaletli ve tarafsız bir yorumlama için model performans metriklerinden biri olarak model değerlendirmesine dahil edilebilmektedir. Buna ek olarak istatistik alanında tip1 ve tip2 hata olarak geçen FP ve FN değerlerinin oransal olarak, değerlendirmeye alınan tüm verilerdeki kapsam alanı, diğer performans metriklerinin değerlendirilmesinde daha güvenilir bir yorumlama yapılmasına imkân sunmaktadır.

		Gerçek Değerler	
		Pozitif(1)	Negatif(0)
Tahmin Değerleri	Pozitif(1)	TP	FP
	Negatif(0)	FN	TN

Şekil 2.4 Karışıklık Matrisi

Doğru pozitif (True Positive, TP), modelin pozitif sınıfı doğru şekilde tahmin ettiği sonuçları temsil ederken benzer şekilde gerçek negatif (True Negative, TN) de modelin negatif sınıfı doğru şekilde tahmin ettiği sonuçları temsil etmektedir. Yanlış pozitif (False Positive, FP, Type 1 Error) modelin pozitif sınıfı yanlış tahmin ettiği sonuçları ifade

ederken yanlış negatif (False Negative, FN, Type 2 Error), modelin negatif sınıfı yanlış tahmin ettiği sonuçlardır. Doğruluk (accuracy) ise sınıflandırma modelinin değerlendirilmesine yönelik kullanılan ölçümdür. Doğruluk, aşağıda belirtilen matematiksel denklem ile ifade edilmiştir:

$$\text{Doğruluk} = \frac{\text{Doğru tahmin sayısı}}{\text{Toplam tahmi sayısı}} \quad [2.16]$$

İkili sınıflandırma için doğruluk, pozitif ve negatifer açısından hesaplaması aşağıdaki şekilde yapılmaktadır:

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad [2.17]$$

Burada TP doğru pozitifleri, TN doğru negatiferi, FP yanlış pozitifleri ve FN yanlış negatiferi temsil etmektedir. Sınıflandırma metriklerinden biri olan hassasiyet, olumlu tanımlamaların ne kadarı gerçekten doğru sorusuna cevap vermek için kullanılmaktadır. Hassasiyet metriği ise şu şekilde tanımlanmaktadır:

$$\text{Precision} = \frac{TP}{TP+FP} \quad [2.18]$$

Başka bir sınıflandırma metriği olan hatırlama, gerçek pozitiflerin ne kadarının doğru olarak belirlendiğini belirtmek için kullanılmaktadır. Hatırlama tanımlaması:

$$\text{Recall} = \frac{TP}{TP+FN} \quad [2.19]$$

şeklinde. Bir modelin etkinliği tam olarak değerlendirmek için hem hassasiyet hem de hatırlama incelenmektedir. Ancak hassasiyet ve hatırlama genellikle gerilim durumundadır. Buna karşın F1 puanı, bir modelin tahmin becerisini, doğrulukla yapılan genel performanstan ziyade sınıf bazında performansını detaylandırarak değerlendiren alternatif bir makine öğrenimi değerlendirme ölçütü olarak kullanılmaktadır. Bu, modelin hassasiyet ve hatırlama puanları olmak üzere iki rakip ölçütü birleştirmesini kapsamaktadır. F1 puanı, hassasiyet ve hatırlama puanlarının harmonik ortalaması olarak hesaplanır. F1 puanının hesaplanması aşağıda verilen bu denklem:

$$F1 \text{ Score} = \frac{2}{\frac{1}{\text{Hassasiyet}} + \frac{1}{\text{Hatırlama}}} \quad [2.20]$$

$$= \frac{2 \times \text{Hassasiyet} \times \text{Hatırlama}}{\text{Hassasiyet} + \text{Hatırlama}} \quad [2.21]$$

ile gerçekleştirilmektedir.

Basit aritmetik veya geometrik ortalamalar yerine harmonik ortalama kullanılarak hesaplanma yapılmasının sebebi, harmonik ortalamanın, hassasiyet ve hatırlama için benzer değerleri teşvik ederek, hassasiyet ve hatırlama değerleri ne kadar birbirlerinden saparsa, harmonik ortalamanın da o kadar kötü olacağından dolayıdır. F1 puanı, kısaltılmış ifadeler ile aşağıdaki gibi;

$$F1\ Score = \frac{TP}{TP + \frac{1}{2}(FP + FN)} \quad [2.22]$$

ifade edilebilmektedir. Sınıflandırma model performansını ölçmek için son olarak kullanılan ROC eğrisi, bir sınıflandırma modelinin tüm sınıflandırma eşiklerindeki performansını gösteren bir grafikdir. Bu grafik, hatırlama değerinin eş anlamlısı olan doğru pozitif oran (TPR) ve yanlış pozitif oran (FPR) düzlemlerinde yer almaktadır. TPR ve FPR hesaplanması şu şekilde gerçekleştirilmektedir:

$$TPR = \frac{TP}{TP + F} \quad [2.23]$$

$$FPR = \frac{FP}{FP + TN} \quad [2.24]$$

ROC eğrisindeki yer alan tüm sınıflandırma eşiklerindeki performansın toplu ölçümü ise AUC ile yapılmaktadır. AUC' ye ihtiyaç duyulmasının en önemli iki nedenin birisi, ölçek ile değişmemesi ve mutlak değerlerinden ziyade tahminlerin ne kadar iyi sıralandığını ölçmesidir. Bir diğeri ise hangi sınıflandırma eşığının seçildiğine bakılmaksızın, sınıflandırma eşığı ile değişmeden model tahminlerinin kalitesini ölçmesidir.

3. UYGULAMALAR VE DENEYSEL ÇALIŞMALAR

3.1 Veri Seti

Yürütülen bilimsel araştırmada, ‘Angle Closure Glaucoma Challenge’ [90] adlı yarışma kapsamında açık kaynak olarak sunulan, CASIA I (SS-1000, Nagoya, Japonya) [91] ile elde edilmiş, SS-OCT incelemesi 0.16 lux ışık yoğunluğuna sahip standart bir karanlık odada yapılmış, ön kamerası 128 meridyene bölünmüş ve her hacim taramasından 16 dilim çıkarılarak, açık, dar, kapalı ve okunamaz olarak sınıflandırılmış, referans standart olarak gonyoskopi kullanılmış ve skleral mahmuzu 4 oftalmolog tarafından bağımsız olarak ön kameranın her iki tarafından lokalize edilmiş [92] açık kaynak AS-OCT görüntülerinden sadece eğitim veri seti kullanılmıştır. Yarışma verisi olarak sunulan verilerden sadece eğitim veri seti kullanılmasının sebebi, test veri setinde sunulan verilerin etiket bilgisinin bulunmaması dolayısıyla yapılan çalışmada doğruluğunun ispatlanamayacağıdır. Çalışmada kullanılan eğitim veri setinde 1600 adet 2130x998 boyutunda AS-OCT görüntüleri, kapalı açılı glokom olma durumlarına göre kapalı açılı glokom örnekleri için 1, diğer durumlar için 0 olacak şekilde etiketleme işlemi uygulanmıştır. Kullanılan veri setinin tüm özellikleri Çizelge 3.1’de sunulduğu gibidir. Tüm görüntüler üzerinde standartlaştırmayı sağlamak üzere ön işleme adımlarından ilk olarak tüm görüntüler imkân verdiği seviyede 128x128 boyutuna indirgenmiştir.

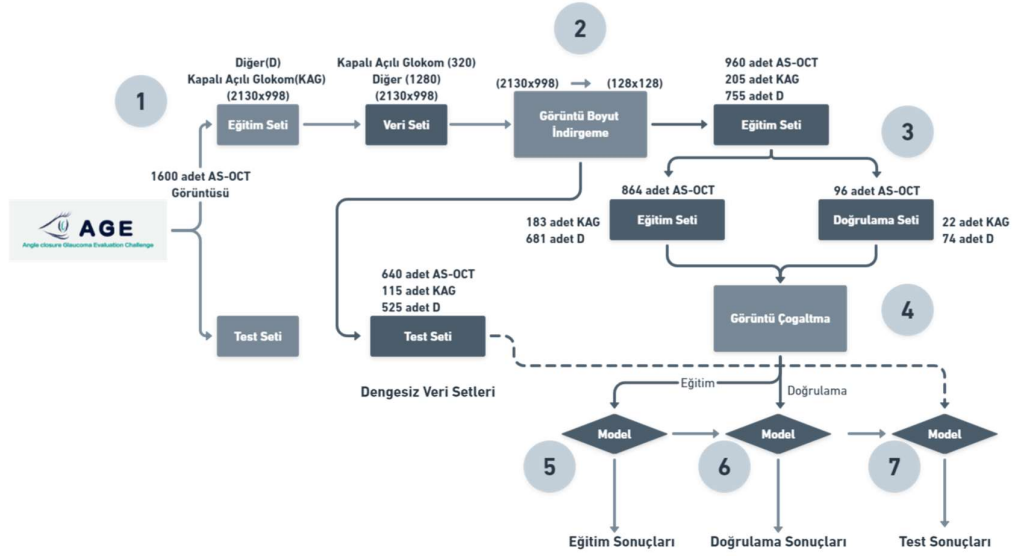
Çizelge 3.1 Angle Glaucoma Challenge Eğitim Veri Seti

Kullanılan Cihaz	CASIA I (SS-1000, Nagoya Japonya)
AS-OCT İncelemesi	0.16 Lux Işık Yoğunluğu, Karanlık Oda
Ön Kamera Bölüm Sayısı	128 Meridyen
Dilim Sayısı	16
Sınıf Türleri	Açık Açılı, Kapalı Açılı, Diğer
Referans Standart	Gonyoskopi
Görüntü Sayısı	1600
Oftalmolog Sayısı	4
Kapalı Açılı Glokom Sayısı	320 (1)
Açık Açılı ve Diğer Glokom Sayısı	1280 (0)

*4 farklı bağımsız oftalmolog tarafından gerçekleştirilmiştir.

Bu yaklaşımla standardizasyona katkıda bulunurken kaynak yetersizliği probleminin de önüne geçilmeye çalışılmıştır. Görüntülerin farklı açılarda ve ters çevrilmiş (ters, baş aşağı) gelebilme ihtimaline ve veri çoğaltma gereksinimine dayanarak, verilere görüntü çoğaltma yöntemleri uygulanmıştır. Görüntü sayısı çoğaltılarak, modelin daha iyi öğrenmesi amaçlanmıştır. Geliştirilecek modelin baş aşağı ve ters çevrilmiş görüntüler için herhangi bir tercih oluşturmadığından emin olmak için,

yarışma veri setinden alınan eğitim veri seti, ayrıştırılarak test ve eğitim veri setine dönüştürüldükten sonra test veri setinde bu ters çevrilmiş görüntüleri istemediğimizden dolayı, veri kümesi genişletmesi eğitim ve test kümelerine ayrıldıktan sonra gerçekleştirilmiştir. Veri ayrıştırma işlemi için tüm verilerde etiket tür sayıları kapalı açılı glokom örnekleri için 320 adet, diğer örnekler için ise 1280 adet olarak tespit edilmiştir. Bu yönüyle kullanılan veri setinin tür bazında 4 kat dengesiz olduğu da saptanmıştır. Yarışma veri setinden alınan eğitim veri kümesi toplam veri kümesi olarak kabul edilerek, en başta 960 adet eğitim ve 640 adet AS-OCT görüntüsü test seti olacak şekilde 4 kat sınıf dengesizliği korunarak ayrıştırılmıştır.



Şekil 3.1 İşlem Akış Şeması

Eğitim veri seti için 205 adet kapalı açılı glokom ve 755 adet diğer türünde, test veri seti için 115 adet kapalı açılı glokom ve 525 adet diğer türünde örneklem elde edilmiştir. Daha sonra elde edilen yeni eğitim veri seti, 183 adet kapalı açılı glokom ve 681 adet diğer olmak üzere 864 adet AS-OCT ve doğrulama veri seti için, 22 adet kapalı açılı ve 74 adet diğer türünde olacak şekilde toplamda 96 adet AS-OCT örneklem veri setleri olarak güncellenmiştir (Şekil 3.1). Ayrıştırma işlemlerinin tümünde ‘numpy’⁹⁴ kütüphanesi yardımı ile rastgele permütasyon [93] yöntemi kullanılmış ve seçilen örnekler sınırlandırılan aralıkta rastgele olarak seçilerek ‘bias’⁹⁵ (yanlılık) [94] etkeni

⁹⁴ Dizilerle çalışmak için kullanılan bir Python kütüphanesidir. Aynı zamanda doğrusal cebir, fourier dönüşümü ve matrisler alanında çalışmaya yönelik işlemlere de sahiptir.

⁹⁵ Bir veri kümesinin bazı yönlerine diğerlerinden daha fazla ağırlık verildiği bir tür hatadır.

devre dışı bırakılmıştır. Rastgele permütasyon fonksiyonu verilen dizinin rastgele örneklerini vermekte ve bu yöntemi kullanarak diziyi döndürmektedir. Eğer dizi çok boyutlu bir diziyse, yalnızca ilk indeksiyle birlikte karıştırılmaktadır. Ayırıştırma işlemi tamamlandıktan sonra ‘tensorflow’⁹⁶ kütüphanesinde yer alan ‘ImageDataGenerator’⁹⁷ [95] fonksiyonu yardımı ile daha önce bahsedilen görüntü zenginleştirme yöntemlerinden yeniden boyutlandırma, yakınlaştırma, döndürme, genişlik ve yükseklik değiştirme, yatay ve dikey aynalama yöntemleri uygulanmıştır.


Çizelge 3.2 Görüntü Çoğaltma Yöntem ve Değerleri

	Eğitim	Doğrulama
Ölçeklendirme (rescale)	1.0/255	1.0/255
Kesme (shear_range)	0.0	0.0
Yakınlaştırma (zoom_range)	0.05	0.05
Dönüş (rotation_range)	180	90
Genişlik (width_shift_range)	0.05	0.05
Yükseklik (height_shift_range)	0.05	0.05
Çevirme (horizontal_flip)	True	True
Çevirme (vertical_flip)	True	True
Doldurma(fill_mode)	‘constant’	‘constant’
Cval	0	0

Eğitim ve doğrulama veri setleri üzerinde uygulanan görüntü zenginleştirme yöntem ve değerleri Çizelge 3.2’ de belirtilmiştir. Uygulanan görüntü zenginleştirme teknikleri sonrasında elde edilen görüntü örnekleri yukarıda sunulmuştur (Şekil 3.2). Görüntü verileri model eğitimi için hazır hale getirildikten sonra, geliştirilecek ve eğitilecek modelin performans değerlerini daha kolay incelemek ve değerlendirmek için ‘check_accuracy’ adında yardımcı bir fonksiyon yazılmıştır. Bu fonksiyon model tahminlemesi sonrasında elde edilen sonuçlar için benzer çalışmalarda [14, 96, 97] model değerlendirmesi için kullanılan karışıklık matrisi (confusion matrix), sınıflandırma raporu (classification report), sınıflandırma metrikleri (classification metrics), genel doğruluk oranı (accuracy) ve alıcı çalışma karakteristik eğrisini (ROC Curve) hesaplamakta ve sonuç olarak sunmaktadır.

⁹⁶ Bir makine öğrenimi sisteminin tüm yönlerini yönetmeye yönelik zengin bir sistemdir

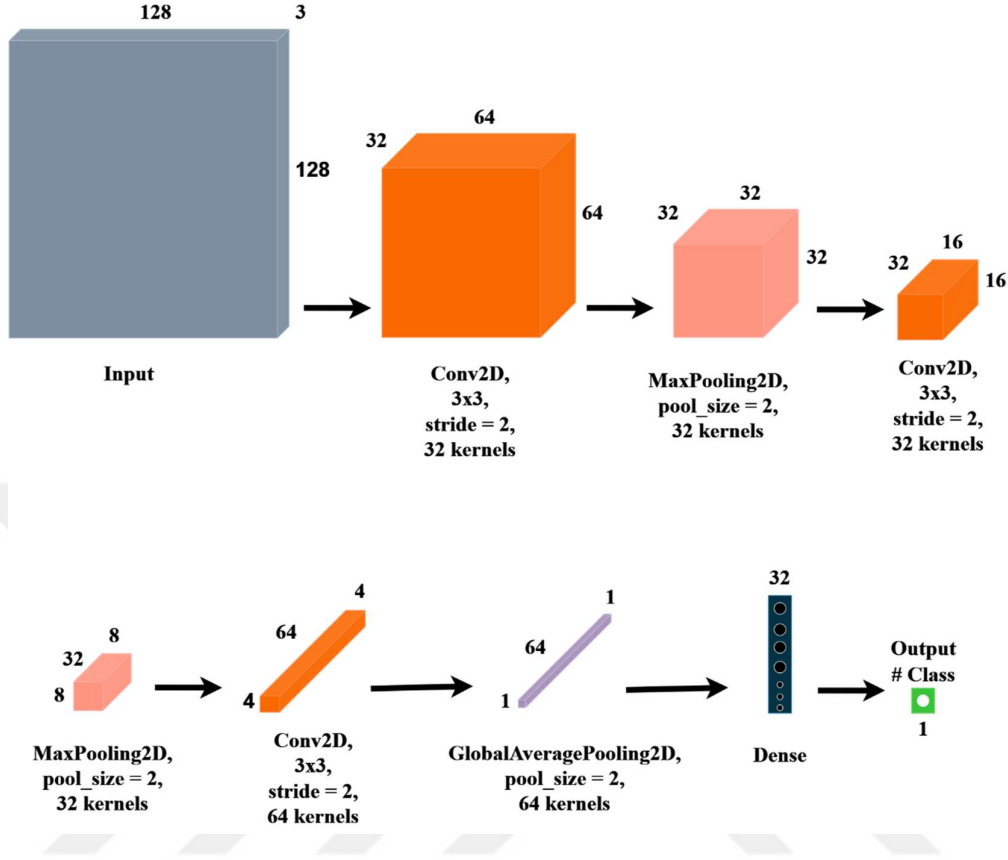
⁹⁷ Orijinal verinin girdisini almak için kullanılır ve bu verinin dönüşümünü rastgele yaparak sadece yeni dönüştürülmüş veriyi içeren çıktı sonucu verir.



Şekil 3.2 Artırılmış AS-OCT Görüntüleri

3.2 Deneysel Tasarım ve Uygulama

Geliştirilen modelde, karmaşıklık ve derinlik kavramlarını minimize ederek daha kısa sürede doğru ve güvenilir bir tahminleyici oluşturmak, büyük ve karmaşık modellere olan ihtiyacı azaltarak AS-OCT görüntüleri üzerinden kapalı açılı glokom tespiti basit yöntemler ve umut vadeci performans değerleri elde ederek gerçekleştirmek hedeflenmiştir. Bu bakış açısıyla geliştirilen model ve kullanılan parametre değerleri Şekil 3.3 ve Çizelge 3.3'te gösterilmiştir.



Şekil 3.3 Model Mimarisi

Model mimarisi incelendiğinde görüntü üzerinden tespit edilmeye çalışılan hastalığa yönelik öznelikleri çıkarmaya yarayan ‘Conv2D’ katman çıktıları, ardından gelen ‘MaxPooling2D’ katmanları ile desteklenerek ağırlık sayıları azaltılmakta ve uygunluk maksimize edilerek kontrol edilmektedir. Kullanılan en son ‘Conv2D’ katmanından sonra eklenen ‘GlobalAveragePooling2D’ katmanı ile genelleştirme desteklenmeye çalışılmıştır. Daha önce kullanılan ‘MaxPooling2D’ katmanları ile bazı öznelıkların ağırlıklarının fazla yükseleceği düşünüldüğünden, ‘GlobalAveragePooling2D’ ve 32 düğüme sahip ‘Dense’ katmanından sonra modele eklenen 0.4 indirgeme oranına sahip ‘Dropout’ katmanları ile modelin ezberlemesi anlamına gelen aşırı öğrenme (overfitting)⁹⁸ önlenmeye çalışılmıştır. Son olarak çözülmeye çalışılan problem bir 2 sınıflı denetimli öğrenme çeşidi olduğundan dolayı 1 düğümden oluşan bir ‘Dense’ katmanı eklenerek model tasarlanmıştır. Son katman hariç olmak üzere sınıflandırma problemlerinde iyi performans gösterdiği kanıtlanan ‘ReLu’ (Rectified Linear Unit) aktivasyon fonksiyonu kullanılmıştır. Son katmanda ise sınıflandırma problemlerinde bir

⁹⁸ Makine öğrenme modelinin eğitim verileri için doğru tahminler vermesi ancak yeni veriler için doğru sonuçlar üretmemesi durumunda ortaya çıkan ve istenmeyen bir makine öğrenimi davranışıdır.

ayırıcı niteliğinde işlev gören ‘sigmoid’ aktivasyon fonksiyonu entegre edilmiştir. Bu şekilde tasarlanan model, daha önce hazırlanan veri setleri ile eğitilmiş ve test edilmiştir.

Çizelge 3.3 Model Hiperparametre Değerleri

Hiperparametreler	Eğitim	Doğrulama
Input Shape	(128, 128, 3)	(128, 128, 3)
Kernel Size	3	3
Pool Size	2	2
Stride	2	2
Activation Function	Relu, sigmoid	Relu, sigmoid
Dropout Rate	0.4	0.4
Loss Function	Binary_crossentropy	Binary_crossentropy
Optimizer	Rmsprop	Rmsprop
Batch Size	128	16
Epoch Size	128	128
Steps Size for Each Epoch	128	100

Doğrulama veri seti sonuçları göz önüne alınarak modelin uydurma sayısının çok yüksek olmadığı gözlemlenmiş ancak bu problemin tıbbi bir hastalık olması nedeniyle elde edilen yanlış negatif sayısının düşürülmesi gerekli görülmüştür. Bu etkene dayanarak yanlış negatif değerlerini cezalandırmak için dengesiz bir veri setinin oluşturulması ile pozitif vaka sayısının artırılarak modelin yanlış pozitifleri yanlış negatiflere tercih etmesi, hastalık etiket sayı ağırlıkları göz önüne alınarak sınıf ağırlık ‘class weight’⁹⁹ [98] etmeni uygulanması, yanlış negatif oranını düşürmeye yönelik (duyarlılığı artırmak) özel kayıp işlev fonksiyonunun tasarlanması [99] ya da hangi kontrol noktasının modeli kaydedeceğine bağlı olarak özel metrikler geliştirilmesi gibi yöntemler değerlendirmeye alınmıştır. Kullanılan veri setinin halihazırda dengesiz bir görünüme sahip olması göz önünde bulundurularak ilk önerilen yöntem çözüm için entegre edilmiştir. Bu yöntemde eğitim veri setinde görülen her bir kapalı açılı glokom örneği için bir adet daha kapalı açılı glokom örneği eklenmiş ve eğitim setinin boyutu 1047 adete çıkarılmıştır. Buradaki amaç, pozitif örneklem sayısını çoğaltarak modelin yanlış negatif seçimini azaltmaktır. ‘Oversampling’¹⁰⁰ ya da ‘Undersampling’¹⁰¹ yöntemlerinin kullanılmamasının sebebi, veri seti içindeki tür dağılımının olabildiğince korunması ve gerçek hayat senaryosuna uygunluğunun muhafaza edilmeye çalışılmasıdır. Bunun yanında modelin tahmin yeteneğinin yetersiz kalmasını önlemek adına 32 düğümlü ‘Dense’ katmanının düğüm

⁹⁹ Eğitim aşamasında her sınıfa farklı ağırlıklar atayarak her sınıfın katkısının dengelenmesini sağlamaktadır. Her sınıfa atanan ağırlıklar genellikle veri kümesindeki frekanslarıyla ters orantılıdır.

¹⁰⁰ Dengesiz veri kümelerinin neden olduğu sorunları çözmeye çalışan, teknik, azınlık sınıfı için sentetik veri noktaları oluşturmayı ve böylece veri kümesindeki temsilini arttırmayı amaçlayan bir tekniktir.

¹⁰¹ Tüm verileri azınlık sınıfında tutarak ve çoğunluk sınıfının boyutunu azaltarak eşit olmayan veri kümelerini dengelemeye yönelik bir tekniktir.

sayısı 2 katına yükseltilerek 64 olarak güncellenmiştir. Geliştirilen model yeniden düzenlenen veri seti ile tekrar eğitilmiş ve test sonuçları nihai sonuç olarak dikkate alınmıştır. Makine öğrenmesinde geliştirilen modellerin elde ettiği tahmine yönelik, modelin bu işlemi nasıl gerçekleştirdiği ya da nasıl bu kaniya vardığına dair bir bilgi sunulmamakta ve bu olay ‘blackbox’ [100] olarak adlandırılmaktadır. Modele ve elde edilen sonuçlara olan güveni ve doğruluğu desteklemek amacıyla kara tutu kavramına karşı geliştirilen CAM (Class Activation Map) yöntemi benzer çalışmalarda [101, 102] olduğu gibi model öğrenmesini denetlemek ve desteklemek için problem çözümünde kullanılmıştır. Sınıf aktivasyon harita modeli (CAM), geliştirilen modelde kullanılan en son konvolüsyon katmanı ile çıktı katmanından önce yer alan dense katmanlarını kapsamaktadır. Bu katman bloklarına entegre edilen CAM, katman ağırlıklarını, analiz edilen AS-OCT görüntüsü ile birleştirerek model tahminlemede dikkate alınan bölgeleri vurgulamaktadır. Bu sayede modelin konvolüsyonel katmanlarına gelen görüntü şekilleri ve model ağırlıkları eşleştirilerek, modelin problem sınıfına karar verirken etkin olarak kullandığı bölümler tespit edilebilmektedir. Bu da geliştirilen modelin tahminleme yaparken hangi özellikleri ve bölümleri dikkate alarak karar verdiğini açıklamaktadır ki bu yönüyle modele olan güven açıklanmaya çalışılmıştır.

4. BULGULAR

Bu bölümde, titiz deneylerle elde edilen verilerin kapsamlı bir analizi sunulurken araştırma yöntemlerinin sonuçları açıklanmıştır. Ham gözlemler ve ölçümler, daha önce ortaya atılan araştırma sorularını ve hipotezleri ele almamıza olanak tanıyacak şekilde anlamlı içgörülere dönüştürülmüştür. Sonuçların sunumu, uygulanan yöntemden ortaya çıkan kalıpların, eğilimlerin ve önemli bulguların net bir şekilde anlaşılmasını kolaylaştırmak için düzenlenmiştir. Detaylı açıklamalar, görsel temsiller ve istatistiksel analizler aracılığıyla, elde edilen bilgilerin zenginliği ve incelenen konuyla ilgili anlayışı iletme açısından sonuçlar aktarılmıştır.

4.1 Model Performans Sonuçları


Materyal bölümünde bahsedilen görüntü önışleme adımları uygulanan eğitim veri seti, geliştirilen model ile eğitildikten sonra elde edilen eğitim ve doğrulama sonuçları Çizelge 4.1’te gösterilmiştir. Model performans sonuçları değerlendirildiğinde, hatırlama ve hassasiyeti birlikte kullanan bir performans metriği olan F1 puanı değerlerinin, D (Diğer) sınıfı için 0.91 KAG (Kapalı Açılı Glokom) için ise 0.56 şeklinde elde edildiği tespit edilmiştir.

Çizelge 4.1 Model Performans Sonuçları

		Precision	Recall	F1 Score	Support
Eğitim	D (0)	0.87	0.96	0.91	681
	KAG (1)	0.75	0.45	0.56	183
	Micro avg	0.85	0.85	0.85	864
	Makro avg	0.81	0.70	0.74	864
	Weighted avg	0.84	0.85	0.84	864
Doğrulama	D (0)	0.87	0.97	0.92	74
	KAG (1)	0.85	0.50	0.63	22
	Micro avg	0.86	0.86	0.86	96
	Makro avg	0.86	0.74	0.77	96
	Weighted avg	0.86	0.86	0.85	96

Buna ek olarak bu benzerliğin hem eğitim hem de doğrulama veri setinde gerçekleştiği de kaydedilmiştir. Hassasiyet değerleri 0.87 D ve 0.75 KAG olmak üzere birbirine daha yakın gözlemlenirken, özellikle hatırlama değerlerinin D için 0.96 ve KAG için 0.45 olarak tespit edilmiştir. Model sonuçlarının detaylı bir şekilde değerlendirilmesi için daha önce hazırlanan ‘check_accuracy’ fonksiyonu yardımıyla karışıklık matrisi,


sınıflandırma raporu, performans metrikleri, genel doğruluk oranı ve alıcı çalışma karakteristik eğrisi çıkarılmıştır. Elde edilen sonuçlar Şekil 4.1, Şekil 4.2 ve Çizelge 4.2’de gösterildiği gibidir.



Şekil 4.1 Eğitim Alıcı Çalışma Karakteristik Eğrisi

Modelin veri seti ile eğitilme aşaması için elde edilen ROC eğrisi ~ 0.5 TPR ve 1 TPR değerleri arasında lineer bir yükseliş grafiği sergilemiş ve ~ 0.72 AUC skoruna sahiptir. ROC eğrisi, modelin farklı eşiklerinde hassasiyeti ve özgüllüğü dengeleme yeteneğini ortaya koymuştur.

Doğrulama veri seti ile test edilen model için ROC eğrisi grafiğine bakıldığında ise, benzer bir grafik ile karşılaşılmış ve herhangi bir farklılık gözlemlenmemiştir. Çizelge 4.2’de sunulan metrik değerlerinin oransal yakınlığı bu benzerliği açıklar nitelikte bir sonuç üretmiştir. Genel başarı oranı eğitim seti için $\sim 85.18\%$ ve doğrulama seti için ~ 86.45 olarak gözlemlenmiştir. Bir yapay zekâ modelindeki eğitim ve doğrulama ROC eğrileri örtüşüyorsa veya birbirine çok benziyorsa, bu genellikle modelin eğitim verilerine gereğinden fazla uymadığını göstermektedir. Ancak ROC eğrisinin mutlak değeri ve genel performans ölçümlerinin dikkate alınması önemlidir.



Şekil 4.2 Doğrulama Alıcı Çalışma Karakteristik Eğrisi

Bununla beraber eğitim setinin oransal olarak %~9.96'sı ve doğrulama setinin %~11.45'i yanlış negatiflerden oluştuğu gözlemlenmiştir. Doğrulama seti için ~0.73 AUC ışığında eğitilen modelin yanlılık durumu değerlendirmeye alınmıştır. Geliştirilen model ile elde edilen sonuçlar sınıf bazında yetersiz görüldüğünden veri seti ve modelde gerçekleştirilen güncellemeler sonrasında yeniden eğitilmiş ve tekrar edilen eğitim seti ve doğrulama seti ile test seti sonuçları Çizelge 4.3'te gösterilmiştir. Model, toplam örnekler arasında doğru şekilde sınıflandırılmış örneklerin oranını temsil eden yüksek bir doğruluk göstermiştir. Bunun yanında kesinlik değerinin yüksek olduğu gözlemlenmiş dolayısıyla modelin az sayıda yanlış pozitif tahmin yaptığı anlaşılmıştır.

Çizelge 4.2 Performans metrikleri ve Genel Başarı Tablosu


	Performans Metrikleri	Örnekleme Sayısı ve Genel Başarı oranı
Eğitim	Doğru Pozitif	82
	Doğru Negatif	654
	Yanlış Pozitif	27
	Yanlış Negatif	101
	Genel Başarı	~85.18%
Doğrulama	Doğru Pozitif	11
	Doğru Negatif	72
	Yanlış Pozitif	2
	Yanlış Negatif	11
	Genel Başarı	~86.45%

Çıktı üreten modelin iyi kalibre edilmiş olasılıklar ürettiği böylelikle tahmin edilen olasılıkların, belirli bir sınıfa ait olmanın gerçek olasılığıyla yakından uyumlu olduğu belirlenmiştir. Doğrulama veri seti boyutunun test veri seti boyutundan daha küçük olması nedeniyle model performans metriklerinden elde edilen değerlerin desteklenmesi için test veri seti ile ölçülen model performansları daha güvenilir ve belirleyici olmuştur.

Çizelge 4.3 Düzenlenen Model Performans Sonuçları


		Precision	Recall	F1 Score	Örneklem Sayısı
Eğitim	D (0)	0.98	0.96	0.97	681
	KAG (1)	0.86	0.95	0.90	183
	Micro avg	0.96	0.96	0.96	864
	Makro avg	0.92	0.95	0.94	864
	Weighted avg	0.96	0.96	0.96	864
Doğrulama	D (0)	0.97	0.96	0.97	74
	KAG (1)	0.87	0.91	0.89	22
	Micro avg	0.95	0.95	0.95	96
	Makro avg	0.92	0.93	0.93	96
	Weighted avg	0.95	0.95	0.95	96
Test	D (0)	0.96	0.97	0.97	511
	KAG (1)	0.88	0.86	0.87	129
	Micro avg	0.95	0.95	0.95	640
	Makro avg	0.92	0.92	0.92	640
	Weighted avg	0.95	0.95	0.95	640

Model değerlendirmesini eşit tutmak amacıyla sonuçlar yeniden çıkarılmış ve Şekil 4.3, Şekil 4.4 ve Çizelge 4.4'te sunulmuştur.



Şekil 4.3 Eğitim Alıcı Çalışma Karakteristik Eğrisi-2

Daha önce 0.75 ve 0.45 olan KAG hassasiyet ve hatırlama değerleri, yeniden düzenlenen veri seti ve model aracılığıyla, 0.86 ve 0.95'e yükselmiştir. Genel başarı oranı, D sınıfında bir değişiklik göstermezken, KAG sınıfı için 0.56 dan 0.90'a yükselmiştir. Eğitim veri seti için AUC skoru ~0.93 olarak saptanmıştır. ROC eğrisinin daha önce geliştirilen model performansına karşın yeni model ile başlangıç değerinde ~0.9 olacak şekilde bir yükseliş gösterdiği ve lineer olarak arttığı gözlemlenmiştir. Doğrulama veri setinde AUC skoru olarak ~0.93 değeri yakalanmıştır.



Şekil 4.4 Doğrulama Alıcı Karakteristik Eğrisi-2

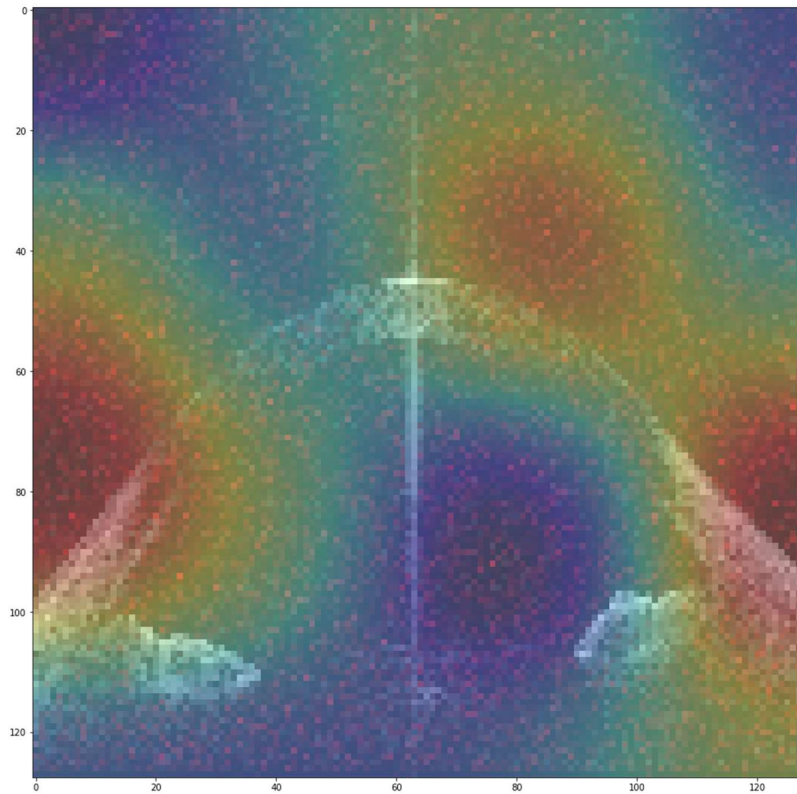
Eğitim veri setinde, ROC eğrisi grafiğin sol üst köşesine doğru yüksek derecede yükseklik ve içbükeylik sergileyen bir eğri ile karakterize olmuştur. Doğrulama veri setinde ise eğitim veri setine göre nispeten daha düşük olsa da benzer bir ROC eğrisi elde edilmiştir. Tekrarlanan performans metrik değerleri ise, Çizelge 4.4'te görüldüğü üzere eğitim seti için ~1.15% yanlış negatif ve doğrulama veri seti için ~2.08% yanlış negatif olacak şekilde bir düşüş gözlemlenmiştir. Ek olarak, genel başarı oranı, eğitim veri seti için %~95.60 ve doğrulama veri seti için %~94.79 şeklinde ölçülmüştür. Test veri setinde ise ~95.0% genel başarı oranı elde edilmiştir. Tahmin edilen yanlış negatif oranı ise toplam test veri seti için ~2.03% olarak tespit edilmiştir. Ayrıca test veri seti için elde edilen AUC skoru ~0.91 olarak belirlenmiştir.

Çizelge 4.4 Performans Metrikleri ve Genel Başarı Tablosu-2

	Hata Metrikleri	Örneklem Sayısı ve Genel Başarı oranı
Eğitim	Doğru Pozitif	173
	Doğru Negatif	653
	Yanlış Pozitif	28
	Yanlış Negatif	10
	Genel Başarı	~95.60%
Doğrulama	Doğru Pozitif	20
	Doğru Negatif	71
	Yanlış Pozitif	3
	Yanlış Negatif	2
	Genel Başarı	~94.79%
Test	Doğru Pozitif	102
	Doğru Negatif	506
	Yanlış Pozitif	19
	Yanlış Negatif	13
	Genel Başarı	~95.0%


4.1.1 Sınıf Aktivasyon Harita Sonuçları

Elde edilen sonuçların doğruluğu ve uygulanan yöntem ve metotlara olan güvenin desteklenmesi amacıyla uygulanan CAM (Sınıf Aktivasyon Haritası) örnekleri Şekil 4.5 ve Şekil 4.6' da gösterilmiştir.



Şekil 4.5 Sınıf Aktivasyon Harita Örneği (T0001-05.jpg)

CAM, son sınıflandırma için giriş görüntüsündeki farklı bölgelerin önemini belirten bir ısı haritası oluşturmuştur. Sınıf aktivasyon harita çıktıları, pozitif vakalar için AS-OCT görüntülerinin sağ ve sol kenarlarında yoğun aktivasyonları ortaya koymuştur. Bu bölgelerin, kapalı açılı glokom için anatomik veya patolojik özelliklere karşılık geldiği doğrulanmıştır. Açık yapıları veya ön segmentin belirli katmanları etrafındaki yüksek aktivasyonlar belirgin olarak tespit edilmiştir.



Şekil 4.6 Sınıf Aktivasyon Harita Örneği (T0022-14.jpg)

Daha yüksek aktivasyon değerlerine sahip bölgeler, modelin tahminleri üzerinde daha güçlü bir etkiye işaret etmektedir. Negatif durumlarda ise CAM daha düşük yoğunluklu aktivasyonlar veya daha yaygın bir model göstermiştir. CAM değerlerinin, özellikle iris ve çevresi için problem tanımlamasında etkin olmayan bir özellik gösterdiği belirlenmiştir. Bir başka deyişle, modelin tespit yaparken, iris ve çevresini güçlü bir şekilde vurgulamadığı gözlemlenmiştir ancak bu durum tüm görüntüler için doğru değildir. Farklı örnekler için elde edilen CAM çıktılarında iris ve çevresinin de dikkate alındığı belirlenmiştir. Çoğunluğu drenaj kanalları ve çevresi olmak üzere göz anatomisinin birçok farklı bölgesinde ısı haritalarının kümeleme oluşturduğu gözlemlenmiştir. Bazı test örneklem görüntülerinde iris çevresinde ısı haritaları etkinlik

göstermezken farklı test örneklemlerinde drenaj kanallarında olduğundan daha fazla kümelenme olduğu saptanmıştır. Isı haritalarından elde edilen görüntüler ile, modelin özellikle açılış mesafesi ve açılış derinliği konusunda etkin bir seçiciliği tespit edilmiştir. Bunun yanında döndürülmüş çevrilmiş ya da kayma gerçekleşmiş görüntü örneklerinde de benzer sonuçlar gözlemlenerek etken çeşidi, oranı ve derecesinin stabil olmadığı çeşitlilik sağladığı belirlenmiştir.



5. TARTIŞMA VE SONUÇ

Geliştirilen ilk model, kullanılan veri seti ve uygulanan yöntem ile elde edilen sonuçlar dikkate alındığında daha küçük yaklaşım sayısı ile eğitilen modelin problemi tanıma performansının %85~ doğruluk oranı ile iyi olduğu gözlemlenmiştir ancak bu çözüm önerisinde sonuçların genel olarak değerlendirilmesinin yanlış olduğu anlaşılmıştır. Bunun sebebi modelin eğitim veri setinde %85~ ve doğrulama veri setinde %81~ genel doğruluk oranına ulaşmasına karşın, sınıf bazında başarı oranları incelendiğinde kapalı açılı glokom örneklerinde %56~ ile diğer örnekler için ise %91~ olarak ölçülmesidir. Bu problem dengesiz veri setine sahip sınıflandırma problemlerinde oldukça sık karşılaşılan bir problemdir ve yanılığa sebep olabilmektedir. Bu nedenle genel değerlendirme yapılırken sınıfsal başarı oranlarının da göz önünde bulundurulması gerekmektedir. Ayrıca daha önce bahsedilen yanlış negatif metrik değerlerinin sayısının da önemi değerlendirmeye alındığında, geliştirilen ilk modelin problemi çözme yetisi yetersiz kalmıştır.

İlk olarak uygulanan yöntem ve model sonuçları ışığında, geliştirilen model ve düzenlenen veri seti ile elde edilen sonuçlar, yanlış negatif problemini çözmek için eğitim veri setindeki dengesizliğin dengelenmesi yönteminin etkili olduğunu göstermektedir. Model mimarisindeki düğüm sayılarının artırılmasının da modelin bu ayrımı dengeli bir şekilde yapabilme yetisine katkıda bulunduğu gözlemlenmiştir. Bunun yanında dengesiz ve nispeten dengeli tür ayrımı yapılan yöntemlerde kullanılan veri setlerine uygulanan görüntü zenginleştirme uygulamalarının etkinliği, bu denli basit bir modelin yüksek performans değerleri göstermesini destekler niteliktedir. Uygulanan model ile eğitim veri setinde ~%95 genel, ~%89 KAG, ~%97 D hastalık sınıf doğruluğu, doğrulama veri setinde ~%95 genel, ~%89 KAG, ~%97 D hastalık sınıf doğruluğu elde edilmesi, eğitim ve validasyon veri setlerindeki başarı oranlarının birbirine benzerliği ile kendisine olan güveni artırmıştır. Nihai sonuç olarak geliştirilen ve düzenlenen son modelin test verileri ile ~%95 genel, ~%86 KAG ve ~%97 D hastalık sınıf doğrulamasına sahip olması sunulan yöntem ve uygulanan metotlara olan güveni destekler niteliktedir. Yanlış negatif değerlerindeki azalma uygulanan yöntemin etkili olduğunu ispatlamıştır. Bu yönüyle sınıfsal tahminleme modellerinde bir sorun olarak görülen veri dengesizliği probleminin bir çözüm olarak kullanılabileceği konusu değerlendirilmiştir. Yanlış olarak tahmin

edilen örneklem sayısı ve çeşidinin artırılması ile modelin tahmin dengesinde iyileşme gözlemlenmiştir. Buna ek olarak yanlış negatif sayısında gözlemlenen azalmayla birlikte yanlış pozitif sayısındaki kısmen gözlemlenen artış da dikkate alınmalıdır. Modelin genel başarı oranı değişmemesine rağmen yanlış negatif ve yanlış pozitif değerleri arasında gerçekleşen bu denge değişiminin, çözülmeye çalışılan problemin bir sağlık problemi olması ve araştırma yapılan alana özgü olması ile ilişkili olduğu unutulmamalıdır. Farklı alanlarda yapılabilecek benzer çalışmalar için yanlış negatif ve yanlış pozitif değerlerinin etki oranları ve önemi farklı olabileceğinden, bu çalışmada uygulanan yöntem uygulanmadan önce araştırma yapılacak alanda tespit edilmesi beklenen hedeflerin etki durumları detaylı bir şekilde değerlendirilmelidir. Ayrıca 0.91 gibi yüksek bir AUC değeri ise, pozitif ve negatif vakalar arasındaki üstün ayrımcılığı göstermektedir. Klinisyenler model performansı ile elde edilmiş bu bilgiyi spesifik klinik gereksinimlere göre uyarlamak için kullanabilir. AUC değeri, yapay zekâ modelinin kapalı açılı glokom vakalarını doğru bir şekilde sınıflandırmada ve hatalı pozitifleri en aza indirmede üstün olduğunu göstermektedir.

Yüksek AUC ve ROC eğrisinin şekli, modelin etkilenen ve etkilenmeyen bireyleri ayırt etmedeki etkinliğini doğrulamaktadır. Bu sonuçlar ışığında yapılan çalışma, yapay zekânın, kapalı açılı glokomun klinik tanısında entegrasyonuna yönelik değerli görüşlere katkıda bulunmaktadır. Açık yapıları veya ön segmentin belirli katmanları etrafındaki yüksek aktivasyon, modelin hastalıkla ilgili modellere odaklandığını göstermektedir. Ancak farklı test örneklerinde ısı haritaları bakımından farklılık görülmesi benzer hastalığın farklı sebeplerden dolayı kaynaklanabileceğini göstermektedir. Bu bakımdan belirgin etmenleri çeşitlilik gösteren glokom tarzı hastalık tahminlerinde veri sayısının ve çeşitliliğin artırılmasının gerekliliği anlaşılmıştır. Bu şekilde elde edilecek aktive edilmiş bölge haritaları daha güvenilir sonuçlar sunacaktır. Klinisyenler bu aktive edilmiş bölgeleri potansiyel patolojik bulgular için rehberlik olarak kullanılabilir ve hedefe yönelik analize yardımcı olabilir. Kritik bölgelerde belirgin aktivasyonların olmaması, modelin olumsuz tahminler için hatalıya özgü özelliklere dayanmadığı anlamına gelmektedir. CAM çıktıları, modelin karar verme sürecine ilişkin şeffaf ve yorumlanabilir bir görünüm sağlamıştır. Isı haritasının görüntü boyunca yaygın dağılım örneklerinin gözlemlendiği örneklerle modelin yalnızca yerel bölgelere odaklanmadığını, bunun yerine girdinin tamamındaki çok sayıda özelliği dikkate aldığını göstermektedir. Modelin, görüntünün farklı kısımlarında mevcut olan çeşitli anatomik veya patolojik

ipuçlarını dikkate alarak tahminlerde bulunurken bütünsel yaklaşımının bir göstergesi olmuştur. Bununla birlikte, yaygın aktivasyonlar aynı zamanda modelin küresel bağlamsal bilgilere dayandığını da öne sürebileceğinden, bu ısı haritalarını dikkatli bir şekilde yorumlamak çok önemlidir. Pozitif ve negatif vakalarda etkileşen bölgelerin anlaşılması, klinisyenlere değerli bilgiler sağlayarak oftalmik tanıda bilinçli ve etkili karar almayı kolaylaştırabilir. Bunun yanında kişiye özel tedavi ve teşhis ile tedavi yöntem süreçleri daha kolay kontrol edilebilir ve izlenebilir. Elde edilen sonuçlar ışığında, yapay zekâ modellerinin kapalı açılı glokom tespitindeki etkinliği açıklanmış ve şeffaf bulgular ile desteklenmiştir.

Sağlık alanında yapılan çalışmalarda kullanılan veri tip ve işleyişi derin farklılık içerdiğinden, geliştirilen yöntem ve metotlar uygulanmadan önce problem tanımının bu çalışmada incelenen vaka ile benzerliği değerlendirilmelidir. Geliştirilen model mimarisinde, farklı vaka türleri için geliştirmeye ihtiyaç duyulabileceği unutulmamalıdır. Son olarak, yapılan çalışmadaki veri setinin büyüklüğü ve sınıf çeşitliliği ile birden fazla hastalığın bir arada bulunduğu vakaların eksikliği modele olan güveni şüpheye düşürmektedir. Farklı göz hastalıkları ile bulunan kapalı açılı glokom vakalarında baskın etkenin hangi göz hastalığından dolayı meydana geldiği açıklanamadığından, hastalığın nedenselleştirilmesi ve çözüm önerilerinin sunulması zorlaşmaktadır. Ayrıca bu tür vaka örneklerinde etkin özellik sayısı artacağından dolayı, problemi tanımlamaya yönelik geliştirilecek model mimarisinde daha derin ve karmaşık yapılara ihtiyaç duyulabilir. Bir diğer yandan kapalı açılı glokom gelişen göz yapı özellikleri farklı glokom tipleri barındıran göz bileşenlerinin de farklılık gösterebileceği unutulmamalıdır. Bununla birlikte tıbbi görüntü sınıflandırmasında derin öğrenmeye ilişkin gelecekteki çalışmalar incelendiğinde, mevcut araştırmaların veri hacmi açısından bir sınırlamayla karşı karşıya olduğu belirtilmektedir. Bu çalışma kapsamında gözlemlenen sınırlı veri boyutu, veri seti havuzunu genişletmek ve çeşitlendirmek için gelecekteki araştırmaların değerlendirilmesini teşvik etmektedir. Gelecekteki araştırma çalışmalarının, tıbbi görüntü sınıflandırmasında kullanılan derin öğrenme modellerinin sağlamlığını ve genelleştirilebilirliğini artırmak için daha büyük ve daha çeşitli veri kümeleri elde etmeye odaklanması önerilmektedir. Yapay zekâ algoritmalarının AS-OCT cihazlarıyla entegrasyonu sayesinde oftalmologların sağlam bir karar destek mekanizmasına erişim sağlayarak kapalı açılı glokom vakalarını doğru şekilde tanımlama ve sınıflandırma yeteneklerini geliştirebilecekleri öngörülmektedir. Bu entegrasyon, görüntü analizinin

otomasyonunu kolaylaştırarak AS-OCT görüntülerinin kapalı açılı glokom patolojisine işaret eden belirtiler açısından hızlı ve hassas bir şekilde değerlendirilmesine olanak tanıyabileceği düşünülmektedir. Derin öğrenme algoritmalarının yeteneklerinden yararlanarak AS-OCT görüntüleri içindeki insan gözünün kolayca fark edemeyebileceği ince özellikler ve desenler etkili bir şekilde tanımlanabilir. Teşhis iş akışını kolaylaştırabilir ve görüntü yorumlama için gereken zamanı ve çabayı azaltabilir. Bununla beraber yanlış teşhis riskini en aza indirerek ve uygun hasta yöntemi stratejileri sağlayarak teşhis doğruluğunu artıracaktır. Yapay zekânın entegrasyonu, standartlaştırılmış değerlendirme protokollerini kolaylaştırarak, farklı klinik ortamlarda tutarlılığı ve tekrarlanabilirliği de destekleyebilme imkânı sunabilir. Ek olarak, araştırma kurumları arasındaki iş birliği ve ortak veri kümelerinin oluşturulması, bu alandaki bilginin kolektif büyümesine katkıda bulunabilir.

Sonuçlar tüm yönüyle değerlendirildikten sonra, derin ağ modellerinin kapalı açılı glokom tespitinde, halihazırda kullanılan teşhis ve tedavi yöntemlerinde kullanılan özelliklere odaklanabildiği anlaşılmıştır. Bu yönüyle kişiselleştirilmiş sağlık ve farklı tedavi yöntemlerinin geliştirilmesi açısından umut vadetmektedir. Buna ek olarak kapalı açılı glokom tahminlemesi için kullanılan AS-OCT görüntülerinin problemi tanımlama ve spesifik özelliklerini barındırma açısından yeterliliği de desteklenmiştir. Yüksek çözünürlük ve öznitelik sayısı ile OCT görüntülerinin glokom teşhis ve tedavisindeki etkinliği, geliştirilen yapay zekâ modelleri ile entegre edilerek yeni çözümler üretmeye imkân sağlamaktadır. Nitekim bu çalışmada kapalı açılı glokom örnekleri ile kapalı açılı olmayan örnekler değerlendirilse de kullanılan yöntemin kapalı açılı glokom ile farklı hastalıkların da bulunduğu daha karmaşık problemlerin çözümünde etkin bir rol oynayabileceği, geliştirilen basit model ile elde edilen yüksek performans değerleriyle kanıtlanmıştır.

KAYNAKLAR

- [1] Blindness and vision impairment. (n.d.). <https://www.who.int/news-room/fact-sheets/detail/blindness-and-visual-impairment> Alındığı tarih: 31.01.2023.
- [2] **Resnikoff, S., & Shunmugam Naidoo, K.** (2017). The impact of myopia and high myopia. Report of the Joint World Health Organization-Brien Holden Vision Institute Global Scientific Meeting on Myopia. <https://www.researchgate.net/publication/318216691>
- [3] **Theophanous, C., Modjtahedi, B. S., Batech, M., Marlin, D. S., Luong, T. Q., & Fong, D. S.** (2018). Myopia prevalence and risk factors in children. *Clinical Ophthalmology*, 12, 1581–1587. <https://doi.org/10.2147/OPTH.S164641>
- [4] **Holden, B. A., Fricke, T. R., Wilson, D. A., Jong, M., Naidoo, K. S., Sankaridurg, P., Wong, T. Y., Naduvilath, T. J., & Resnikoff, S.** (2016). Global Prevalence of Myopia and High Myopia and Temporal Trends from 2000 through 2050. *Ophthalmology*, 123(5), 1036–1042. <https://doi.org/10.1016/j.ophtha.2016.01.006>
- [5] **Quigley, H., & Broman, A. T.** (2006). The number of people with glaucoma worldwide in 2010 and 2020. In *British Journal of Ophthalmology* (Vol. 90, Issue 3, pp. 262–267). <https://doi.org/10.1136/bjo.2005.081224>
- [6] **Toledo Leite, M., Massanori Sakata, L., & Medeiros, F. A.** (2011). Managing glaucoma in developing countries Lidando com o glaucoma em países em desenvolvimento. In *Arq Bras Oftalmol* (Vol. 74, Issue 2). <http://data.un.org/Explorer.aspx?d=PopDiv>
- [7] **Gopinath, K., Sivaswamy, J., & Mansoori, T.** (2016). Automatic Glaucoma Assessment from Angio-OCT Images. <https://doi.org/10.1109/ISBI.2016.7493242>
- [8] **Sehi, M., Grewal, D. S., Sheets, C. W., & Greenfield, D. S.** (2009). Diagnostic Ability of Fourier-Domain vs Time-Domain Optical Coherence Tomography for Glaucoma Detection. *American Journal of Ophthalmology*, 148(4), 597–605. <https://doi.org/10.1016/j.ajo.2009.05.030>
- [9] **García, G., Colomer, A., & Naranjo, V.** (2021). Glaucoma Detection from Raw SD-OCT Volumes: A Novel Approach Focused on Spatial Dependencies. *Computer Methods and Programs in Biomedicine*, 200. <https://doi.org/10.1016/j.cmpb.2020.105855>
- [10] **Kamalipour, A., & Moghimi, S.** (2021). Macular optical coherence tomography imaging in glaucoma. In *Journal of Ophthalmic and Vision Research* (Vol. 16, Issue 3, pp. 478–489). Knowledge E. <https://doi.org/10.18502/jovr.v16i3.9442>
- [11] **Thompson, A. C., Jammal, A. A., & Medeiros, F. A.** (2020). A review of deep learning for screening, diagnosis, and detection of glaucoma progression. *Translational Vision Science and Technology*, 9(2), 1–19. <https://doi.org/10.1167/tvst.9.2.42>
- [12] **Lisboa, R., Paranhos, A., Weinreb, R. N., Zangwill, L. M., Leite, M. T., & Medeiros, F. A.** (2013). Comparison of different spectral domain OCT scanning

protocols for diagnosing preperimetric glaucoma. *Investigative Ophthalmology and Visual Science*, 54(5), 3417–3425. <https://doi.org/10.1167/iovs.13-11676>

[13] **Siva Raja, P. M., & Jothilakshmi, S. L.** (2021). Deep Learning Algorithms and Glaucoma Detection: A Review. *International Research Journal of Engineering and Technology*. www.irjet.net

[14] **Singh, L. K., Pooja, Garg, H., & Khanna, M.** (2021). An Artificial Intelligence-Based Smart System for Early Glaucoma Recognition Using OCT Images. *Int. J. E Health Medical Commun.*, 12(4), 32–59. <https://doi.org/10.4018/IJEHMC.20210701.OA3>

[15] **Salam, A. A., Khalil, T., Akram, M. U., Jameel, A., & Basit, I.** (2016). Automated detection of glaucoma using structural and non-structural features. *SpringerPlus*, 5(1). <https://doi.org/10.1186/S40064-016-3175-4>

[16] **Raj, V. K., Patil, A., Gudaje, S., & B, K. G.** (2020). Detection of Glaucoma in Retinal Image using Image Processing and SVM.

[17] **Madhumalini, M., & Devi, T. M.** (2022). Detection of Glaucoma from Fundus Images Using Novel Evolutionary-Based Deep Neural Network. *Journal of Digital Imaging*, 35(4), 1008. <https://doi.org/10.1007/S10278-021-00577-5>

[18] **Li, H., Jhanji, V., Dorairaj, S., Liu, A., Lam, D. S. C., & Leung, C. K.** (2012). Anterior Segment Optical Coherence Tomography and its Clinical Applications in Glaucoma. *Journal of Current Glaucoma Practice*, 6(2), 68. <https://doi.org/10.5005/JP-JOURNALS-10008-1109>

[19] Lighthouse Guild. <https://lighthouseguild.org/understanding-glaucoma-the-sneak-thief-of-sight>. Alındığı Tarih: 21.03.2022.

[20] **Allison, Karen et al.** (2020). “Epidemiology of Glaucoma: The Past, Present, and Predictions for the Future.” *Cureus* vol. 12,11 e11686. 24 Nov. 2020.

[21] **Liu, H., Li, L., Wormstone, I. M., Qiao, C., Zhang, C., Liu, P., Li, S., Wang, H., Mou, D., Pang, R., Yang, D., Zangwill, L. M., Moghimi, S., Hou, H., Bowd, C., Jiang, L., Chen, Y., Hu, M., Xu, Y., ... Wang, N.** (2019). Development and validation of a deep learning system to detect glaucomatous optic neuropathy using fundus photographs. *Jama Ophthalmol*, 137(12), 1353–1360. <https://doi.org/10.1001/jamaophthalmol.2019.3501>

[22] **Soofi, A. A., & Fazal-e-Amin.** (2023). Exploring Deep Learning Techniques for Glaucoma Detection: A Comprehensive Review. <https://arxiv.org/abs/2311.01425v1>

[23] Glaucoma | National Eye Institute. (n.d.). <https://www.nei.nih.gov/learn-about-eye-health/eye-conditions-and-diseases/glaucoma>. Alındığı Tarih: 15.11.2023.

[24] **Wang, B., Sakata, L. M., Friedman, D. S., Chan, Y. H., He, M., Lavanya, R., Wong, T. Y., & Aung, T.** (2010). Quantitative Iris Parameters and Association with Narrow Angles. *Ophthalmology*, 117(1), 11–17. <https://doi.org/10.1016/j.ophtha.2009.06.017>

- [25] **da Soh, Z., Tan, M., Nongpiur, M. E., Yu, M., Qian, C., Tham, Y. C., Koh, V., Aung, T., Xu, X., Liu, Y., & Cheng, C.-Y.** (2023). Deep learning-based quantification of anterior segment optical coherence tomography parameters. *Ophthalmology Science*, 100360. <https://doi.org/10.1016/j.xops.2023.100360>
- [26] **Sun, X., Dai, Y., Chen, Y., Yu, D. Y., Cringle, S. J., Chen, J., Kong, X., Wang, X., & Jiang, C.** (2017). Primary angle closure glaucoma: What we know and what we don't know. *Progress in Retinal and Eye Research*, 57, 26–45. <https://doi.org/10.1016/J.PRETEYERES.2016.12.003>
- [27] **Singh, L. K., Pooja, Garg, H., & Khanna, M.** (2021). An Artificial Intelligence-Based Smart System for Early Glaucoma Recognition Using OCT Images. *Int. J. E Health Medical Commun.*, 12(4), 32–59. <https://doi.org/10.4018/IJEHMC.20210701.OA3>
- [28] **Yang, G., Li, K., Yao, J., Chang, S., He, C., Lu, F., Wang, X., Wang, X., Wang, X., Wang, Z., & Wang, Z.** (2023). Automatic measurement of anterior chamber angle parameters in AS-OCT images using deep learning. *Biomedical Optics Express*, Vol. 14, Issue 4, Pp. 1378-1392, 14(4), 1378–1392. <https://doi.org/10.1364/BOE.481419>
- [29] **Ziaul, Y. H., Mahale, A., Varghese, S., Khanam, F., AlFutaise, M., Ahad, M. A., Edward, D. P., & Khandekar, R. B.** (2021). The Iris Thickness in a Healthy Saudi Population. *Cureus*, 13(1). <https://doi.org/10.7759/CUREUS.12521>
- [30] **de Oliveira, R. C., & Wilson, S. E.** (2020). Descemet's membrane development, structure, function and regeneration. In *Experimental Eye Research* (Vol. 197). Academic Press. <https://doi.org/10.1016/j.exer.2020.108090>
- [31] **Gregg Aggarwala, K. R.** (2020). Ocular Accommodation, Intraocular Pressure, Development of Myopia and Glaucoma: Role of Ciliary Muscle, Choroid and Metabolism. *Medical Hypothesis, Discovery and Innovation in Ophthalmology*, 9(1), 66. [/pmc/articles/PMC6969557/](https://pubmed.ncbi.nlm.nih.gov/36969557/)
- [32] **Heys, J. J., & Barocas, V. H.** (n.d.). Computational Evaluation of the Role of Accommodation in Pigmentary Glaucoma.
- [33] **Goel, M., Picciani, R. G., Lee, R. K., & Bhattacharya, S. K.** (2010). Aqueous Humor Dynamics: A Review. *The Open Ophthalmology Journal*, 4(1), 52. <https://doi.org/10.2174/1874364101004010052>
- [34] **Physiology, Aqueous Humor Circulation - StatPearls - NCBI Bookshelf.** (n.d.). <https://www.ncbi.nlm.nih.gov/books/NBK553209/>. Alındığı Tarih: 17.11.2023.
- [35] **Duman, N.** (2016). Topikal Prostaglandin Analogları ve Hiperpigmentasyon. *Journal of Contemporary Medicine*, 6(0). <https://doi.org/10.16899/ctd.74630>
- [36] **Brooks, V., & Gillies, wE.** (1992). Ocular β -Blockers in Glaucoma Management Clinical Pharmacological Aspects. In *Drugs & Aging* (Vol. 2, Issue 3).

- [37] **Sidjanin, D. J., McCarty, C. A., Patchett, R., Smith, E., & Wilke, R. A.** (2008). Pharmacogenetics of ophthalmic topical β -blockers. *Personalized Medicine*, 5(4), 377. <https://doi.org/10.2217/17410541.5.4.377>
- [38] **Arthur, S., & Cantor, L. B.** (2011). Update on the role of alpha-agonists in glaucoma management. *Experimental Eye Research*, 93(3), 271–283. <https://doi.org/10.1016/j.exer.2011.04.002>
- [39] Carbonic Anhydrase Inhibitors - StatPearls - NCBI Bookshelf. (n.d.). <https://www.ncbi.nlm.nih.gov/books/NBK557736/>. Alındığı Tarih: 17.11.2023.
- [40] **Frost, S. C., & McKenna, R. (Eds.)**. (2014). *Carbonic Anhydrase: Mechanism, Regulation, Links to Disease, and Industrial Applications (Vol. 75)*. Springer Netherlands. <https://doi.org/10.1007/978-94-007-7359-2>
- [41] **Alm, A.** (2014). Latanoprost in the treatment of glaucoma. *Clinical Ophthalmology (Auckland, N.Z.)*, 8, 1967. <https://doi.org/10.2147/OPHTH.S59162>
- [42] The role of trabeculectomy in enhancing glaucoma patient's quality of life - PMC. (n.d.). <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC5657155/>. Alındığı Tarih: 17.11.2023.
- [43] Trabeculectomy Surgery for Glaucoma | Wills Eye Hospital. (n.d.). <https://www.willseye.org/trabeculectomy-surgery-glaucoma/>. Alındığı Tarih: 17.11.2023
- [44] Minimally Invasive Glaucoma Surgery - StatPearls - NCBI Bookshelf. (n.d.). <https://www.ncbi.nlm.nih.gov/books/NBK582156/>. Alındığı Tarih: 17.11.2023
- [45] **Cohen, A., Wong, S. H., Patel, S., & Tsai, J. C.** (2017). Endoscopic cyclophotocoagulation for the treatment of glaucoma. *Survey of Ophthalmology*, 62(3), 357–365. <https://doi.org/10.1016/j.survophthal.2016.09.004>
- [46] Cyclodestructive Procedures in Treatment of Glaucoma - EyeWiki. (n.d.). https://eyewiki.aao.org/Cyclodestructive_Procedures_in_Treatment_of_Glaucoma. Alındığı Tarih: 17.11.2023.
- [47] **He, M., Jiang, Y., Huang, S., Chang, D. S., Munoz, B., Aung, T., Foster, P. J., & Friedman, D. S.** (2019). Laser peripheral iridotomy for the prevention of angle closure: a single-centre, randomised controlled trial. *The Lancet*, 393(10181), 1609–1618. [https://doi.org/10.1016/S0140-6736\(18\)32607-2](https://doi.org/10.1016/S0140-6736(18)32607-2)
- [48] Laser Peripheral Iridotomy (LPI) | Bumrungrad. (n.d.). <https://www.bumrungrad.com/en/treatments/laser-peripheral-iridotomy-lpi>. Alındığı Tarih: 17.11.2023.
- [49] **Kwon, Y. H., Fingert, J. H., Kuehn, M. H., & Alward, W. L. M.** (2009). Primary Open-Angle Glaucoma. *The New England Journal of Medicine*, 360(11), 1113. <https://doi.org/10.1056/NEJMRA0804630>
- [50] Open Angle Glaucoma - StatPearls - NCBI Bookshelf. (n.d.). <https://www.ncbi.nlm.nih.gov/books/NBK441887/>. Alındığı Tarih: 17.11.2023.

- [51] **Stamper, Robert L.** (2009). Becker-Shaffer's Diagnosis and Therapy of the Glaucomas || Primary open angle glaucoma. , (), 239–265. doi:10.1016/b978-0-323-02394-8.00017-6
- [52] **Wright, C., Tawfik, M. A., Waisbourd, M., & Katz, L. J.** (2016). Primary angle-closure glaucoma: An update. In *Acta Ophthalmologica* (Vol. 94, Issue 3, pp. 217–225). Blackwell Publishing Ltd. <https://doi.org/10.1111/aos.12784>
- [53] Normal Tension Glaucoma - StatPearls - NCBI Bookshelf. (n.d.). <https://www.ncbi.nlm.nih.gov/books/NBK576377/>. Alındığı tarih: 17.11.2023
- [54] **Krishnadas, R., & Ramakrishnan, R.** (2001). Secondary Glaucomas: The Tasks Ahead. *Community Eye Health*, 14(39), 40. /pmc/articles/PMC1705934/
- [55] **Badawi, A. H., Al-Muhaylib, A. A., al Owaifeer, A. M., Al-Essa, R. S., & Al-Shahwan, S. A.** (2019). Primary congenital glaucoma: An updated review. *Saudi Journal of Ophthalmology*, 33(4), 382. <https://doi.org/10.1016/J.SJOPT.2019.10.002>
- [56] Juvenile Glaucoma - StatPearls - NCBI Bookshelf. (n.d.). <https://www.ncbi.nlm.nih.gov/books/NBK562263/>. Alındığı Tarih: 17.11.2023.
- [57] **Abonamah, A. A., Tariq, M. U., & Shilbayeh, S.** (2021). On the Commoditization of Artificial Intelligence. In *Frontiers in Psychology* (Vol. 12). Frontiers Media S.A. <https://doi.org/10.3389/fpsyg.2021.696346>
- [58] **Goertzel, B.** (2014). Artificial General Intelligence: Concept, State of the Art, and Future Prospects. *Journal of Artificial General Intelligence*, 5(1), 1–48. <https://doi.org/10.2478/jagi-2014-0001>
- [59] **Sarker, I. H.** (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. In *SN Computer Science* (Vol. 2, Issue 6). Springer. <https://doi.org/10.1007/s42979-021-00815-1>
- [60] **Firescholars, F., & Furtado, E. L.** (n.d.). Role in the Conception and Development of Role in the Conception and Development of Intelligent Machinery Intelligent Machinery. <https://firescholars.seu.edu/honors/92>
- [61] **Boucher, P.** (2020). STUDY Panel for the Future of Science and Technology EPRS | European Parliamentary Research Service.
- [62] **Toosi, A., Bottino, A. G., Saboury, B., Siegel, E., & Rahmim, A.** (2021). A Brief History of AI: How to Prevent Another Winter (A Critical Review). In *PET Clinics* (Vol. 16, Issue 4, pp. 449–469). W.B. Saunders. <https://doi.org/10.1016/j.cpet.2021.07.001>
- [63] **Ostrovski, G., Castro, P. S., & Dabney, W.** (2021). The Difficulty of Passive Learning in Deep Reinforcement Learning. <http://arxiv.org/abs/2110.14020>
- [64] **Aggarwal, A., Mittal, M., & Battineni, G.** (2021). Generative adversarial network: An overview of theory and applications. In *International Journal of Information Management Data Insights* (Vol. 1, Issue 1). Elsevier Ltd. <https://doi.org/10.1016/j.jjime.2020.100004>

- [65] **Gemini Team, Anil, R., Borgeaud, S., Wu, Y., Alayrac, J.-B., Yu, J., Soricut, R., Schalkwyk, J., Dai, A. M., Hauth, A., Millican, K., Silver, D., Petrov, S., Johnson, M., Antonoglou, I., Schrittwieser, J., Glaese, A., Chen, J., Pitler, E., ... Vinyals, O.** (2023). Gemini: A Family of Highly Capable Multimodal Models. <http://arxiv.org/abs/2312.11805>
- [66] **Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (n.d.). ImageNet Classification with Deep Convolutional Neural Networks. <http://code.google.com/p/cuda-convnet/>
- [67] **Simonyan, K., & Zisserman, A.** (2015). VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION. <http://www.robots.ox.ac.uk/>
- [68] **He, K., Zhang, X., Ren, S., & Sun, J.** (2016). Deep residual learning for image recognition. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2016-December, 770–778. <https://doi.org/10.1109/CVPR.2016.90>
- [69] **Hochreiter, S., & Schmidhuber, J.** (1997). Long Short-Term Memory. Neural Computation, 9(8), 1735–1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- [70] **Graves, A.** (2013). Generating Sequences With Recurrent Neural Networks. <http://arxiv.org/abs/1308.0850>
- [71] **Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., & Bengio, Y.** (2020). Generative adversarial networks. Communications of the ACM, 63(11), 139–144. <https://doi.org/10.1145/3422622>
- [72] **Arjovsky, M., Chintala, S., & Bottou, L.** (2017). Wasserstein GAN. <http://arxiv.org/abs/1701.07875>
- [73] **Gulrajani, I., Ahmed, F., Arjovsky, M., Dumoulin, V., & Courville, A.** (2017). Improved Training of Wasserstein GANs. <http://arxiv.org/abs/1704.00028>
- [74] **Bahdanau, D., Cho, K., & Bengio, Y.** (2014). Neural Machine Translation by Jointly Learning to Align and Translate. <http://arxiv.org/abs/1409.0473>
- [75] **Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, L., & Polosukhin, I.** (2017). Attention Is All You Need. <http://arxiv.org/abs/1706.03762>
- [76] **Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S.** (2017). Dermatologist-level classification of skin cancer with deep neural networks. Nature, 542(7639), 115–118. <https://doi.org/10.1038/nature21056>
- [77] **Deng, K., Zeng, H., & Zhu, Y.** (2019). Political connection, market frictions and financial constraints: evidence from China. Accounting and Finance, 59(4), 2377–2414. <https://doi.org/10.1111/acfi.12301>
- [78] **Bojarski, M., del Testa, D., Dworakowski, D., Firner, B., Flepp, B., Goyal, P., Jackel, L. D., Monfort, M., Muller, U., Zhang, J., Zhang, X., Zhao, J., & Zieba, K.** (2016). End to End Learning for Self-Driving Cars. <http://arxiv.org/abs/1604.07316>

- [79] Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., van der Laak, J. A. W. M., van Ginneken, B., & Sánchez, C. I. (2017). A survey on deep learning in medical image analysis. In *Medical Image Analysis* (Vol. 42, pp. 60–88). Elsevier B.V. <https://doi.org/10.1016/j.media.2017.07.005>
- [80] Gulshan, V., Peng, L., Coram, M., Stumpe, M. C., Wu, D., Narayanaswamy, A., Venugopalan, S., Widner, K., Madams, T., Cuadros, J., Kim, R., Raman, R., Nelson, P. C., Mega, J. L., & Webster, D. R. (2016). Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs. *JAMA - Journal of the American Medical Association*, 316(22), 2402–2410. <https://doi.org/10.1001/jama.2016.17216>
- [81] Li, Y., He, Q., & Luo, J. (n.d.). A Deep Learning Trial on Transient Elastography for Assessment of Liver Fibrosis.
- [82] Liu, X., Liu, C., Huang, R., Zhu, H., Liu, Q., Mitra, S., & Wang, Y. (2021). Long short-term memory recurrent neural network for pharmacokinetic-pharmacodynamic modeling. *International Journal of Clinical Pharmacology and Therapeutics*, 59(2), 138–146. <https://doi.org/10.5414/CP203800>
- [83] Wang, F., Jiang, M., Qian, C., Yang, S., Li, C., Zhang, H., Wang, X., & Tang, X. (n.d.). Residual Attention Network for Image Classification.
- [84] Zhang, J., Xie, Y., Wu, Q., & Xia, Y. (2019). Medical image classification using synergic deep learning. *Medical Image Analysis*, 54, 10–19. <https://doi.org/10.1016/j.media.2019.02.010>
- [85] McKinney, S. M., Sieniek, M., Godbole, V., Godwin, J., Antropova, N., Ashrafiyan, H., Back, T., Chesus, M., Corrado, G. C., Darzi, A., Etemadi, M., Garcia-Vicente, F., Gilbert, F. J., Halling-Brown, M., Hassabis, D., Jansen, S., Karthikesalingam, A., Kelly, C. J., King, D., ... Shetty, S. (2020). International evaluation of an AI system for breast cancer screening. *Nature*, 577(7788), 89–94. <https://doi.org/10.1038/s41586-019-1799-6>
- [86] Cheplygina, V. (2019). Cats or CAT scans: Transfer learning from natural or medical image source data sets? In *Current Opinion in Biomedical Engineering* (Vol. 9, pp. 21–27). Elsevier B.V. <https://doi.org/10.1016/j.cobme.2018.12.005>
- [87] Esteva, A., Robicquet, A., Ramsundar, B., Kuleshov, V., DePristo, M., Chou, K., Cui, C., Corrado, G., Thrun, S., & Dean, J. (2019). A guide to deep learning in healthcare. In *Nature Medicine* (Vol. 25, Issue 1, pp. 24–29). Nature Publishing Group. <https://doi.org/10.1038/s41591-018-0316-z>
- [88] Duchi, J., & Hazan, E. (2011). Adaptive Subgradient Methods for Online Learning and Stochastic Optimization *. In *Journal of Machine Learning Research* (Vol. 12).
- [89] Tieleman, T., & Hinton, G. (2012). Lecture 6.5-rmsprop: Divide the gradient by a running average of its recent magnitude. COURSE: Neural networks for machine learning, 4(2), 26-31.

- [90] **Fu H, Li F, Sun X, Cao X, Liao J, Orlando JI, Tao X, Li Y, Zhang S, Tan M, Yuan C.** (2020). Age challenge: Angle closure glaucoma evaluation in anterior segment optical coherence tomography. *Medical Image Analysis*. 2020 Dec 1;66:101798.
- [91] **Li F, Zhou R, Gao K, et al.** (2019). Volumetric parameters-based differentiation of narrow angle from open angle and classification of angle configurations: an SS-OCT study[J]. *British Journal of Ophthalmology*, 2019: bjophthalmol-2018-313386.
- [92] **Joseph, F.J.J., Nonsiri, S., Monsakul, A.** (2021). Keras and TensorFlow: A Hands-On Experience. In: Prakash, K.B., Kannan, R., Alexander, S., Kanagachidambaresan, G.R. (eds) *Advanced Deep Learning for Engineers and Scientists*. EAI/Springer Innovations in Communication and Computing. Springer, Cham.
- [93] `numpy.random.permutation` — NumPy v1.26 Manual. (n.d.). <https://numpy.org/doc/stable/reference/random/generated/numpy.random.permutation.html>. Alındığı Tarih: 9.12.2023
- [94] **Pagano, T. P., Loureiro, R. B., Lisboa, F. V. N., Cruz, G. O. R., Peixoto, R. M., Guimarães, G. A. de S., Santos, L. L. dos, Araujo, M. M., Cruz, M., de Oliveira, E. L. S., Winkler, I., & Nascimento, E. G. S.** (2022). Bias and unfairness in machine learning models: a systematic literature review. <http://arxiv.org/abs/2202.08176>.
- [95] `tf.keras.preprocessing.image.ImageDataGenerator` | TensorFlow v2.14.0. (n.d.). https://www.tensorflow.org/api_docs/python/tf/keras/preprocessing/image/ImageDataGenerator. Alındığı Tarih: 9.12.2023.
- [96] **Kim, J. A., Yoon, H., Lee, D., Kim, M. H., Choi, J. H., Lee, E. J., & Kim, T. W.** (2023). Development of a deep learning system to detect glaucoma using macular vertical optical coherence tomography scans of myopic eyes. *Scientific Reports* 2023 13:1, 13(1), 1–10. <https://doi.org/10.1038/s41598-023-34794-5>
- [97] **Wanichwecharungruang, B., Kaothanthong, N., Pattanapongpaiboon, W., Chantangphol, P., Seresirikachorn, K., Srisuwanporn, C., Parivisutt, N., Grzybowski, A., Theeramunkong, T., & Ruamviboonsuk, P.** (2021). Deep learning for anterior segment optical coherence tomography to predict the presence of plateau iris. *Translational Vision Science and Technology*, 10(1), 1–10. <https://doi.org/10.1167/TVST.10.1.7>
- [98] **Kumar, K.** (2022) (n.d.). Class Weight technique for Handling Class Imbalance. <https://www.researchgate.net/publication/362066936>
- [99] **Li, M., Zhang, X., Thrampoulidis, C., Chen, J., & Oymak, S.** (2022). AutoBalance: Optimized Loss Functions for Imbalanced Data. <http://arxiv.org/abs/2201.01212>
- [100] **Bunod, R., Lubrano, M., Pirovano, A., Chotard, G., Brasnu, E., Berlemont, S., Labbé, A., Augstburger, E., & Baudouin, C.** (2023). A Deep Learning System Using Optical Coherence Tomography Angiography to Detect Glaucoma and Anterior Ischemic Optic Neuropathy. *Journal of Clinical Medicine*, 12(2). <https://doi.org/10.3390/JCM12020507>

- [101] **Christopher, M., Belghith, A., Bowd, C., Proudfoot, J. A., Goldbaum, M. H., Weinreb, R. N., Girkin, C. A., Liebmann, J. M., & Zangwill, L. M.** (2018). Performance of Deep Learning Architectures and Transfer Learning for Detecting Glaucomatous Optic Neuropathy in Fundus Photographs. *Scientific Reports*, 8(1). <https://doi.org/10.1038/S41598-018-35044-9>
- [102] **Fu, H., Baskaran, M., Xu, Y., Lin, S., Wong, D. W. K., Liu, J., Tun, T. A., Mahesh, M., Perera, S. A., & Aung, T.** (2019). A Deep Learning System for Automated Angle-Closure Detection in Anterior Segment Optical Coherence Tomography Images. *American Journal of Ophthalmology*, 203, 37–45. <https://doi.org/10.1016/J.AJO.2019.02.028>Glossary
- [103] **Lee, S. Y., Bae, H. W., Kwon, H. J., Seong, G. J., & Kim, C. Y.** (2018). Utility of Goldmann applanation tonometry for monitoring intraocular pressure in glaucoma patients with a history of laser refractory surgery. *PLoS ONE*, 13(2). <https://doi.org/10.1371/JOURNAL.PONE.0192344>
- [104] *Applanation Tonometry - StatPearls - NCBI Bookshelf.* (n.d.). <https://www.ncbi.nlm.nih.gov/books/NBK582132/>. Alındığı Tarih: 17.11.2023
- [105] **Geevarghese, A., Wollstein, G., Ishikawa, H., & Schuman, J. S.** (2021). Optical Coherence Tomography and Glaucoma. *Annual Review of Vision Science*, 7, 693. <https://doi.org/10.1146/ANNUREV-VISION-100419-111350>
- [106] **Sathyan, P., & Anitha, S.** (2012). Optical Coherence Tomography in Glaucoma. *Journal of Current Glaucoma Practice*, 6(1), 1. <https://doi.org/10.5005/JP-JOURNALS-10008-1099>
- [107] *Spectral Domain Optical Coherence Tomography in Glaucoma - EyeWiki.* (n.d.). https://eyewiki.aao.org/Spectral_Domain_Optical_Coherence_Tomography_in_Glaucoma. Alındığı Tarih: 17.11.2023
- [108] **Dong, Z. M., Wollstein, G., & Schuman, J. S.** (2016). Clinical Utility of Optical Coherence Tomography in Glaucoma. *Investigative Ophthalmology & Visual Science*, 57(9), OCT556–OCT567. <https://doi.org/10.1167/IOVS.16-19933>
- [109] *Humphrey Visual Field - StatPearls - NCBI Bookshelf.* (n.d.). <https://www.ncbi.nlm.nih.gov/books/NBK585112/>. Alındığı Tarih: 17.11.2023
- [110] **Marchini, G., Chemello, F., Berzaghi, D., & Zampieri, A.** (2015). New findings in the diagnosis and treatment of primary angle-closure glaucoma. In *Progress in Brain Research* (Vol. 221, pp. 191–212). Elsevier B.V. <https://doi.org/10.1016/bs.pbr.2015.05.001>
- [111] **Nolan, W., & Onakoya, A.** (2021). Gonioscopy skills and techniques. *Community Eye Health*, 34(112), 40. [/pmc/articles/PMC8862628/](https://pubmed.ncbi.nlm.nih.gov/PMC8862628/)
- [112] **von Eicken, J., Kohlhaas, M., Stodtmeister, R., & Höh, H.** (2006). Die rolle der pachymetrie in der täglichen glaukomdiagnostik. In *Klinische Monatsblätter für Augenheilkunde* (Vol. 223, Issue 2, pp. 117–130). <https://doi.org/10.1055/s-2005-858724>

[113] **Iester, M., Mete, M., Figus, M., & Frezzotti, P.** (2009). Incorporating corneal pachymetry into the management of glaucoma. *Journal of Cataract and Refractive Surgery*, 35(9), 1623–1628. <https://doi.org/10.1016/j.jcrs.2009.05.015>



EKLER

EK-1 'Check Accuracy' Algoritması

```
def check_accuracy(model, setX, actual, print_images=True):
    predicted = np.array([int(x[0] > 0.5) for x in
model.predict(setX)])
    if print_images:
        rows = math.ceil(len(predicted)/10.)
        plt.figure(figsize=(20, 3 * rows))
        for i in range(len(predicted)):
            plt.subplot(rows, 10, i+1)
            plt.imshow(setX[i])
            plt.title("pred "+str(predicted[i])+" actual
"+str(actual[i]))

        confusion = confusion_matrix(actual, predicted, labels=[0,1])
        print(confusion)

        classification_Report = classification_report(actual, predicted,
labels = [0,1])
        print(classification_Report)
        tn, fp, fn, tp = confusion.ravel()
        print("True positive:", tp, ", True negative:", tn,
            ", False positive:", fp, ", False negative:", fn)

        print("Total accuracy:", np.sum(predicted==actual) /
len(predicted) * 100., "%")

    fpr, tpr, threshold = metrics.roc_curve(actual, predicted)
    roc_auc = metrics.auc(fpr, tpr)
    auc_keras = auc(fpr, tpr)
```

```
plt.subplots(1, figsize=(10,10))
plt.title('Receiver Operating Characteristic')
plt.plot(fpr, tpr, 'b', label = 'AUC = %0.2f' % roc_auc)
plt.plot([0, 1], ls="--")
plt.plot([0, 0], [1, 0] , c=".7"), plt.plot([1, 1] , c=".7")
plt.ylabel('True Positive Rate')
plt.xlabel('False Positive Rate')
plt.show()
```

```
return (tn, fp, fn, tp, auc_keras)
```