



GLOKOM HASTALIĞININ DERİN ÖĞRENME YÖNTEMİYLE ÖN TANISI

**2023
YÜKSEK LİSANS TEZİ
BİYOMEDİKAL MÜHENDİSLİĞİ**

Mahmoud NAES

**Tez Danışmanı
Dr. Öğr. Üyesi Hakan YILMAZ**

GLOKOM HASTALIĐININ DERİN ÖĐRENME YÖNTEMİYLE ÖN TANISI

Mahmoud NAES

**Tez Danışmanı
Dr. Öğr. Üyesi Hakan YILMAZ**

**T.C.
Karabük Üniversitesi
Lisansüstü Eğitim Enstitüsü
Biyomedikal Mühendisliği Anabilim Dalında
Yüksek Lisans Tezi
Olarak Hazırlanmıştır**

**KARABÜK
Haziran 2023**

Mahmoud NAES tarafından hazırlanan “GLOKOM HASTALIĞININ DERİN ÖĞRENME YÖNTEMİYLE ÖN TANISI” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Hakan YILMAZ

.....

Tez Danışmanı, Biyomedikal Mühendisliği Anabilim Dalı

Bu çalışma, jürimiz tarafından oy birliği ile Biyomedikal Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 22/06/2023

Unvanı, Adı SOYADI (Kurumu)

İmzası

Başkan : Doç. Dr. Daver ALİ (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Hakan YILMAZ (KBÜ)

.....

Üye : Dr. Öğr. Üyesi Murat KORKMAZ (İÜ)

.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile Yüksek Lisans derecesini onamıştır.

Prof. Dr. Müslüm KUZU

.....

Lisansüstü Eğitim Enstitüsü Müdürü

“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”

Mahmoud NAES

ÖZET

Yüksek Lisans Tezi

GLOKOM HASTALIĞININ DERİN ÖĞRENME YÖNTEMİYLE ÖN TANISI

Mahmoud NAES

Karabük Üniversitesi

Lisansüstü Eğitim Enstitüsü

Biyomedikal Mühendisliği Anabilim Dalı

Tez Danışmanı:

Dr. Öğr. Üyesi Hakan YILMAZ

Haziran 2023, 41 sayfa

Glokom hastalığı, dünyada görme kaybının ana nedenlerinden biri olarak tanımlanan geri dönüşü olmayan nörodejeneratif bir göz hastalığıdır. Bu göz hastalığı optik sinir lifi hasarı ile karakterize edilmektedir. Ana risk faktörü olarak bilinen göz içi basıncı yeterince yükseldiğinde optik sinire zarar vermektedir. Glokom hastalığı erken teşhis ve tedavi edilmezse geri dönüşü olmayan körlüğe neden olabilmektedir. Günümüzde yapay zekâ yaklaşımları neredeyse tüm alanlarda uygulanmaktadır. Sağlık alanında da derin öğrenme ve makine öğrenimi yaklaşımlarının kullanımı gittikçe artmaktadır. Makine öğrenimi ve derin öğrenme yaklaşımları yardımı ile hastalık teşhisi, izlemesi ve tıbbi görüntü analizi gibi görevlerde dikkate değer sonuçları göstermektedir. Bu tez çalışmasında, genelde göz hastalıklarının ve bilhassa glokom hastalığının tanısı konusunda yardımcı olan fundus görüntüleri kullanarak glokom hastalığı ön tanısı koyan özgün bir derin öğrenme modeli geliştirilmiştir. Fundus görüntüleri yardımı ile gözün iç yapısı incelenebilmektedir. Bu tez çalışmasının kapsamında halka açık olan Kaohsiung Chang Gung (KCG) Memorial Hastanesi, High Resolution Fundus (HRF),

Drishti-GS1 ve Ocular Disease Intelligent Recognition (ODIR) veri setlerinden yaklaşık 4600 renkli fundus görüntüsü toplanmıştır. Toplanan görüntüler glokomlu ve sağlıklı olarak etiketlenmiş durumdadır. Görüntülere gerekli görüntü işleme teknikleri uygulandıktan sonra bu tez çalışması kapsamında oluşturulan evrişimli sinir ağı (CNN) modelinde kullanılmıştır. Geliştirilen modelin performansını değerlendirmek amacıyla doğruluk, duyarlılık, kesinlik, AUC, özgüllük, MCC ve F1-skoru metrikleri hesaplanmıştır. Sonuç olarak doğruluk, duyarlılık, kesinlik ve özgüllük sırasıyla %99.03 (± 1.53), %97.64 (± 3.21), %98.59 (± 2.84) ve %99.52 (± 0.91) olarak hesaplanmıştır. Elde edilen sonuçların literatürdeki diğer çalışmalara göre yüksek olduğu görülmüştür.

Anahtar Sözcükler : Glokom, Glokom Hastalığı Ön Tanısı, Göz Hastalıkları, Derin Öğrenme, CNN

Bilim Kodu : 92.5.17

ABSTRACT

M.Sc. Thesis

PRE-DIAGNOSIS OF GLAUCOMA DISEASE WITH DEEP LEARNING METHODS

Mahmoud NAES

**Karabük University
Institute of Graduate Programs
Department of Biomedical Engineering**

Thesis Advisor:

Assist. Prof. Dr. Hakan YILMAZ

June 2023, 41 pages

Glaucoma is a neurodegenerative ocular disorder and one of the leading causes of vision impairment worldwide. Damage to optic nerve fibers that occurs due to elevating intraocular pressure to high levels characterizes glaucoma. Early diagnosis and treatment are crucial in preventing the irreversible blindness associated with glaucoma. In recent years, artificial intelligence approaches, particularly deep learning, and machine learning, have been applied in almost all fields, including healthcare. These methodologies have exhibited remarkable capabilities in disease diagnosis, monitoring, and medical image analysis. In this thesis, a novel deep-learning model has been developed specifically for the pre-diagnosis of glaucoma using fundus images. Fundus images are valuable tools for detecting various eye ailments, including glaucoma. They enable examination of the internal structure of the eye. For this thesis, we collected a dataset consisting of around 4600 colour fundus images from multiple open-source datasets. This dataset includes Kaohsiung Chang

Gung (KCG) Memorial Hospital, High-Resolution Fundus (HRF), Drishti-GS1, and Ocular Disease Intelligent Recognition (ODIR) datasets. These images were labeled as either glaucoma or healthy cases. After applying appropriate image processing techniques, a convolutional neural network (CNN) model was employed, specifically designed for this thesis. We calculated some evaluation metrics for measuring the ability of the model to classify images into glaucoma and healthy categories. These metrics include accuracy, sensitivity, precision, the area under the curve (AUC), specificity, Matthew's correlation coefficient (MCC), and the F1-score. As a result, accuracy, sensitivity, precision, and specificity were 99.03% (± 1.53), 97.64% (± 3.21), 98.59% (± 2.84), and 99.52% (± 0.91), respectively. These results surpassed those reported in previous studies.

Key Words : Glaucoma, Glaucoma Detection, Eye Diseases, Deep Learning, CNN
Science Code : 92.5.17

TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandıęım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında őekillendiren sayın hocam Dr. Öğr. Üyesi Hakan YILMAZ'a sonsuz teşekkürlerimi sunarım.

Maddi ve manevi hiçbir desteęini esirgemeyen ve benimle ilgilenerek bu günlere gelmemde katkıda bulunan sevgili aileme çok teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ.....	xi
ÇİZELGELER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ	xiii
BÖLÜM 1	1
GİRİŞ	1
BÖLÜM 2	3
GLOKOM HASTALIĞI.....	3
2.1. GLOKOM HASTALIĞI TEŞHİSİNDE KULLANILAN TESTLER	4
2.2. GLOKOM HASTALIĞI TİPLERİ.....	5
2.3. FUNDUS GÖRÜNTÜLERİ.....	6
BÖLÜM 3	7
YAPAY ZEKÂ VE GLOKOM HASTALIĞI.....	7
3.1. MAKİNE ÖĞRENME YAKLAŞIMLARI.....	8
3.2. DERİN ÖĞRENME YAKLAŞIMLARI.....	9
BÖLÜM 4	13
MATERYAL VE METOT	13
4.1. KULLANILAN VERİ SETLER	13
4.1.1. KCG Memorial Hastanesi Veri Seti	14
4.1.2. HRF Veri Seti	14

	<u>Sayfa</u>
4.1.3. Drishti-GS1 Veri Seti.....	14
4.1.4. ODIR Veri Seti	14
4.2. GÖRÜNTÜLERİN ÖN İŞLEMESİ	15
4.3. EVRİŞİMLİ SİNİR AĞLARI	16
4.3.1. Evrişim Katmanı	17
4.3.2. Aktivasyon Katmanı	18
4.3.3. Havuzlama Katmanı.....	18
4.3.4. Bırakma (Dropout) Katmanı	19
4.3.5. Batch Normalizasyon (BN) Katmanı.....	19
4.3.6. Flatten Katmanı.....	20
4.3.7. Tam Bağlantılı (Fully Connected) Katmanı	20
4.4. HİPER PARAMETRELERİN OPTİMİZASYONU	20
4.5. GELİŞTİRİLEN MODELİN MİMARİSİ	21
4.5.1. Çapraz Doğrulama	23
4.6. MODELİN PERFORMANS ÖLÇÜLERİ	24
BÖLÜM 5	27
BULGULAR VE TARTIŞMA	27
5.1. ÖNERİLEN MODEL İLE ELDE EDİLEN BULGULAR	27
5.2. TARTIŞMA	32
BÖLÜM 6	35
SONUÇLAR VE ÖNERİLER	35
KAYNAKLAR	37
ÖZGEÇMİŞ	41

ŞEKİLLER DİZİNİ

Sayfa

Şekil 2.1. Glokom hastalığı oluşumu [4]	3
Şekil 2.2. Renkli fundus görüntüsü	6
Şekil 3.1. makine öğrenme yaklaşımı	8
Şekil 3.2. Derin öğrenme yaklaşımı	9
Şekil 4.1. Kullanılan veri setlerin örnekleri	13
Şekil 4.2. Görsel korteksi çalışma mantığı [32]	16
Şekil 4.3. Convolution işlemi	17
Şekil 4.4. Havuzlama çeşitleri	19
Şekil 4.5. Modelin yapısı	22
Şekil 4.6. Sınıflar dağılım grafiği	23
Şekil 4.7. Karışıklık matrisi	24
Şekil 5.1. Tahmin sonuçları	28
Şekil 5.2. Modelin karışıklık matrisi	28
Şekil 5.3. ROC eğrisi	29
Şekil 5.4. Kesinlik-Duyarlılık eğrisi	29
Şekil 5.5. 10-katlı Stratified Shuffle Split Doğruluk sonucu	31

ÇİZELGELER DİZİNİ

	<u>Sayfa</u>
Çizelge 2.1. Glokom hastalığı sınıflandırması ve tipleri.....	5
Çizelge 4.1. Aktivasyon fonksiyonları.....	18
Çizelge 5.1. Elde edilen sonuçlar	30
Çizelge 5.2. Kullanılan veri setlerinin ayrı olarak değerlendirmesi.....	31
Çizelge 5.3. Aynı veri setleri kullanan çalışmalarla karşılaştırması	33
Çizelge 5.4. Farklı çalışmalarla Karşılaştırması	34

SİMGELER VE KISALTMALAR DİZİNİ

SİMGELER

- mmHg : millimeters of mercury (milimetre cıva)
 $\sigma(x)$: Sigmoid

KISALTMALAR

- HRF : High Resolution Fundus (Yüksek Çözünürlüklü Fundus)
ODIR : Ocular Disease Intelligent Recognition (Göz Hastalıkları Akıllı Tanıma)
CNN : convolutional Neural Network (Evrışimli Sinir Ağı)
AUC : Area Under Curve (Eğri Altındaki Alanı)
MCC : Matthews Correlation Coefficient (Matthews Korelasyon Katsayısı)
VGG : Visual Geometry Group (Görsel Geometri Grubu)
RNFL : Retinal Nerve Fiber Layer (Retina Sinir Lifi Tabakası)
OCT : Optic Coherence Tomography (Optik Koherens Tomografi)
AI : Artificial intelligence (Yapay Zekâ)
CDR : Cup-to-Disc Ratio (Kap Disk Oranı)
MLP : Multi Layer Perceptron (Çok Katmanlı Algılayıcı)
SVM : Support Vector Machine (Destek Vektör Makinesi)
MATLAB : Matrix Laboratory (Matris Laboratuvarı)
VCDR : Vertical Cup-Disc Ratio (Dikey Kupa Disk Oranı)
ISNT : Inferior Superior Nasal Temporal (Alt Üst Nazal Temporal)
DL : Deep Learning (Derin Öğrenme)
VF : Visual Field (Görsel Alanı)
RF : Random Forest (Rastegale Ormanı)
KNN : K-Nearest Neighbours (En Yakın Komşu)
RCNN : Region-based Convolutional Neural Network (Bölgesel Evrışimli Sinir Ağı)

DCNN	: Deep Convolutional Neural Network (Derin Evriřimli Sinir Ađı)
LGN	: Lateral Geniculate Nucleus (Yan Genikulat ekirdek)
IT	: Inferior Temporal Cortex (Alt Temporal Korteks)
ReLU	: Rectified Linear Unit (Dođrultulmuř Dođrusal Birim)
BN	: Batch Normalization (Batch Normalizasyon)
SGD	: Stochastic Gradient Descent (Stokastik Gradyan İniř)
SSS	: Stratified Shuffle Split (Katmanlı Karıřık Bölme)
TP	: True Positive (Dođru/Gerek Pozitif)
FP	: False Positive (Yanlıř Pozitif)
TN	: True Negative (Dođru/Gerek Negatif)
FN	: False Negative (Yanlıř Negatif)
ROC	: Receiver Operating Characteristic (Alıcı İřletim Karakteriřtiđi)
FPR	: False Positive Rate (Yanlıř Pozitif Oranı)
PRC	: Precision-Recall Curve (Kesinlik Duyarlılık Eđrisi)

BÖLÜM 1

GİRİŞ

Glokom hastalığı, gözdeki optik sinirin zarara uğradığında oluşan kronik bir göz hastalığıdır. Glokom hastalığı geri dönüşü olmayan körlüğün ana sebeplerinden biridir. Son istatistiklere göre dünya çapında yaklaşık 80 milyon kişi glokom hastalığından etkilenmektedir [1]. Türkiye'deki istatistiklere göre 40 yaş üzeri her 100 kişiden 1'i glokom hastalığı geçirmektedir [2]. Glokom hastalığının çok farklı tipleri vardır. Ancak, en yaygın olanı birincil açık açılı glokomdur.

Glokom hastalığı tanısı koyulurken farklı testler ve yöntemler incelenmektedir. İncelenen yöntemlerin amacı, gözün iç yapısını ve optik sinirinin durumunu değerlendirmektir. Fundus görüntüleme tekniği bu yöntemlerin arasındadır. Fundus görüntüleme yönteminde gözün iç yapısı görüntülenir ve glokom hastalığının olup olmadığı kararının verilmesinde yaygın olarak kullanılan bir tekniktir. Bununla birlikte, fundus görüntülerinin deneyimli göz doktorları tarafından bile yorumlanması zor olduğundan dolayı otomatik ve objektif yöntemlere ihtiyaç duyulmaktadır.

Son yıllarda tüm alanlarda olduğu gibi sağlık alanında da yapay zekâ yaklaşımları kullanımı yaygınlaşmıştır. Derin öğrenme ve makine öğrenimi modelleri hastalıkların tespiti ve sınıflandırması da dahil olmak üzere çeşitli tıbbi görüntü analizi ve hastalıklarının izlenmesi gibi görevlerde büyük rol oynamaktadır. Derin öğrenme modelleri, insan müdahalesi olmaksızın görüntülerden karmaşık özellikleri öğrenip doğru tahminler yapabilmektedir.

Son zamanlarda göz hastalıklarının fundus görüntüleri ile teşhisi ve sınıflandırması ile ilgili çalışmaların sayısı artmaktadır. Bu çalışmalar, göz hastalıklarının ön tanısı konusunda yüksek doğruluğa ve başarılı sonuçlara ulaşmaktadır.

Bu tez çalışmasının amacı, dünyadaki görme bozuklukları sayısında önemli rol oynayan glokom hastalığının, fundus görüntüleri kullanarak ve bu çalışma için oluşturulup eğitilmiş derin öğrenme modeli ile ön tanısını sağlamaktır. Bu çalışmanın kapsamında açık kaynaklı veri setleri kullanarak özgün bir evrişimli sinir ağı (CNN) modeli geliştirilmiştir. Önerilen modelin bu çalışma için oluşturulması çalışmaya değer katmaktadır. Literatürde geçen benzer çalışmaların çoğu önceden eğitilmiş VGG16 ve EfficientNet gibi CNN modelleri kullanmaktadır. Önerilen model ile elde edilen sonuçlar diğer çalışmalara göre yüksektir.

Bu tez çalışmanın giriş bölümünde tez konusu ile ilgili özet bilgiler, çalışmanın amacı ve kapsamı hakkında bilgiler verilmiştir. Çalışmanın ikinci bölümünde glokom hastalığının tanımı, belirtileri, tipleri ve fundus görüntüleri anlatılmıştır.

Çalışmanın üçüncü bölümünde glokom hastalığının yapay zekâ yaklaşımları ile tanısı ile ilgili literatürde geçen çalışmalardan bahsedilmiştir. Çalışmanın dördüncü bölümünde bu çalışmada kullanılan materyal ve yöntemleri detaylıca anlatılmıştır.

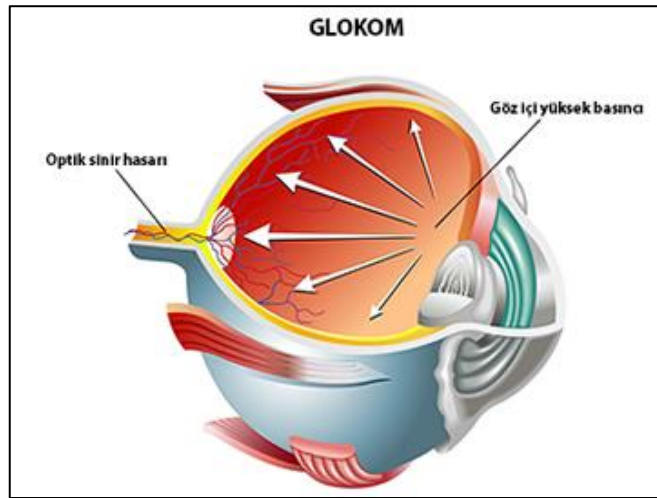
Beşinci bölümde bu tez çalışması kapsamında oluşturulan model ile elde edilen sonuçlar ve literatürdeki benzer çalışmaları ile karşılaştırılmasından bahsedilmiştir. Çalışmanın altıncı bölümünde ise bu tez çalışmasının sonuçları özetleyerek sonraki çalışmalara yönelik öneriler verilmiştir.

BÖLÜM 2

GLOKOM HASTALIĞI

Glokom hastalığı, göz ile beyin arasındaki iletişimden sorumlu olan optik sinirin hasar gördüğü yaygın bir göz hastalığıdır. Genellikle, gözün ön kısmında sıvı birikmesinden kaynaklanıp göz içi basıncı artırmaktadır [3].

Göz, iç yapılarını besleyen sulu hümör (aqueous humor) olarak bilinen bir sıvı içermektedir. Bu sıvı gözün arka kısmında (iris arkasında) üretilip trabeküler ağ örgüsü vasıtasıyla gözün ön kısmına sızdırılmaktadır. Bazı durumlarda, gözdeki drenaj sisteminde oluşan bozukluklar nedeniyle üretilen sıvı sızmasında anormallikler olup göz içi basıncı yükselmesine neden olur. Yükselen göz içi basıncından dolayı optik sinir başında hasar oluşur ve böylece gözü beyne bağlayan ve görmekten sorumlu olan sinir bozulabilmektedir. Şekil 2.1’de glokom hastalığı oluşumu gösterilmiştir. Öte yandan, göz içi basıncı normal seviyesinde olabilir, ancak gözün sinir liflerini yetersiz kan beslediğinden dolayı glokom yine de oluşabilmektedir. Bunun neticesinde, glokom hastalığı erken teşhis ve tedavi edilmez ise görme kaybına neden olabilmektedir.



Şekil 2.1. Glokom hastalığı oluşumu [4]

Glokom hastalığı özellikle erken aşamalarında belirtileri olmadığından dolayı zor teşhis edilmektedir. Klinikte teşhis edilirken birkaç ölçüm ve testler incelenmektedir. Bu testler, gözün iç yapısını ve onu besleyen damarların ve sinirlerin durumunu değerlendirmeyi amaçlamaktadır. Onun yanı sıra, hastanın şikayetleri, geçmişteki sağlık durumu ve ailesinde glokom hastalığı olup olmadığı da değerlendirilmektedir [5]. İstenilen testler aşağıda bahsedilmiştir.

2.1. GLOKOM HASTALIĞI TEŞHİSİNDE KULLANILAN TESTLER

Bu bölümde glokom hastalığı teşhisinde önemli rol oynayan ölçümler ve testler hakkında bilgi verilmiştir.

- 1. Göz içi basıncı değerlendirmesi:** Yukarıda bahsedildiği gibi göz içi basıncı yüksekliği glokomu karakterize eden bir ölçümdür. Genellikle tonometri kullanılarak ölçülmektedir. Normal değeri 11-21 mmHg olmakla birlikte çeşitli sebeplerden dolayı kişiden kişiye değişebilir ve optik sinir başında hasar oluşturmayacak bir değer ile değerlendirilmelidir [5,6].
- 2. Optik sinir başı ve retina sinir lifi tabakası (RNFL) değerlendirmesi:** Glokom hastalığı teşhisinde optik sinir başında oluşan hasar en belirgin parametredir [6]. Tüm glokom hastalığı tipleri optik sinir başı bozulması, optik sinir disk çukurlaşması ve RNFL inceltmesi ile tanımlanmışlardır. Erken glokom hastalığı gözün yapısal değişiklikleri ve optik sinirin hasarı Optik Koherens Tomografi (OCT) ile görüntüleyip tanı koyulmaktadır [5].
- 3. Görme alanı testi:** Göz sabit bir noktaya bakarken üç boyutlu uzayda görebildiği tüm alanına görme alanı denir. Glokom hastalığı ilerledikçe optik sinir başı ve RNFL hasarı fazla olur. O yüzden görme alanı ve görme keskinliği de zayıflamaktadır. İleri glokomdaki fonksiyonel değişiklikler görme alanı testi ile tespit edilebilmektedir [5–7].

Yukarıdaki bahsedilen testler ve diğerleri glokom hastalığı teşhisinde göz doktorları etkin rol oynamaktadır.

2.2. GLOKOM HASTALIĞI TIPLERİ

Birkaç farklı glokom türü vardır. Her glokom türü farklı olmasına rağmen çoğunun erken belirtileri yoktur [8]. En yaygın olanı birincil açık açılı glokom olarak adlandırılmaktadır [5,9]. Glokom hastalığı için farklı sınıflandırma yöntemleri bulunmaktadır [10]. Çizelge 2.1’de glokom hastalığı sınıflandırma yöntemleri ve türleri anlatılmıştır.

Çizelge 2.1. Glokom hastalığı sınıflandırması ve tipleri

Glokom Hastalığı Sınıflandırması ve Tipleri		
Sınıflandırma Kriterleri	Tipler	Özellikler
Yaş	Konjenital glokom	Doğumdan 10 yaşına kadar
	Juvenil glokom	10 yıldan 35 yıla kadar
	Yetişkin	35 yaşından sonra
Nedeni	Birincil	Tanımlanamayan neden
	İkincil	Diğer nedenlere bağlı olarak oluşur. (Travma, ilaçlar, diğer göz hastalıkları, göz içi ameliyatları vb. nedeniyle oluşan glokom hastalıkları)
Drenaj Sisteminin Tıkanma Yeri	Açık açılı glokom	Trabeküler ağ sistemine ulaşmak için sulu hümanın akışını hiçbir şey engellemez, ancak trabeküler ağ sistemi boşluklarındaki anormallikler nedeniyle sıvının çıkışı engellemektedir. Yavaş gelişmektedir [9].
	Açı kapanması glokomu	Gözün drenaj açısı tamamen kapalıdır. Hızla gelişmektedir [9].

2.3. FUNDUS GÖRÜNTÜLERİ

Fundus görüntüleme, görüntüleme düzlemine yansıtılan üç boyutlu ve yarı saydam retina dokularının yansıtılan ışığın yardımıyla iki boyutlu görüntüsünü elde etmek için kullanılan süreçtir [11]. Diğer bir deyişle, retina, optik sinir ve kan damarları dahil olmak üzere gözün iç yüzeyinin görüntülerini elde etme işlemi fundus görüntüleme olarak adlandırılmaktadır.

Fundus görüntüleme gerçekleştirebilmek için renkli fundus görüntüleme ve floresan anjiyografi fundus görüntüleme gibi farklı teknikler bulunmaktadır [11]. Bu tez çalışmasında sadece renkli fundus görüntüleri kullanılmıştır.

Renkli fundus görüntüleme, görüntü yoğunlukları, sensörün spektral hassasiyeti tarafından belirlendiği şekliyle yansıyan kırmızı, yeşil ve mavi dalga bantlarının miktarını temsil etmektedir [11]. Şekil 2.2’de renkli fundus görüntü örneği gösterilmiştir.

Fundus görüntüleri, oftalmolojide glokom hastalığı dahil olmak üzere çeşitli göz hastalıklarının tanı ve izlenmesinde yaygın olarak kullanılmaktadır. Fundus görüntüleri, glokom hastalığı teşhisinde önemli rol oynayan retina ve optik sinirin yapısı ve işlevi hakkında göz doktorlarına önemli bilgiler vermektedir.



Şekil 2.2. Renkli fundus görüntüsü

BÖLÜM 3

YAPAY ZEKÂ VE GLOKOM HASTALIĞI

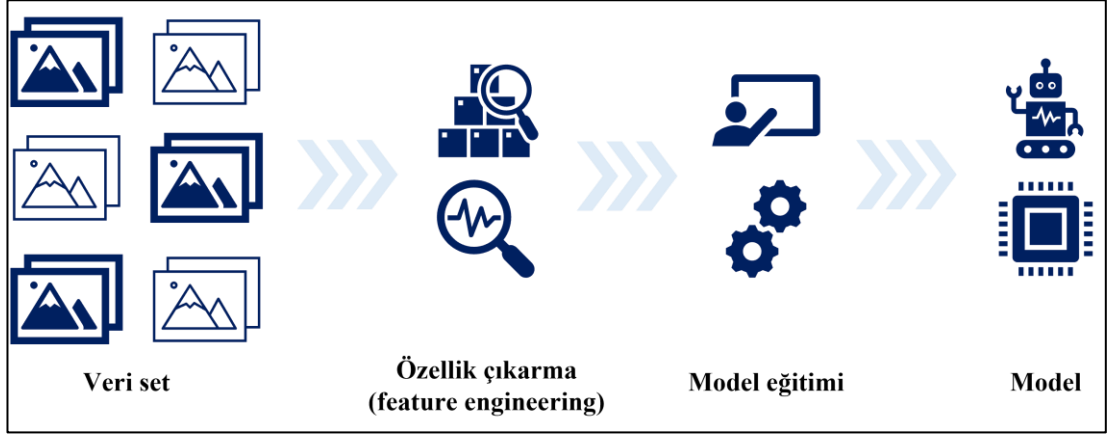
Yapay zekâ, normalde insan zekâsı gerektiren görevleri gerçekleştirebilen bir bilgisayar sistemidir [12]. Son zamanlarda neredeyse tüm alanlara uygulanan yapay zekâ yaklaşımları sağlık alanlarında da kullanılmaktadır. Tıbbi görüntülerin analizi, hastalıkların ön teşhisi, sınıflandırması ve izlemesi gibi uygulamaları yapay zekâ yaklaşımları ile daha hızlı ve yüksek doğruluklara sahip hale gelmiştir.

Yapay zekâ, göz hastalıklarının ön tanısı ve sınıflandırması sırasında yardımcı olarak kullanılabilir. Örneğin, yapay zekâ algoritmaları, yaşlılıkla ilişkili makula dejenerasyonu, diyabetik retinopati ve glokom gibi belirli hastalıklara işaret eden retinal görüntülerdeki öznelikleri tanımlamak için eğitilebilir.

Onun sayesinde, göz hekimlerinin daha doğru tanımlar koymasına ve potansiyel olarak hastalıkların daha erken aşamada farkedilmelerine yardımcı olabilmektedir. Ayrıca, yapay zekâ, hastalığın ilerlemesini izlemek ve tedavilerin etkililiğini öngörmek için de kullanılabilir.

Bu bölümde glokom hastalığı teşhisinde kullanılan makine öğrenmesi ve derin öğrenme yaklaşımları literatür özeti verilmiştir.

3.1. MAKİNE ÖĞRENME YAKLAŞIMLARI



Şekil 3.1. Makine öğrenmesi yaklaşımı

Makine öğrenmesi, insanların öğrenme yoluna benzeyerek veriler ve algoritmalarından yararlanarak doğruluğunu aşamalı olarak artıran bir yapay zekâ dalı olarak tanımlanabilir. İstatistiksel yöntemlerin kullanılmasıyla sınıflandırmalar veya tahminler yapmak için eğitilmektedir. Makine öğrenmesinde veri setlerinden özellik çıkarma işlemi manuel olarak yapılmaktadır. Şekil 3.1’de makine öğrenmesi yaklaşımı anlatılmıştır.

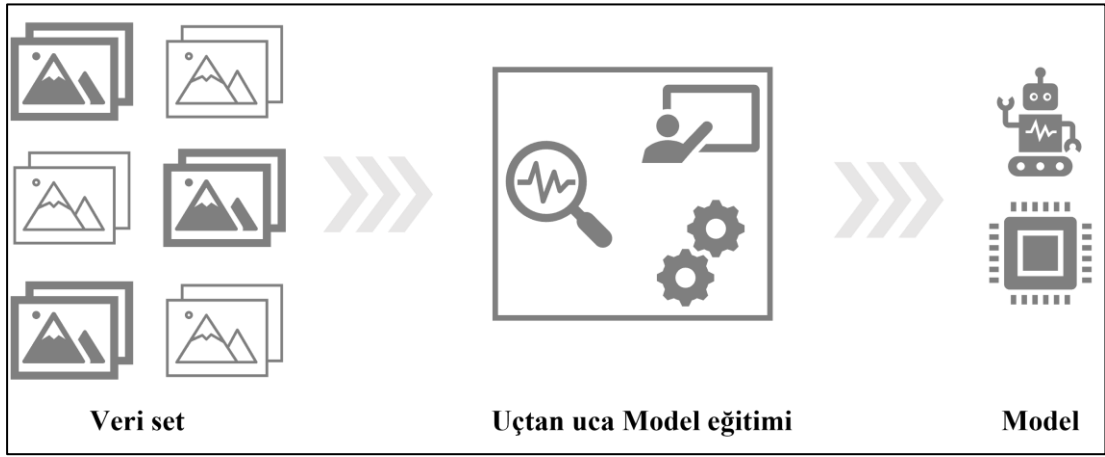
Aşağıda, literatürde glokom hastalığının makine öğrenmesi yaklaşımlarıyla ön tanısı ile ilgili yapılan bazı çalışmalar özetlenmiştir.

Kausu vd. (2018) çalışmada, zamanla değişmeyen özellik kap disk oranı (CDR) ve anizotropik çift ağaç karmaşık dalgacık dönüşümü (anisotropic dual-tree complex wavelet transform) özelliklerine dayanan yeni bir glokom tanımlama yöntemi geliştirmiştir. Optik disk bölütleme, Fuzzy C-Means kümeleme yöntemi kullanarak yapılr ve optik kap bölütleme için Otsu'nun eşikleme kullanılmıştır. Sonuçlar olarak, önerilen yöntemin mevcut çalışmalara kıyasla klinik olarak anlamlı kabul edilen çok katmanlı bir algılayıcı (MLP) modeli kullanarak %98 hassasiyeti ve %97.67 doğruluk oranına ulaştığı gösterilmiştir [13].

Pathan vd. (2021) önerdiği çalışmada, glokom tespiti için bilgisayar destekli bir teşhis sistemi geliştirilmiştir. İlk olarak, ilgilenen bölge ile arka plan arasında var olan azaltılmış değişkenliğin üstesinden gelen optik disk ve optik kap için otomatik

segmentasyon algoritmaları geliştirilmiştir. Ondan sonra, sınıflandırma işlemi için SVM algoritması kullanıp halka açık DRISHTI veri seti üzerinde uygularken %96.66'lık bir doğruluk, %100'lük bir hassasiyet ve %95'lik bir özgüllük elde edilmiştir. Ancak, özel bir veri seti üzerinde uygulandığı zaman doğruluk, hassasiyet ve özgüllük değerleri sırasıyla, %90, %93.47 ve %91,2'e düşmüştür [14].

3.2. DERİN ÖĞRENME YAKLAŞIMLARI



Şekil 3.2. Derin öğrenme yaklaşımı

Derin öğrenme, makine öğrenmesinin alt alanı olarak tanımlanabilmektedir. Makine öğrenmesinde veri setlerinden özellik çıkarma işlemi manuel olarak yapılırken derin öğrenmede otomatik olarak yapılmaktadır. Bu yaklaşım sayesinde özellik mühendisliğinin yükünü neredeyse tamamen ortadan kaldırıp bir modeli doğrudan ham verilerden eğiterek daha düzenli bir süreç sağlamaktadır [15]. Şekil 3.2’de derin öğrenme yaklaşımı gösterilmiştir.

Aşağıda, literatürde glokom hastalığı derin öğrenme ile ön tanısı ile ilgili yapılan çalışmalar özetlenmiştir.

Yıldırım ve Altunbey Özbay (2022) çalışmasında, fundus görüntülerinden glokom tespiti için ‘AlexNet’, ‘ResNet-18’, ‘VGG16’, ‘SqueezeNet’ ve ‘GoogleNet’ gibi önceden eğitilmiş Evrişimli Sinir Ağı (CNN) mimarileri kullanılmıştır. Kullanılan mimarilerden doğruluk, duyarlılık, özgüllük ve F_1 skoru değerleri gibi elde edilen farklı performans metrikleri hesaplanmıştır. Sonuç olarak, test veri setinde en iyi duyarlılık değeri %97.96 ‘VGG16’ mimarisi ile elde edilmiştir. Ancak, özgüllük,

doğruluk ve F₁ skoru için en iyi değerler sırasıyla %98.97, %97.98 ve %98 'GoogleNet' ile elde edilmiştir [16].

Uçar (2021) çalışmasında, yeni oluşturulan veri setinin fundus görüntüleri kullanarak otomatik glokom tespiti için evrişimli sinir ağları kullanılmıştır. Sınıflandırma problemlerinde en sık kullanılan mimariler olan 'VGG16', 'Inception-V3', 'EfficientNet', 'DenseNet', 'ResNet 50' ve 'MobileNet' mimarileri denenmiştir. Denemelerin sonucunda 'DenseNet' mimarisinin %96,19 ile en yüksek doğruluk oranına ulaştığı görülmüştür [17].

Duru vd. (2020) çalışmasında, 'MATLAB' derin Evrişimli Sinir Ağı (CNN) kullanarak glokom hastalığının erken tespiti için farklı prosedür ve yöntemleri denemiştir. Derin Evrişimli Sinir Ağı'nda, bir gizli katman, 16 giriş nöronu ve sağlıklı ya da değil şeklinde 2 çıktı kullanılmıştır. Veriler, %70 eğitim için %15 doğrulama ve %15 test için olacak şekilde eğitim ve test veri setlerine bölünmüştür. Elde edilen doğruluğu ise %92.78 olarak hesaplanmıştır [18].

Thanh vd. (2020) çalışmasında, 'Darknet YOLO' mimarisi, öncelikle optik diski ve optik kabı algılamak ve eğitmek için kullanıp gerçek zamanlı bir glokom tarama sistemi oluşturulmuştur. Dikey Kupa Disk Oranı (VCDR 0,6'dan fazla) ve ISNT¹ kuralı uyması dahil olmak üzere glokom teşhisi kriterlerinin uygulanmasına dayanarak, glokom uzmanları tarafından etiketlenmiş 1677 sağlıklı ve glokom optik disk görüntüsü bir eğitim veri setinde oluşturulmuştur. Doğrulama veri setindeki diğer 500 görüntü AI algoritması ile sınıflandırılmıştır. Hassasiyet, özgüllük, doğruluk ve kesinlik sırasıyla %92.68, %91.34, %92.0 ve %91.2 olarak elde edilmiştir [19].

¹ Normal gözlerdeki nöroretinal çerçeve özgün biçim göstermektedir. Genellikle, alt kenarda en geniştir, ardından üst ve nazal kenarlar gelir ve temporal disk bölgesinde en incedir. Bu kenar genişliği modeli ISNT kuralı olarak bilinmektedir (inferior ≥ superior ≥ nazal ≥ temporal).

Diaz-Pinto vd. (2019) arařtırmasında, 1707 fundus görüntüleri kullanarak otomatik glokom teşhisi için 'VGG16', 'VGG19', 'InceptionV3', 'ResNet 50' ve 'Xception' beş farklı 'ImageNet' eğitilmiş derin öğrenme modelleri değerlendirilmiştir. Elde edilen doğrulukları sırasıyla %89.84, %90.69, %90, %90.29 ve %89.77'dir. modelleri değerlendirmek için 10-kat çapraz doğrulama (10-fold cross validation) yöntemi kullanılmıştır [20].

Chen vd. (2015) konferans bildirisinde, otomatik glokom teşhisi için evrişimli sinir ağı ile bir derin öğrenme (DL) modeli geliştirilmiştir. Evrişimli sinir ağları (CNN) gibi derin öğrenme sistemleri glokom ve glokom olmayan görüntüleri ayırt etmek için kullanılmaktadır. Önerilen derin öğrenme mimarisi dört evrişimli katman ve iki tam bağlantılı katman olmak üzere toplam altı öğrenilmiş katmandan oluşmaktadır. Glokom teşhisinin performansını daha da artırmak için bırakma (Dropout) ve veri artırma (data augmentation) stratejileri kullanılmıştır. ORIGA ve SCES veri setleri üzerinde kapsamlı deneyler yapılmıştır. İki veri tabanında performansı değerlendirmek için eğri altındaki alanı (AUC) hesaplanıp sırasıyla 0,831 ve 0,887 elde edilmiştir [21].

Li vd. (2018) makalesinde, görsel alanlı (VF) test sonuçlarına dayalı olarak glokomlu ve glokom olmayan sınıflandırması yapabilen CNN geliřtirmek için Çin'deki 3 farklı göz hastalıkları merkezinden görsel alanlı testleri toplanmıştır. 1352 hastadan alınan toplam 4012 görüntü, 3712'si eğitim ve 300'ü doğrulama olmak üzere bölünmüştür. Sonuç olarak, doğrulama setinde doğruluk, özgüllük ve duyarlılık sırasıyla 0,876 0,826 ve 0,932 elde edilmiştir. Ayrıca, destek vektör makinesi (SVM), rastgele orman (RF) ve k-en yakın komşu (KNN) olmak üzere üç geleneksel makine öğrenme algoritması da deneyerek sırasıyla 0,670, 0,644 ve 0,591 doğruluęu elde edilmiştir [22].

Ibrahim ve Hacıbeyoęlu (2020) makalesinde, 337 görsel değerlendirerek derin öğrenme yardımıyla glokom tanı karar sistemi oluşturulmuştur. Sonuç olarak, %97 doğruluęu elde edilmiştir [23].

Bajwa vd. (2019) arařtırmasında, önce optik diski bulan ve lokalize eden ardından onu sağlıklı veya glokomlu olarak sınıflandıran iki aşamalı yöntem kullanılmıştır. İlk

ařama Bölgesel Evriřimli Sinir Ađı (RCNN)'na dayanmakta ve bir retinal fundus görüntüsünden optik diskin lokalize edilmesinden ve çıkarılmasından sorumludur. İkinci aşama ise, çıkarılan diski sağlıklı veya glokomlu olarak sınıflandırmak için Derin Evriřimli Sinir Ađı (DCNN) kullanılmıřtır. Geliřtirilen model 7 veri setinde deđerlendirilip eđri altındaki alanı (AUC) 0,874 olarak bulunmuřtur [24].

BÖLÜM 4


MATERYAL VE METOT

Bu tez çalışmasında glokom hastalığı ile ilgili halka açık dört veri seti kullanılmıştır. Bu veri setleri, normal ve glokomlu olarak sınıflandırılmış renkli fundus görüntülerinden oluşmaktadır. Fundus görüntüleri, bölüm ikide bahsedildiği gibi glokom hastalığı başta olmak üzere diğer göz hastalıklarının teşhisinde önemli rol oynamaktadırlar. Toplanan görüntülere bazı görüntü işleme teknikleri uygulanıp geliştirilen modelde kullanılmak üzere uygun hale getirilmiştir. Geliştirilen modelin performansı farklı metriklerle değerlendirilmiştir.

Materyal ve metot bölümünde, veriler, verilerin hazırlanması, modelin yapısı ve değerlendirmesi ile ilgili detaylıca bilgi verilmiştir.

4.1. KULLANILAN VERİ SETLER

Bu tez çalışmasının kapsamında Kaohsiung Chang Gung (KCG) Memorial Hastanesi [25], High Resolution Fundus (HRF) [26], Drishti-GS1 [27] ve Ocular Disease Intelligent Recognition (ODIR) [28,29] veri setleri kullanılmıştır. Bu veri setlerinden 4598 renkli fundus görüntüsü toplanmıştır. Aşağıdaki alt bölümlerde her veri setinin özelliklerinden bahsedilmiştir. Şekil 4.1’de her veri setinden bir örnek gösterilmiştir.



Şekil 4.1. Kullanılan veri setlerin örnekleri

a) KCG Memorial Hastanesi [23] b) HRF [24] c) Drishti-GS1 [25] d) ODIR [27]

4.1.1. KCG Memorial Hastanesi Veri Seti

Tayvan'daki KCG Memorial Hastanesi'nden 899 glokomlu ve 551 sağlıklı toplam 1450 renkli fundus görüntüsü toplanmıştır. Görüntülerin orijinal boyutu 750X500 pikseldir. Görüntüler üzerindeki hasta bilgileri ve tüm metinler siyaha dönüştürülmüştür [25].

4.1.2. HRF Veri Seti

Bu veri seti, retinal fundus görüntüleri üzerinde otomatik bölütleme algoritmaları geliştirmek için bir araştırma grubu tarafından kurulmuştur. Halka açık bu veri setinde sağlıklı, glokomlu ve diyabetik retinopati'li olmak üzere üç sınıf bulunmaktadır. Her sınıfta sadece 15 yüksek çözünürlüklü renkli fundus görüntüsü vardır [26]. Görüntülerin orijinal boyutu 3504X2336 pikseldir. Bu tez çalışmasının kapsamında sadece sağlıklı ve glokomlu sınıfları kullanılmıştır.

4.1.3. Drishti-GS1 Veri Seti

Drishti-GS1 veri seti, Hindistan'daki Aravind göz hastanesinde toplanmıştır. Bu veri setinde 70 glokomlu ve 31 sağlıklı olmak üzere toplam 101 renkli fundus görüntüsü bulunmaktadır. Glokom hastası seçiminde klinik bulgulara göre klinik araştırmacılar tarafından yapılmıştır. Rutin refraksiyon testi yapılan ve glokomlu olmadığı saptanan hastalar normal sınıfı temsil edecek şekilde kabul edilmiştir [27].

4.1.4. ODIR Veri Seti

Pekin Üniversitesi ve Shangong Medical Technology Co. Ltd. tarafından düzenlenen göz hastalıklarının tanısı yarışması için 5000 renkli fundus görüntüsü verilmiştir. Bu veri seti, kooperatif hastanelerinde ve sağlık kurumlarında göz sağlığı muayenesi yapılan hastalardan oluşturulmuştur [29]. ODIR veri setindeki görüntüler normal ve 7 farklı göz hastalıkları olmak üzere toplam 8 kategoriye ayrılmıştır [28]. Bu tez çalışmasının kapsamında sadece normal ve glokomlu olan fundus görüntüleri kullanılmış ve veri setinden yaklaşık 3000 fundus görüntüsü alınmıştır.

4.2. GÖRÜNTÜLERİN ÖN İŞLEMESİ

Farklı veri setlerinden toplanan fundus görüntülerinin derin öğrenme modeline aktarılmadan önce özelliklerinin standart hale getirilmesi için farklı görüntü işleme teknikleri uygulanmıştır. İlk olarak, görüntülerin siyah arka planı alanını en aza indirmek için ve sadece retina bölgesine odaklayabilmek için görüntülere kırpma işlemi uygulanmıştır. Kırpma işlemi sadece KCG Memorial Hastanesi ve ODIR veri setleri için MATLAB ile yazılan kodlarla gerçekleştirilmiştir.

Daha sonra, derin öğrenme algoritmalarında görüntülerin kaynak tüketimini azaltmak amaçlı tüm görüntülere yeniden boyutlandırma (resize) işlemi yapıp daha küçük hale getirilmiştir. Tüm görüntülerin yeni boyutları 512X512 piksel olmuştur. Ancak bu durumda da modelin öğrenme süresi fazla olduğu için görüntülerin daha küçük boyutları (256X256 ve 128X128) kullanılmıştır. Böylece derin öğrenme modelin öğrenme süresi hızlandırılmıştır.

Son olarak, görüntülere normalizasyon işlemi uygulanmıştır. Veri normalizasyonu, her bir girdi parametresinin (bu durumda piksel) benzer bir veri dağılımına sahip olmasını sağlayan önemli bir adımdır. Eşitlik 4.1’de görüntü normalizasyonu ifade edilmiştir. Burada, I_N yeni görüntüyü, I orijinal görüntüyü, (Min ve Max) orijinal görüntünün yoğunluk aralığını (0-255) ve (New_{min} ve New_{max}) istenilen yeni yoğunluk aralığını (0-1) ifade etmektedir.


$$I_N = (I - Min) \frac{New_{max} - New_{min}}{Max - Min} + New_{min} \quad (4.1)$$

Normalizasyonun sonucu orijinal görüntülerinin piksel değerleri 0 ile 255 arasında dağılırken yeni görüntülerinin piksel değerleri 0 ile 1 arasında dağılmaktadır. Böylece, görüntülerdeki olası aykırı değerlerden kaynaklı olan olumsuz etkileri önlenmiştir.

4.3. EVRİŞİMLİ SİNİR AĞLARI

Evrışimli sinir ağı (CNN), evrişim yapılarıyla verilerden özellikler çıkarabilen bir tür ileri beslemeli (feed-forward) yapay sinir ağıdır. CNN, derin öğrenme alanındaki önemli ağlardan biridir. Bu ağlar, görüntü sınıflandırma işlemi başta olmak üzere diğer bilgisayarlı görü uygulamalarda kullanılmaktadır [30].

CNN, beynin görsel korteksinin incelenmesinden ortaya çıkmıştır. Görsel korteksteeki birçok nöronların küçük bir yerel alıcı alanı olduğundan dolayı yalnızca görsel alanın sınırlı bir bölgesinde bulunan görsel uyarılara tepki verebilmektedir. Farklı nöronların alıcı alanları üst üste gelip birlikte tüm görsel alanı kapsayabilmektedir. Bu süreçte, bazı nöronlar yalnızca yatay çizgilerin görüntülerine tepki verirken, diğerleri ise sadece farklı yönelimlere sahip çizgilere tepki verebilmektedir. Öte yandan, bazı nöronların geniş alıcı alanlarının olduğundan dolayı düşük seviyeli örüntülerin kombinasyonlarından oluşan karmaşık örüntülere tepki verebilmektedir. Bundan dolayı, üst düzey nöronların alt düzey nöronlarının çıktılarına dayandığı anlaşılmıştır. Bu güçlü mimari, görsel alanındaki her türlü karmaşık örüntüleri algılayabilmektedir [31]. Şekil 4.2’de bu süreç anlatılmıştır.



Şekil 4.2. Görsel korteksi çalışma mantığı [32]

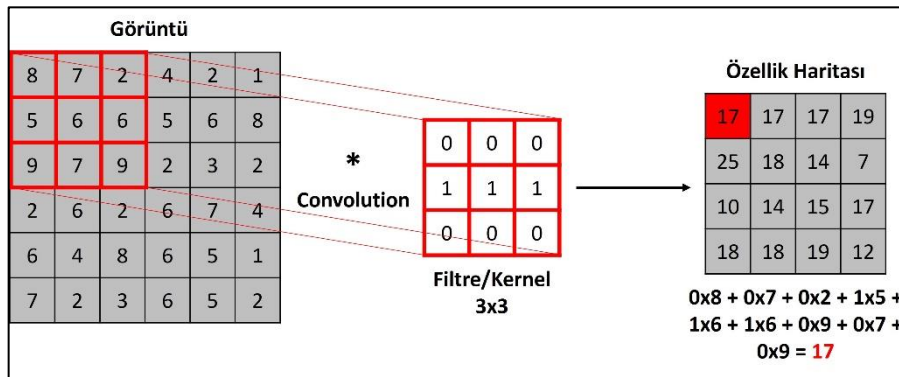
Evrışimli sinir ağları diğer ağlara (özellikle tam bağlantılı ağlara) göre birkaç önemli özelliğe sahiptir. İlk olarak, her bir nöron bir önceki katmanın tüm nöronlarına değil, yalnızca az sayıda nörona bağlıdır. Bu yerel bağlantılı özelliğin sayesinde hem modelin parametreleri azaltmış olur hem de yakınsamayı hızlandırmış olur [30]. CNN ait bir diğer özellik ise, ağırlık paylaşımıdır. Evrişim katmanda birden fazla filtre bulunmakta olup her filtre başına bir özellik haritası (feature map) oluşturmaktadır.

Özellik haritasındaki piksel başına bir nörona sahiptir ve o özellik haritasına ait tüm nöronlar aynı parametreleri (aynı ağırlıklar ve önyargı (bias) terimi) paylaşmaktadır. Bu özelliğin sayesinde, modeldeki parametre sayısını önemli ölçüde azaltmış olur. Ayrıca, CNN, görüntüde bir konumdaki bir örüntüyü tanımayı öğrendiğinde, başka herhangi bir konumdaki aynı örüntüyü tanıyabilmektedir [30,31,33]. CNN'in diğer önemli özelliği ise, havuzlama katmanı barındırmasıdır. Havuzlama katmanının amacı, evrişim katmanından sonuçlanan özellik haritalarına alt örnekleme işlemi yapıp boyutları düşürmektir. Böylece, modelin aşırı öğrenmesini (overfitting) önleyebilmiş olur ve yararlı verileri koruyup iş yükünü azaltmış olur [30,31,34].

CNN yapılarında evrişim ve havuzlama katmanlarından başka katmanlar da vardır. Aşağıdaki alt bölümlerde bu tez kapsamında geliştirilen CNN modelinde kullanılan katmanlar hakkında bilgi verilmiştir.

4.3.1. Evrişim Katmanı

Evrişim katmanı CNN yapılarının en önemli katmanıdır. Bu katmanın sayesinde görüntülerdeki özellikler algılanmaktadır. Görüntülere uygulanan filtrelerin/kernel yardımıyla özellikler algılanıp özellik haritaları oluşturulmaktadır [34]. Bu süreçte, filtre ve görüntü değerleri indislerine göre birbirleri ile çarpılıp elde edilen sonuçları toplanmaktadır. Bu işlem, görüntü boyunca kaydırılarak tekrar edilmektedir. Sonuç olarak, toplanan sonuçları ile özellik haritası oluşturulmaktadır. Şekil 4.3'te evrişim (convolution) işlemi gösterilmiştir.



Şekil 4.3. Evrişim (convolution) işlemi

4.3.2. Aktivasyon Katmanı


Aktivasyon katmanında problem durumuna göre ReLU, sigmoid, tanh ve softmax gibi farklı aktivasyon fonksiyonu uygulanmaktadır. Çizelge 4.1’de aktivasyon fonksiyonlarının eşitlikleri gösterilmiştir. Aktivasyon fonksiyonu, insan beyninin nöron modelinin işlevine benzer şekilde, bir sonraki nörona hangi bilginin iletilmesi gerektiğini belirleyen bir birimdir. Bu fonksiyonlar sayesinde geliştirilen modele doğrusal olmayan (non-linear) özelliği verip daha karmaşık verileri öğrenip modelin doğruluğu artmaktadır. Genel olarak, CNN modellerin katmanlarında ReLU aktivasyon fonksiyonu kullanılmaktadır. Onun yanı sıra ise, ikili sınıflandırma problemleri için son katmanı sigmoid fonksiyonundan yararlanabilirken çoklu sınıflandırma problemleri için son katmanı softmax fonksiyonundan yararlanabilmektedir [30].

Çizelge 4.1. Aktivasyon fonksiyonları

Aktivasyon Fonksiyonları		
ReLU	$ReLU(x) = \max(0, x)$	(4.2)
tanh	$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} = \frac{e^{2x} - 1}{e^{2x} + 1}$	(4.3)
Sigmoid	$\sigma(x) = \frac{1}{1 + e^{-x}}$	(4.4)
Softmax	$softmax(x)_i = \frac{e^{x_i}}{\sum_{j=1}^K e^{x_j}}$, K = sınıf sayısı	(4.5)

4.3.3. Havuzlama Katmanı

Daha önce bahsedildiği gibi, havuzlama (pooling) katmanının sayesinde özellik haritalarının boyutları küçültüp modelin hesaplama yükü azaltılmaktadır [31]. Havuzlama katmanlarının filtresinin boyutlarına göre girdi değerinin ortalamasını veya maksimumunu alarak kendi özellik haritasını oluşturmaktadır. Şekil 4.4’te maks ve ortalama havuzlama işlemleri gösterilmiştir.



Şekil 4.4. Havuzlama çeşitleri

4.3.4. Bırakma (Dropout) Katmanı

Bırakma katmanı, aşırı öğrenmeyi önlemek için kullanılan bir düzenleme (regularization) tekniği olup CNN modellerde yaygın olarak kullanılmaktadır. Eğitim sırasında katmandaki belirli bir oranda nöronların rastgele bırakılması (sıfıra ayarlanması) nöronların birlikte uyumunu (co-adaptation) ve ağıın veriye özgü özelliklerine olan hassasiyetini azaltmaktadır. Sonuç olarak, modelin aşırı öğrenmesini önleyip genelleme performansını artmaktadır [35].

4.3.5. Batch Normalizasyon (BN) Katmanı

BN katmanı, her katmanın çıktısına normalizasyon işlemi yaparak sonraki katmana aktarmaktadır. Verilere yapılan normalizasyon işleminden modelin ara katmanları yararlanmamaktadır. O yüzden modelin eğitim süreci daha yavaş ve kararsız hale gelebilmektedir. Bu sorunun üstesinden gelebilmek için BN katmanı kullanarak girdilerin ortalamayı çıkararak ve girdilerin standart sapmasına bölerek katmanın girdilerini normalleştirmektedir. Böylece, yapay sinir ağlarının eğitimini daha hızlı ve daha kararlı hale getirip genelleme performansını iyileştirebilmektedir [36].

4.3.6. Flatten Katmanı

CNN modellerde, flatten katmanı önceki evrişim katmanının çıktısını (iki boyutlu özellik haritalarından oluşan) tek boyutlu diziye dönüştürmek için kullanılmaktadır. Bu işlem, tam bağlantılı katmana aktarmak için gereklidir. Çünkü tam bağlantılı katmanlarda sadece tek boyutlu diziler işlenmektedir [31].

4.3.7. Tam Bağlantılı (Fully Connected) Katmanı

Tam bağlantılı katmanı, evrişim ve havuzlama katmanları tarafından özellik çıkarma işlemi yapıldıktan sonra ağın sonunda kullanılmaktadır. Bu katmanda her bir nöron bir önceki katmanın tüm nöronlarına bağlıdır. Ağ tarafından tahmin yapmak için kullanılmaktadır [34].

4.4. HİPER PARAMETRELERİN OPTİMİZASYONU

Hiper parametrelerin belirtilmesi ve verilerin doğru bir şekilde hazırlanması derin öğrenme modellerin eğitiminde önemli rol oynamaktadır. Çünkü bu parametreler modelin performansını doğrudan etkilemekte olup genelleme sonuçlara yol açmaktadır. Hatalı parametreler seçilmesi durumunda model eksik öğrenme (underfitting) veya aşırı öğrenme (overfitting) gibi sıkıntılarla karşılaşmaktadır. Ancak bu optimizasyon işlemi uzun süre almaktadır.

Bu tez çalışmasının kapsamında geliştirilen CNN modelinin evrişim katman sayısı, katmanlardaki filtre/kernel sayısı, filtrelerin boyutu, dropout oranı, flatten katmandan sonra gelen tam bağlantılı katmanın nöron sayısı ve kullanılan aktivasyon fonksiyonları gibi hiper parametreler optimize edilmiştir.

Öncelikle, model performansına en çok etkileyen parametrelerinden biri olan evrişim katman sayısı ve nöron sayısı belirtmek için bazı kombinasyonları denenmiştir. Bunun için (32-64-128), (32-64-128-64-32), (32-64-64-32), (16-32-64-128) ve (16-32-32-64) kombinasyonları test edilmiştir. Ayrıca, tam bağlantılı katman için 64, 128, 192 ve 256 nöron sayısı denenmiştir.

Evrişim katmanlardaki filtre boyutları (3x3) ve (5x5) olarak denenmiştir. Dropout oranı için 0.1, 0.3 ve 0.5 oranları denenmiştir. Evrişim katmanları için kullanılan aktivasyon fonksiyonları olarak ReLU ve tanh fonksiyonları denenirken tam bağlantılı katmanı için ReLU, elu ve tanh denenmiştir.

Optimizer için ‘Adam’, ‘Nadam’, ‘RMSprop’, ‘Adamax’ ve ‘SGD’ optimizer çeşitleri denenmiştir. Her optimizer için de öğrenme oranı 10^{-2} , 10^{-3} , 10^{-4} ve 10^{-5} olarak denenmiştir.

Batch_size için 32,38,64,128 olarak denenmiştir. Epoch yani devir sayısı belirtmek için erken durdurma fonksiyonu kullanılmıştır. Ayrıca, girişte kullanılan görüntülerin boyutları (128x128), (256x256) ve (512x512) olarak denenmiştir.

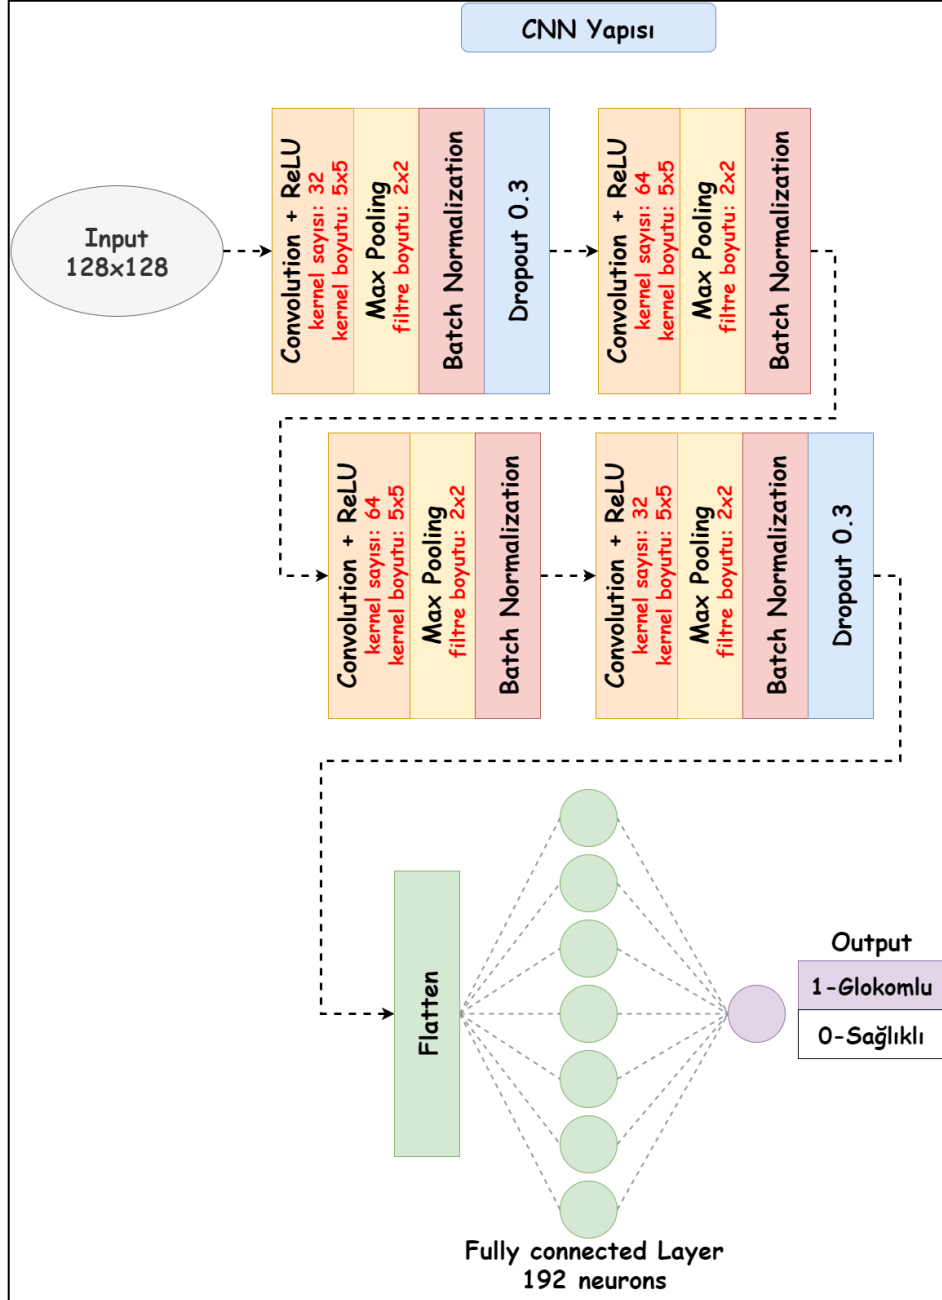
Tüm bu bahsedilen parametrelerine bir arada denenmesi için 172800 deneme yapılmasını gerektirmektedir. Bu da çok fazla zaman alması anlama gelmektedir. O yüzden bazı parametreleri parçalayarak birbiriyle denemeler yapıp en iyi performansı veren parametreleri belirlenmiştir.

4.5. GELİŞTİRİLEN MODELİN MİMARİSİ

Hiper parametreler optimizasyon işleminin sonucuna göre modelin yapısı belirlenmiştir. Bu tez çalışmasının kapsamında geliştirilen modelde dört evrişim katmanı (32-64-64-32) kullanılmıştır. Her katmanda ReLU aktivasyon fonksiyonu kullanılmıştır. evrişim katmanlarda kullanılan Kernel boyutu 5x5 olarak seçilmiştir. Her evrişim katmanından sonra maks havuzlama (max pooling) katmanı ve batch normalizasyon katmanı kullanılmıştır.

İlk ve son evrişim – maks havuzlama kombinasyonundan sonra bırakma katmanı 0.3 bırakma oranı ile kullanılmıştır. Son olarak, flatten katmanı yardımıyla önceki katmanlardan elde edilen sonucu düzleştirilip tam bağlantılı katmana aktarılmıştır. Tam bağlantılı katmanda 192 nöron ve “elu” aktivasyon fonksiyonu kullanılmıştır.

Son katmanda ise, modelde ikili sınıflandırma işlemi yapılacağı için sigmoid aktivasyon fonksiyonu olarak seçilmiştir. Optimizer olarak Adamax 10^{-3} öğrenme oranı ile seçilmiştir. Şekil 4.5'te geliştirilen modelin detayları gösterilmiştir. batch_size parametresi için 38 olarak seçilmiştir.



Şekil 4.5. Modelin yapısı

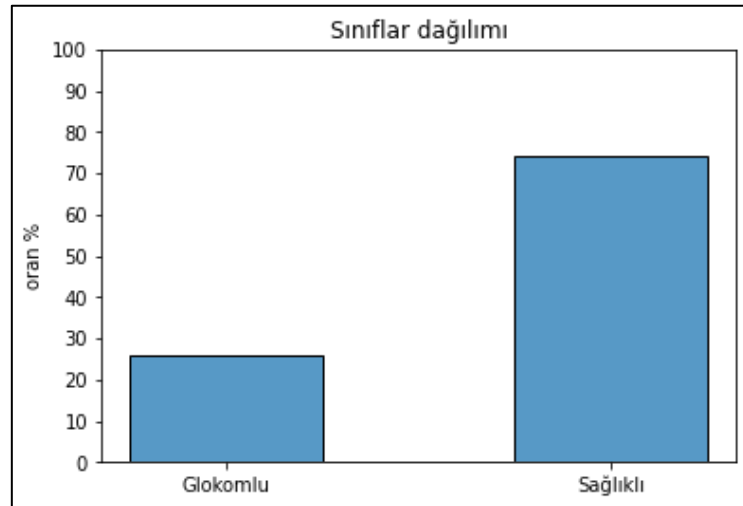
4.5.1. Çapraz Doğrulama

Geliştirilen modelde kullanılan veri setinin sınıflarında örnek sayıları eşit olmadığından dolayı (~26% glokomlu, 74% sağlıklı) Stratified Shuffle Split (SSS) tekniği kullanılmıştır. Şekil 4.6'da sınıflar dağılım grafiği gösterilmiştir.

SSS, makine öğreniminde kullanılan bir çapraz doğrulama tekniğidir. Bu teknik, veri setini eğitim ve test kümelerine ayırırken her iki kümedeki sınıf oranlarının korunmasını sağlamaktadır [37].

Bu projede SSS kullanırken, veri seti rastgele karıştırılıp (n=10) şeklinde alt parçalara bölünmüştür. Her alt parça, toplam veri setindeki sınıf dağılımına benzer bir oranla örnek sayısı içermektedir.

Geliştirilen model (n-1) parça üzerinde eğitilir ve kalan parça test için kullanılmaktadır. Bu işlem parça sayısı kadar tekrarlanmakta olup her defada farklı bir parça üzerinde test edilmektedir. Modelin doğruluğu, tüm parçalar üzerindeki hesaplanan doğrulukların ortalamasına göre değerlendirilmektedir.



Şekil 4.6. Sınıflar dağılım grafiği

4.6. MODELİN PERFORMANS ÖLÇÜLERİ

Derin öğrenme modellerinin performansını değerlendirmek için farklı ölçüler vardır. Bu ölçüler geliştirilen modelin hakkında sayısal bilgiler vererek modelin genel tahmin gücünü geliştirmeye yardımcı olmaktadır.

Bu bölümde sınıflandırma değerlendirmesinde sıklıkla kullanılan değerlendirme metrikleri ile ilgili bilgiler verilmiştir.

Karışıklık matrisi (Confusion Matrix), her sınıf için doğru pozitif (TP), yanlış pozitif (FP), doğru negatif (TN) ve yanlış negatif (FN) sayısını gösteren bir tablodur. Buradaki TP, glokomlu olarak sınıflandırılan ve gerçekte glokomlu olarak tanımlanan görüntülerinin sayısını ifade ederken TN, sağlıklı olarak sınıflandırılan ve gerçekte sağlıklı olarak tanımlanan görüntülerinin sayısını ifade etmektedir.

Öte yandan, FP, glokomlu olarak sınıflandırılan ancak gerçekte sağlıklı olarak tanımlanan görüntülerinin sayısını ifade ederken FN, sağlıklı olarak sınıflandırılan ancak gerçekte glokomlu olarak tanımlanan görüntülerinin sayısını ifade etmektedir. Böylece, karışıklık matrisi modelin performansının daha ayrıntılı bir görünümünü sağlamakta ve modelin hangi sınıflarda zorlandığını belirlemeye yardımcı olabilmektedir. Şekil 4.7’de örnek bir karışıklık matrisi gösterilmiştir.

		Tahmin	
		0-Sağlıklı	1-Glokomlu
Gerçek	0=>Negatif 1=>Pozitif	0-Sağlıklı	1-Glokomlu
	0-Sağlıklı	TN	FP
	1-Glokomlu	FN	TP

Şekil 4.7. Karışıklık matrisi

Karışıklık matrisi yardımıyla diğer metrikler de hesaplanabilmektedir. Bu metrikler hakkında aşağıda bilgi verilmiştir.

Doğruluk (Accuracy), doğru sınıflandırılmış örneklerin toplam örneklere oranını ölçmektedir. Sınıflandırma modelleri için en sık kullanılan performans ölçüsüdür. Doğruluğun hesaplanma şekli eşitlik 4.6'da verilmiştir.

$$\text{Doğruluk} = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.6)$$

Özgüllük (Specificity), bir modelin negatif örnekleri doğru bir şekilde sınıflandırma yeteneğini değerlendirmek için kullanılan bir performans ölçüsüdür. Eşitlik 4.7'de özgüllük ifade edilmiştir.

$$\text{Özgüllük} = \frac{TN}{TN + FP} \quad (4.7)$$

Duyarlılık (Sensitivity/Recall), doğru pozitif örneklerin toplam pozitif örnek sayısına (hem doğru pozitifler hem de yanlış negatifler) oranını ölçmektedir. Eşitlik 4.8'de duyarlılık ifade edilmiştir.

$$\text{Duyarlılık} = \frac{TP}{TP + FN} \quad (4.8)$$

Kesinlik (Precision), doğru pozitif örneklerin pozitif olarak sınıflandırılan toplam örnek sayısına (hem doğru pozitifler hem de yanlış pozitifler) oranını ölçmektedir. Eşitlik 4.9'da kesinlik ifade edilmiştir.

$$\text{Kesinlik} = \frac{TP}{TP + FP} \quad (4.9)$$

F1 skoru, kesinlik ve duyarlılık değerlerinin harmonik ortalamasıdır. Hem FP hem de FN dikkate alarak daha dengeli bir performans ölçüsü sağlamaktadır. Eşitlik 4.10'da F1 skoru ifade edilmiştir.

$$F_1 = 2 \times \frac{\text{Kesinlik} \times \text{Duyarluluk}}{\text{Kesinlik} + \text{Duyarluluk}} \quad (4.10)$$

Receiver Operating Characteristic (ROC) eğrisi, farklı sınıflandırma eşiklerinde duyarlılık ile yanlış pozitif oranını (FPR) karşılaştırmaktadır. Eşitlik 4.11’de FPR ifade edilmiştir. Ayrıca, ROC eğrisinin altındaki alanı (AUC) hesaplanarak modelin performansının özeti olarak temsil edilmektedir.

$$FPR = \frac{FP}{FP + TN} \quad (4.11)$$

BÖLÜM 5

BULGULAR VE TARTIŞMA


Bulgular ve tartışma bölümünde geliştirilen model ile elde edilen sonuçlar bahsedilip literatürde geçen ve aynı veri setleri kullanan çalışmaları ile kıyaslanmıştır.

5.1. GELİŞTİRİLEN MODEL İLE ELDE EDİLEN BULGULAR


Bu tez çalışmasında fundus görüntülerinden glokom hastalığı ön tanısı koyabilmek için açık kaynaklı veri setlerinden elde edilen yaklaşık olarak 4600 fundus görüntüsü yardımıyla derin öğrenme sistemi oluşturulmuştur. Geliştirilen model, VGG16, Inception v3 ve EfficientNet gibi önceden eğitilmiş modelleri kullanan diğer çalışmalardan farklı olarak baştan ve özgün olarak oluşturulup eğitilmiştir. Oluşturulan model ile hem toplanan tüm veri setleri bir arada değerlendirilmiş hem de her veri seti üzerinde ayrı ayrı olarak değerlendirilmiştir.

Modelde kullanılan görüntülerin %80'i eğitim ve %20'si test için bölümlenmiştir. Test veri seti üzerinde yapılan tahmin sonuçları değerlendirilmiştir. Görüntülerin çoğu doğru bir şekilde sınıflandırılırken bazı görüntüler ise yanlış olarak sınıflandırılmıştır. Şekil 5.1'de test veri seti üzerinde yapılan tahmin sonuçları gösterilmiştir.

Karışıklık matrisine bakıldığında test veri setinde glokomlu olup ancak sağlıklı olarak sınıflandırılan görüntülerin sayısı 6'dır. Öte yandan, sağlıklı olup ancak glokomlu olarak sınıflandırılan görüntülerin sayısı 5'tir. Böylece, yanlış pozitif oranı (FPR) %0.73 olarak hesaplanmıştır. Kalan görüntüler ise doğru bir şekilde sınıflandırılmıştır. Şekil 5.2'de karışıklık matrisi gösterilmiştir.




Şekil 5.1. Tahmin sonuçları



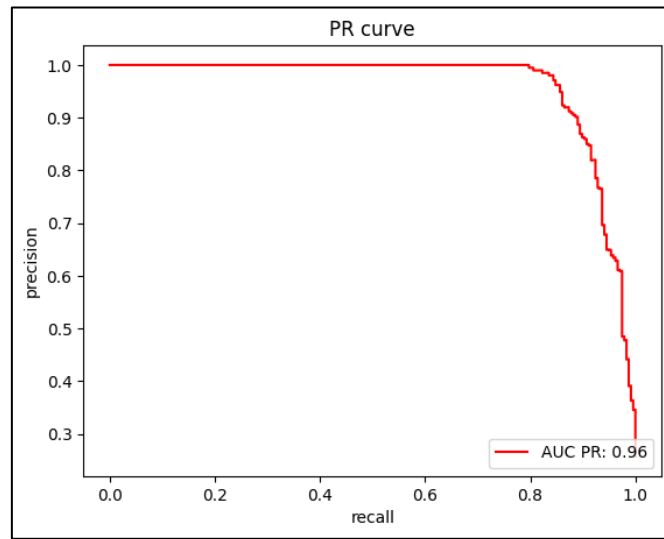
Şekil 5.2. Modelin karışıklık matrisi

doğru pozitif (TP), yanlış pozitif (FP), doğru negatif (TN), yanlış negatif (FN)

Sınıflandırma modellerinin performansını değerlendirebilmek için en önemli değerlendirme ölçütlerinden olan ROC ve kesinlik-duyarlılık (PRC) eğrilerine bakılmıştır. Genel olarak, PRC eğrisi dengesiz (sınıflar eşit olmadığı durumlarda) veri setlerinde kullanılmaktadır. Ayrıca, bu eğrilerden modelin ne kadar başarılı olduğunu sayısal olarak ifade etmek gerekirse AUC yani eğrinin altındaki alanı hesaplanmaktadır. AUC değeri ne kadar 1'e yakınsa o kadar model başarılıdır. ROC eğrisi için AUC değeri 0.98 olarak hesaplanmışken PRC eğrisi için 0.96 olarak hesaplanmıştır. Şekil 5.3'te ROC eğrisi ve Şekil 5.4'te PRC eğrisi gösterilmiştir.



Şekil 5.3. ROC eğrisi



Şekil 5.4. Kesinlik-Duyarlılık eğrisi

Modelin başarısını ölçmek için daha önce bahsedilen çeşitli performans metrikleri kullanılmıştır. Geliştirilen model hem renkli hem de gri görüntüler üzerinde test edilmiştir. Genel olarak, sonuçlar birbiriyle çok yakın olmasına rağmen gri görüntüler üzerindeki performans sonuçları daha yüksektir. Ayrıca, veri seti üzerinde bazı sağlıklı görüntüler rasgele olarak çıkarılarak glokomlu görüntü ile sağlıklı görüntülerin sayıları eşitlenerek bir alt veri seti oluşturulmuştur. Geliştirilen model, bu alt veri setinde de test edilmiştir ve elde edilen sonuçlar ile modelin glokom hastalığının ön tanısında başarılı olduğu anlaşılmıştır. Çizelge 5.1’de elde edilen sonuçlar verilmiştir.

Geliştirilen model her veri set üzerinde ayrı olarak test edilmiştir. KCG ve ODIR veri setlerinde performansı yüksek olduğu görülmüştür. Çizelge 5.2’de veri setler üzerindeki değerlendirme skorları verilmiştir.

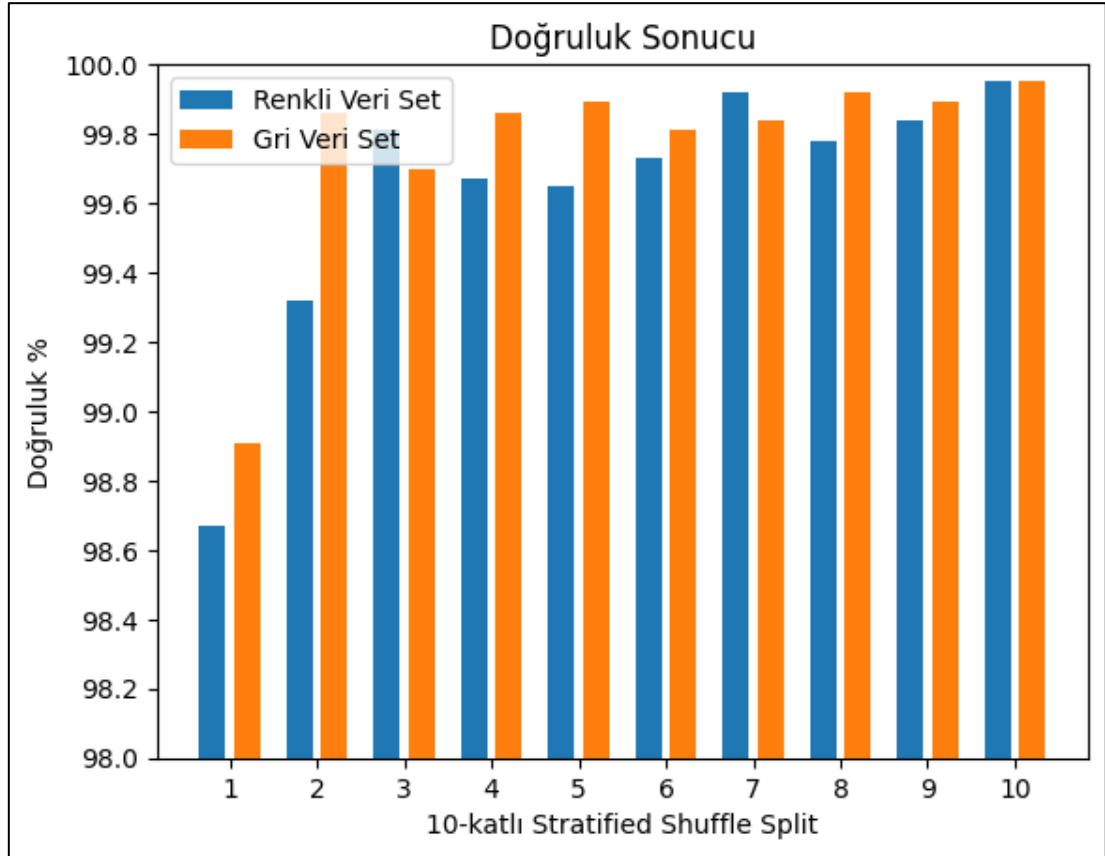
Çizelge 5.1. Elde edilen sonuçlar

Elde Edilen Sonuçlar							
Veri set	doğruluk	duyarlılık	kesinlik	AUC	özgüllük	MCC	F1- skoru
Tüm veri setler (gri görüntüler)	%99.03 (± 1.53)	%97.64 (± 3.21)	%98.59 (± 2.84)	%99.55 (± 0.94)	%99.52 (± 0.91)	%97.46 (± 4.00)	%98.11 (± 2.98)
Tüm veri setler (renkli görüntüler)	%98.52 (± 1.66)	%95.78 (± 4.43)	%98.42 (± 2.53)	%99.39 (± 0.89)	%99.41 (± 0.87)	%96.11 (± 4.38)	%97.06 (± 3.31)
Tüm veri setler (sınıflar eşitleyerek)	%98.23 (± 2.47)	%98.57 (± 2.26)	%97.96 (± 3.08)	%99.64 (± 0.69)	%97.90 (± 3.19)	%96.49 (± 4.92)	%98.25 (± 2.45)

Çizelge 5.2. Kullanılan veri setlerinin ayrı olarak değerlendirilmesi

Kullanılan Veri Setlerinin Ayrı Olarak Değerlendirmesi							
Veri set	doğruluk	duyarlılık	kesinlik	AUC	özgüllük	MCC	F1- skoru
KCG	%100.0	%100.0	%100.0	%100.0	%100.0	%100.0	%100.0
HRF	%50.0	%100.0	%50.0	%55.0	-	-	%66.66
Drishti- GS1	%71.43	%69.33	%69.93	%79.05	%76.66	%46.44	%68.50
ODIR	%97.83	%82.75	%86.44	%96.57	%98.90	%83.29	%84.26

Önerilen modelin başarısını doğrulamak ve veri setinin farklı bölümlerinde de iyi sonuçlar alabildiği göstermek için çapraz doğrulama kullanılmıştır. Daha önce bahsedildiği gibi veri setinde sınıflar eşit olmadığı için Stratified Shuffle Split çapraz doğrulayıcı kullanarak 10 katlı çapraz doğrulama uygulanmıştır ve tüm görüntülerin olduğu veri setinde metrikler hesaplanmıştır (Şekil 5.5).



Şekil 5.5. 10-katlı Stratified Shuffle Split Doğruluk sonucu

5.2. TARTIŞMA

Dünya çapında geri dönüşü olmayan körlüğün önde gelen nedenlerinden biri glokom hastalığıdır. Görme kaybını önlemek için glokom hastalığı erken teşhisi ve tanısı çok önemlidir.

Fundus görüntüleme, glokom hastalığının önemli belirtileri olan optik sinir başı ve retina sinir lifi tabakasını görüntülemesi ve incelemesi için yaygın olarak kullanılan non-invaziv bir yöntemdir. Son yıllarda, derin öğrenme modelleri, özellikle CNN modelleri ile fundus görüntüleri kullanarak glokom hastalığının ön tanısında umut verici sonuçlar alınmaktadır.

Bu tez çalışmasında glokom hastalığının teşhisi için fundus görüntüleri kullanan ve çalışma kapsamında oluşturulan bir CNN modeli kullanılmıştır. Elde edilen sonuçlar diğer çalışmalara göre daha yüksektir. Bu çalışmada kullanılan veri setleri farklı bölgelerden toplandığından dolayı modele genelleme özelliği kazandırılmıştır.

Geliştirilen modelde kullanılan veri setlerinin ana çalışmalarıyla karşılaştırılmıştır. Karşılaştırma sonucu olarak, KCG veri seti için Song vd. (2021) çalışmasında %97.0 doğruluk elde edilmişken [25], önerilen modelde %100.0 doğruluğa varılmıştır. ODIR veri seti için Gour vd. (2021) çalışmasında %66.5 doğruluğa varılmışken [28], geliştirilen modelde %97.83 doğruluk elde edilmiştir. DRISHTI-GS1 veri seti için Shoukat vd. (2021) çalışmasında %98.0 doğruluk elde edilmiştir [38]. Bunun karşısında önerilen modelde %71.43 doğruluğa ulaşılmıştır. Bunun nedeninin ilgili veri setinde görüntülerin az olması nedeniyle genel ağın öğrenememesi olduğu düşünülmektedir. Çizelge 5.3'te doğruluk ve diğer değerlendirme metriklerin karşılaştırma sonuçları verilmiştir.

Diğer çalışmalarda modelin performansını değerlendirmesi için sadece doğruluk, duyarlılık ve özgüllük metriklerine odaklanmışken bu tez çalışmasında sınıflandırma modellerde kullanılan tüm değerlendirme metrikleri hesaplanmıştır. Veri sayısı açısından incelenen çalışmaların çoğu 1000-2500 görüntü arasındayken bu çalışmada yaklaşık 4600 fundus görüntüsü kullanılmıştır.

Glokom hastalığının ön teşhisi için farklı veri setlerinin tipleri üzerinde yapılan çalışmalar vardır. Ancak, fundus görüntüleri kullanan çalışmalarının performansı diğerleri ile daha başarılıdır. Çizelge 5.4’te literatürde geçen glokom hastalığının ön teşhisi için yapılan farklı çalışmalarla elde edilen sonuçlar önerilen çalışmanın sonuçlarıyla detaylı bir şekilde karşılaştırılmıştır.

Çizelge 5.3. Aynı veri setleri kullanan çalışmalarla karşılaştırması

Aynı Veri Setleri Kullanan Çalışmalarla Karşılaştırması					
Veri Set	Çalışma	Yöntem	Doğruluk %	Duyarlılık %	Özgüllük %
KCG	[25]	CNN	97.0	95.0	98.0
	Önerilen Model	CNN	100.0	100.0	100.0
DRISHTI- GS1	[38]	EfficientNet	98.0	95.0	94.0
	Önerilen Model	CNN	71.43	69.33	76.66
ODIR	[28]	VGG16	66.5	58.5	40.5
	Önerilen Model	CNN	97.83	82.75	98.90

Çizelge 5.4. Farklı çalışmalarla Karşılaştırması

Çalışma	Veriler	Kaynaklar	Yöntem	Doğruluk %	Duyarlılık %	Kesinlik %	AUC %	Özgüllük %	MCC %	F1-Skoru %
Yıldırım vd. [16]	1000 fundus görüntüsü	Origa (-light)	VGG16	97.98	97.03	-	-	98.97	-	98.0
Uçar [17]	4854 fundus görüntüsü	Beijing Tongren Hastanesi	DenseNet	96.19	96.06	95.64	-	96.06	-	-
Thanh vd. [19]	2177 fundus görüntüsü	Özel veri seti	Darknet YOLOv3	92.0	92.68	91.2	-	91.34	-	-
Diaz-Pinto vd. [20]	1707 fundus görüntüsü	ACRIMA, HRF Drishti-GS1 RIM-ONE	VGG19	90.69	92.4	-	96.86	88.46	-	91.25
Chen vd. [21]	2372 fundus görüntüsü	ORIGA SCES	CNN	-	-	-	83.1-88.7	-	-	-
Liv d. [22]	4012 görsel alanı test görüntüleri	Özel veri seti	VGG15	87.6	93.2	-	96.6	82.6	-	-
Ibrahim vd. [23]	337 görsel alanı test görüntüleri	-	MLP	97.0	98.0	98.0	-	95.0	-	98.0
Shoukat vd. [38]	1121 fundus images	G1020 DRISHTI-GS1	EfficientNet	98.0	95.19	-	-	94.0	-	-
Ahmed vd. [39]	-	Kaggle Dataset	DCNN	92.78	-	-	-	-	-	-
Önerilen model	4598 fundus görüntüsü	KCG HRF Drishti-GS1 ODIR	CNN	%99.03 (± 1.53)	%97.64 (± 3.21)	%98.59 (± 2.84)	%99.55 (± 0.94)	%99.52 (± 0.91)	%97.46 (± 4.00)	%98.11 (± 2.98)

BÖLÜM 6

SONUÇLAR VE ÖNERİLER

Bu tez çalışması kapsamında glokom hastalığının derin öğrenme modelleri ile teşhisi üzerine çalışılmıştır. Bu çalışmada, açık kaynaklı veri setlerinden toplanan fundus görüntüleri kullanarak hastaların glokomlu olup olmadığını tespit eden bir CNN modeli üzerine çalışılmıştır. Elde edilen sonuçlar ve öneriler aşağıda özetlenerek maddeler halinde listelenmiştir.

1. Bu çalışmada tamamen özgün olarak geliştirilen CNN modeli ile elde edilen sonuçların literatürde geçen ve önceden eğitilmiş modelleri kullanan diğer çalışmaların sonuçlarından daha yüksek olduğu gözlemlenmiştir.
2. Bu tez çalışması kapsamında geliştirilen model ve geliştirilen yazılımın fundus görüntüleri kullanarak glokom hastalığının ön tanısı konusunda başarılı olduğu doğrulanmıştır.
3. Bu çalışmada kullanılan veri setlerinin çeşitliliğinin modelin başarısına ve genelleme kabiliyetine olumlu bir şekilde yansıdığı görülmüştür.
4. Bu tez çalışması kapsamında geliştirilen yazılım diğer veri setlerine kolaylıkla uygulanabilmektedir. Daha sonra eklenecek veri setleri veya kliniklerde özel olarak toplanacak veri setleri üzerinde modelin performans değerlendirmesi yapılması planlanmaktadır.
5. İlerleyen çalışmalarda glokom hastalığını tiplerine ve seviyesine göre sınıflandıran bir derin öğrenme modeli geliştirilmesi hedeflenmektedir.

6. İlerleyen süreçte fundus görüntülerinin yanı sıra glokom hastalığının tanısında yardımcı olan diğer testlerin sonuçları ile birleştirerek kombine bir derin öğrenme modeli geliştirilmesi amaçlanmaktadır.
7. Son zamanlarda geliştirilen akıllı telefon tabanlı fundus görüntüleme teknolojileri yardımı ile glokom hastalığı ve diğer göz hastalıkları ön tanısını koyabilen bir mobil uygulama tasarlanması hedeflenmektedir.

KAYNAKLAR

1. Allison, K., Patel, D., and Alabi, O., "Epidemiology of Glaucoma: The Past, Present, and Predictions for the Future", *Cureus*, (2020).
2. "Göz Tansiyonu (Glokom)", <https://besiridh.saglik.gov.tr/TR-9855/goz-tansiyonu-glokom.html> (2023).
3. "Glaucoma Information Definition | Glaucoma Information", <https://www.glaucomapatient.org/basic/definition/> (2021).
4. "Glokom - Göz Tansiyonu | NeoRetina", <https://ziyakapran.com/glokom> (2022).
5. Wagner, I. V., Stewart, M. W., and Dorairaj, S. K., "Updates on the Diagnosis and Management of Glaucoma", *Mayo Clinic Proceedings: Innovations, Quality & Outcomes*, 6 (6): 618–635 (2022).
6. HacıEfendiOğlu, Ş., "MAKİNE ÖĞRENMESİ YÖNTEMLERİ İLE GLOKOM HASTALIĞININ TEŞHİSİ", Yüksek Lisans, *SELÇUK ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ*, 12-21, (2012).
7. UTİNE, C. A., "SUPRA-THRESHOLD CONTRAST PERCEPTION IN GLAUCOMATOUS AND NORMAL HUMAN SUBJECTS", Master Of Science, *Bogaziçi University*, (2006).
8. "Types of Glaucoma | National Eye Institute", <https://www.nei.nih.gov/learn-about-eye-health/eye-conditions-and-diseases/glaucoma/types-glaucoma> (2021).
9. Jipeng, T., P, S., and Manjunath, T. C., "Use of Artificial Intelligence & Machine Learning with Deep Learning for Glaucoma Detection in Human Eyes & its Real Time Hardware Implementation", *European Journal Of Electrical Engineering And Computer Science*, 4 (2): (2020).
10. "Types of Glaucoma", <https://www.glaucomapatient.org/basic/types-of-glaucoma/> (2023).
11. Abramoff, M. and Kay, C. N., "Chapter 6 - Image Processing", *Retina* (Fifth Edition), *W.B. Saunders*, London, 151–176 (2013).
12. Coan, L. J., Williams, B. M., Krishna Adithya, V., Upadhyaya, S., Alkafri, A., Czanner, S., Venkatesh, R., Willoughby, C. E., Kavitha, S., and Czanner, G., "Automatic detection of glaucoma via fundus imaging and artificial intelligence: A review", *Survey Of Ophthalmology*, 68 (1): 17–41 (2023).

13. Kausu, T. R., Gopi, V. P., Wahid, K. A., Doma, W., and Niwas, S. I., "Combination of clinical and multiresolution features for glaucoma detection and its classification using fundus images", *Biocybernetics And Biomedical Engineering*, 38 (2): 329–341 (2018).
14. Pathan, S., Kumar, P., Pai, R. M., and Bhandary, S. V., "Automated segmentation and classification of retinal features for glaucoma diagnosis", *Biomedical Signal Processing And Control*, 63: 102244 (2021).
15. Ittoop, S. M., Jaccard, N., Lanouette, G., and Kahook, M. Y., "The Role of Artificial Intelligence in the Diagnosis and Management of Glaucoma", *Journal Of Glaucoma*, 31 (3): 137–146 (2022).
16. Yildirim, Ö. and Altunbey Özbay, F., "Fundus Görüntülerinden Derin Öğrenme Teknikleri ile Glokom Hastalığının Tespiti", *European Journal Of Science And Technology*, (2022).
17. Uçar, M., "Glokom Hastalığının Evrişimli Sinir Ağı Mimarileri ile Tespiti", *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen Ve Mühendislik Dergisi*, 23 (68): 521–529 (2021).
18. AHMED, M. R., AHMED, S. R., DURU, A. D., UÇAN, O. N., and BAYAT, O., "An Expert System to Predict Eye Disorder Using Deep Convolutional Neural Network", *Academic Platform Journal Of Engineering And Science*, 9 (1): 47–52 (2021).
19. Thanh, T. H. P., Thuy, T. P. T., Hieu, T. N., and Nguyen, M. S., "A Real-Time Classification of Glaucoma from Retinal Fundus Images Using AI Technology", *International Conference on Advanced Computing and Applications (ACOMP)*, (2020).
20. Diaz-Pinto, A., Morales, S., Naranjo, V., Köhler, T., Mossi, J. M., and Navea, A., "CNNs for automatic glaucoma assessment using fundus images: an extensive validation", *BioMedical Engineering OnLine*, 18 (1): 29 (2019).
21. Chen, X., Xu, Y., Wong, D. W. K., Wong, T. Y., and Liu, J., "Glaucoma detection based on deep convolutional neural network", *Proceedings Of The Annual International Conference Of The IEEE Engineering In Medicine And Biology Society, EMBS*, (2015).
22. Li, F., Wang, Z., Qu, G., Song, D., Yuan, Y., Xu, Y., Gao, K., Luo, G., Xiao, Z., Lam, D. S. C., Zhong, H., Qiao, Y., and Zhang, X., "Automatic differentiation of Glaucoma visual field from non-glaucoma visual field using deep convolutional neural network", *BMC Medical Imaging*, 18 (1): (2018).
23. Ibrahim, M. H. and Hacibeyoğlu, M., "Diagnosis of Glaucoma Disease by Analyzing the Visual Field with Deep Learning", *European Journal Of Science And Technology*, (Special Issue): 412–416 (2020).
24. Bajwa, M. N., Malik, M. I., Siddiqui, S. A., Dengel, A., Shafait, F., Neumeier, W., and Ahmed, S., "Two-stage framework for optic disc localization and

- glaucoma classification in retinal fundus images using deep learning", *BMC Medical Informatics And Decision Making*, 19 (1): (2019).
25. Song, W. T., Lai, I.-C., and Su, Y.-Z., "A Statistical Robust Glaucoma Detection Framework Combining Retinex, CNN, and DOE Using Fundus Images", *IEEE Access*, 9: 103772–103783 (2021).
 26. Budai, A., Bock, R., Maier, A., Hornegger, J., and Michelson, G., "Robust Vessel Segmentation in Fundus Images", *International Journal Of Biomedical Imaging*, 2013: 154860 (2013).
 27. Sivaswamy, J., Krishnadas, S. R., Chakravarty, A., Joshi, G. D., and Syed, T. A., "A Comprehensive Retinal Image Dataset for the Assessment of Glaucoma from the Optic Nerve Head Analysis", *JSM Biomed Imaging Data Pap*, 2(1): 1004 (2015).
 28. Gour, N. and Khanna, P., "Multi-class multi-label ophthalmological disease detection using transfer learning based convolutional neural network", *Biomedical Signal Processing And Control*, 66: 102329 (2021).
 29. "ODIR-2019 - Grand Challenge", <https://odir2019.grand-challenge.org/> (2023).
 30. Li, Z., Liu, F., Yang, W., Peng, S., and Zhou, J., "A Survey of Convolutional Neural Networks: Analysis, Applications, and Prospects", *IEEE Transactions On Neural Networks And Learning Systems*, 33 (12): 6999–7019 (2022).
 31. Géron, A., "Deep Computer Vision Using Convolutional Neural Networks", Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow, SECOND EDITION. Ed., *O'Reilly Media, Inc*, 587–657 (2019).
 32. Lindsay, G. W., "Convolutional Neural Networks as a Model of the Visual System: Past, Present, and Future", *Journal Of Cognitive Neuroscience*, 33 (10): 2017–2031 (2021).
 33. Chollet, F., "Deep learning for computer vision", Deep Learning with Python, *Manning Publications Co*, Shelter Island, New York, 119–177 (2018).
 34. Brownlee, J., "Crash Course In Convolutional Neural Networks", Deep Learning With Python Develop Deep Learning Models On Theano And TensorFlow Using Keras, Melbourne, Australia, 115–120 (2016).
 35. Brownlee, J., "Reduce Overfitting With Dropout Regularization", Deep Learning With Python Develop Deep Learning Models On Theano And TensorFlow Using Keras, Melbourne, Australia, 102–107 (2016).
 36. Doğan, F. and Türkoğlu, İ., "Derin Öğrenme Modelleri ve Uygulama Alanlarına İlişkin Bir Derleme", *DÜMF Mühendislik Dergisi*, 10 (2): 409–445 (2019).

37. "Sklearn.Model_selection.StratifiedShuffleSplit", https://scikit-learn/stable/modules/generated/sklearn.model_selection.StratifiedShuffleSplit.html (2023).
38. Shoukat, A., Akbar, S., and Safdar, K., "A Deep Learning-based Automatic Method for Early Detection of the Glaucoma using Fundus Images", *2021 International Conference on Innovative Computing (ICIC)*, Lahore, Pakistan, (2021).
39. AHMED, M. R., AHMED, S. R., DURU, A. D., UÇAN, O. N., and BAYAT, O., "An Expert System to Predict Eye Disorder Using Deep Convolutional Neural Network", *Academic Platform Journal Of Engineering And Science*, 9 (1): 47–52 (2021).

ÖZGEÇMİŞ

Mahmoud NAES 2014 yılında lise öğrenimini sınıf birincisi olarak bitirdi. Hazırlık eğitimini tamamladıktan sonra 2016 yılında Karabük Üniversitesi Tıp Mühendisliği bölümünde lisans eğitimine başladı ve 2020 yılında onur derecesi alarak mezun oldu. 2017 yılında Biyomedikal Mühendisliği bölümünde çift anadal programına başladı ve 2021 yılında onur derecesi alarak tamamladı. 2018-2021 yıllarında farklı kurumlarda zorunlu stajları yaptı. 2020 yılında TÜBİTAK 2209/A programına katılıp destek almayı hak kazandı. Aynı yılda da TEKNOFEST yarışması altında TÜBİTAK 2242 programına başvurup Ankara bölgesi sergisinde ‘Stay Awake Bracelet-Uyanık Kal Bilekliği’ adlı lisans bitirme projesi sundu. 2020 yılında başladığı yüksek lisans eğitimini Karabük Üniversitesi Lisansüstü Eğitim Enstitüsü Biyomedikal Mühendisliği Anabilim Dalında “Glokom Hastalığının Derin Öğrenme Yöntemiyle Ön Tanısı” adlı tezini savunarak tamamladı.