

T.C.
KASTAMONU ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI



**SEZGİSEL OPTİMİZASYON YÖNTEMİ İLE İNSAN RETİNA
GÖRÜNTÜLERİNDE OPTİK DİSK SEGMENTASYONU VE
DERİN ÖĞRENME İLE HASTALIK TEŞHİSİ**

HAMIDA ALI ALMESHRKY

DOKTORA TEZİ

DOÇ. DR. ABDULKADİR KARACI

OCAK - 2025
KASTAMONU

TEZ ONAYI

Hamida Ali Almeshrky tarafından hazırlanan “**SEZGİSEL OPTİMİZASYON YÖNTEMİ İLE İNSAN RETİNA GÖRÜNTÜLERİNDE OPTİK DİSK SEGMENTASYONU VE DERİN ÖĞRENME İLE HASTALIK TEŞHİSİ**” adlı tez çalışmasının savunma sınavı **16.01.2025** tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği ile Kastamonu Üniversitesi Fen Bilimleri Enstitüsü **Malzeme Bilimi ve Mühendisliği Ana Bilim Dalı Doktora Tezi** olarak kabul edilmiştir.

Danışman	Doç. Dr. Abdulkadir Karacı Samsun Üniversitesi	
Jüri Üyesi	Doç. Dr. Kemal AKYOL Kastamonu Üniversitesi	
Jüri Üyesi	Dr. Öğr. Üyesi Faruk ERKEN Kastamonu Üniversitesi	
Jüri Üyesi	Doç. Dr. Selçuk ÇAKMAK Samsun Üniversitesi	
Jüri Üyesi	Dr. Öğr. Üyesi Emel SOYLU Samsun Üniversitesi	

Jüri üyeleri tarafından kabul edilmiş olan bu tez Kastamonu Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulunca onanmıştır.

Enstitü Müdürü Doç. Dr. Selçuk MEMİŞ

TAAHHÜTNAME

Bu tezin tasarımı, hazırlanması, yürütülmesi, araştırmalarının yapılması ve bulgularının analizlerinde bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu; ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını, bilimsel etiğe uygun olarak kaynak gösterildiğini bildirir ve taahhüt ederim.

Hamida Ali Almeshrky

ÖZET

DOKTORA TEZİ

SEZGİSEL OPTİMİZASYON YÖNTEMİ İLE İNSAN RETİNA GÖRÜNTÜLERİNDE OPTİK DİSK SEGMENTASYONU VE DERİN ÖĞRENME İLE HASTALIK TEŞHİSİ

HAMIDA ALI ALMESHRKY

KASTAMONU ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
MALZEME BİLİMİ VE MÜHENDİSLİĞİ ANA BİLİM DALI
DANIŞMAN:DOÇ. DR. ABDULKADİR KARACI

Glokom, optik sinirin hasar görmesiyle karakterize, genellikle geri dönüşü olmayan görme kaybıyla sonuçlanan yaygın bir göz hastalığıdır. Sinsi doğası, özellikle de minimal semptomlarla seyreden erken evrelerde, zamanında teşhis ve müdahaleyi zorlaştırmaktadır. Bu çalışma, retina görüntülerinde optik diski lokalize etme ve segmentlere ayırmanın yanı sıra tanı doğruluğunu artırmak için glokom varlığını sınıflandırmanın kritik zorluğunu ele almaktadır. Bunun yanı sıra, gri kurtların sosyal davranışlarını simüle eden doğadan ilham alan meta sezgisel bir algoritma olan Gri Kurt Optimizasyonunu (GKO) kullanarak insan retina görüntülerinde optik disk segmentasyonu için yeni bir yaklaşım önermekte ve bu yaklaşımı ilk defa bu amaçla kullanmaktadır. Ayrıca çalışma kapsamında glokom hastalığını sınıflandırma için iki model geliştirilmiştir: Model 1, ResNet50, Inception V3, VGG19, DenseNet201 ve Swin Transformer gibi gelişmiş ağlarla uçtan uca bir derin öğrenme mimarisi kullanırken, Model 2, Bi-LSTM, Destek Vektör Makinesi (DVM), Rastgele Orman (RO) ve k-enyakın komşu (k-NN) gibi geleneksel makine öğrenimi tekniklerini CNN modelleriyle entegre etmektedir. Bunun yanı sıra, araştırma sınıflandırma için iki yaklaşım uygulamaktadır: modellere tüm görüntüyü besleyen tek aşamalı bir yaklaşım ve YOLO segmentasyon yöntemi ile kırılmış görüntüleri modellere besleyen iki aşamalı bir yaklaşım. Çalışmada, glokom hastalığının ve optic disk bölgesinin tespit doğruluğunu önemli ölçüde artıran optimum hiperparametreleri belirlemek için kapsamlı deneyler yapılmıştır. GKO ile segmentasyon için Drishti-GS1 veri setinde ortalama %96,04 duyarlılık, %99,58 özgüllük, %99,39 doğruluk, %94,15 DICE katsayısı ve %90,4 Jaccard indeksi elde etmiştir. Sınıflandırma için, Swin Transformer modeli Drishti-GS1 veri setinde dışarıda tutma doğrulaması ve üç kat çapraz doğrulama için sırasıyla %100 ve %88,18'lik yüksek test doğruluğu elde etmiştir. Ayrıca, ORIGA veri setinde dışarıda tutma doğrulamada Swin Transformer %96,15 ve beş kat çapraz doğrulamada ise InceptionV3 %93,84'lük yüksek test doğruluğu ile dikkate değer sonuçlar elde etmiştir. Sonuçlar önceki çalışmalarla karşılaştırıldığında önerilen bu modeller daha iyi performans göstermiştir.

ANAHTAR KELİMELELER:Optik disk bölütleme; glokom hastalığı, insan retina görüntüleri; önceden eğitilmiş ESA'ler; gri kurt optimizasyonu; YOLO; Swin dönüştürücü

Ocak 2025, 80 Sayfa

ABSTRACT

PH.D THESIS

OPTIC DISC SEGMENTATION IN HUMAN RETINA IMAGES WITH HEURISTIC OPTIMIZATION METHOD AND DISEASE DIAGNOSIS WITH DEEP LEARNING

HAMIDA ALI ALMESHRY

**KASTAMONU UNIVERSITY INSTITUTE OF SCIENCE
DEPARTMENT OF MATERIALS SCIENCE AND ENGINEERING
SUPERVISOR: ASSOC. PROF. DR. ABDULKADİR KARACI**

Glaucoma is a prevalent eye disease characterized by damage to the optic nerve, often resulting in irreversible vision loss. Its insidious nature, particularly in early stages with minimal symptoms, complicates timely diagnosis and intervention. This study addresses the critical challenge of localizing and segmenting the optic disc in retinal images, along with classifying Glaucoma's presence to enhance diagnostic accuracy. This study introduces a novel approach for optic disc segmentation in human retina images using Grey Wolf Optimization (GWO), a nature-inspired meta-heuristic algorithm that simulates the social behavior of grey wolves, marking its first application in this context. For classification, two models are developed: Model 1 employs an end-to-end deep learning architecture with advanced networks such as ResNet50, Inception V3, VGG19, DensNet201, and Swin Transformer, while Model 2 integrates Bi-LSTM and traditional machine learning techniques, including DVM, Random Forest, and K-Nearest Neighbour (KNN) with CNNs models. The research implements two classification approaches: a one-stage method that processes the entire image and a two-stage method that analyses cropped images using the YOLO framework. Comprehensive experiments are conducted to identify optimal hyperparameters, significantly enhancing the accuracy of Glaucoma detection. GWO achieved an average sensitivity of 96.04%, a specificity of 99.58%, an accuracy of 99.39%, a DICE coefficient of 94.15%, and a Jaccard index of 90.4% on the Drishti-GS1 dataset for segmentation. For classification, the Swin Transformer model achieved high test accuracy of 100% for hold-out validation and 88.18% for 3-fold cross-validation on the Drishti-GS1 dataset. Additionally, on the ORIGA dataset, the Swin Transformer model obtained remarkable results with 96.15% test accuracy for hold-out validation and InceptionV3 achieved 93.84% test accuracy for 5-fold cross-validation. Compared to previous studies, the proposed models in this work have demonstrated superior performance.

KEYWORDS: optic disc segmentation; Glaucoma disease; human retinal images; pre-trained CNNs; grey wolf optimization; YOLO; swin transformer

January 2025, 80 Page

TEŞEKKÜR

Bu tez çalışmasında önemli çabalar sarf ettim; ancak, danışmanım Doç. Dr. Abdulkadir KARACI'nın nazik desteği ve yardımı olmadan mümkün olmazdı. Rehberliği için kendisine derinden minnettarım, doktora tezim için daha iyi bir danışman ve akıl hocasına sahip olmayı hayal edemezdim. Ayrıca değerli önerileri için tüm komite üyelerim Doç. Dr. Kemal AKYOL ve Dr. Öğr. Üyesi Faruk ERKEN'e en içten teşekkürlerimi sunarım.

Ailemin sarsılmaz desteği olmasaydı bu çalışma mümkün olmazdı. Anneme (Mona), eşime (Milad), oğullarıma (Saleem ve Sufyan), kızlarıma (Safa ve Rana) ve kız kardeşlerime sevgileri ve cesaretlendirmeleri için en derin şükranlarımı sunarım.

Hamida Ali Almeshrky

Kastamonu, 2025

İÇİNDEKİLER

	<u>Sayfa</u>
TEZ ONAYI	ii
TAAHHÜTNAME	iii
ÖZET.....	iv
ABSTRACT	v
TEŞEKKÜR	vi
İÇİNDEKİLER	vii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ	x
SİMGELEr VE KISALTMALAR DİZİNİ	xii
1. GİRİŞ.....	1
1.1 İnsan Gözü	1
1.2 Optik Disk.....	4
1.3 Problem	6
1.4 Tezin Amaçları.....	7
1.5 Tezin Katkıları	8
1.6 Tezin Kapsamı ve Sınırlılıkları	9
2. LİTERATÜR TARAMASI	11
2.1 Optik Disk Segmentasyonu Üzerine Çalışmalar	11
2.1.1 Optik Disk Segmentasyon Teknikleri.....	11
2.1.2 Meta Sezgisel Optimizasyon Algoritmaları.....	13
2.2 Glokom Sınıflandırması Üzerine Çalışmalar	15
2.2.1 Glokom Tanı Çalışmaları için Derin Öğrenme.....	15
2.2.2 Glokom Çalışmaları için Vision Transformer	18
3. MATERYAL VE YÖNTEM	20
3.1 Veri Setleri	20
3.1.1 DRISHTI-GS1 Veriseti	20
3.1.2 ORIGA Veriseti	20
3.1.3 Füzyon Veriseti.....	21
3.2 Metod	21
3.2.1 Gri Kurt Meta-Ssezgisel Algoritması	21
3.2.1.1 Gri kurt meta-sezgisel algoritması	21
3.2.1.2 GKO'nun matematiksel modeli	23
3.2.1.3 Optik disk segmentasyonu için GKO	26
3.2.2 Derin Öğrenme Temelli Glokom Sınıflandırma	29
3.2.2.1 YOLO	30
3.2.2.2 Transfer öğrenme	31
3.2.2.3 Makine öğrenmesi.....	33
3.2.2.4 Bi-LSTM.....	34
3.2.2.5 Görüntü transformatörü (ViT)	34
3.2.2.6 Derin özellik çıkarımı	35
3.3 Performans Ölçütleri	35
4. BULGULAR ve TARTIŞMA	37
4.1 Hiperparametre Seçimi	37
4.2 GKO İle OD Segmentasyonu Sonuçları	38

4.3	YOLO ile Nesne Algılama.....	40
4.4	Glokom Sınıflandırma Sonuçları	41
4.4.1	DRISHIT-GS Veri Seti için Sınıflandırma Sonuçları.....	41
4.4.2	ORIGA Veri Seti için Sınıflandırma Sonuçları	49
4.4.3	Füzyon Veri Seti için Sınıflandırma Sonuçları.....	55
4.5	Tartışma	62
5.	SONUÇ	66
5.1	Tüm Modeller Arasında En İyi Sonuçlar.....	67
5.2	Kırılmış ve Kırılmamış Görüntüler Arasında Karşılaştırma.....	68
5.3	Model-1 ve Model-2 Arasındaki Karşılaştırma	70
	KAYNAKLAR	72
	ÖZGEÇMİŞ.....	80



ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1 Gözün Anatomisi	2
Şekil 1.2 Retina Retinanın konumu ve görünümü	2
Şekil 1.3 Sağlıklı Retinanın Özellikleri)	3
Şekil 1.4 Fundus Görüntüsüne Genel Bakış:	4
Şekil 1.5 Retina Görüntüleme ve Özellikleri	5
Şekil 1.6 Diyabetik Retinopatinin Optik Disk Üzerindeki Etkisi.	5
Şekil 1.7 Optik kabın dış çapa oranının değişimi.	6
Şekil 3.1 Bozkurt Hiyerarşisi	22
Şekil 3.2 Bozkurtların Avlanma Davranışı	23
Şekil 3.3 Bozkurtların Avlanma Stratejileri.....	25
Şekil 3.4 Optik disk tespiti için akış şema	28
Şekil 3.5 Ön işleme adımı	28
Şekil 3.6 Segmentasyon Sonucu	29
Şekil 3.7 Önerilen glokom sınıflandırma çerçevesine genel bakış	30
Şekil 3.8 Derin özelliklerin çıkarılması	35
Şekil 3.9 Optik disk segmentasyonu ve glokom sınıflandırması için kullanılan metrik	36
Şekil 4.1 Ön plan boyutunun segmentasyon doğruluğu üzerindeki etkisi	39
Şekil 4.2 GKO metasezgisel algoritması kullanılarak optik disk bölütleme yöntemi performansları.	40
Şekil 4.3 YOLO ile Tespit Edilen Optik Disk Bölgesinin Kırılması.....	41
Şekil 5.1 Model 1'in kırılmış görüntüler üzerinde hold-out doğrulaması ile elde ettiği en iyi doğruluk değerleri	68
Şekil 5.2 Model 1'in kırılmamış görüntüler üzerinde hold-out doğrulaması ile elde ettiği en iyi doğruluk değerleri	69
Şekil 5.3 Model 1'in kırılmış görüntüler üzerinde çapraz doğrulama ile elde ettiği en iyi doğruluk değeleri.....	69
Şekil 5.4 Model 1'in kırılmamış görüntüler üzerinde çapraz doğrula ile elde ettiği en iyi doğruluk değeleri.....	70

TABLÖLAR DİZİNİ

Sayfa

Tablo 4.1 DRISHTI-GS1, ORIGA ve Füzyon Veri seti için önceden eğitilmiş modellerin parametreleri.	38
Tablo 4.2 YOLOV7 algılama algoritması için mAP, R ve P performans ölçümleri .41	
Tablo 4.3 DRISHTI-GS1 Veri Seti İçin Tek Aşamalı Ve İki Aşamalı Yaklaşımların Dışarda Tutma Doğrulama Sınıflandırma Sonuçları	42
Tablo 4.4 Model-1'in DRISHTI-GS1 Veri Setinde Kırılmış Görüntüler İçin 3-Kat Çapraz Doğrulama Sınıflandırma Sonuçları (İki Aşamalı Yaklaşım).	43
Tablo 4.5 Model-1'in DRISHTI-GS1 Veri Setinde Kırılmamış Görüntüler için 3-Kat Çapraz Doğrulama Sınıflandırma Sonuçları (Tek Aşamalı Yaklaşım).....	43
Tablo 4.6 DRISHTI-GS1 Veri Setinde Yolo ile Kırılmış Görüntüler İçin Bi-LSTM, RO, k-NN ve DVM Modellerinin Dışarda Tutma Doğrulama Sınıflandırma Sonucu (İki Aşamalı Yaklaşım).....	45
Tablo 4.7 DRISHTI-GS1 Veri Setinde Kırılmamış Görüntüler İçin Bi-LSTM, RO, k-NN ve DVM Modellerinin Dışarda Tutma Doğrulama Sınıflandırma Sonuçları (Tek Aşamalı Yaklaşım).....	45
Tablo 4.8 DRISHTI-GS1 veri setinde Yolo ile kırılmış görüntü için Bi-LSTM, RO, k-NN ve DVM Modellerinin 3-kat çapraz doğrulama sınıflandırma sonucu	46
Tablo 4.9 DRISHTI-GS1 veri setinde kırılmamış görüntü için Bi-LSTM, RO, k-NN ve DVM Modellerinin 3 katlı çapraz doğrulama sınıflandırma sonucu	48
Tablo 4.10 Model-1'in ORIGA veri setinde tek aşamalı ve iki aşamalı yaklaşımlar için dışarda tutma doğrulama sınıflandırma sonuçları	49
Tablo 4.11 Model-1'in ORIGA veri setinde kırılmış veri seti için 5-kat çapraz doğrulama sınıflandırma sonucu	50
Tablo 4.12 Model-1'in ORIGA veri setinde kırılmamış veri seti için 5-kat çapraz doğrulama sınıflandırma sonucu	51
Tablo 4.13 Bi-LSTM, RO, k-NN ve DVM Modellerinin ORIGA veri setinde kırılmış görüntüler için dışarda tutma doğrulama sınıflandırma sonuçları	51
Tablo 4.14 ORIGA veri setinde kırılmamış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerinin dışarda tutma sınıflandırma sonuçları.....	52
Tablo 4.15 ORIGA veri setinde kırılmış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerinin 5-kat çapraz doğrulama sınıflandırma sonuçları	53
Tablo 4.16 ORIGA veri setinde kırılmamış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerinin 5-kat çapraz doğrulama sınıflandırma sonuçları.54	
Tablo 4.17 Model-1'in Füzyon veri seti için tek aşamalı ve iki aşamalı yaklaşımların dışarda tutma doğrulama sınıflandırma sonuçları	56
Tablo 4.18 Model-1'in Füzyon veri setinde kırılmış görüntüler için 5-kat çapraz doğrulama sınıflandırma sonuçları.....	56
Tablo 4.19 Model-1'in Füzyon veri setinde kırılmamış görüntüler için 5-kat çapraz doğrulama sınıflandırma sonuçları	57

Tablo 4.20 Füzyon veri setinde kırpılmış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerini dışarda tutma doğrulama sonuçları.....	58
Tablo 4.21 Füzyon veri setinde kırılmamış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerinin dışarda tutma doğrulama sonuçları.....	59
Tablo 4.22 Füzyon veri setinde kırpılmış görüntüler için Bi-LSTM, RO, k-NN ve DVM Modellerinin 5-kat çapraz doğrulama sınıflandırma sonuçları.....	60
Tablo 4.23 Füzyon veri setinde kırılmamış görüntü için Bi-LSTM, RO, k-NN ve DVM modellerin 5-kat çapraz doğrulama sınıflandırma sonuçları	61
Tablo 4.24 DRISHTI-GS1 veri seti üzerinde segmentasyon için farklı yöntemlerin karşılaştırılması	63
Tablo 4.25 Sınıflandırma sonuçlarının önceki çalışmaların sonuçlarıyla karşılaştırılması	65



SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

OD	: Optik Disk (Optic Disc)
CAD	: Bilgisayar Destekli Tanı
GKO	: Gri Kurt Optimizasyonu
S	: Özgüllük (Specificity)
R	: Hassasiyet (Recall)
P	: Kesinlik(Precision)
TP	: Gerçek Pozitif (True Positive)
TN	: Gerçek Negatif (True Negatives)
FP	: Yanlış Pozitif (False positive)
FN	: Yanlış Negatif (False negative)
CNN	: Evrimsel Sinir Ağı
ST	: Swin Transformer
YOLO	: You Only Look Once
ROI	: İlgi Alanı (Region of Interest)
Bi-LSTM	: Çift yönlü LSTM (Bidirectional Long Short-Term Memory)
RO	: Rastgele Orman
DVM	: Destek Vektör Makinesi
k-NN	: k-en yakın komşu
Vit	: Vision Transformer


1. GİRİŞ

Son zamanlarda, dijital görüntülerin elde edilmesi ve işlenmesindeki gelişmeler, tıbbi görüntülerin çeşitli patolojilerin tedavisinde kullanılmasını mümkün kılmıştır. Tıbbi görüntü teşhisi, hastalık belirtilerini belirlemede son derece yararlıdır ve muayene eden kişi için nispeten daha az zahmetlidir (Hayashi vd., 2001). Geleneksel X-ışını muayeneleri, Bilgisayarlı Tomografi (BT) ve Manyetik Rezonans (MR) gibi tıbbi görüntüleme cihazlarının kullanıldığı muayeneler gibi yaygın olarak kullanılmaya başlanmıştır. Bu durum, Bilgisayar Destekli Tanı (BDT) sistemleri olarak bilinen otomatik tıbbi tanı sistemlerinin geliştirilmesine ilgi duyulmasına yol açmıştır. BDT sistemleri üzerine yapılan çalışmalar, doktorların önemli anatomik yapıları ölçmelerine, ardışık görüntüleri karşılaştırarak değişiklikleri izlemelerine, teşhis koymalarına ve en iyi tedaviyi planlamalarına yardımcı olabileceklerini göstermektedir. Tıp alanındaki en köklü BDT uygulamaları arasında mamografi, göğüs tomografisi ve radyografide otomatik sistemlerin kullanımı yer almaktadır ve ayrıca insan gözünün görüntülenmesi için oftalmik alanda da kullanılmaktadır.

Bu bölümde ilk olarak insan gözü, retinal görüntüleme ve optik disk (OD) gözden geçirilmiştir. Daha sonra problem cümlesi ve çalışmanın amaçları açıklanmıştır. Ayrıca araştırmanın ana katkıları da ortaya konulmuş ve son olarak çalışmaya genel bir bakış sunulmuştur.


1.1 İnsan Gözü

İnsan gözü, Şekil 1.1'de gösterildiği gibi retina, göz bebeği, iris kornea, lens, siliyer cisim, fundus, kan damarları ve optik sinir gibi birbiriyle mükemmel şekilde ilişkili alt sistemlere sahip en karmaşık organdır. Göz genellikle bir kameraya benzetilir; kamera bir kare oluşturmak için bir film kullanır, göz ise bir görüntü oluşturmak için retina adı verilen hücrelerden oluşan 12 karmaşık bir katman kullanır (Zafar vd., 2016).



Şekil 1.1 Gözün Anatomisi (URL-1, 2020)


Retina, gözün arka kısmında bulunan ve iç yüzeyin yaklaşık %65'ini içeren ışığa duyarlı bir zardır. Retina yüz milyonlarca ışığa duyarlı hücreden oluşur. Gelen ışık ışınlarını optik sinir yoluyla beyne gönderilen elektriksel uyarılara dönüştüren bu hücreler bu süreçten sorumludur. Retina iki tip ışığa duyarlı hücre içerir: çubuklar ve koniler. Çubuklar yaklaşık 125 milyon ve koniler yaklaşık 6 ila 7 milyondur. Çubuklar ışığa daha duyarlıyken koniler ten rengine daha duyarlıdır. Konilerin “kırmızı” (%64), “yeşil” (%32) ve “mavi” (%2) olarak adlandırılan üç türü vardır. Şekil 1.2 insan gözündeki retinanın yerini ve görünümünü göstermektedir.



Şekil 1.2 Retina Retinanın konumu ve görünümü (Balasubramanian vd., 2008)

Dijital tıpta insan retina görüntüleri, çeşitli retinal oftalmik ve sistemik hastalıkların erken tespiti, taranması ve tedavi planlaması için yaygın olarak kullanılmaktadır. Zahoor vd. (2017)'nin çalışması şeker hastalığı, glokom, hidrosefali, iyi huylu intrakraniyal hipertansiyon ve beyin tümörleri gibi diğer durumların yanı sıra glokom

varlığını göstermek için kullanılan yapısal değişiklikler de dahil olmak üzere göz ve optik sinir başları hakkında temel bilgiler sağlar. Retina fundus görüntüleri, OD, optik kap (OC), kan damarları, nöroretina kenarı ve fovea gibi önemli bölgelerin boyutu, şekli ve rengi dahil olmak üzere retinanın her yönünün ayrıntılı bir tanımını ortaya koyar (Hoover ve Goldbaum 2003; Yu vd., 2019). Şekil 1.3'te bir retina fundus görüntüsündeki ana yapılar gösterilmektedir (Zafar vd., 2016).



Şekil 1.3 Sağlıklı Retinanın Özellikleri (Thakur ve Juneja, 2019)

Şekil 1.4 (a)'da gösterildiği gibi Retinadaki fundusun görüntülerini almak için fundus kamerası kullanılır. Bu kamera, makula (yani fundus) ve OD gibi gözün iç yüzeyini filme almak için monte edilmiş bir kamera ve sofistike bir düşük güçlü mikroskoptan oluşur. Fundus kameralarının optik tasarımı, dolaylı olarak oftalmoskopa dayanmaktadır. Bir fundus kamerası fundusa büyütülmüş dik bir görüş sağlar. Standart bir kamera, retina bölgesini normal görüş açısı olarak 30 ila 50 derece arasında, gerçeğinden 2,5 kat daha bir büyütme ile görüntüler. Bu ortaklık, görüntüyü yarı yarıya küçülten geniş açılı bir lens ile 140 dereceye kadar 5 kat büyütülür (Abramoff vd., 2010). Şekil 1.4 (b) bir fundus illüstrasyonu örneğini göstermektedir.




Şekil 1.4 Fundus Görüntüsüne Genel Bakış: (a): fundus kamera (b): fundus kamera tarafından alınan fundus görüntüsü (Abramoff vd., 2010).

1.2 Optik Disk


OD, Şekil 1.5'te de gösterildiği gibi retinanın ana yapılarından biridir. OD özellikleri arasında yer alan uzunluk ve parlaklık, dedektör programlarının girişinde kullanılan önemli parametrelerdir ve bu nedenle dikkatle değerlendirilmelidir. OD'nin parlaklığı ile görülebilen en önemli özellikler kan damarlarıdır (Akita ve Kuga, 1982). Optik disk formu elipse benzer ve optik diskler 1.8 ± 0.2 mm uzunluğunda ve 1.9 ± 0.2 mm kalınlığındadır (Sinthanayothin vd.,1999). Ortalama değer 1.5 mm olduğunda optik disk sinir bölgesinde ve optik disk merkezinde (CUP olarak adlandırılan parlak bir bölge) lifler bulunur. Şekil 1.5 (b)'de gösterildiği gibi, optik diskin kenarında onu çevreleyen ince şerit (RIM) mevcuttur (Lalonde vd., 2016). Kan arterleri optik disklerin görünümünü değiştirebilir. OD dahil retina görüntülerinde bulunan bu özellikler, Şekil 1.5 (a)'da gösterildiği gibi tüm görüntü yerine oftalmologlar ve oküler görüntüleme teknikleri için bu bölgeyi bir ilgi alanı (ROI) olarak tanımlamak ve yakalamak için kullanılabilir.

Şekil 1.6 (a)'da gösterildiği gibi OD ana kan damarlarının çıktığı bölge olduğu için, göz doktorlarının diyabetik retinopati gibi görmeyi tehdit eden göz hastalıklarını teşhis etmesine olanak tanır. Diyabetik retinopati, Şekil 1.6 (b)'de gösterildiği gibi retina içindeki kan damarlarına zarar verir ve hatta retinada yeni, anormal kan damarlarının oluşumunu uyabilir.



Şekil 1.5 Retina Görüntüleme ve Özellikleri: (a) OD dahil tüm retina görüntüsü, (b) Ana özelliklerle birlikte retinanın ilgi bölgesi (ROI)


Diyabetik retinopati rahatsızlığı derhal tedavi edilmezse potansiyel olarak görme kaybına yol açabilir (Akyol vd., 2016; Cole vd.,2016). Bu hastalık OD bölgesi çıkarılarak tespit edilir ki bu da retinal eksüdaların segmentasyonunu iyileştirilebilir ve yanlış pozitiflerin sayısında bir azalmaya yol açar.



Şekil 1.6 Diyabetik Retinopatinin Optik Disk Üzerindeki Etkisi: (a) Diyabetik retinopati olmayan optik disk (b) Diyabetik retinopatili optik disk.

Optik disk analizi ile tespit edilebilen bir diğer göz hastalığı da glokomdur. Glokom dünyada körlüğün en yaygın nedenidir ve tedavi edilebilir bir hastalık olmasına rağmen halen dünya çapında iki taraflı geri dönüşümsüz körlüğün ikinci önde gelen nedenidir. Yaklaşık 66,8 milyon kişi primer açık açılı glokom taşımaktadır ve glokom hastaları başlangıçta hiçbir belirti göstermemektedir.

Glokom, çanağın kalınlığını artırarak OD'yi etkiler. Bu değişiklikler, optik diskin genişlemesine kıyasla ekskavasyonun (en iç kısım) daha fazla genişlemesine yol açar ve çanak-disk çapı oranı (CDR) kullanılarak tanımlanır. Yüksek bir CDR değeri hastada glokom varlığını gösterir. Şekil 1.7'de gösterilen optik diskin çanak çapına oranı, tanısal bir gösterge olarak kullanılabilir.



Şekil 1.7 Optik kabın dış çapa oranının değişimi: (a) düşük glokom şüphesi, (b) orta glokom şüphesi ve (c) güçlü glokom şüphesi (Abramoff vd., 2010).

Bu çalışma, optik disk bölgesine odaklanan teknikler kullanarak daha yüksek doğrulukla glokom tespitine odaklanmaktadır. Alternatif olarak, sadece optik diskin yanı sıra diğer özellikleri de içeren tüm görüntünün kullanılması da glokom tespiti için iyi sonuçlar verebilir.

1.3 Problem

Glokom, erken evrelerde kontrol edilmediği takdirde kalıcı körlükle sonuçlanan ciddi bir hastalıktır. Ancak manuel prosedür çok uzun sürmektedir. Göz uzmanı için gereken minimum kontrol sayısı beştir. Oftalmologlar, göz ve görme sisteminin hastalıklarının

teşhisi, tedavisi ve yönetimi konusunda uzmanlaşmış tıp doktorlarıdır. Oftalmologların karşılaştığı önemli zorluklar şunlardır.

- (i) Geleneksel yaklaşımları kullanarak çok sayıda hastayı analiz etmek pratik değildir.
- (ii) Çok sayıda retina görüntüsünü analiz ederken insan yorgunluğu nedeniyle gözden kaçan bilgi olabilir.
- (iii) Zaman alıcı ve son derece öznel bir görevdir.

Ancak bu muayene ve tedavi stratejileri otomatik sistemler kullanılarak gerçekleştirilebilir (Patton, 2006; Tobin, 2007; Welfer, 2010). Otomatik sistem, patolojik davranışların tanımlanması ve değerlendirilmesi için büyük fayda sağlayacaktır. Bununla birlikte, fundus görüntülerinde optik disk için ilgi bölgesinin lokalizasyonu ve segmentasyonu, retina hastalığının teşhisi için önemli bir adımdır. Bireysel farklılıklar, fundus hastalıkları, retinal damar tıkanıklığı, düzensiz aydınlatma, gürültüler veya bulanık kenarlar optik diskin doğru konumunu bulmayı zorlaştıran faktörlerdir. Bu nedenle görüntülerdeki görünüm, boyut ve konum farklılıkları dikkate alınmalıdır. Öte yandan, fundus görüntüleri gibi zorlu görüntülerde, fundus görüntülerinin kalitesi OD'yi tam olarak tespit etmek için yeterince iyi değildir. Görüntü bozulmaları ve teknisyenin teknik uzmanlık eksikliği gibi nedenler, bozulmuş fundus görüntü kalitesinin başlıca nedenleridir. Bu nedenle, optik diskin tespit alanını hızlandırabilecek ve ardından glokomu doğru bir şekilde sınıflandırabilecek etkili ve doğru bir yöntem ihtiyacı vardır (Veiga vd., 2014).

1.4 Tezin Amaçları

Bu tezin temel amacı, OD'nin yerini belirlemeye ve segmentlere ayırmaya yardımcı olacak otomatik, hızlı ve doğru bir bilgisayar tabanlı sistem sunmaktır. Ayrıca, diğer bir amaç retina görüntüsünden glokomu sınıflandırabilen otomatik ve gelişmiş algoritmaları sunmak ve değerlendirmektir. Bu ana amaçlara ulaşmak için aşağıdaki görevler gerçekleştirilmiştir.

-Bu çalışma, retina fundus görüntülerinden optik diski doğru bir şekilde segmente etmek için yeni bir yaklaşım olarak Gri Kurt Optimizasyonunu (GKO) tanıtmış ve değerlendirmiştir.

- Glokom varlığını doğru bir şekilde sınıflandırmaya odaklanarak çeşitli modelleri ve makine öğrenimi algoritmalarını araştırmıştır.

- Hem tek aşamalı hem de iki aşamalı sınıflandırma yöntemlerini kullanarak glokom tespiti için retina görüntülerini analiz eden en etkili strateji belirlenmeye çalışılmıştır.

- Glokom sınıflandırması ve segmentasyonu için önerilen modellerin etkinliğini ortaya koymak için önceki çalışmalarla farklı açılardan karşılaştırmalar yapılmıştır.

Tez çalışması, bu hedeflere ulaşarak, oftalmoloji alanına ve glokomun erken teşhisine önemli ölçüde katkı sağlamayı amaçlamaktadır.

1.5 Tezin Katkıları

Tezin ana katkıları aşağıda maddeler halinde sunulmuştur.

i. Fundus görüntülerinde optik disk segmentasyonu için literatürde daha önce bu amaçla kullanılmamış olan GKO algoritmasını kullanan bir metasezgisel yaklaşım sunuyoruz. Bu yaklaşım sayesinde optik disk segmentasyonunda %99,39 gibi yüksek bir doğruluk elde edilmiştir;

ii. Swin Transformer da dahil olmak üzere görüntü dönüştürücüleri, tıbbi görüntülemelerde sık karşılaşılan zorluklar olan görüntü kalitesi ve gürültüdeki değişikliklere karşı sağlamlık gösterir. Bu nedenle, önceki araştırmalarda çok az ilgi gören glokom görüntü sınıflandırması için vision transformer uygulaması, özellikle de son teknoloji Swin transformer kullanılmıştır. Bu yöntem sayesinde yüksek sınıflandırma performansı elde edilmiştir;

iii. Glokom sınıflandırması için iki aşamalı ve tek aşamalı yaklaşımların kapsamlı bir değerlendirmesini ve karşılaştırmasını sunuyoruz. Bu değerlendirme, glokom

sınıflandırması üzerinde çalışan araştırmacılar için değerli bir rehberlik sağlamaktadır. Bu iki yaklaşım glokom sınıflandırması için farklı stratejileri temsil etmektedir. Tek aşamalı yaklaşım, potansiyel olarak daha geniş bağlamsal bilgileri yakalamakla birlikte ilgisiz özellikleri de içerecek şekilde tüm görüntüyü dikkate alır. Öte yandan, iki aşamalı yaklaşım özellikle glokom teşhisi ile doğrudan ilgili olan optik disk bölgesine odaklanmaktadır;

iv. ORIGA ve DRISHTI-GS1 veri setlerindeki sınıf dengesizliği sorununu etkili bir şekilde ele alarak, deneysel sonuçlarımız glokom tespiti ve sınıflandırmasında iyi sonuçlar elde edebilmiştir.

1.6 Tezin Kapsamı ve Sınırlılıkları

Bu çalışmanın kapsamı, sağlıklı ve sağlıklı olmayan retina görüntülerini ayırt etmek için otomatik bir sınıflandırma sistemi geliştirmek amacıyla özellikle sadece glokom hastalığına odaklanmıştır. Segmentasyon tekniği, retina görüntülerinden optik disk bölgesini tanımlamak ve izole etmek amacıyla tek bir veri setine uygulanmıştır.

Çalışmanın sınırlılığının biri dengesiz bir veri seti kullanmış olmasıdır. Bu da sağlıklı ve sağlıklı olmayan sınıflar arasında eşit olmayan bir örnek dağılımı olabileceği anlamına gelmektedir. Bu durum, sınıflandırma modelinin performansını ve genelleştirilebilirliğini potansiyel olarak etkileyebilir. Ayrıca, ek deneysel çalışmalar yapmak için daha fazla çaba gerekmektedir.

Segmentasyonda, GKO algoritması tipik olarak retina görüntülerinde optik diski bulmak için bir optimizasyon tekniği olarak kullanılır. Optik diskle ilişkilendirilen parlaklık veya yoğunluk gibi belirli karakteristiklere ve özelliklere dayanır. Algoritma, bu özelliklere dayanarak optik diskin en uygun konumunu bulmayı amaçlar. Bununla birlikte, yalnızca parlaklık veya yoğunluğa güvenmenin doğru segmentasyon için yeterli olmayabileceğini belirtmek gerekir. Şekil, doku ve bağlamsal bilgi gibi diğer faktörler de optik diski retina görüntüsündeki diğer benzer görünümlü bölgelerden ayırt etmede önemlidir.

Çalışmanın devamı şu şekilde yapılandırılmıştır. Bölüm 2, optik diskin tespiti ve segmentasyonu ile ilgili araştırmaların bir derlemesini sunmaktadır. Ayrıca, sezgisel

optimizasyon algoritmasını kullanan son teknoloji yaklaşımlar incelenmektedir. Buna ek olarak hem tek aşamalı hem de iki aşamalı yöntemler kullanarak glokom sınıflandırmasına vurgu yapan çalışmalar da yer almaktadır. Bölüm 3, glokom tespitine odaklanan bu çalışmada kullanılan veri kümeleri hakkında daha fazla ayrıntı sunmaktadır. Ayrıca hem segmentasyon hem de sınıflandırmada önerilen yöntemlerin mimarisi ve ana işlevleri açıklanmaktadır. Bölüm ayrıca önerilen algoritmaların tüm sürecini de göstermektedir. Bölüm 4, segmentasyon ve sınıflandırma deneylerini detaylı bir şekilde sunmakta olup, yöntemlerimizin ne kadar başarılı olduğu, diğer çalışmalarla karşılaştırılarak bu bölümde değerlendirilmektedir. Bölüm 5, genel sonuçları ve tartışmayı içermekte, sonuçları ve gelecek çalışmaları özetlemektedir.



2. LİTERATÜR TARAMASI

Bu bölümde, sezgisel optimizasyona dayalı yöntemler de dahil olmak üzere optik disk segmentasyonu ve glokom sınıflandırması üzerine mevcut araştırmalara genel bir bakış sağlanmıştır.

2.1 Optik Disk Segmentasyonu İle İlgili Çalışmalar

2.1.1 Optik Disk Segmentasyon Teknikleri

Bharkad (2017), retinal damarları çıkarmak için alçak geçiren sonlu dürtü yanıtı (FIR) filtresi kullanılmasını önermiştir. Ancak bu yaklaşım, uygun bir frekans yanıtı ve optimize edilmiş bir filtre sırası elde etmek için filtre tasarım parametrelerinin dikkatli bir şekilde seçilmesini gerektirmektedir. Araştırmacılar, OD sınırına yaklaşmak için gri tonlamalı bir morfolojik genişletme işlemi ve ardından medyan filtreleme kullanmışlardır. Ancak algoritma, düşük parlaklıkta OD rengine sahip retina görüntülerinde etkili bir performans göstermekte zorlanmıştır. Yöntem dört açık erişimli veri seti üzerinde değerlendirilmiştir: DRIVE, DiaretDB0, DiaretDB1 ve DRIONS. Bildirilen doğruluk oranları sırasıyla %100; %96,92;%98,98 ve %100'dür.

Shaikha ve Sallow (2019), eşleşen histogram şablon algoritması ile OD boyut bilgisini birleştiren yeni bir OD segmentasyon tekniği önermiştir. Algoritma ilk olarak RGB düzlem histogramlarını (kırmızı, yeşil ve mavi) analiz ederek ve orijinal görüntü ile bir şablon arasındaki çapraz korelasyonu kullanarak OD'nin merkezini tanımlamaktadır. OD merkezi ve boyutu belirlendikten sonra, ROI yaklaşımı kullanılarak OD'yi bölümlere ayırmak için ikili bir maske oluşturulur. Bununla birlikte, OD boyutunun hastalık nedeniyle anormal olduğu veya OD'nin ROI'sinin dairesel olmadığı durumlarda teknik zorlanmaktadır. Önerilen teknik DIARTDB0, DIARTDB1 ve DRIVE veri setleri kullanılarak değerlendirilmiştir.

Priyadharsini vd. (2018), retina görüntülerinde ROI tespit etmek için kanal çıkarma ve histogram eşitleme gibi görüntü işleme tekniklerini kullanmıştır. Optik disk sınırlarını tespit etmek için dairesel Hough dönüşümünü uygulamışlardır. Aktif kontur

yöntemleriyle karşılaştırıldığında dairesel Hough dönüşümü yaklaşımının avantajları vardır: Optik çanağı ve optik diski etkili bir şekilde tanımlamak için daha az parametre gerektirir ve uygulamayı basitleştirir. Buna ek olarak, hesaplama açısından verimlidir ve son segmentasyonda karmaşıklık ve doğruluk arasında iyi bir denge sağlar.

Perez vd. (2019), renkli fundus görüntülerinde optik diski belirlemek için bir ön işleme yaklaşımı sunmuşlardır. Ön işlemedeki ilk adım, giriş görüntüsünün boyutunu daha yönetilebilir bir ölçeğe düşürmektir. Ardından, Otsu eşikleme yöntemi kullanılarak bir maske oluşturulur ve ilgili özellikleri geliştirmek için görüntünün kontrastı artırılır. Kan damarları gibi daha küçük nesneleri kaldırmak için bir Gauss filtresi uygulanır. Bu yaklaşım, OD'yi tespit etmek için dijital renkli görüntünün üç RGB kanalına uygulanmıştır. Dairesel Hough dönüşümü, Shannon bilgi içeriğini ölçerek optik diskin merkezini konumlandırmak için kullanılır. Üç kanal kullanımının tek bir kanal kullanımından daha iyi performansa yol açtığı hipotezini kontrol etmek için bir dizi hesaplama yapılmıştır. Önerilen yöntem optik disk tespit işlemi için srare, drive ve messidor veri tabanları kullanılarak değerlendirilmiştir.

Ramani ve Shanthamalar (2020), glokomun erken teşhisi için OD tespiti, lokalizasyonu ve segmentasyonuna odaklanan gelişmiş bir görüntü işleme algoritması önermiştir. Önerilen algoritma dört ana aşamadan oluşmaktadır: Görüntü ön işleme, OD lokalizasyonu, OD segmentasyonu ve performans değerlendirmesi. OD lokalizasyonu aşamasında yazarlar piksel yoğunluğu hesaplama ve çok seviyeli lokalizasyon yöntemlerini kullanmışlardır. Nihai OD segmentasyonu için, kırmızı renk kanalının kullanımı ve Hough Tepe değeri seçimi ile geliştirilmiş bir Dairesel Hough Dönüşümü kullanmışlardır. Bunun yanı sıra, OD segmentasyonu için süper piksel segmentasyonu da kullanılmıştır. Önerilen yöntem, yalnızca görüntü işleme tekniklerine dayanarak, farklı görüntü boyutlarına sahip halka açık sekiz veri seti kullanılarak değerlendirilmiştir. Yazarlar, OD lokalizasyonu için %99,93 ve OD segmentasyonu için %99,5 gibi etkileyici bir doğruluk oranı bildirmişlerdir. Bununla birlikte, lokalizasyon doğruluğunun bazı görüntülerdeki patolojik dikkat dağıtıcı unsurların varlığından etkilendiğini belirtmişlerdir.

Thakur ve Juneja (2019), retina görüntülerinde optik disk ve optik kap segmentasyonu için otomatik bir hibridizasyon yaklaşımı sunmuşlardır. Yazarlar, tahmin edilen sınırlar için Uyarlamalı Düzenlenmiş Çekirdek tabanlı bulanık küme ortalaması (BKO) ve Sezgisel Bulanık C ortalamalarının bir kombinasyonunu içeren bir yaklaşım önermişlerdir. Bunu segmentasyon için Seviye Kümesi yaklaşımı ile birleştirmişlerdir. Önerdikleri yaklaşım üç genel veri seti ile değerlendirilmiş ve diğer kümeleme yaklaşımları ile karşılaştırılmıştır. Önerilen tekniğin sonucu, sistemin diğer algoritmalarla karşılaştırıldığında maksimum 39,56 saniye hesaplama süresi ile yüksek bir hesaplama süresine sahip olduğunu göstermektedir. Bununla birlikte, segmentasyon doğruluğu diğer mevcut tekniklere kıyasla azalmıştır. Abdullah ve diğerleri (2019), optik disk lokalizasyonu ve segmentasyonu için tanıtılan BKO kümeleme algoritmasına dayalı bir aktif kontur modeli sunmaktadır. Yöntem üç aşamadan oluşmaktadır. İlk aşamada, damarları kaldırmak için RGB renkli görüntüden kırmızı kanalın seçilmesi, ardından görüntüyü iyileştirmek için medyan filtresi ve Otsu yöntemi kullanılarak görüntünün ikileştirilmesi dahil olmak üzere bir dizi ön işleme uygulanır. İkinci aşamada, BKO kullanarak OD merkezi tespit edilir. Üçüncü aşamada ise, OD kenarlarının tespiti ve segmentasyonu için aktif kontur tabanlı BKO uygulanır. Önerilen yöntem DRIVE, DIRATEDB1, DRIONS ve STARE veri kümeleri kullanılarak test edilmiştir. OD lokalizasyonunda, ilk 3 veri seti için %100 ve STARE için %97,53 doğruluk oranı elde edilirken; optik disk segmentasyonu için ise, dört veri tabanında ortalama %97,01-99,46 aralığında doğruluk elde edilmiştir.

2.1.2 Meta Sezgisel Optimizasyon Algoritmaları

Son zamanlarda, optik diskin tespiti için sürü zekası teknikleri büyük ilgi görmektedir. Bu teknikler, doğruluk ve hesaplama süresinde ilerleme sağlayan doğadan ilham alan algoritmalarlardır.

Devarajan vd. (2020), her tür retina renkli fundus görüntüsünde optik diskin yerini belirlemek ve bölütleme için otomatik bir algoritma önermişlerdir. Ön işleme aşamasında, yeniden boyutlandırma, kan damarı çıkarma ve kırmızı kanal seçimi işlemleri gerçekleştirilmişlerdir. Daha sonra görüntüyü yumuşatmak için histogram eşitleme tekniği uygulanmışlardır. Parçacık Sürü Optimizasyonu (PSO) tabanlı

algoritma, global eşiklemeye dayalı olarak optik diski çıkarmaktadır. Yöntem, DRION genel veri tabanından elde edilen görüntüler üzerinde test edilmiştir ve makul doğruluk ve umut verici sonuçlar göstermiştir.

Abdullah vd. (2018), OD segmentasyonu için üç ana aşamadan oluşan bir yöntem önermişlerdir. Bu aşamalar, ön işleme, OD Lokalizasyonu ve OD Segmentasyonu şeklindedir. Ön işleme aşamasında, giriş görüntüsü gri tonlamaya dönüştürülür ve kan damarları gibi karanlık öğeleri kaldırmak için morfolojik işlemler gerçekleştirilir. Bir sonraki aşamada, OD bölgesinin yerini belirlemek için optimum eşik değerini bulmak üzere bir Yarasa Algoritması (YA) kullanılır. Son olarak, segmentasyon aşamasında, segmente edilmiş OD sınırını geliştirmek ve yumuşatmak için bir elips uydurma yaklaşımı kullanılır. Önerilen yöntem, kamuya açık altı veri seti üzerinde değerlendirilmiştir: MESSIDOR, DRIVE, DIARETDB1, DIARETDB0, STARE ve DRIONS-DB. Bildirilen OD segmentasyonu ortalama örtüşmeleri %78,5 ile %88,2 arasında değişirken, doğruluk bu altı veri tabanında %96,6 ile %99,91 arasında tespit edilmiştir. OD segmentasyonu görüntü başına 2,1 saniyeden daha kısa sürede gerçekleştirilmiştir.

Al-Roomi ve Al-Shayegi (2016) ve Pruthi vd. (2018) tarafından yapılan çalışmaların her ikisi de optik disk segmentasyonu için yeniden ölçeklendirme, gri tonlama dönüştürme, filtreleme ve arka plan kaldırma dahil olmak üzere benzer birçok aşamalı ön işleme yaklaşımı kullanmıştır. Bununla birlikte, iki çalışma son optik disk algılama aşaması için farklı meta sezgisel optimizasyon algoritmalarını araştırmıştır. Pruthi vd. (2018), Karınca Kolonisi Optimizasyonu (ACO), Bakteriyel Yemleme Optimizasyonu (BFO), Ateşböceği Algoritması (FA), Guguk Kuşu Arama (CS) ve Krill Sürüsü'nü (KH) test ederken; Al-Roomi ve Al-Shayegi (2016), Ateşböceği Algoritması (FA), Guguk Kuşu Arama (CS), Yapay Arı Kolonisi (ABC), Parçacık Sürüsü Optimizasyonu (PSO) ve Yarasa Algoritmasını (BA) kullanmışlardır. Al-Roomi ve Al-Shayegi (2016), FA algoritmasının %98,45 ile en yüksek optik disk tespit doğruluğuna ulaştığını göstermiştir. Buna karşılık, Pruthi vd. (2018), BFO algoritmasının en iyi performansa sahip olduğunu, ancak gürültülü görüntüleri işlemek için modifikasyon gerektirdiğini ortaya koymuşlardır.

Kumar vd. (2022)'nin önerdiği metodoloji, Abed vd. (2019)'nin yaklaşımındaki adımlara benzer şekilde fundus görüntülerinin ön işlemden geçirilmesini içermektedir. Optik diskin yerini belirlemek için ise Jaya algoritması adı verilen yeni bir meta sezgisel algoritma kullanılmaktadır. Ek olarak, optik disk lokalizasyonunun doğruluğunu artırmak için yeni bir uygunluk fonksiyonu tanıtılmıştır. Önerilen metodolojinin etkinliği, DIARETDB1, DIARETDB0, CHASEDB1, DRIONS ve DRIVE dahil olmak üzere halka açık çeşitli veri kümeleri üzerinde değerlendirilmiştir. Sonuçlar, önerilen metodolojinin optik disk için %99 gibi çok yüksek bir konum doğruluğuna ulaştığını göstermektedir.

Abed vd. (2019), çoklu ön işleme kullanmaktadır, araştırmacılar ön işleme görüntüsündeki en parlak pikseli bulmak için bir Balık Sürüsü Arama (FSS) tekniğini uygulamış ve bunu optik disk konumu olarak işaretlemiştir. İlginç bir şekilde, araştırmacı çalışma süresini en aza indirmek için FSS algoritmasını bir Programlanabilir Kapı Dizisi (FPGA) üzerinde uygulamış ve FPGA tabanlı uygulamanın sadece 1,605 ms'lik çok hızlı bir yürütme süresine sahip olduğunu bulmuştur.

2.2 Glokom Sınıflandırması ile İlgili Çalışmalar

Glokomun doğru bir şekilde tespit edilmesi için çok sayıda çalışma yapılmıştır. Bu çalışmalar aşağıda sunulmuştur.

2.2.1 Glokom Tanı Çalışmaları için Derin Öğrenme

Bajwa vd. (2019), tarafından önerilen yaklaşım glokom sınıflandırmasını iki aşamada gerçekleştirmektedir: İlk aşamada, OD çıkarımı ve lokalizasyonu için bir RCNN modeli kullanılmaktadır. Bu aşama aynı zamanda optik diskin konumunu içeren yer doğruluğu (ground truth) verilerinin oluşturulmasına yardımcı olan yarı otomatik bir bileşen içerir. Bu yer doğruluğu verisi daha sonra RCNN'yi eğitmek için kullanılır. İkinci aşamada, dört evrişimli katman ve üç tam bağlı katmana sahip bir derin sinir ağı mimarisi oluşturulur. Bu ağ ROI görüntülerini alır ve bunları nihai glokom sınıflandırma görevi için kullanır.

Saxena vd. (2020), SCES ve ORIGA veri kümelerini kullanarak glokom tespiti için altı katmanlı bir CNN modeli geliştirmiştir. ROI, ARGALI yaklaşımı kullanılarak çıkarılmış ve aşırı uyum sorununu önlemek için veri artırma tekniği ve bırakma tekniği kullanılmıştır. Model, SCES veri seti üzerinde 0,882 ve ORIGA veri seti üzerinde ise 0,822 AUC değeri elde etmiştir.

Guo vd. (2020), optik çanak ve disk segmentasyon özelliklerini çıkarmak için CP-FD-UNet++ adlı iyileştirilmiş bir U-Net sinir ağı önermişlerdir. Glokomatöz fundus görüntülerinin sayısı normal sınıftan neredeyse üç kat daha fazla olduğundan, ORIGA veri setindeki dengesizliği azaltmak için bu uyarlanabilir sentetik örnekleme yaklaşımı kullanarak özellik seçimi yapmışlardır. Çıkarılan özellikleri bir gradyan-boosting karar ağacı sınıflandırıcısını eğitmek için kullanmışlar ve ORIGA'da %84,30 doğruluk elde edilmişlerdir.

Serte ve Serener (2019), SCES ve ORIGA veri setlerine dayalı bir topluluk yaklaşımı kullanarak bir glokom tespit modeli geliştirmişlerdir. ROI, bir grafik belirginlik bölgesi tekniği kullanılarak çıkarılmıştır. Topluluk sınıflandırıcıları olarak ResNet-50, ResNet-152 ve AlexNet olmak üzere üç CNN mimarisi kullanılmıştır. Belirginlik haritası olmadan ve belirginlik haritasıyla birlikte olmak üzere üç CNN yöntemi de test edilmiş ve aşırı uyum sorununu önlemek için veri artırma tekniği kullanılmıştır. SCES ve ORIGA veri kümelerinde en iyi sonuçlar 0,882 AUC değeri ile topluluk yaklaşımı için elde edilmiştir.

Chaudhary ve Pachori (2021), RIM-ONE, ORIGA ve DRISHTI-GS1 veri kümelerini kullanarak iki yönteme dayalı bir glokom tespit modeli geliştirmiştir. İlk adım, fundus görüntülerinin sınırını segmente etmek için iki boyutlu Fourier-Bessel serisi genişleme tabanlı ampirik dalgacık dönüşümü (2D-FBSE-EWT) kullanmayı içerir. Bu segmentasyon adımı fundus görüntülerini alt görüntülere ayırır. Alt görüntülerden glokom tespiti için geleneksel makine öğrenimi ve ResNet-50 modelleri kullanılmıştır. En iyi sonuçlar ResNet-50 derin öğrenme yaklaşımında %91,1 doğruluk, %91,1 duyarlılık, %94,3 özgülük, %83,3 AUC ve %96 ROC değerleri ile elde edilmiştir.

Thakoor vd. (2019), Optik Koherens Tomografi (OCT) olasılık haritalarından oluşan bir veri seti kullanarak bir glokom tespit modeli geliştirmişlerdir. VGG16, ResNet18 ve Inception-v3 olmak üzere üç farklı CNN mimarisini denemişlerdir. Veri dengesizliğini gidermek ve aşırı uyumu önlemek için araştırmacılar çeşitli veri artırma teknikleri kullanmışlardır. Önceden eğitilmiş ResNet, VGG ve InceptionNet modellerinin performansını RO sınıflandırıcısıyla birlikte, doğrudan OCT görüntüleri üzerinde eğitilmiş bağımsız CNN mimarileriyle karşılaştırmışlardır. En iyi sonuçlar, doğrudan OCT görüntüleri üzerinde eğitilen CNN modelleri ile elde edilmiş ve %96,27 gibi yüksek bir doğruluk oranına ulaşılmıştır.

Li vd. (2019), glokom sınıflandırması için üç aşama içeren dikkat tabanlı bir CNN modeli sunmuşlardır. Bu aşamalar, ROI'nin tanımlanması, dikkat haritası kullanılarak patolojik alanın lokalizasyonu ve normal veya glokomatöz olarak sınıflandırma şeklindedir. Sonti vd. (2023), bir CNN mimarisi kullanarak glokom tespiti sunmuşlardır. Metodolojileri ROI seçimini içermektedir. Al-Bander vd. (2017), 160 ham fundus görüntülerinden özellikler çıkarmak için AlexNet CNN'leri kullanmışlardır. Görüntüler üzerinden çıkarılan bu özellikler destek vektör makinesine (DVM) beslenmiş ve normal ve glokomatöz olarak sınıflandırma işlemi gerçekleştirilmiştir.

Abbas vd. (2017), denetimsiz bir CNN mimarisi ve derin inanç ağı modelinin bir kombinasyonunu geliştirmiş ve uygulamışlardır. Ön işleme aşamasında, yeşil kanal görüntüsünden ROI çıkarılmıştır. CNN bu ROI görüntüleri kullanılarak eğitilmiştir. Maetschke vd. (2019), 1110 OCT görüntüsü kullanarak glokom tespiti için CNN tabanlı bir model geliştirmişler ve performansını makine öğrenmesi (ML) algoritmalarıyla karşılaştırmışlardır. Toplam 22 özellik çıkarılmış ve NB (Naive Bayes), RO, DVM, LR (Logistic Regression), Gradient Adaboost ve Extra Trees gibi farklı makine öğrenimi sınıflandırıcılarına beslenmiştir. CNN modeli, 0,97 AUC ile lojistik regresyon gibi diğer makine öğrenimi yaklaşımlarından daha iyi sonuçlar elde etmiştir. Bunun dışında, Kim vd. (2019) glokom sınıflandırması ve lokalizasyonu için iki yönlü bir yaklaşım önermiştir. İlk yaklaşım, modelin genellemesini artırmak için çeşitli düzenleme tekniklerinin kullanıldığı üç farklı CNN mimarisi (VGGNet, InceptionNet ve ResNet) kullanılarak glokom sınıflandırmayı içermektedir. ResNet-

152-M ağı en iyi teşhis sonuçlarını üretmiştir. İkinci yaklaşım, herhangi bir segmentasyon verisi kullanmadan bir giriş görüntüsündeki glokom bölgelerini tanımlamak için "Grad-CAM" adı verilen haftalık denetimli bir yöntemle dayalı lokalizasyon tespitini kullanır. Bu çalışma aynı zamanda glokomun yerini belirlemek ve teşhis etmek için web tabanlı bir uygulamanın geliştirilmesini de içermektedir. Alghamdi vd. (2021), transfer, denetimli ve yarı denetimli öğrenme tekniklerine dayalı üç CNN mimarisinin kullanılmasını önermiştir; burada üç model, seçilen verilere herhangi bir ön işleme veya iyileştirme tekniği uygulanmadan halka açık fundus görüntüleri veri setleri üzerinde eğitilmiştir. İlk olarak, transfer öğrenme algoritması sınırlı bir veri setine uygulanmış ve ardından etiketli ve etiketsiz veri kümelerine yarı denetimli öğrenme uygulanmıştır. Son olarak, gerekli özellikleri çıkarmak için 6 katmanlı bir CNN oto kodlayıcı modeli kullanılarak denetimsiz öğrenme, denetimli öğrenme aşamasıyla birlikte uygulanmıştır.

Juneja vd. (2022), retina fundus görüntüsünün merkezinde yer alan optik disk ve optik çanakdan kesin özellikler çıkarmak için daha az katman ve daha büyük filtre boyutları kullanarak glokomu erken aşamalarda teşhis etmek için kendi kendine öğrenmeyi sağlayan modifiye bir Diagnostics Xception ağına dayalı bir sınıflandırma sistemi önermiştir. Buna ek olarak, önerilen modelin performansını artırmak amacıyla görüntü boyutunu ve hesaplama süresini azaltmak için giriş görüntüleri kırılmış ve veri artırma uygulanmıştır. Ayrıca, Joshi ve diğerleri (2022), transfer öğrenmeye dayalı üç önceden eğitilmiş CNN mimarisini (ResNet50, VGG16Net ve GoogLeNet) topluluk yöntemiyle birleştirerek glokomun erken teşhisi için bir yöntem sunmuştur. Önerilen yöntem, konvolüsyonel sinir ağlarını kullanarak özellikleri çıkarmak için hem kamu hem de özel veri tabanlarından önceden işlenmiş retina fundus görüntülerini kullanır. Çıkarılan özellikler daha sonra maksimum oylama tekniğini kullanarak görüntüleri normal veya anormal olarak kategorize etmek için bir sınıflandırıcıya beslenir.

2.2.2 Glokom Çalışmaları için Vision Transformer

Renkli fundus görüntülerinde diyabetik retinopati (DR) derecelendirmesi için Vision Transformer (ViT) tabanlı modelleri kullanan birkaç çalışma (Adak vd., 2023; Gu vd., 2023; Mohan vd., 2022; Sun vd., 2021; Wu vd., 2021; Yao vd., 2022; Zhao vd., 2022)

yapılmıştır. Ancak, özellikle renkli fundus fotoğrafları kullanarak glokomu normal gözlerden ayırt etmeye odaklanan nispeten daha az sayıda çalışma vardır. ViT tabanlı modeller, glokom sınıflandırmasında umut verici sonuçlar ortaya koymuştur. Örneğin, Wassel vd. (2022), halka açık altı fundus görüntü koleksiyonundan oluşan birleşik bir veri seti kullanarak glokom tespiti için yediden fazla farklı ViT temel modelinin performansını değerlendirmişlerdir. Araştırmacılar ayrıca en iyi performans gösteren ViT modellerinden oluşan bir topluluk önermişler. Swin Transformer, %92,57 duyarlılık, %96,94 özgüllük ve %97,90 AUC ile en yüksek performansa ulaşmıştır.

Fan vd. (2023), ViT derin öğrenme tekniğinin tespitte genellenebilirliğini ve açıklama yeteneğini kapsamlı bir şekilde araştırmışlardır. Veri etkin görüntü Dönüştürücüsü (DeiT) ve ResNet-50 modellerinin performansını karşılaştırmışlardır. DeiT için AUROC 0,82 ile 0,91 arasında değişmektedir ve farklı sınıflandırmalarda güçlü performansa işaret etmektedir. Buna karşılık, ResNet-50 modelleri aynı veri kümelerinde daha düşük AUROC değerlerine sahiptir.

Mallick vd. (2022), ViT, Swin transformer ve tam bağlantılı bir CNN dahil olmak üzere çeşitli transformatör tabanlı sinir ağı mimarilerine odaklanmaktadır. Çalışmada üç genel veri seti ve bunların kombinasyonları kullanılmıştır. Sonuçlar, transformatör tabanlı ağların, özellikle transfer öğrenme teknikleri ve çeşitli veri setleriyle birleştirildiğinde, glokom tespiti için umut verici bir performans gösterdiğini ortaya koymaktadır. Haouli vd. (2023) ve Hwang vd. (2023) tarafından yapılan çalışmalar, fundus görüntülerinde glokom tespiti için ViT ve CNN'lerin performansını karşılaştırmaktadırlar. Sonuçlar çalışmalar arasında farklılık göstermektedir: Haouli vd. (2023), Vision Transformer yaklaşımının, özellikle dengesiz veri kümeleriyle uğraşırken CNN'lere kıyasla daha üstün performans elde ettiğini göstermektedir. Öte yandan, Hwang vd. (2023) her iki derin öğrenme stratejisinin glokom tespit görevlerinde benzer performans gösterdiğini belirtmektedirler.

3. MATERYAL VE YÖNTEM

Bu bölümde hem segmentasyon hem de sınıflandırma için kullanılan veri setleri açıklanmış ve her iki görev için kullanılan yöntemler ana hatlarıyla belirtilmiştir.

3.1 Veri Setleri

Bu çalışmada ORIGA (Zhang vd., 2010) ve DRISHTI-GS1 (Sivaswamy vd., 2014) olmak üzere iki dengesiz veri seti kullanılmıştır. Ayrıca, füzyon veri seti olarak adlandıracağımız bu iki veri setinin bir kombinasyonu da çalışmaya dahil edilmiştir. Dengesiz veri kümeleri, farklı sınıflardaki (örneğin, sağlıklı ve hastalıklı) örnek sayısının önemli ölçüde orantısız olduğu durumları ifade eder. DRISHTI-GS1 veri setinde glokom görüntülerinin sayısı sağlıklı görüntülerin sayısından daha fazlayken, ORIGA'da sağlıklı sınıfın çoğunlukta olduğu ters yönde bir dengesizlik vardır.

3.1.1 DRISHTI-GS1 Veriseti

Bu veri seti, PNG formatında 101 fundus görüntüsünden oluşmaktadır. Bunlardan 77 tanesi glokomatöz gözleri, 33 tanesi ise normal veya sağlıklı gözleri içermektedir. Görüntüler Hindistan'daki Aravind Göz Hastanesi'nden toplanmıştır ve 40 ila 80 yaş arası hastaların retinalarını temsil etmektedir. Her görüntü sıkıştırılmamış 30 derecelik bir görüş alanına sahiptir, optik disk üzerinde merkezlenmiştir ve 2896 x 1944 piksel boyutlarındadır. Bu görüntüler için ortalama optik disk ve çanak sınırları, çanak-disk oranı değerleri ve dört tıp uzmanı tarafından yapılan görüntü düzeyinde hastalık sınıflandırmaları dahil olmak üzere temel doğruluk bilgileri sağlanmıştır (Sivaswamy vd., 2014).

3.1.2 ORIGA Veriseti

ORIGA (Online Retinal Fundus Image Database for Glaucoma Analysis and Research) veri seti (Zhang vd., 2010), araştırmacıların bilgisayar destekli sınıflandırma algoritmalarını kıyaslamaları için açık erişim sağlamayı amaçlamaktadır. Sol göze ait 336 ve sağ göze ait 314 görüntü içeren bu veri tabanı, tamamı Singapur Göz Araştırma

Enstitüsünden eğitimli uzmanlar tarafından elde edilen 650 görüntüden oluşmaktadır. Görüntülerin tümü 3072×2048 piksel boyutlarında JPEG formatındadır. Bu görüntüler yaşları 40 ila 80 arasında değişen Malezyalı hastalardan toplanmıştır. Veri seti CDR ölçümleri sağlamaktadır ve her görüntü glokomatöz veya sağlıklı olarak etiketlenmiştir.

3.1.3 Füzyon Veriseti

Füzyon veri seti, farklı dosya uzantılarına ve boyutlarına sahip iki orijinal ORIGA ve DRISHTI-GS1 veri setinin bir karışımını içerir. Yaklaşık 515 sağlıklı ve 245 glokomatöz örnek içerir.

3.2 Metod


Literatür taraması bölümünde bahsedilen tüm meta sezgisel algoritmaların uygulanmasıyla elde edilen umut verici sonuçlar, fundus görüntü segmentasyonu için ek meta sezgisel algoritmaları keşfetmemiz için bize ilham verdi. Ayrıca, sınıflandırma görevleri alanında, son bölümde bahsedilen bazı çalışmalar, temel bağlamsal bilgi sağlayan görüntünün tümündeki özellikleri kullanmıştır. Bununla birlikte, birkaç çalışma özellikle optik diski çevreleyen ROI'ye odaklanmıştır. Bu çalışmalar, ROI'yi vurgulayarak karmaşıklığı azaltmış ve lokalize özelliklerin önemini vurgulayarak sınıflandırmada daha fazla doğruluk sağlamıştır. Bu tez çalışmasında sınıflandırma için hem kırılmış görüntüler (iki aşama) hem de kırılmamış görüntüler (tek aşama) kullanılmıştır. Bunun nedeni, en uygun modeli belirlemek ve kırılmış ROI kullanmanın daha iyi doğruluk sağlayıp sağlamadığını ortaya koymaktır. Aşağıdaki başlıklarda, bu çalışmada kullanılan segmentasyon ve sınıflandırma mimarileri ayrıntılı olarak açıklanmaktadır.

3.2.1 Gri Kurt Meta-Sezgisel Algoritması

3.2.1.1 Gri kurt optimizasyonunun sosyal hiyerarşisi

GKO algoritması, gri kurtların sosyal hiyerarşi avlanma davranışından esinlenen bir meta sezgisel algoritmadır. Algoritma gürbüz ve sürü tabanlı olarak düşünülebilir

(Komaki ve Kayvanfar, 2015). Gri kurtlar grup halinde yaşamayı tercih ederler. Bu grubun tüm üyelerinin belirli görevleri vardır. Her kurt sürüsünde, Şekil 3.1'de gösterildiği gibi piramidal bir yapı olarak modellenen 4 avlanma seviyesi vardır: Alfa, Beta, Omega ve Delta. Alfa grubun lideridir, bir erkek ve bir dişiden oluşur. Alfa çoğunlukla avlanma, uyku, yürüyüş zamanı ve benzeri konularda karar vermekten sorumludur. Alfa komutlarının diğer kurtlar tarafından takip edilmesi gerektiği düşünüldüğünde, bir alfanın grubun en güçlü üyesi olması gerekmez, ancak yönetim açısından en iyi üye olması ilginçtir. Beta kurtlar karar verme ya da gruba ilgili diğer faaliyetlerde alfalara yardımcı olur. Beta kurt, erkek ya da dişi olabilir ve bir alfa çok yaşlanırsa ya da ölürse alfa'nın yerini alacak en iyi adaydır. Beta, alfa komutlarını grup genelinde uygular ve geri bildirimleri alfaya iletir. Bir kurt alfa, beta veya omega gruplarına ait değilse, delta kurtlarıdır ve alfa ve betalara rapor vermelidir. Gözcüler, muhafızlar, yaşlılar, avcılar ve bakıcılar bu kategoriye aittir. Gözcüler bölgenin sınırlarını denetler ve herhangi bir tehlike durumunda grubu uyarır.



Şekil 3.1 Bozkurt Hiyerarşisi (Mirjalili vd., 2014)

Sosyal hiyerarşilerine ek olarak, gri kurtlar bir optimizasyon stratejisi olarak görülebilecek son derece uzmanlaşmış bir avlanma sürecine sahiptir. Gri kurtlar avlanırken aşağıdaki gibi özetlenen bir dizi verimli yöntem izler (Mirjalili vd., 2014):

1. Avı takip etme ve yaklaşma.
2. Avı hareket etmeyi bırakana kadar kovalamak, çevrelemek ve taciz etmek.

3. Bitkin düştüğünde avına saldırma ve Avlanma

Bu aşamalar Şekil 3.2'de gösterilmiştir



Şekil 3.2 Bozkurtların Avlanma Davranışı (a) Avı takip etme, kovalama ve yaklaşma (kırmızı daire). (b): Avı hareket etmeyi bırakana kadar kovalamak, kuşatmak ve taciz etmek. (c): Av bitkin düştüğünde saldırma ve avlamak (Mosavi vd.,2016)

3.2.1.2 GKO'nun matematiksel modeli

Bu bölüm GKO algoritmasını tasarlamak ve optimizasyon işlemini gerçekleştirmek için Şekil 3.2'de gösterildiği gibi avlanma yöntemi izleme, kuşatma ve saldırmanın matematiksel formülasyonlarını sunmaktadır.

Avın kuşatılması: Avı takip edip yaklaştıktan sonra (Şekil 3.2 (a)), avlanmanın ilk adımı avı kovalamak ve kuşatmaktır (Şekil 3.2 (b)). Bu süreci matematiksel olarak modellemek simüle etmek için önerilen denklem aşağıdaki gibidir:

$$X(t + 1) = X(t) - A . D \quad (3.1)$$

Burada $X(t+1)$ Gri kurdun bir sonraki konumu, $X(t)$ gri kurt'un (GK) mevcut konumu, D avın konumuna (X_p) bağlı bir vektör ve A , denklem 3.2 ve 3.3 ile hesaplanan bir katsayı matrisidir:

$$D = |C . X_p - X(t)| \quad (3.2)$$

$$A = 2a . r1 - a \quad (3.3)$$

$$\text{Burada} \quad C = 2 . r2 \quad (3.4)$$

a bir vektördür ve değeri algoritma çalışırken 2'den 0'a doğrusal olarak azalır. $r1$ ve $r2$ rastgele vektör $\in [0,1]$ 'dir ve kurtların iki belirli nokta arasında herhangi bir konuma ulaşmasına izin verir. Bu nedenle bir gri kurt, yukarıda belirtilen denklemlerle herhangi bir rastgele konumda avın etrafındaki uzay içindeki konumunu güncelleyebilir.

Avlanma süreci: Yukarıda sunulan denklemler ile bir kurt, avın etrafındaki bir arama uzayında herhangi bir noktaya yerleşebilir (Mirjalili vd., 2014). GK, avın konumunu optimum çözüm (X_p) olarak kabul ederek ve kurdun konumunu arama uzayındaki çözüm olarak temsil ederek avın konumunu tespit edebilir ve onu çevreleyebilir. Ne yazık ki, arama uzayında optimum çözümün (avın) gerçek konumu hakkında hiçbir bilgi yoktur. GK'nın davranışını matematiksel olarak simüle etmek için, alfa (mevcut en iyi çözüm), beta ve deltanın da bu sürece katıldığı varsayılmaktadır. Bu üç kurdun, en iyi üç arama ajanının türetilmesine yardımcı olan olası av bölgesi hakkında bilgi sahibi olduğu ve bu ajanların Eşitlik 3.5, 3.6 ve 3.7 ile temsil edildiği gibi diğer kurtların konumlarının güncellenmesine yardımcı olduğu varsayılmaktadır (Mosavi vd., 2016).


$$D_\alpha = |C_1 . X_\alpha - X|, \quad D_\beta = |C_2 . X_\beta - X|, \quad D_\delta = |C_3 . X_\delta - X| \quad (3.5)$$

$$X_1 = X_\alpha - A_1 . D_\alpha, \quad X_2 = X_\beta - A_2 . D_\beta, \quad X_3 = X_\delta - A_3 . D_\delta \quad (3.6)$$

$$X(t + 1) = X_1 + X_2 + X_3/3 \quad (3.7)$$

Ava saldırma (kullanım): Yukarıda belirtildiği gibi, GK'ler ava saldırarak ve av hareket etmeyi bırakır bırakmaz avı bitirecektir. Yaklaşma sürecini matematiksel olarak modellemek için a değerinin azaltılması gerekir. Başka bir deyişle A, $[-2a, 2a]$ aralığında rastgele bir değişkendir, A'nın rastgele değerleri $[-1, 1]$ aralığında yer alırken, bir arama ajanının (GK) bir sonraki konumu, mevcut konumu ile avın konumu arasındaki herhangi bir konumda olabilir. Şekil 3.3(a), $|A| < 1$ eşitsizliğinin kurtları ava saldırmaya zorladığını göstermektedir.

Optimum bir çözüm için arama veya keşif, kurtların arama davranışına göre modellenmiştir. GK'ler arasındaki arama süreci esas olarak alfa, beta ve delta kurtların konumu dikkate alınarak yapılır. Kurtlar av aramak için ayrışır ve av bulduklarında yakınsarlar. Rastgele değere sahip A vektörü 1'den büyük veya -1'den küçükse kurtlar daha iyi av bulmak için ayrışır. Bu prosedür tanımlama sürecini gösterir ve GKO algoritmasının küresel olarak arama yapmasını sağlar. Yerel optimumdan kaçınmak ve keşfi desteklemek için rastgele bir C kullanılır. Şekil 3.3(b), $|a| > 1$ eşitsizliğinin kurtları daha iyi bir av bulmak için çevreye dağılmaya zorladığını göstermektedir



Şekil 3.3 Bozkurtların Avlanma Stratejileri: (a): Avına saldırmak (b) ve avını aramak.

GKO algoritmasının temel adımları aşağıdaki gibi detaylandırılmıştır:

Adım 1: GKO algoritması için ilk parametre kurulumu.

Parametrenin popülasyon (kurt sayısı) boyutunun başlatılması, maksimum iterasyonlar

- Arama uzayı için UB ve LB, burada UB: Değişkenlerin üst sınırları, LB: Değişkenlerin alt sınırları
- UB ve LB kullanarak başlangıç gri kurt popülasyonu X_i (gri kurtların başlangıç konumu) oluşturun
- a, A ve C'yi başlat.

Adım 2: Her bir ajanın uygunluk fonksiyonunu hesaplayın,

Adım 3: En iyi arama aracı X_α , X_β ve X_δ 'yi bulun:

X_α = en iyi arama ajanı,

X_β = ikinci en iyi arama ajanı,

X_δ = üçüncü en iyi arama ajanı

Adım 4: Yineleme: başla;

n=0;

While (n < IterMax)

do - for{her bir arama ajanı}

denklemini kullanarak mevcut aracının konumunu güncelleyin (3.7).

a, A, C'yi güncelleyin tüm araçların uygunluğunu hesaplayın


güncelle X_α , X_β , X_δ

3.2.1.3 Optik disk segmentasyonu için GKO


GKO algoritması, OD'yi arka plandan izole eden gri seviye maskesinin eşik değerini tahmin etmek için kullanılır. Bu işlem glokom tespitinde ilk aşama olarak hizmet eder. OD'nin tespiti için GKO yaklaşımı Şekil 3.4'te gösterilmektedir. Veri setindeki her görüntü için ön işleme adımları uygulanır. Bu adımlar, Şekil 3.5(a)'daki gibi orijinal görüntünün okunmasını ve ardından optik disk bölgesinin görünürlüğü artırarak için Şekil 3.5(b)'deki gibi kırmızı kanalı çıkararak görüntünün gri ölçeğe dönüştürülmesini içerir. Şekil 3.5(c)'de görüldüğü gibi morfolojik kapatma işlemi uygulanarak optik diskteki sınırlar yumuşatılır ve boşluklar veya delikler doldurulur. Ayrıca, Şekil 3.5 (d)'de gösterildiği gibi arka planı bastırırken optik disk bölgesini etkili bir şekilde vurgulayarak ilgili özellikleri vurgulamaya ve gereksiz ayrıntıları kaldırmaya yardımcı olan gri bir maske (Abdullah vd., 2018) uygulanır. Gri tonlama maskesinin ardından

bir sonraki adım histogram eşitleme uygulamaktır. Histogram eşitleme, genel kontrastı iyileştirmek için görüntünün yoğunluklarını yeniden dağıtan bir işlemdir. Histogram eşitleme, yoğunluk değerlerini tüm aralık boyunca esneterek optik disk bölgesinin görünürlüğünü artırır ve daha sonra GKO tarafından yapılan analizi daha etkili hale getirir. Ardından, optik disk bölgesi için segmentasyon eşiğini optimize etmek üzere GKO algoritması kullanılır. Kurtlar, görüntünün histogram analizinden elde edilen görüntünün yoğunluk değerine dayalı olarak arama ajanlarının konumlarını yinelemeli olarak günceller. Bu çalışmada 30 arama ajanı (kurt sayısı) kullanılmaktadır.

Optimize edilmiş segmentasyon eşiği (av) elde edildikten sonra, segmente edilmiş optik disk bölgesini iyileştirmek için işlem sonrası teknikler kullanılır. Bu, gürültüyü gidererek ve optik diskin şeklini geliştirerek segmentasyon sonucunu daha da iyileştirmek için morfolojik işlemleri içerir. Şekil 3.6(a) ve (b) son olarak bölütleme sonucunu yer gerçeği (gerçek veri) ile karşılaştırmaktadır. Segmentasyonu değerlendirmek için duyarlılık, özgüllük, doğruluk, Jaccard indeksi ve Dice katsayısı gibi çeşitli değerlendirme ölçütleri kullanılmaktadır. Bu metrikler, segmentasyon algoritmasının performansının yer gerçeği verilerine kıyasla nicel ölçümlerini sağlar.



Şekil 3.4 Optik disk tespiti için akış şema



Şekil 3.5 Ön işleme adımı




Şekil 3.6 Segmentasyon Sonucu

3.2.2 Derin Öğrenme Temelli Glokom Sınıflandırma

Glokom sınıflandırma için çalışma kapsamında kullanılan ana çerçeve Şekil 3.7’de gösterilmektedir. Bu kapsamlı çerçeve, retina fundus görüntülerini kullanarak glokomlu ve sağlıklı bireyleri sınıflandırmada farklı model ve yaklaşımların performansının değerlendirilmesini sağlamıştır. Bu çalışmada sınıflandırma için iki model kullanılmıştır. Model-1, DenseNet201, VGG19, ResNet50, InceptionV3 önceden eğitilmiş CNN’ler ve Swin Transformer ile sınıflandırma yapmaktadır. Model-2 ise, Model-1’deki CNN’lerden çıkarılan özellikler ile beslenen Bi-LSTM, RO, k-NN ve DVM ile sınıflandırma işlemini gerçekleştirmektedir.

Bunun yanı sıra çalışma kapsamında Şekil 3.7’de de görüleceği üzere iki sınıflandırma yaklaşımı önerilmektedir. Bunlardan birincisi görüntüleri kırpmadan orijinal haliyle modellere besleyerek sınıflandırma yapan tek aşamalı bir yaklaşım ve ikincisi ise YOLO algılama algoritması ile kırptılan OD bölgesini modellere besleyerek sınıflandırma yapan iki aşamalı yaklaşımdır. İki aşamalı yaklaşım, optik diske odaklandığı ve genel sınıflandırma performansını artırdığı için özellikle avantajlıdır.



Şekil 3.7 Önerilen glokom sınıflandırma çerçevesine genel bakış

3.2.2.1 YOLO

YOLO, Redmon tarafından 2016 yılında geliştirilen son teknoloji ürünü bir nesne algılama algoritmasıdır. Nesne tespitini bir sınıflandırma ve regresyon problemi olarak ele alır. YOLO'nun tek aşamalı olarak tespiti derin öğrenmeye dayanır. YOLO, her bir sınırlayıcı kutuyu tahmin etmek için tüm görüntüden çıkarılan özellikleri kullanır.

Dahası, verilen bir görüntü için tüm sınıfların tüm sınırlayıcı kutularını aynı anda tahmin eder (Sarraf vd., 2016)

YOLO modeli, girdi görüntüsünün hücrelerden (C) oluşan bir ızgaraya bölündüğü ve böylece $S \times S$ boyutlarında kare blokların oluşturulduğu bir metodoloji kullanır. Bir sınırlayıcı kutunun her tahmini beş temel unsurdan oluşur: x, y, w, h ve güven. x ve y koordinatları, sınırlayıcı kutunun merkezinin ait olduğu ızgara hücresine göre konumunu belirtirken, w genişliği ve h ise yüksekliği belirtir. Sınırlayıcı kutunun genişliği ve yüksekliği tüm görüntüye oranlanarak gösterilir. Güven puanı, sınırlayıcı kutunun bir nesneyi kapsama olasılığını ve tahmininin doğruluğunu gösterir. YOLO algoritmasındaki tahminler, tahmin edilen sınırlayıcı kutu ile yer gerçeği sınırlayıcı kutusu arasındaki birlik üzerindeki kesişime (IoU) dayanmaktadır. Kesişim, iki kutunun örtüştüğü alanı ifade ederken, birleşme her iki kutunun birleşik alanını ifade eder. IoU, denklem (3.8)'de gösterildiği gibi kesişim alanının birleşme alanına bölünmesiyle hesaplanır (Gou vd., 2021).

$$IOU = (\text{Area of intersction} / \text{Area of Union}) \quad (3.8)$$

Modellerin nesne tespitindeki etkinliğini değerlendirmek için kullanılan bir diğer ölçüt de denklem 3.9'da verilen ortalama hassasiyettir (mAP). Bu denklemde, AP_k , k sınıfı için ortalama hassasiyeti temsil ederken, n toplam sınıf sayısını temsil eder. mAP metriği tanımlanan sınırlayıcı kutuyu temel gerçek ile karşılaştırır.

$$mAP = \frac{1}{n} \sum_{k=1}^n AP_k \quad (3.9)$$

3.2.2.2 Transfer öğrenme

Transfer öğrenme (TÖ), bir modelin başka bir görev için hizmet etmeden önce başka problemler üzerinde öğrenmenin gerçekleştiği bir öğrenme yöntemidir. Bu, birincil probleme yakın bir prosedürün zaten mevcut olduğu ve ilgili görevin çok fazla veri gerektirdiği problemler için uygun bir yaklaşımdır (Wainberg vd., 2018). Transfer öğrenimi, önceden eğitilmiş bir CNN modelinden özellik çıkarma tekniğini kullanır. Bu durum, geliştiricilerin bir modeli eğitirken baştan başlama ihtiyacını ortadan

kaldırır. Bir TÖ modeli genellikle büyük bir veri seti (örneğin ImageNet) üzerinde eğitilir (Pan vd., 2018). Bu çalışmada, önceden eğitilmiş CNN modellerinin eğitiminde transfer öğrenme yaklaşımı kullanılmıştır. Retina görüntüleri üzerinde glokomu sınıflandırma ve tanımlama görevi için dört popüler ve güçlü son teknoloji DenseNet201, ResNet50, InceptionV3 ve VGG19 CNN mimarileri kullanılmıştır.

DenseNet201 modeli, 201 derin katmana sahip önceden eğitilmiş bir CNN'dir. DenseNet201, katmanlar arasında $L(L-1)/2$ doğrudan bağlantı ile yoğun bağlantılı bir mimariye sahiptir. Bu, önceki tüm katmanlardan gelen özellik haritalarının sonraki her katman için girdi olarak kullanıldığı anlamına gelir. Bu yoğun bağlantı önemli avantajlar sağlamaktadır: Çok derin sinir ağlarında yaygın olan kaybolan gradyan sorununu hafifletir. Özelliklerin model boyunca yayılmasını geliştirir (He vd., 2016).

ResNet50 modelinin, adındaki "50", Resnet mimarisinin bu versiyonunun 50 derin, yığılmış katmana sahip olduğunu gösterir. Bazı katmanların ağdaki bazı katmanların "üzerinden atlamasına" izin vermek için "atlama bağlantıları" veya "kısayollar" adı verilen benzersiz bir yaklaşım kullanır. ResNet50'deki katmanlar, katmanın girişi ve çıkışı arasındaki farkı temsil eden bir artık işlevi öğrenir. Bu, çok derin mimarilerde bile ağın gerekli dönüşümleri öğrenmesini kolaylaştırır (He vd., 2016).

Bir başka önceden eğitilmiş CNN olan InceptionV3 mimarisi 48 konvolüsyon katmanına, simetrik ve asimetrik yapı taşlarına, ortalama/maksimum havuzlamaya ve tam bağlı katmanlara sahiptir (Szegedy vd., 2015). Mimari boyunca toplu normalizasyon uygulanır ve kayıp fonksiyonu olarak Softmax kullanılır. InceptionV3, katmanlar arası ve uzamsal korelasyonları ayrı ayrı dikkate alan işlem kümelerini çözerek daha basit ve verimli çalışır. Toplu normalleştirme, mimari boyunca tutarlı bir şekilde uygulanır ve Softmax, kayıp işlevi olarak hizmet eder. Esasen, InceptionV3, katmanlar arası ve uzamsal korelasyonları ayrı ayrı dikkate alan işlem kümelerini ele alarak basitliği ve verimliliği artırır (Arshad vd., 2020).

VGG19 modeli, Oxford Robotik Enstitüsü'ndeki Görsel Geometri Grubu tarafından geliştirilen CNN mimarisidir. VGG19 mimarisi beş yapı taşından oluşmaktadır. Birinci ve ikinci blokların her biri 2 konvolüsyonel katman ve 1 havuzlama katmanı

içerir. Üçüncü ve dördüncü bloklar 4 konvolüsyonel katman ve 1 havuzlama katmanı içerir. Son blok ise 4 konvolüsyonel katmandan oluşmaktadır (Arshad vd., 2020).

3.2.2.3 Makine öğrenmesi

Sağlam bir uygulama geliştirmek için, üç klasik makine öğrenmesi algoritmasından da tahminler elde edilerek sınıflandırma sistemi geliştirilmiştir.

1- RO, tahminlerde bulunmak için birden fazla karar ağacını birleştiren yaygın bir makine öğrenimi topluluğu yöntemidir. Birçok karar ağacından oluşan bir topluluk oluşturarak tek bir karar ağacının sınırlamalarının üstesinden gelir. RO'nın en temel özelliği, RO'daki her karar ağacının eğitim verilerinin rastgele seçilmiş bir alt kümesi üzerinde eğitilmesidir. Her ağaç ayrıca mevcut özelliklerin rastgele bir alt kümesini kullanır. Sınıflandırma görevleri için nihai tahmin, tüm bireysel ağaç tahminleri arasında bir çoğunluk oyu ile yapılır (Subbarayudu vd., 2024).

2- DVM, çeşitli sınıflandırma ve regresyon problemlerini çözmek için yakın zamanda geliştirilmiş bir tekniktir. DVM'nin temel fikri, en yakın eğitim örüntülerinden maksimum uzaklığa (marj) sahip karar düzlemini bulmaktır. Bu çalışmada retina fundus görüntüleri kullanılarak Glokom tespiti gibi ikili sınıflandırma görevleri için kullanılmaktadır. DVM'nin sınıflandırıcılardan biri olarak seçilmesinin sebebi çeşitli düzenleme parametreleri sağlayarak aşırı uyumu önlemesidir. Ayrıca, DVM araştırmacılar tarafından glokom tespiti için ikili sınıflandırma yapmada yaygın olarak kullanılmaktadır (Aljohani vd., 2024).

3- k-NN, bir örnek, özellik uzayında en yakın komşusuyla aynı sınıfa veya bir grup komşunun çoğunluk sınıfı olarak tanıtılır (Arsyan ve Al Maki vd., 2022). k-NN algoritmasının kullanımı zor değildir ve uzun bir hesaplama süresi gerektirmez. Bir diğer avantajı ise veriler hakkında varsayımlarda bulunmamasıdır. İyi bir doğruluğa sahip olmak için iyi kalitede veri gerektirir. En zorlayıcı yönü k için en uygun değeri bulmaktır.

3.2.2.4 Bidirectional Long Short-Term Memory

LSTM ve çift yönlü LSTM (Bi-LSTM), öncelikle doğal dil işlemede kullanılan tekrarlayan bir sinir ağına aittir (URL-2, 2024). Geleneksel LSTM, gizli durumlar aracılığıyla yalnızca geriye doğru girdiler aldığı için önceki verileri sunar (Wei vd., 2021). Bi-LSTM ağı, LSTM ağlarını aynı anda ileri ve geri yönde eğitir ve LSTM'den daha iyi tahmin sonuçları elde etmek için örneğin geçmiş ve gelecek zaman özelliklerini aynı anda çıkarabilir. Joshi vd. (2022)'ye göre, geleneksel LSTM ağında, çıkış katmanı mevcut t zaman adımındaki giriş verilerinden ve önceki zaman adımlarından ($t-1, t-2, \dots, t-N$) geriye doğru gizli durumdan bilgi alır. Buna karşılık, çift yönlü LSTM ağı ayrıca gelecek zaman adımlarından ($t+1, t+2, \dots, t+N$) ileriye doğru gizli durumu kullanır. Bu çift yönlü işleme, Bi-LSTM'nin giriş dizisinden daha fazla bağlamsal bilgi yakalamasını sağlar. Bi-LSTM, her bir LSTM ağının bir grup girdiyi işlediği ve bir grup çıktı ürettiği çoklu girdi ve çoklu çıktı stratejisiyle tasarlanabilir. Bi-LSTM, denklem 3.10'da gösterildiği gibi, zaman serisi verilerinden n adımlı bir tahmin modeli F 'yi eğitir.

$$F(x_1, x_2, \dots, x_t) = [x_{t+1}, x_{t+2}, \dots, x_{t+n}] \quad (3.10)$$


Burada, $x_{t+1}, x_{t+2}, \dots, x_{t+n}$ çoklu giriş ve çoklu çıkış stratejisini kullanan Bi-LSTM modelinden elde edilen n -adım ileri tahmin sonuçlarıdır.

3.2.2.5 Görüntü transformatörü (ViT)

ViT, ilk olarak makine çevirisi için geliştirilmiştir ve bilgisayarla görme alanındaki potansiyelleri fark edilmiştir. Dönüştürücünün mimarisi ESA'lerden farklıdır. CNN'ler konvolüsyonel, havuzlama ve tam bağlı katmanlar dahil olmak üzere birçok katman türünden oluşur (Singh vd., 2023). ViT'ler, her biri bir öz dikkat katmanı ve bir ileri besleme katmanından oluşan bir dizi transformatör bloğu içerir (Lin vd., 2022). Ayrıca, dönüştürücünün ön işleme adımında giriş görüntüsünün boyutunu benimsemesine gerek yoktur. Dikkat mekanizmaları çoğunlukla, dönüşüme dayalı modelin girdi görüntüsünün ilgili kısımlarına odaklanmasına ve uzun menzilli bağımlılıkları etkili bir şekilde yakalamasına olanak tanıyan görme dönüştürücülerinde kullanılır.

3.2.2.6 Derin özellikleri çıkarımı

Geleneksel makine öğrenimi ve Bi-LSTM tabanlı Model-2'yi eğitmek için hem kırılmamış retina görüntüleri hem de YOLO kullanılarak kırılmış görüntüler önceden eğitilmiş CNN modellerine beslenerek derin özellikler çıkarılmıştır. Özellikle, DenseNet201, ResNet50, InceptionV3 ve VGG19 CNN modellerinin tam bağlı katmanlarından hemen önceki katmanlar özellikleri çıkarmak için kullanılmıştır. Öznitelikleri çıkarmak için kullanılan katmanlar ve her katmandan elde edilen öznitelik sayısı Şekil 3.8'de gösterilmektedir. DenseNet201 modelinin 'global_average_pooling2d_12' katmanından 1920 özellik, ResNet50 ve InceptionV3 modellerinin 'global_average_pooling2d' katmanlarından 2048 özellik ve VGG19 modelinin 'flatten' katmanından ise 25.088 özellik elde edilmiştir.



Şekil 3.8 Derin özelliklerin çıkarılması

3.3 Performans Ölçütleri

Çalışma kapsamında önerilen segmentasyon ve sınıflandırma yöntemlerinin performansını değerlendirmek için çeşitli metrikler kullanılmıştır. Segmentasyon için Dice Benzerlik Katsayısı (Dice), Jaccard İndeksi (Jaccard), Özgüllük (Specificity), Hassasiyet (Sensitivity) ve Doğruluk (Accuracy) metriklerine göre değerlendirmeler yapılmıştır. Sınıflandırma görevleri için ise, doğruluk, hassasiyet ve özgüllüğe ek

olarak F1 puanı (F1-Score) ve kesinlik (precision) metrikleri de kullanılmıştır. Bu metriklerin matematiksel formülasyonu aşağıdaki gibidir:

$$\text{Accuracy} = TP / (TN + FN + TP + FP) \quad (3.11)$$

$$\text{Dice} = 2 \times TP / (FN + 2 \times TP + FP) \quad (3.12)$$

$$\text{Specificity} = TN / (TN + FP) \quad (3.13)$$


$$\text{Sensitivity} = TP / (TP + FN) \quad (3.14)$$

$$\text{Jaccard} = TP / (TP + FP + FN) \quad (3.15)$$

$$\text{Precision} = TP / (TP + FP) \quad (3.16)$$

$$\text{F1-Score} = (2 \times (\text{Precision} * \text{Recall})) / ((\text{Precision} + \text{Recall})) \quad (3.17)$$

Tüm bu metrikler ortalama değer olarak hesaplanır ve Eşitlik 3.11 ile Eşitlik 3.17'de gösterilen TP, FP, TN ve FN değerlerine dayanır. Burada TP, FN, TN ve FP sırasıyla doğru pozitif, yanlış pozitif, doğru negatif ve yanlış pozitif piksel oranlarıdır (Şekil 3.9).



Şekil 3.9 Optik disk segmentasyonu ve glokom sınıflandırması için kullanılan metrik

4. BULGULAR ve TARTIŞMA

Bu bölümde, optik disk segmentasyonu için GKO algoritmasının uygulanmasına ilişkin deneysel sonuçlar ve bulguların kapsamlı bir tartışması sunulmaktadır. Ayrıca, glokom tespiti için önemli bir ön işleme adımı olarak OD'nin YOLO ile tespitine ilişkin deneysel sonuçlar, derin öğrenme ve makine öğrenimi modelleri kullanılarak gerçekleştirilen sınıflandırma sonuçları ayrıntılı olarak açıklanmaktadır. Bunun yanı sıra, sonuçların ayrıntılı analizi sayesinde, her bir modelin güçlü yönleri ve sınırlamalarına yönelik öngörüler tartışılarak glokom tespiti alanında gelecekteki araştırmalar için bir temel sağlanmaktadır.

4.1 Hiperparametre Seçimi

Sınıflandırma için kullanılan Model-1 ve Model-2'nin eğitiminde dışarda tutma ve k-kat çapraz doğrulama yöntemleri kullanılmıştır. Dışarda tutma yönteminde her iki veri setinde verilerin %80'i eğitim ve %20'si test için kullanılmıştır. Ayrıca, DRISHTI-GS1 için üç kat ve ORIGA için beş kat çapraz doğrulama kullanılmıştır.

An vd. (2018)'e göre optimizasyon, milyonlarca hatta milyarlarca parametrenin nasıl güncelleneceğini belirleyen bir öğrenme algoritmasıdır. Eğitim için optimizasyon tekniklerinin seçilmesi zorlu bir görevdir (Maas vd., 2017). Bu nedenle, modeller geliştirilirken Adam, Sgd, Rmsprop, Adamax ve Nadam algoritmaları test edilmiştir. Tablo 4.1'de en iyi sınıflandırma performansının elde edildiği hiper parametreler gösterilmektedir. "Temel Model Eğitilebilir" parametresi evrişim ve havuzlama katmanları ile ilgilidir. Bu parametre "False" olarak ayarlandığında, hiçbir eğitim gerçekleştirilmez ve bu katmanlar dondurulur. "imagenet" ağırlıkları aynen olduğu gibi kullanılır. Önceden eğitilmiş CNN modellerinde bu parametre "False" olarak ayarlanmıştır.

Öğrenme oranı, model eğitiminde çok önemli bir parametredir. Aşırı yüksek öğrenme oranları eğitim sürecinde salınımlara neden olabilir. Çok düşük ayarlanırsa eğitim süresi artabilir. Bu nedenle, model eğitimi sırasında çeşitli öğrenme oranları test edilmiş ve en iyi performansı üreten değer çalışmada raporlanmıştır.


Tablo 4.1 DRISHTI-GS1, ORIGA ve Füzyon Veri seti için önceden eğitilmiş modellerin parametreleri.

Önceden Eğitilmiş CNN Modeli	Optimizasyon Algoritması	Öğrenme Oranı	Küme Boyutu	Epoch	Aktivasyon Fonksiyonu	Temel Model Eğitilebilir	Kayıp Fonksiyon
SwinTransform	RmsProp	0,001	32	150	Relu Softmax	False	Categorical Cross-entropy
DenseNet201	Rmsprop	0,001	32	150			
Resnet50	Adam	0,001	32	150			
InceptionV3	Sgd	0,01	32	150			
VGG19	Adamax	0,001	32	150			
DenseNet201+ Bi-LSTM	Nadam	0,02	32	100	rnnWidth=64, pdropOut=0,001		
VGG19+ Bi-LSTM	Adamax	0,001	32	100	rnnWidth=64, pdropOut=0,01		
ResNet50+ Bi-LSTM	Nadam	0,0002	32	100	rnnWidth=64, pdropOut=0,01		
InceptionV3+ Bi-LSTM	Nadam	0,0002	32	100	rnnWidth=64, pdropOut=0,01		

4.2 GKO ile OD Segmentasyon Sonuçları


Optik disk segmentasyonunda GKO modelinin etkinliğini ve doğruluğunu ölçmek için, Şekil 4.2a gösterilen GKO segmentasyon sonucu Şekil 4.2b’de verilen temel gerçek ile karşılaştırılmaktadır. Hesaplanan çeşitli metriklere göre GKO modeli retina görüntülerinde optik diski segmente etmede oldukça etkili bir performansa işaret etmektedir. GKO modeli 0,9604’lük bir duyarlılık ortaya koymaktadır. Bu, modelin gerçek pozitifleri (optik disk) %96,04 oranında doğru bir şekilde tanımladığını ve hedef alanları bulma konusunda yüksek bir yeteneğe sahip olduğunu göstermektedir. Bunun yanı sıra, 0,9958’lik bir özgülük, modelin gerçek negatifleri (arka plan alanları) %99,58 oranında doğru tanımladığını gösterir. Bu da modelin yanlış pozitifleri önleme konusunda çok iyi olduğu anlamına gelmektedir. Modelin %99,39’luk bir doğruluk oranına ulaşması, GKO modeli tarafından yapılan tüm tahminlerin (hem pozitif hem de negatif) doğru olduğunu gösterir. Bu, modelin genel performansının güçlü bir göstergesidir, ancak özellikle sınıf dengesizliği durumlarında dikkatle yorumlanmalıdır. Ön planın (OD), arka plandan çok daha küçük olduğu durumlarda, bir model çoğu zaman çoğunluk sınıfını (arka plan) tahmin ederek yüksek doğruluk elde edebilir. Örneğin, aşağıdaki Şekil 4.1a’daki ROI bölgesinin Şekil 4.1b’deki temel gerçekten daha küçük olmasına rağmen doğruluğun %98,32 olduğunu göstermektedir. Bu nedenle, tahmin edilen ve gerçek pozitif bölgeler arasındaki örtüşmeye

odaklanmak için Dice Katsayısı (DIC) ve Jaccard Endeksi gibi metrikler de çalışma kapsamında kullanılmıştır.



Şekil 4.1 Ön plan boyutunun segmentasyon doğruluğu üzerindeki etkisi

Modelde %94,15'lik Dice katsayısı elde edilmiştir. Bu değer, tahmin edilen segmentasyon ve temel gerçek arasında güçlü bir örtüşme olduğunu göstermektedir. Ayrıca segmentasyonun klinik analiz için gerekli olan gerçek optik disk sınırlarıyla yakından eşleştiğini göstermektedir. Jaccard indeksinin %90,4 olması da sağlam segmentasyon performansını desteklemektedir. Bu metrik hem yanlış pozitifleri hem de yanlış negatifleri dikkate aldığı için Dice katsayısından biraz daha düşüktür, ancak yine de ilgili bölgeleri yakalamada güçlü bir performansa işaret etmektedir. Şekil 4.2, DRISHTI-GS1 veri setinden hem sağlıklı hem de glokomlu retina görüntüleri üzerindeki segmentasyon sonuçlarını göstermekte ve nicel bulguları tamamlayan görsel kanıtlar sunmaktadır.



Şekil 4.2 GKO metasezgisel algoritması kullanılarak optik disk bölütleme yöntemi performansları (a): retina görüntüleri; (b): bölütleme sonucu, (c): temel gerçek.


4.3 YOLO ile Nesne Algılama

YOLO tespit algoritması DRISHTI-GS1 ve ORIGA veri kümeleri üzerinde çalıştırılmıştır. Bu uygulamada YOLO'nun amacı, retina fundus görüntülerindeki optik disk bölgesini tespit etmek ve bu bölgeyi kırparak yeni bir veri seti elde etmektir. Bu yaklaşımda, elde edilen kırpılmış veri seti önceden eğitilmiş ESA modellerine beslenerek modellerin hastalıklı bölgeye odaklanması amaçlanmıştır. YOLO'yu eğitmeden önce, DRISHTI-GS1 veri setindeki 101 retinal fundus görüntüsündeki OD bölgesi labelImg (<https://github.com/tautalin/labelImg>) uygulaması ile etiketlenmiştir. Daha sonra, YOLOv7 rastgele seçilen 70 etiketli görüntü üzerinde 300 epok boyunca eğitilmiştir. Test işlemi kalan 31 görüntü üzerinde gerçekleştirilmiştir. Modelin performansı mAP ve IoU metriklerine göre değerlendirilmiştir. Eğitim ve test verilerinden elde edilen performans metrikleri Tablo 4.2'de gösterilmiştir. Ortalama hassasiyet (mAP) metriğine göre değerlendirme yapılırken, belirli bir IoU eşiğinin üzerindeki sınırlayıcı kutular dikkate alınmıştır. IoU eşiği 0,50 olarak alındığında, eğitim ve test verileri için mAP değerleri sırasıyla %99,53 ve %99,50'dir. Hem eğitim hem de test verileri için R ve P değerleri 1'dir.

Tablo 4.2 YOLOV7 algılama algoritması için mAP, R ve P performans ölçümleri

Eğitim/Test	mAP@0.5 (%)	P	R
Eğitim	99.53	1	1
Test	99.50	1	1

YOLOV7 modeli eğitildikten sonra tüm görüntüler bu modele verilmiş ve optik disk bölgesi belirlenerek otomatik olarak kırpılmıştır. Kırpılmış optik disk bölgelerinden oluşan görüntülerle yeni bir veri seti oluşturulmuştur. Test verisi üzerinde YOLO modelinin optik disk bölgesini tespit ettiği bir görüntü örneği Şekil 4.3'te sunulmuştur.



Şekil 4.3 YOLO ile Tespit Edilen Optik Disk Bölgesinin Kırpılması

4.4 Glokom Sınıflandırma Sonuçları

4.4.1 DRISHIT-GS1 Veri Seti için Sınıflandırma Sonuçları

Tablo 4.3'te önceden eğitilmiş DenseNet201, ResNet50, Vgg19, InceptionV3 ve Swin Transformer mimarileri (Model1) ile tek aşamalı ve iki aşamalı yaklaşımlar kullanılarak yapılan dışarda tutma doğrulama sınıflandırmasının sonuçları DRISHTI-GS1 veri seti için gösterilmektedir. Kırpılmış veri seti üzerinde (iki aşamalı yaklaşım) DenseNet201 ve Vgg19 benzer sonuçlar sergilemektedir. Her iki model de %90,48 doğruluğa, %93,33 duyarlılığa ve %83,33 özgüllüğe sahiptir. Bu modeller glokom vakalarını %90,48 oranında ve sağlıklı vakaları ise %83,33 oranında doğru bir şekilde sınıflandırmaktadır. ResNet50 modeli bu modellere benzer bir doğruluğa sahiptir. Ancak, modelleri doğruluk temelinde karşılaştırmak uygun olmayabilir. ResNet50 glokom vakalarını %100 oranında doğru sınıflandırırken, sağlıklı vakaları yalnızca %66,67 oranında doğru sınıflandırmaktadır. Benzer bir durum InceptionV3 modeli

için de geçerlidir. Swin Transformer, kırılmış veri seti üzerinde düşük doğruluk (%76,19) değerine sahipken kırılmamış veri seti üzerinde %100 doğruluk değerine sahiptir. Kırılmamış görüntüler söz konusu olduğunda, Swin Transformer tüm ölçütlerde üstünlük sağlayarak %100 doğruluk elde eder. Diğer modellerde ise kırılmış veri seti üzerindeki sınıflandırma doğruluğu kırılmamış veri setine göre genel olarak daha yüksektir.

Tablo 4.3 DRISHTI-GS1 veri seti için tek aşamalı ve iki aşamalı yaklaşımların dışarda tutma doğrulama sınıflandırma sonuçları

Modeller	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	F1_Skoru (%)	Kesinlik (%)
Kırılmış Veri Seti (İki Aşamalı Yaklaşım)					
DenseNet201	90,48	93,33	83,33	90,48	90,48
Vgg19	90,48	93,33	83,33	90,48	90,48
ResNet50	90,48	100	66,67	89,82	91,60
Swin Transformer	76,19	100	16,67	69,39	82,14
Inception V3	80,95	93,33	50,00	79,64	80,25
Kırılmamış Veri Seti (Tek Aşamalı Yaklaşım)					
Swin Transformer	100	100	100	100	100
ResNet50	85	80	86,7	81,87	83,33
Inception V3	80	75	81,2	74,62	78,125
DenseNet201	75	57	84,6	70,88	72,62
Vgg19	75	66,7	76,5	71,56	63,09

Model performansını test etmek için tek başına dışarda tutma doğrulama kullanmak yeterli değildir. Bu nedenle, daha adil bir karşılaştırma için k-kat çapraz doğrulama yöntemi de çalışma kapsamında kullanılmıştır. Bu çalışmada, DRISHTI-GS1 veri seti için 3 katlı çapraz doğrulama yöntemi uygulanmış ve iki aşamalı yaklaşım için sınıflandırma performansları Tablo 4.4'te sunulmuştur. En yüksek sınıflandırma performansı %81,19 doğrulukla DenseNet201 ve ResNet50 modelleri ile elde edilmiştir. Bu doğruluk değeri, dışarıda tutma doğrulama yönteminden elde edilene kıyasla daha düşüktür. Örtüşen karışıklık matrisinden elde edilen R ve S metrik değerlerine göre, DenseNet201 glokom vakalarını %92,86; sağlıklı bireyleri ise %54,84 oranında doğru sınıflandırmaktadır. ResNet50 için bu oranlar sırasıyla %94,29 ve %51,61'dir. Bu iki model glokom vakalarını sınıflandırmada yüksek doğruluk sergilerken sağlıklı bireyleri sınıflandırmada düşük doğruluk sergilemektedir.

Tablo 4.4 Model-1'in DRISHTI-GS1 veri setinde kırılmış görüntüler için 3-kat çapraz doğrulama sınıflandırma sonuçları

Modeller	Kat	TP	TN	FP	FN	R	S	P	F1	Acc
DenseNet-201	Kat 1	21	8	2	3	87,50	80,00	85,84	85,49	85,29
	Kat 2	21	5	6	2	91,0	45,45	75,72	84,00	76,47
	Kat 3	23	4	6	0	100	40,00	85,58	78,97	81,82
	Örtüşen									
	Glokom	65	17	14	5	92,86	54,84	82,28	87,25	
	Normal	17	65	5	14	54,84	92,86	77,27	64,15	
	Ortalama					73,85	73,85	79,78	75,7	81,19
RESNET50	Glokom	66	16	15	4	94,29	51,61	81,48	87,42	
	Normal	16	66	4	15	51,61	94,29	62,74	62,75	
	Ortalama					72,95	72,95	72,11	75,09	81,19
	Örtüşen									
Başlangıç V3	Glokom	63	16	15	7	90,00	51,61	80,77	85,14	
	Normal	16	63	7	15	51,61	90,00	69,57	59,26	
	Ortalama					70,81	70,81	75,17	72,20	78,28
	Örtüşen									
VGG19	Glokom	64	13	18	6	91,43	41,94	78,05	84,21	
	Normal	13	64	6	18	41,94	91,43	68,42	52	
	Ortalama					66,69	66,69	73,24	68,11	76,20
	Örtüşen									
Swin Transformatör	Glokom	66	10	21	4	94,29	32,26	75,87	84,08	
	Normal	10	66	4	21	32,26	94,29	71,43	44,44	
	Ortalama					63,28	63,28	73,65	64,26	75,31
	Örtüşen									

Ayrıca, bu modellerin performansını ortaya koymak için kırılmamış veri seti de kullanılmıştır. Tablo 4.5, %88,18'lik doğruluk oranıyla Swin Transformatörünün en yüksek sınıflandırma performansına sahip olduğu sonuçları sunmaktadır. Bu sonuç, dışarda tutma yönteminde elde edilen sonuçla uyumludur. Swin Transformatör glokom vakalarını %94,29 oranında, sağlıklı bireyleri ise %74,19 oranında doğru bir şekilde sınıflandırmaktadır. Genel olarak, Drishti GS veri setindeki glokom sonuçları, önceden eğitilmiş CNN modellerinin, özellikle de Swin transformatörünün, dışarda tutma ve 3-Kat yöntemleri kullanılarak glokom sınıflandırmasındaki etkinliğini göstermektedir

Tablo 4.5 Model-1'in DRISHTI-GS1 veri setinde kırılmamış görüntüler için 3-kat çapraz doğrulama sınıflandırma sonuçları

Modeller	Kat	TP	TN	FP	FN	R	S	P	F1	Acc
Swin Transformer	Kat 1	21	6	5	2	91,30	54,55	78,90	78,42	79,41
	Kat 2	23	8	2	1	95,83	80	91,08	91,03	91,18
	Kat 3	22	9	1	1	95,65	90	93,94	93,94	93,94
	Ortalama									
	Glokom	66	23	8	4	94,29	74,19	89,19	91,67	88,18

Tablo 4.5'nin devamı

	Normal	23	66	4	8	74,19	94,29	85,19	79,31
	Ortalama					84,24	84,24	87,19	85,49
	Örtüşen								
Inception V3	Glokom	65	19	12	5	92,86	61,29	84,42	88,44
	Normal	19	65	5	12	61,29	92,86	79,17	69,09
	Ortalama					77,08	77,08	81,80	78,77
	Örtüşen								83,18
DenseNet-201	Glokom	67	14	17	3	95,71	45,16	79,76	87,01
	Normal	14	67	3	17	45,16	95,71	82,35	58,33
	Ortalama					70,44	70,44	81,06	72,67
	Örtüşen								80,21
RESNET50	Glokom	62	18	13	8	88,57	58,06	82,67	85,52
	Normal	18	62	8	13	58,06	88,57	69,23	63,16
	Ortalama					73,32	73,32	75,95	74,34
	Örtüşen								79,26
VGG19	Glokom	59	19	12	11	84,29	61,29	83,10	83,69
	Normal	19	59	11	12	61,29	84,29	63,33	62,30
	Ortalama					72,79	72,79	73,22	72,99
	Örtüşen								77,21

Tablo 4.6, Model-2'deki Bi-LSTM, RO, k-NN ve DVM modellerinin kırılmış görüntüler için dışarda tutma doğrulama sınıflandırma sonuçlarını göstermektedir. Bu tabloda da görüldüğü gibi en yüksek doğruluk değeri Model-1'e benzer şekilde %90,48'dir. Bi-LSTM tabanlı modeller DenseNet201, ResNet50 ve VGG19 modelleri için iyileştirme sağlamamıştır. Başka bir deyişle, önceden eğitilmiş modellerden özelliklerin çıkarılması ve bunların Bi-LSTM modeline beslenmesi performansı artırmamıştır. Ancak, InceptionV3 modeli için doğrulukta hafif bir artış vardır. Önceden eğitilmiş InceptionV3 modelinin doğruluğu %80,95 iken, InceptionV3+Bi-LSTM modelinin doğruluğu %85,71'dir. Ayrıca, DenseNet201 modelinden çıkarılan özelliklerle beslenen RO modeli, tüm modeller arasında en yüksek sınıflandırma performansına sahiptir. Doğruluk oranı %95,24'tür. Glokom vakalarını %100 oranında ve sağlıklı bireyleri ise %83,33 oranında doğru bir şekilde sınıflandırmaktadır. Diğer modellerle karşılaştırıldığında, bu model Glokom'u doğru sınıflandırmada iyileşme sağlarken, sağlıklı bireyler için iyileşme göstermemektedir. DenseNet201+k-NN, ResNet50+RO, ResNet50+k-NN, VGG19+RO ve VGG19+k-NN modelleri %90,48'lik bir doğruluğa sahiptir ki bu daha önce Model-1'de elde edilen performans değeriyle aynıdır. En düşük sınıflandırma doğruluğu InceptionV3 ile beslenen RO, k-NN ve DVM modelleri tarafından elde edilmiştir. Ayrıca, DVM modeli en kararsız modeldir ve en düşük sınıflandırma performansına sahiptir.

Tablo 4.6 DRISHTI-GS1 veri setinde kırılmış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerinin dışarda tutma doğrulama sınıflandırma sonucu

Modeller	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	F1-Skoru (%)	Kesinlik (%)
Kırılmış Veri Seti					
DenseNet201+Bi-LSTM	90,48	93,33	83,33	90,48	90,48
ResNet50+Bi-LSTM	90,48	93,33	83,33	90,48	90,48
Vgg19+Bi-LSTM	90,48	93,33	83,33	90,48	90,48
Inception V3+Bi-LSTM	85,71	86,67	83,33	86,02	86,73
DenseNet201+RO	95,24	100	83,33	95,10	95,54
DenseNet201+k-NN	90,48	93,33	83,33	90,48	90,48
DenseNet201+DVM	80,95	88,24	50,00	77,31	84,96
Resnet50+RO	90,48	100	66,67	89,82	91,60
Resnet50+k-NN	90,48	93,33	83,33	90,48	90,48
Resnet50+DVM	71,43	100	0	59,52	51,02
Vgg19+RO	90,48	100	66,67	89,82	91,60
Vgg19+k-NN	90,48	66,67	100	89,82	91,60
Vgg19+DVM	71,43	100	0	59,52	51,02
InceptionV3+RO	85,71	93,33	66,67	85,30	85,36
InceptionV3+k-NN	85,71	100	80,00	86,35	90,48
InceptionV3+DVM	71,43	100	0	59,52	51,02

Tablo 4.7, Model-2'deki Bi-LSTM, RO, k-NN ve DVM modellerinin kırılmamış görüntüler için dışarda tutma doğrulama sınıflandırma sonuçlarını göstermektedir. Bu tabloda da görüleceği üzere kırılmamış veri seti için %90,48 doğruluk değeri ile Vgg19+RO ve DenseNet201+RO en iyi performansı gösteren modellerdir. Model-2'deki mimariler iki aşamalı yaklaşımda tek aşamalı yaklaşıma göre genel olarak daha yüksek performans sergilemiştir

Tablo 4.7 DRISHTI-GS1 veri setinde kırılmamış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerinin dışarda tutma doğrulama sınıflandırma sonuçları

Modeller	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	F1_Skoru (%)	Kesinlik (%)
Kırılmamış Veri Seti					
DenseNet201+Bi-LSTM	85,71	93,33	66,67	85,30	85,36
ResNet50+Bi-LSTM	85,71	86,67	83,33	86,02	86,73
Vgg19+Bi-LSTM	85,71	93,33	66,67	85,30	85,36
Inception V3+Bi-LSTM	85,71	93,33	66,67	85,30	85,36
DenseNet201+RO	90,48	100	66,67	89,82	91,60
DenseNet201+k-NN	80,95	93,33	50,00	79,64	80,25
DenseNet201+DVM	71,43	100	0	59,52	51,02
Resnet50+RO	85,71	100	50,00	83,98	88,10
Resnet50+k-NN	85,71	86,67	83,33	86,02	86,73
Resnet50+DVM	80,95	100	33,33	77,31	84,96
Vgg19+RO	90,48	100	66,67	89,82	91,60

Tablo 4.7'nin devamı

Vgg19+k-NN	85,71	93,33	66,67	85,30	85,36
Vgg19+DVM	71,43	100	0	59,52	51,02
InceptionV3+RO	85,71	100	50,00	83,98	88,10
InceptionV3+k-NN	85,71	86,67	83,33	86,02	86,73
InceptionV3+DVM	85,71	100	50,00	83,98	88,10

Yukarıdaki Tablo 4.6 ve 4.7'de sunulan sonuçlara göre, YOLO ile kırılmış veri setinin kırılmamış veri setine kıyasla genel olarak daha iyi performans gösterdiği görülmektedir. Kırılmış veri seti söz konusu olduğunda, %95,24 ile en yüksek doğruluk DenseNet201+RO modeli tarafından elde edilmiştir. Buna karşılık, kırılmamış veri setinde en iyi performans gösteren Vgg19+RO, DenseNet201+RO ve ResNet50+RO modellerinin en yüksek doğruluğu %90 civarındadır.

Model-2'deki Bi-LSTM, RO, k-NN ve DVM modelleri için kırılmış veri seti kullanılarak yapılan 3-kat çapraz doğrulama sınıflandırma sonuçları Tablo 4.8'de sunulmuştur. En yüksek sınıflandırma doğruluğu, ResNet50 modelinden çıkarılan özelliklerle eğitilen k-NN modeli tarafından elde edilmiş ve %85,15'lik bir doğruluğa ulaşmıştır. Bu model Glokom vakalarını %95,71 oranında, sağlıklı bireyleri ise %61,29 oranında doğru sınıflandırmaktadır. Ancak Model-2'de kullanılan bu hibrit yaklaşım, Model-1'deki modellere kıyasla sınıflandırma doğruluğunu artırmamıştır.

Tablo 4.8 DRISHTI-GS1 veri setinde Yolo ile kırılmış görüntü için Bi-LSTM, RO, k-NN ve DVM Modellerinin 3-kat çapraz doğrulama sınıflandırma sonucu

Modeller	Kat	TP	TN	FP	FN	R	S	F1	P	Acc
RESNET50+k-NN	Kat 1	23	7	3	1	95,83	70	87,82	88,18	88,24
	Kat 2	22	6	5	1	95,65	54,55	81,10	82,85	82,35
	Kat 3	22	6	4	1	95,65	60	83,98	84,95	84,85
	Örtüşen									
	Glokom	67	19	12	3	95,71	61,29	89,93	84,81	
	Normal	19	67	3	12	61,29	95,71	71,70	86,36	
	Ortalama					78,5	78,5	80,81	85,585	85,15
RESNET50+Bi-LSTM	Örtüşen									
	Glokom	64	17	14	6	91,43	54,84	86,49	82,05	
	Normal	17	64	6	14	54,84	91,43	62,96	73,91	
	Ortalama					73,13	73,13	74,72	77,98	80,18
VGG19+Bi-LSTM	Örtüşen									
	Glokom	67	8	23	3	95,71	25,81	83,75	74,44	
	Normal	8	67	3	23	25,81	95,71	38,10	72,73	
	Ortalama					60,76	60,76	60,92	73,58	74,27
Inception V3+Bi-LSTM	Örtüşen									
	Glokom	61	11	20	9	87,14	35,48	80,79	87,14	
	Normal	11	61	9	20	35,48	87,17	43,14	35,48	
	Ortalama					61,31	61,31	61,96	65,15	71,27
DenseNet201+Bi-LSTM	Örtüşen									
	Glokom	62	17	14	8	88,57	54,84	84,93	81,57	78,22

Tablo 4.8'nin devamı

	Normal	17	62	8	14	54,84	88,57	60,71	68,00	
	Ortalama					71,70	71,70	72,82	74,78	
RESNET50+RO	Örtüşen									
	Glokom	70	12	19	0	100	38,70	88,05	78,65	
	Normal	12	70	0	19	38,70	100	55,81	38,71	
	Ortalama					69,35	69,35	71,93	58,68	81,22
RESNET50+DVM	Örtüşen									
	Glokom	70	7	24	0	100	22,58	85,37	74,47	
	Normal	7	70	0	24	22,58	100	36,84	100	
	Ortalama					61,29	61,29	61,10	87,23	76,17
VGG19+RO	Örtüşen									
	Glokom	68	11	20	2	97,14	35,48	86,08	97,14	
	Normal	11	68	2	20	35,48	97,14	50	35,48	
	Ortalama					66,31	66,31	68,04	80,94	78,28
VGG19+k-NN	Örtüşen									
	Glokom	65	17	14	5	92,86	54,84	87,25	82,28	
	Normal	17	65	5	14	54,84	92,86	64,15	77,27	
	Ortalama					73,85	73,85	75,7	79,77	81,22
VGG19+DVM	Örtüşen									
	Glokom	70	0	31	0	100	0	81,87	100	
	Normal	0	70	0	31	0	100	0	0	
	Ortalama					50,0	50,0	40,93	50,0	69,31
Inception V3+RO	Örtüşen									
	Glokom	70	10	21	0	100	32,26	86,96	76,92	
	Normal	10	70	0	21	32,26	100	48,78	76,92	
	Ortalama					66,13	66,13	67,87	76,92	79,26
Inception V3+k-NN	Örtüşen									
	Glokom	68	11	20	2	97,14	35,48	86,08	77,27	
	Normal	11	68	2	20	35,48	97,14	50	84,62	
	Ortalama					66,31	66,31	68,04	80,94	78,25
Inception V3+DVM	Örtüşen									
	Glokom	69	4	27	1	98,57	12,90	83,13	71,88	
	Normal	4	69	1	27	12,90	98,57	22,22	80	
	Ortalama					75,09	75,09	78,14	88,13	72,25
DenseNet201+RO	Örtüşen									
	Glokom	70	12	19	0	100	38,70	88,05	78,65	
	Normal	12	70	0	19	38,70	100	55,80	100	
	Ortalama					69,35	69,35	71,92	89,32	81,22
DenseNet201+k-NN	Örtüşen									
	Glokom	69	13	18	1	98,57	41,93	87,90	79,31	
	Normal	13	69	1	18	41,93	98,57	57,78	92,86	
	Ortalama					70,25	70,25	72,84	86,08	81,16
DenseNet201+DVM	Örtüşen									
	Glokom	70	5	26	0	100	16,12	84,34	72,92	
	Normal	5	70	0	26	0	100	27,77	100	
	Ortalama					58,06	58,06	56,05	86,46	74,24

Kırılmış veri üzerinde yapılan deneysel çalışmaya ek olarak, kırılmamış veri seti üzerinde de benzer deneysel çalışmaların yapılması önemlidir. Bu nedenle aynı modeller üzerinde benzer deneysel çalışmalar yapılmış ve sınıflandırma performansları Tablo 4.9'da sunulmuştur. En yüksek sınıflandırma performansı %87,14 doğruluk oranı ile VGG19+RO modeli tarafından elde edilmiştir.

Tablo 4.9 DRISHTI-GS1 veri setinde kırılmamış görüntü için Bi-LSTM, RO, k-NN ve DVM Modellerinin 3 katlı çapraz doğrulama sınıflandırma sonucu

Modeller	Kat	TP	TN	FP	FN	R	S	F1	P	Acc
VGG19+RO	Kat 1	23	6	5	0	100	54,55	83,85	87,92	85,29
	Kat 2	24	6	4	0	100	60	87,22	89,92	88,24
	Kat 3	23	6	4	0	100	60	86,85	89,67	87,88
	Örtüşen									
	Glokom	70	18	13	84,34	100	58,06	91,50	84,34	
	Normal	18	70	0	100	58,06	100	73,47	100	
	Ortalama					79,03	79,03	82,48	92,17	87,14
RESNET50+Bi-LSTM	Örtüşen									
	Glokom	62	18	13	8	88,57	58,06	85,52	82,67	
	Normal	18	62	8	13	58,06	88,57	63,16	69,23	
	Ortalama					73,31	73,31	74,34	75,95	79,26
VGG19+Bi-LSTM	Örtüşen									
	Glokom	64	21	10	6	91,43	67,74	88,89	86,49	
	Normal	21	64	6	10	67,74	91,43	72,41	77,78	
	Ortalama					79,58	79,58	80,65	82,135	84,17
Inception V3+Bi-LSTM	Örtüşen									
	Glokom	65	16	15	5	92,86	51,61	86,67	81,25	
	Normal	16	65	5	15	51,61	92,86	61,54	76,19	
	Ortalama					72,23	72,23	74,10	78,72	80,18
DenseNet201+Bi-LSTM	Örtüşen									
	Glokom	62	18	13	8	88,57	58,06	85,52	82,67	
	Normal	18	62	8	13	58,06	88,57	63,16	69,23	
	Ortalama					73,31	73,31	74,34	75,95	79,20
RESNET50+RO	Örtüşen									
	Glokom	67	13	18	3	95,71	41,94	86,45	78,82	
	Normal	13	67	3	18	41,94	95,71	55,32	81,25	
	Ortalama					68,82	68,82	70,88	80,03	79,20
RESNET50+k-NN	Örtüşen									
	Glokom	68	19	12	2	97,14	61,29	90,67	85	
	Normal	19	68	2	12	61,29	97,14	73,08	90,48	
	Ortalama					79,21	79,21	81,87	87,74	86,19
RESNET50+DVM	Örtüşen									
	Glokom	70	7	24	0	100	22,58	85,37	74,47	
	Normal	7	70	0	24	22,58	100	36,84	100	
	Ortalama					61,29	61,29	61,10	87,235	76,20
VGG19+k-NN	Örtüşen									
	Glokom	64	14	17	6	91,43	45,16	84,77	79,01	
	Normal	14	64	6	17	45,16	91,43	54,90	70	
	Ortalama					68,29	68,29	69,83	74,505	77,24
VGG19+DVM	Örtüşen									
	Glokom	70	0	31	0	100	0	81,87	69,31	
	Normal	0	70	0	31	0	100	0	0	
	Ortalama					50	50	40,93	17,32	69,93
Inception V3+RO	Örtüşen									
	Glokom	69	17	14	1	98,57	54,84	90,20	83,13	
	Normal	17	69	1	14	54,84	98,57	69,39	94,44	
	Ortalama					76,70	76,70	76,70	88,78	85,12
Inception V3+k-NN	Örtüşen									
	Glokom	68	19	12	2	97,14	61,29	90,67	85	
	Normal	19	68	2	12	61,29	97,14	73,08	90,48	
	Ortalama					79,21	79,21	81,87	87,74	86,13
Inception V3+DVM	Örtüşen									
	Glokom	69	16	15	1	98,57	51,61	89,61	82,14	
	Normal	16	69	1	15	51,61	98,57	66,67	94,12	
	Ortalama					75,09	75,09	78,14	88,13	84,19
DenseNet201+RO	Örtüşen									

Tablo 4.9'nin devamı

	Glokom	70	17	14	0	100	54,84	90,90	83,33	
	Normal	17	70	0	14	54,84	100	70,83	100	
	Ortalama					77,42	77,42	80,86	91,665	86,16
	Örtüşen									
DenseNet201+k-NN	Glokom	67	18	13	3	95,71	58,06	89,33	83,75	
	Normal	18	67	3	13	58,06	95,71	69,23	85,71	
	Ortalama					76,88	76,88	79,28	84,73	84,17
	Örtüşen									
DenseNet201+DVM	Glokom	70	0	31	0	100	0	81,87	69,31	
	Normal	0	70	0	31	0	100	0	0	
	Ortalama					50	50	40,93	17,32	69,31

4.4.2 ORIGA Veri Seti için Sınıflandırma Sonuçları

Tablo 4.10, Model-1 ile hem tek aşamalı hem de iki aşamalı yaklaşımlar kullanılarak yapılan dışarda tutma doğrulama için sınıflandırma sonuçlarını göstermektedir. En yüksek doğruluk kırılmış veri setinde Swin Transformer modeli ile elde edilmiştir. Bu modelin doğruluğu %96,15'tir. Swin Transformer modeli ayrıca en yüksek R, S, P ve F1 puanını elde etmiştir. Kırılmamış veri setinde de yine Swin Transformer en iyi sınıflandırma performansını elde etmiştir. Bu sonuçlar, veri setinin kırılmış veya kırılmamış olmasına bakılmaksızın Swin Transformer modelinin Glokom sınıflandırmasındaki diğer modellere göre etkinliğini göstermektedir. Durum böyle olsa da Swin Transformer modelinin kırılmış veri setinde kırılmamış veri setine göre daha yüksek doğruluk elde ettiği de aşikardır.

Tablo 4.10 Model-1'in ORIGA veri setinde tek aşamalı ve iki aşamalı yaklaşımlar için dışarda tutma doğrulama sınıflandırma sonuçları

Pre-Trained CNN Modeller	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	Kesinlik (%)	F1_Skoru (%)
Kırılmış veri seti					
DenseNet201	69,33	72,44	52,17	89,32	80,00
ResNet50	73,85	96	73,85	54,53	62,74
Vgg19	75,38	75,38	N	100	84,96
Inception V3	74,62	76,03	55,56	95,83	84,79
Swin Transformer	96,15	95,05	100	100	97,46
Kırılmamış veri seti					
DenseNet201	78,15	79,17	74,19	92,23	85,20
ResNet50	73,85	96	73,85	54,53	62,74
Vgg19	72,31	96,91	0	74,02	83,93
Inception V3	69,23	100	0	69,23	81,82
Swin Transformer	86,15	88,24	78,57	93,75	90,91

Çalışmada, Model-1 için 5-kat çapraz doğrulama ile de deneysel çalışmalar yapılmıştır. Model-1'in kırılmış veri seti için elde edilen 5-kat çapraz doğrulama ile sınıflandırma sonuçları Tablo 4.11'de gösterilmiştir. En yüksek sınıflandırma performansı %93,53 doğruluk oranı ile Inception V3 modeli ile elde edilmiştir. Bu model Glokom vakalarını %83,33 oranında ve sağlıklı bireyleri %97,10 oranında doğru sınıflandırmaktadır.

Tablo 4.12'de ise, kırılmamış veri seti için 5-kat çapraz doğrulama kullanılarak elde edilen sınıflandırma sonuçları gösterilmektedir. Sonuçlar, yine Inception V3 modelinin %93,84 doğruluk oranıyla en yüksek sınıflandırma performansını elde ettiğini göstermektedir. Bu model Glokom vakalarını %84,52 oranında, sağlıklı bireyleri ise %97,10 oranında doğru sınıflandırmaktadır. 5-kat çapraz doğrulama bulguları, Inception V3, DenseNet201 ve Swin Transformer gibi bazı modellerin kırılmamış görüntülerde kırılmış görüntülere göre daha iyi performans gösterdiğini de ortaya koymaktadır.

Tablo 4.11 Model-1'in ORIGA veri setinde kırılmış veri seti için 5-kat çapraz doğrulama sınıflandırma sonucu

Modeller	Kat	TP	TN	FP	FN	R	S	F1	P	ACC
Inception V3	Kat 1	16	87	10	17	48,48	89,69	78,36	78,04	79,23
	Kat 2	23	94	3	10	69,70	96,91	89,58	89,90	90,00
	Kat3	33	96	0	1	97,06	100	99,23	99,24	99,23
	Kat 4	34	95	1	0	100	98,96	99,23	99,25	99,23
	Kat 5	34	96	0	0	100	100	100	100	100
	Örtüşen									
	Glokom	140	468	14	28	83,33	97,10	86,96	90,91	
	Normal	468	140	28	14	97,10	83,33	95,71	94,35	
	Ortalama					90,21	90,21	91,33	92,63	93,53
	Örtüşen									
VGG19	Glokom	135	470	12	13	91,22	97,51	91,53	91,84	
	Normal	470	135	13	12	97,51	91,22	97,41	97,31	
						94,36	94,36	94,47	94,57	93,07
Swin Transformer	Örtüşen									
	Glokom	100	414	68	68	59,52	85,89	59,52	59,52	
	Normal	414	100	68	68	85,89	59,52	85,89	85,89	
DenseNet-201	Ortalama					72,71	72,71	72,71	72,71	79,07
	Örtüşen									
	Glokom	127	368	114	41	75,60	76,35	62,10	52,70	
RESNET50	Normal	368	127	41	114	76,35	75,60	82,60	89,98	
						75,97	75,97	72,35	71,34	76,15
	Örtüşen									
RESNET50	Glokom	0	482	0	168	0	100	N	N	
	Normal	482	0	168	0	100	0	85,16	74,15	

Tablo 4.11'nin devamı

Ortalama	50	50	N	N	74,15
-----------------	----	----	---	---	-------

Tablo 4.12 Model-1'in ORIGA veri setinde kırılmamış veri seti için 5-kat çapraz doğrulama sınıflandırma sonucu

Modeller	Kat	TP	TN	FP	FN	R	S	F1	P	ACC
Inception V3	Kat 1	14	86	11	19	42,42	88,66	75,79	75,33	76,92
	Kat 2	33	97	0	0	100	100	100	100	100
	Kat3	30	95	1	4	88,24	98,96	96,09	96,17	96,15
	Kat 4	31	94	2	3	91,18	92,97	96,14	96,13	96,15
	Kat 5	34	96	0	0	100	100	100	100	100
	Örtüşen									
	Glokom	142	468	14	26	84,52	97,10	87,65	91,03	
	Normal	468	142	26	14	97,10	84,52	95,90	94,74	
	Ortalama					90,81	90,81	91,77	92,88	93,84
VGG19	Örtüşen									
	Glokom	136	463	19	32	80,95	96,06	87,82	84,21	
	Normal	463	136	32	19	96,06	80,59	93,54	94,78	
	Ortalama					88,50	88,32	90,68	89,49	92,15
Swin transform	Örtüşen									
	Glokom	127	442	40	41	75,60	91,70	76,05	75,82	
	Normal	442	127	41	40	91,70	75,60	91,51	91,61	
	Ortalama					83,65	83,65	83,78	83,71	87,54
DenseNet-201	Örtüşen									
	Glokom	114	448	34	54	67,86	92,95	72,15	77,03	
	Normal	448	114	54	34	92,95	67,86	91,06	89,24	
	Ortalama					80,40	80,40	81,60	83,13	86,46
RESNET50	Örtüşen									
	Glokom	0	482	0	168	0	100	N	N	
	Normal	482	0	168	0	100	0	85,16	74,15	
	Ortalama					50	50	N	N	74,15

Model-2'nin hem kırılmış hem de kırılmamış optik disk görüntülerinde dışarda tutma doğrulama için glokomu sınıflandırma performansları Tablo 4.13 ve Tablo 4.14'te gösterilmiştir. Kırılmış veri seti için en iyi performans gösteren model, %81,54 doğruluk, %81,58 duyarlılık ve %81,25 özgüllük elde eden Vgg19+Bi-LSTM olmuştur. Genel olarak, tekrarlayan bileşenlere sahip derin öğrenme modeli Bi-LSTM; RO, k-NN ve DVM gibi makine öğrenimi modellerinden daha iyi performans göstermiştir.

Tablo 4.13 Bi-LSTM, RO, k-NN ve DVM Modellerinin ORIGA veri setinde kırılmış görüntüler için dışarda tutma doğrulama sınıflandırma sonuçları

Modeller	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	F1_Skoru (%)	Kesinlik (%)
Kırılmış veri seti					

Tablo 4.13'nin devamı

DenseNet201+Bi-LSTM	76,15	82,18	55,17	84,26	86,46
ResNet50+Bi-LSTM	73,85	73,85	NaN	84,96	100
Vgg19+Bi-LSTM	81,54	81,58	81,25	88,57	96,88
Inception V3+Bi-LSTM	77,69	79,65	64,71	86,12	93,75
DenseNet201+RO	77,69	78,15	72,73	86,51	96,88
DenseNet201+k-NN	80	79,66	83,33	87,85	97,92
DenseNet201+DVM	77,69	77,24	85,71	86,76	98,96
Resnet50+RO	73,85	73,85	NaN	84,96	100
Resnet50+k-NN	73,85	73,85	NaN	84,96	100
Resnet50+DVM	73,85	73,85	NaN	84,96	100
Vgg19+RO	76,92	77,50	70	86,11	96,88
Vgg19+k-NN	77,69	77,69	77,78	86,64	97,92
Vgg19+DVM	73,85	73,85	NaN	84,96	100
InceptionV3+RO	76,15	76,00	80	85,97	98,96
InceptionV3+k-NN	76,92	78,45	64,29	85,85	94,79
InceptionV3+DVM	74,62	74,80	66,67	85,20	98,96

Tablo 4.14 ORIGA veri setinde kırılmamış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerinin dışarda tutma sınıflandırma sonuçları

Modeller	Doğruluk (%)	Hassasiyet (%)	Özgünlük (%)	F1_Skoru (%)	Kesinlik (%)
Kırılmamış veri seti					
DenseNet201+Bi-LSTM	77,69	84,54	57,58	84,97	85,42
ResNet50+Bi-LSTM	73,85	73,85	NaN	84,96	100
Vgg19+Bi-LSTM	75,38	75,81	66,67	85,45	97,92
Inception V3+Bi-LSTM	81,54	82,14	77,78	88,46	95,83
DenseNet201+RO	78,46	77,87	87,50	87,16	98,96
DenseNet201+k-NN	73,08	76,07	46,15	83,57	92,71
DenseNet201+DVM	73,85	73,85	NaN	84,96	100
Resnet50+RO	73,85	73,85	NaN	84,96	100
Resnet50+k-NN	73,85	73,85	NaN	84,96	100
Resnet50+DVM	73,85	73,85	NaN	84,96	100
Vgg19+RO	74,62	75,20	60	85,07	97,92
Vgg19+k-NN	75,38	76,67	60	85,19	95,83
Vgg19+DVM	73,85	73,85	NaN	84,96	100
InceptionV3+RO	76,92	77,05	75	86,24	97,92
InceptionV3+k-NN	77,69	78,63	69,23	86,38	95,83
InceptionV3+DVM	73,08	73,64	0	84,44	98,96

Tablo 4.15 ve Tablo 4.16'da Model-2'nin 5-kat çapraz doğrulama sonuçları tek ve iki aşamalı yaklaşımlar için gösterilmektedir. Sonuçlar %80'i aşmayan orta düzeyde doğruluk elde edildiğini göstermektedir. Buna ek olarak, birkaç model, üst üste binen karışıklık matrisine göre glokom vakalarını doğru sınıflandırmak için düşük R değeri

göstermiştir. DenseNet201 ile birleştirilmiş RO sınıflandırıcısı, kırılmış görüntü veri setinde en umut verici performansı göstermiştir.

Tablo 4.15 ORIGA veri setinde kırılmış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerinin 5-kat çapraz doğrulama sınıflandırma sonuçları

Modeller	Kat	TP	TN	FP	FN	R	S	F1	P	ACC
DenseNet201+RO	Kat1	9	96	24	1	80,00	90	76,65	82,54	80,77
	Kat2	5	93	28	4	76,86	55,56	69,71	71,45	75,38
	Kat 3	10	90	24	6	78,95	62,50	73,76	74,65	76,92
	Kat 4	5	93	29	3	76,23	62,50	69,23	72,64	75,38
	Kat 5	9	90	25	6	78,26	60	72,60	73,48	76,15
	Örtüşen									
	Glokom	38	462	20	130	22,62	95,85	33,63	65,52	
	Normal	462	38	130	20	95,85	22,62	86,03	78,04	
	Ortalama					59,23	59,23	59,83	71,78	76,92
	Örtüşen									
ResNet50+Bi-LSTM	Glokom	0	482	0	168	35,71	88,79	42,55	52,63	
	Normal	482	0	168	0	88,79	35,71	84,09	79,85	
	Ortalama					50	50	85,15	74,30	74,15
	Örtüşen									
Vgg19+Bi-LSTM	Glokom	60	428	54	108	35,71	88,79	42,55	52,63	
	Normal	428	60	108	54	88,79	35,71	84,09	79,85	
	Ortalama					62,25	62,25	63,32	66,24	75,07
	Örtüşen									
Inception V3+Bi-LSTM	Glokom	47	447	35	121	27,89	92,74	37,60	57,32	
	Normal	447	47	121	35	92,74	27,89	85,14	78,70	
	Ortalama					60,31	60,31	61,37	68,01	76
	Örtüşen									
DenseNet201+Bi-LSTM	Glokom	64	427	55	104	38,10	88,59	44,60	53,78	
	Normal	427	64	104	55	88,59	38,10	84,30	80,41	
	Ortalama					63,34	63,34	64,45	67,09	75,53
	Örtüşen									
Resnet50+RO	Glokom	0	482	0	168	0	100	NaN	NaN	
	Normal	480	0	166	0	100	0	85,15	74,30	
	Ortalama					50	50	85,15	74,30	74,15
	Örtüşen									
Resnet50+KNN	Glokom	0	482	0	168	0	100	NaN	NaN	
	Normal	480	0	166	0	100	0	85,15	74,30	
	Ortalama					50	50	85,15	74,30	74,15
	Örtüşen									
Resnet50+DVM	Glokom	0	482	0	168	0	100	NaN	NaN	
	Normal	482	0	168	0	100	0	85,15	74,30	
	Ortalama					50	50	85,15	74,30	74,15
	Örtüşen									
VGG19+RO	Glokom	145	472	10	23	13,69	97,93	22,89	69,70	
	Normal	472	145	23	10	97,93	13,69	85,90	76,50	
	Ortalama					55,81	55,81	54,39	73,1	76,15
	Örtüşen									
VGG19+KNN	Glokom	20	462	20	148	11,90	95,85	19,23	50	
	Normal	462	20	148	20	95,85	11,90	84,62	75,74	
	Ortalama					53,87	53,87	51,92	62,87	75,15
	Örtüşen									
VGG19+DVM	Glokom	0	482	0	168	0	100	NaN	NaN	
	Normal	482	0	168	0	100	0	85,16	74,15	
	Ortalama					50	50	85,26	74,15	74,15
	Örtüşen									
Inception V3+RO	Glokom	10	471	11	158	0,05	97,72	10,58	47,62	
	Normal	471	10	158	11	97,72	0,05	84,79	74,88	
	Ortalama					48,88	48,88	47,68	61,25	74
	Örtüşen									
Inception V3+KNN	Glokom	28	463	41	118	19,18	91,87	26,05	40,58	
	Örtüşen									

Tablo 4.15'nin devamı

	Normal	463	28	118	41	91,87	19,18	85,35	79,69	
	Ortalama					55,52	55,52	55,7	60,13	
	Örtüşen									
Inception V3+DVM	Glokom	6	478	4	162	0,03	99,17	0,06	60	
	Normal	478	6	162	4	99,17	0,03	85,20	74,69	
	Ortalama					49,6	49,6	42,63	67,34	74,76
	Örtüşen									
DenseNet201+knn	Glokom	38	458	24	130	22,62	95,02	33,04	61,29	
	Normal	458	38	130	24	95,02	22,62	85,31	77,89	
	Ortalama					58,82	58,82	59,17	69,95	75,30
	Örtüşen									
DenseNet201+DVM	Glokom	8	478	4	160	0,04	0,99	0,088	66,67	
	Normal	487	8	160	4	99,17	0,04	85,36	74,92	
	Ortalama					49,60	49,60	42,72	70,79	74,76

Tablo 4.16 ORIGA veri setinde kırılmamış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerinin 5-kat çapraz doğrulama sınıflandırma sonuçları

Modeller	Kat	TP	TN	FP	FN	R	S	F1	P	ACC
Inception V3 +KNN	Kat 1	1	96	1	32	75	50	65,12	68,65	74,62
	Kat 2	6	94	3	27	77,69	66,67	71,60	74,89	76,92
	Kat 3	2	93	3	32	74,40	40	64,83	65,40	73,08
	Kat 4	5	94	2	29	76,42	71,43	69,77	75,12	76,15
	Kat 5	8	93	3	26	78,15	72,73	73,18	76,73	77,69
	Örtüşen									
	Glokom	22	470	12	146	13,10	97,51	21,17	64,71	
	Normal	470	22	146	12	97,51	13,10	85,61	76,30	
	Ortalama					55,30	55,30	53,39	70,50	75,69
	Örtüşen									
ResNet50+Bi- LSTM	Glokom	0	482	0	168	0	100	NaN	NaN	
	Normal	482	0	168	0	100	0	85,15	74,30	
	Ortalama					50	50	85,15	74,30	74,15
	Örtüşen									
Vgg19+Bi-LSTM	Glokom	0	482	0	168	0	100	NaN	NaN	
	Normal	482	0	168	0	100	0	85,15	74,30	
	Ortalama					50	50	85,15	74,30	74,15
	Örtüşen									
Inception V3+Bi- LSTM	Glokom	47	447	35	121	27,98	92,74	37,60	57,32	
	Normal	447	47	121	35	92,74	27,98	85,14	78,70	
	Ortalama					60,36	60,36	61,37	68,01	75,80
	Örtüşen									
DenseNet201+Bi- LSTM	Glokom	63	389	93	105	37,50	80,71	38,89	40,38	
	Normal	389	63	105	93	80,71	37,50	79,71	78,74	
	Ortalama					59,10	59,10	59,3	59,56	69,69
	Örtüşen									
Resnet50+RO	Glokom	0	482	0	168	0	100	NaN	NaN	
	Normal	480	0	166	0	100	0	85,15	74,30	
	Ortalama					50	50	85,15	74,30	74,15
	Örtüşen									
Resnet50+KNN	Glokom	0	482	0	168	0	100	NaN	NaN	
	Normal	480	0	166	0	100	0	85,15	74,30	
	Ortalama					50	50	85,15	74,30	74,15
	Örtüşen									
Resnet50+DVM	Glokom	0	482	0	168	0	100	NaN	NaN	
	Normal	482	0	168	0	100	0	85,15	74,30	

Tablo 4.16'nin devamı

	Ortalama					50	50	85,15	74,30	74,15
	Örtüşen									
VGG19+RO	Glokom	23	462	20	145	13,69	95,85	21,80	53,49	
	Normal	462	23	145	20	95,85	13,69	84,85	76,11	
	Ortalama					54,7	54,7	53,32	64,8	74,61
	Örtüşen									
VGG19+KNN	Glokom	21	462	20	147	12,50	95,85	20,10	51,22	
	Normal	462	21	147	20	95,85	12,50	84,69	75,86	
	Ortalama					54,77	54,77	53,32	64,8	74,34
	Örtüşen									
VGG19+DVM	Glokom	0	482	0	168	0	100	NaN	NaN	
	Normal	482	0	168	0	100	0	85,16	74,15	
	Ortalama					50	50	85,26	74,15	74,15
	Örtüşen									
Inception V3+RO	Glokom	24	462	20	144	14,29	95,85	22,64	54,55	
	Normal	462	24	144	20	95,85	14,29	84,93	76,24	
	Ortalama					55,07	55,07	53,78	65,39	74,74
	Örtüşen									
Inception V3+DVM	Glokom	5	473	9	163	0,02	98,13	0,054	35,71	
	Normal	473	5	163	9	98,13	0,02	84,62	74,37	
	Ortalama					49,07	49,07	42,33	55,03	74,62
	Örtüşen									
DenseNet201+RO	Glokom	30	451	31	138	17,86	93,57	26,20	49,18	
	Normal	451	30	138	31	93,57	17,86	84,22	76,57	
	Ortalama					49,07	49,07	42,31	55,04	74
	Örtüşen									
DenseNet201+knn	Glokom	21	458	24	147	12,50	95,02	19,72	46,67	
	Normal	458	21	147	24	95,02	12,50	84,27	75,70	
	Ortalama					53,76	53,76	51,99	61,18	73,69
	Örtüşen									
DenseNet201+DVM	Glokom	2	480	2	166	0,01	99,59	0,02	50	
	Normal	480	2	166	2	99,59	0,01	85,11	74,30	
	Ortalama					49,80	49,80	42,71	62,15	74,76

4.4.3 Füzyon Veri Seti için Sınıflandırma Sonuçları

Veri füzyonu, veri entegrasyonu, veri kombinasyonu, veri asimilasyonu ve görüntü füzyonu gibi diğer ilgili terimlere de sahiptir (Zhang vd., 2021). Füzyon veri setinin önemine rağmen, çeşitli kaynaklardan elde edilen veya üretilen veriler normalde farklı boyutlara ve yapılaraya sahip olduğundan, veri füzyonunu gerçekleştirmek karmaşık bir görev olabilir (Wang vd., 2020). Dolayısıyla, bu veri setinden özellik çıkarımı, yararlı veya gizli bilgilerin kaybına yol açabilir.

Model-1'in kırılmış ve kırılmamış veri kümelerinde dışarda tutma doğrulama için sınıflandırma performansı Tablo 4.17'de sunulmaktadır. Swin Transformer hem kırılmış hem de kırılmamış veri setinde diğer modellerden daha yüksek doğruluk sergilemiştir. Kırılmış veri setindeki doğruluk değeri %92,72'dir. Bunun yanı sıra,

DenseNet201 kırılmış verilerde daha iyi performans gösterirken Vgg19 kırılmamış verilerde daha iyi performans göstermektedir. Inception V3, kırılmış veri setinde en düşük R değerini göstererek glokomun tespit edilmesinde zorluk yaşandığını göstermektedir. Genel olarak, Swin Transformer bu sınıflandırma görevi için en güvenilir model olarak ortaya çıkmaktadır.

Tablo 4.17 Model-1'in Füzyon veri seti için tek aşamalı ve iki aşamalı yaklaşımların dışarda tutma doğrulama sınıflandırma sonuçları

Modeller	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	F1_Skoru (%)	Kesinlik (%)
Kırılmış veri seti					
DenseNet201	79,66	75	77,31	78,17	78,67
ResNet50	68,21	68,21	N	55,32	45,53
Vgg19	70,34	83,33	62	74,47	70,86
Inception V3	74,67	24,32	66,67	72,77	73,47
Swin transform	92,72	92,76	87,76	92,72	92,74
Kırılmamış veri seti					
DenseNet201	71,33	72,87	61,90	69,36	67,40
ResNet50	68,21	46,53	NaN	55,32	68,21
Vgg19	83,33	85,98	76,74	83,03	83,07
Inception V3	70,86	70,34	83,33	74,47	62
Swin transform	88,08	87,61	89,47	96,12	91,67

Tablo 4.18'de Model-1'in kırılmış füzyon veri seti görüntüleri üzerinde 5-kat çapraz doğrulama sonuçları gösterilmektedir. En yüksek sınıflandırma performansı %93,76 doğrulukla VGG19 modeli ile elde edilmiştir. Bu model glokom vakalarını %90,34 ve sağlıklı olanları %95,32 oranında doğru sınıflandırmaktadır.

Tablo 4.18 Model-1'in Füzyon veri setinde kırılmış görüntüler için 5-kat çapraz doğrulama sınıflandırma sonuçları

Modeller	Kat	TP	TN	FP	FN	R	S	F1	P	ACC
VGG19	Kat 1	30	88	15	18	62,50	85,44	64,52	66,67	78,15
	Kat 2	46	95	7	2	95,83	93,14	91,09	86,79	94,00
	Kat 3	45	102	0	3	93,75	100	96,77	100	98,00
	Kat 4	47	102	1	0	100	99,03	98,95	97,92	99,33
	Kat 5	47	102	1	0	100	99,03	98,95	97,92	99,33
	Örtüşen									
	Glokom	215	489	24	23	90,34	95,32	90,15	89,96	
	Normal	489	215	23	24	95,32	90,34	95,41	95,51	
	Ortalama					92,83	92,83	92,825	92,73	93,76
	Örtüşen									
DenseNet-201	Glokom	197	487	26	41	82,77	94,93	85,47	88,34	
	Normal	487	197	41	26	94,93	82,77	93,56	92,23	
	Ortalama					88,85	88,85	89,515	90,28	91,10
	Örtüşen									

Tablo 4.18'nin devamı

RESNET50	Örtüşen								
	Glokom	0	513	0	238	0	100	NaN	NaN
	Normal	513	0	0	238	100	0	81,17	68,31
	Ortalama					50,0	50,0	81,17	68,31
Swin transform	Örtüşen								
	Glokom	193	486	27	34	85,02	94,74	86,35	87,73
	Normal	486	193	34	27	94,74	85,02	94,09	93,46
	Ortalama					89,88	89,88	90,22	90,59
Inception V3	Örtüşen								
	Glokom	216	473	40	22	90,76	92,20	87,45	84,38
	Normal	473	216	22	40	92,20	90,76	93,85	95,56
	Ortalama					91,48	91,48	90,65	89,97

Tablo 4.19'da Model-1'in kırılmamış füzyon veri seti görüntüleri üzerinde 5-kat çapraz doğrulama sonuçları gösterilmektedir. En yüksek sınıflandırma performansı %92,97 doğruluk oranıyla VGG19 modeliyle elde edilmiştir. Inception V3 ve DenseNet-201 modelleri güçlü performans gösteren modeller olarak görünmektedir. Ancak, VGG19 hafif bir üstünlüğe sahiptir. Swin Transformer modeli, iyi ancak olağanüstü olmayan sonuçlar vermiştir. Tüm modeller normal sınıfta Glokom sınıfından daha iyi performans göstermiştir.

Kırılmış ve kırılmamış füzyon veri seti için farklı CNN mimarileri ile elde edilen sonuçlar genel olarak değerlendirildiğinde, kırılmış görüntüler için en yüksek %93,76 ve kırılmamış görüntüler için ise en yüksek %92,97 genel sınıflandırma doğruluğu elde edilmiştir. Dışarda tutma yöntemi kullanıldığında, VGG19 ve Swin Transformer'ın kırılmış görüntüler için de iyi performans gösterdiği gözlemlenmiştir. Ancak, DenseNet201 hem kırılmış hem de kırılmamış görüntülerde iyi performans göstermektedir. Sonuçlardan, VGG19 modelinin normal ve Glokom görüntüleri 5-kat çapraz doğrulama için mevcut mimarilerden daha yüksek doğrulukla sınıflandırabildiği de açıkça görülmektedir.

Tablo 4.19 Model-1'in fusion veri setinde kırılmamış görüntüler için 5-kat çapraz doğrulama sınıflandırma sonuçları

Modeller	Kat	TP	TN	FP	FN	R	S	F1	P	ACC
VGG19	Kat 1	25	84	19	23	52,08	81,55	54,35	56,82	72,19
	Kat2	44	101	1	4	91,67	99,02	94,62	97,78	96,67
	Kat3	48	98	4	0	100	96,08	96	92,31	97,33
	Kat 4	45	103	0	2	95,74	100	97,83	100	98,67
	Kat 5	47	103	0	0	100	100	100	100	100

Tablo 4.19'nin devamı

	Örtüşen								
	Glokom	209	489	24	29	87,82	95,32	88,75	89,70
	Normal	489	209	29	24	95,32	87,82	94,86	94,40
	Ortalama					91,45	91,45	91,80	92,05
DenseNet-201	Örtüşen								
	Glokom	201	480	33	37	84,45	93,57	85,17	85,90
	Normal	480	201	37	33	93,57	84,45	93,20	92,84
	Ortalama					89,01	89,01	89,18	89,37
RESNET50	Örtüşen								
	Glokom	0	513	0	238	0	100	NaN	NaN
	Normal	513	0	238	0	100	0	81,17	68,31
	Ortalama					50,0	50,0	81,17	68,31

Tablo 4.19'nin devamı

Swin transform	Örtüşen								
	Glokom	183	472	41	55	76,89	92,01	79,22	81,70
	Normal	472	183	55	41	92,01	76,89	90,77	89,56
	Ortalama					84,45	84,45	84,995	85,60
Inception V3	Örtüşen								
	Glokom	187	503	3	51	78,57	99,41	87,38	98,42
	Normal	503	187	51	3	99,41	78,57	94,91	90,79
	Ortalama					88,99	88,99	91,145	94,605

Tablo 4.20 ve Tablo 4.21, Model-2'nin tek ve iki aşamalı yaklaşımlar için dışarda tutma doğrulama sonuçlarını göstermektedir. Tablo 4.20'deki kırılmış veri seti sonuçlarına bakıldığında, DenseNet201+Bi-LSTM modeli %84,11 ile en yüksek doğruluğu elde etmiş, yüksek hassasiyet (%86,92) ve düşük özgüllük (%77,27) sağlamıştır. VGG19+Bi-LSTM ve Inception V3+Bi-LSTM modelleri de %82'nin üzerindeki doğruluk oranlarıyla iyi performans göstermiştir.

Tablo 4.21'de gösterilen kırılmamış veri seti için modellerin performansları kırılmış veri setine kıyasla genel olarak düşüktür. En yüksek doğruluk %79,47 ile DenseNet201+DVM modeli tarafından elde edilmiştir. VGG19+Bi-LSTM ve Inception V3+Bi-LSTM modelleri de %78 civarında nispeten yüksek doğruluk oranlarını korumuştur.

Tablo 4.20 Füzyon veri setinde kırılmış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerini dışarda tutma doğrulama sonuçları

Modeller	Doğruluk (%)	Hassasiyet (%)	Özgüllük (%)	F1_Skoru (%)	Kesinlik (%)
Kırılmış Veri Seti					
DenseNet201+Bi-LSTM	84,11	86,92	77,27	88,57	90,29
ResNet50+Bi-LSTM	68,21	68,21	Nan	81,10	100
Vgg19+Bi-LSTM	82,78	85,32	76,19	87,74	90,29

Tablo 4.20'nin devamı

Inception V3+Bi-LSTM	82,12	83,93	76/92	87,44	91,26
DenseNet201+RO	81,46	80,99	83,33	87,50	95,15
DenseNet201+k-NN	79,47	80,51	75,76	85,97	92,23
DenseNet201+DVM	80,13	77,86	95	87,18	99,03
Resnet50+RO	68,21	68,21	Nan	81,10	100
Resnet50+k-NN	68,21	68,21	Nan	81,10	100
Resnet50+DVM	68,21	68,21	Nan	81,10	100
Vgg19+RO	80,13	77,86	95,00	87,18	99,03
Vgg19+k-NN	76,16	77,69	70	83,93	91,26
Vgg19+DVM	68,21	68,21	Nan	81,10	100
InceptionV3+RO	74,83	73,05	100	84,43	100
InceptionV3+k-NN	73,51	93,07	22,50	83,19	75,20
InceptionV3+DVM	75,50	74,63	82,35	84,39	97,09

Tablo 4.21 Füzyon veri setinde kırılmamış görüntüler için Bi-LSTM, RO, k-NN ve DVM modellerinin dışarda tutma doğrulama sonuçları

Modeller	Doğruluk (%)	Hassasiyet (%)	Özgünlük (%)	F1_Skoru (%)	Kesinlik (%)
kırılmamı Veri Seti					
DenseNet201+Bi-LSTM	76,16	80,73	64,29	83,02	85,44
ResNet50+Bi-LSTM	68,21	68,21	Nan	81,10	100
Vgg19+Bi-LSTM	78,15	81,82	71,43	84,51	87,38
Inception V3+Bi-LSTM	78,15	81,82	68,29	84,44	87,38
DenseNet201+RO	77,48	76,74	81,82	83,34	96,12
DenseNet201+k-NN	74,17	77,12	63,64	82,35	88,35
DenseNet201+DVM	79,47	80	77,42	86,10	93,20
Resnet50+RO	68,21	68,21	Nan	81,10	100
Resnet50+k-NN	68,21	68,21	Nan	81,10	100
Resnet50+DVM	68,21	68,21	Nan	81,10	100
Vgg19+RO	76,16	75,97	77,27	84,48	95,15
Vgg19+k-NN	78,81	80,81	73,53	85,45	91,26
Vgg19+DVM	77,48	76,34	85,47	85,47	97,09
InceptionV3+RO	79,47	80,	77,42	86,10	93,20
InceptionV3+k-NN	78,81	79,83	75,00	85,59	92,23
InceptionV3+DVM	74,17	76,67	64,52	82,51	89,32

Genel olarak sonuçlar, YOLO ile kırılmış veri setinin kırılmamış veri setine kıyasla daha iyi performans sağladığını göstermektedir. Bunun yanı sıra, DenseNet201+Bi-LSTM, VGG19+Bi-LSTM ve Inception V3+Bi-LSTM modelleri RO, k-NN ve DVM'ye göre daha yüksek sınıflandırma performansı sergilemektedir.

Tablo 4.22'de Model-2'nin füzyon veri setindeki 5-kat çapraz doğrulama sonuçları iki aşamalı yaklaşım için gösterilmektedir. Sonuçlara göre, DenseNet201 + RO modeli, %77,61 doğruluk elde ederek Glokom sınıflandırması için en iyi performans gösteren model olarak görünmektedir. Bunun yanı sıra, Inception V3 + RO modeli de %77,09 doğruluk ile Tablo 4.23'te gösterildiği gibi tek aşamalı yaklaşım için en iyi sonucu

veren modeldir. Füzyon veri setinde, sadece birkaç model hem tek aşamalı hem de iki aşamalı yaklaşımlarda 5-kat çapraz doğrulama kullanarak orta düzeyde doğruluk elde etmiştir. Bunun yanı sıra, çoğu model için ortak zorluk R değerinin düşük olması ve hastalıklı bireyleri iyi sınıflandıramamasıdır. Bi-LSTM tabanlı modeller, özellikle de DenseNet201 + Bi-LSTM mimarisi, kırılmış veri setinde DenseNet201 + RO ile aynı sonucu göstermiştir. Ancak, kırılmamış veri setinde, Bi-LSTM tabanlı modeller diğer yaklaşımlara benzer sonuçlar göstermiştir.

Tablo 4.22 Füzyon veri setinde kırılmış görüntüler için Bi-LSTM, RO, k-NN ve DVM Modellerinin 5-kat çapraz doğrulama sınıflandırma sonuçları

Modeller	Kat	TP	TN	FP	FN	R	S	F1	P	ACC
DenseNet201+RO	Kat1	20	99	4	28	41,67	83,33	76,38	79,66	78,81
	Kat2	20	98	4	28	41,67	83,33	76,38	79,66	78,81
	Kat 3	18	94	8	30	37,50	92,16	48,65	69,23	74,67
	Kat 4	26	96	7	21	55,32	93,20	65	78,79	81,33
	Kat 5	22	91	12	25	46,81	88,35	54,32	64,71	75,33
	Örtüşen									
	Glokom	106	478	35	132	44,54	93,18	55,94	75,18	
	Normal	478	106	132	35	93,18	44,54	85,13	78,36	
	Ortalama					68,86	68,86	70,53	76,77	77,61
ResNet50+Bi-LSTM	Örtüşen									
	Glokom	0	513	0	238	0	100	NaN	NaN	
	Normal	513	0	238	0	100	0	81,17	68,31	
	Ortalama					50,0	50,0	81,17	68,31	68,30
Vgg19+Bi-LSTM	Örtüşen									
	Glokom	129	431	82	119	52,02	84,02	56,21	61,14	
	Normal	431	129	119	82	84,02	52,02	81,09	78,36	
	Ortalama					67,84	67,84	67,65	69,75	73,23
Inception V3+Bi-LSTM	Örtüşen									
	Glokom	128	450	63	110	53,78	87,72	59,67	67,02	
	Normal	450	128	110	63	87,72	53,72	83,38	80,36	
	Ortalama					70,75	70,75	71,51	72,69	76,97
DenseNet201+Bi-LSTM	Örtüşen									
	Glokom	139	442	71	99	58,40	86,16	62,05	66,19	
	Normal	442	139	99	71	86,16	58,40	83,87	81,70	
	Ortalama					72,28	72,28	72,96	73,94	77,36
DenseNet201+knn	Örtüşen									
	Glokom	94	478	35	144	39,50	93,18	51,23	72,87	
	Normal	478	94	144	35	93,18	39,50	84,23	76,85	
	Ortalama					66,34	66,34	67,73	74,86	71,33
DenseNet201+DVM	Örtüşen									
	Glokom	492	85	21	153	76,28	80,19	84,97	95,91	
	Normal	85	492	153	21	80,19	76,28	49,42	35,71	
	Ortalama					83,11	83,11	67,19	65,81	76,82
Resnet50+RO	Örtüşen									
	Glokom	0	513	0	238	0	100	NaN	NaN	
	Normal	513	0	238	0	100	0	81,17	68,31	
	Ortalama					50,0	50,0	81,17	68,31	68,30
Resnet50+KNN	Örtüşen									
	Glokom	0	513	0	238	0	100	NaN	NaN	
	Normal	513	0	238	0	100	0	81,17	68,31	
	Ortalama					50,0	50,0	81,17	68,31	68,30
Resnet50+DVM	Örtüşen									
	Glokom	0	513	0	238	0	100	NaN	NaN	
	Normal	513	0	238	0	100	0	81,17	68,31	
	Ortalama					50,0	50,0	81,17	68,31	68,30

Tablo 4.22'nin devamı

VGG19+RO	Örtüşen									
	Glokom	87	486	27	151	36,55	94,74	49,43	76,32	
	Normal	486	87	151	27	94,74	36,55	84,52	76,32	
	Ortalama					65,64	65,64	66,97	76,32	76,29
VGG19+KNN	Örtüşen									
	Glokom	83	471	42	155	34,87	91,81	45,73	66,40	
	Normal	471	83	155	42	91,81	34,87	82,70	75,24	
	Ortalama					58,65	36,34	57,93	65,32	73,77
VGG19+DVM	Örtüşen									
	Glokom	0	513	0	238	0	100	NaN	NaN	
	Normal	513	0	238	0	100	0	81,17	68,31	
	Ortalama					50,0	50	81,17	68,31	68,30
Inception V3+RO	Örtüşen									
	Glokom	53	494	19	185	22,27	96,30	34,19	73,61	
	Normal	494	53	185	19	96,30	22,27	82,89	72,75	
	Ortalama					59,28	59,28	58,54	73,18	72,84
Inception V3+KNN	Örtüşen									
	Glokom	62	469	45	176	26,05	91,25	35,94	57,94	
	Normal	469	62	176	45	91,25	26,05	80,93	72,71	
	Ortalama					58,65	58,65	57,93	65,32	70,70
Inception V3+DVM	Örtüşen									
	Glokom	75	486	27	163	31,51	94,74	44,12	73,53	
	Normal	486	75	163	27	94,74	31,51	83,65	74,88	
	Ortalama					63,12	63,12	63,88	74,20	74,69

Tablo 4.23 Füzyon veri setinde kırılmamış görüntü için Bi-LSTM, RO, k-NN ve DVM modellerin 5-kat çapraz doğrulama sınıflandırma sonuçları

Modeller	Kat	TP	TN	FP	FN	R	S	F1	P	ACC
Inception V3+RO	Kat 1	19	96	7	29	39,58	93,20	51,35	73,08	76,16
	Kat 2	20	97	5	28	41,67	95,10	54,79	80	78
	Kat 3	18	96	6	30	41,67	94,12	50	75,00	76
	Kat4	25	93	10	22	53,19	90,29	60,98	71,43	78,67
	Kat 5	19	96	7	28	40,43	93,20	52,05	73,08	76,67
	Örtüşen									
	Glokom	101	478	35	137	42,44	93,18	54,01	74,26	
	Normal	478	101	137	35	93,18	42,44	84,75	77,72	
	Ortalama					67,81	67,81	69,38	75,99	77,09
	Örtüşen									
ResNet50+Bi-LSTM	Glokom	0	513	0	238	0	100	NaN	NaN	
	Normal	513	0	238	0	100	0	81,17	68,31	
	Ortalama					50,0	50,0	81,17	68,31	68,30
	Örtüşen									
Vgg19+Bi-LSTM	Glokom	117	464	437	76	49,55	84,69	53,37	57,81	
	Normal	464	117	76	437	84,69	49,55	82,14	79,79	
	Ortalama					66,62	66,62	67,75	68,8	74,30
	Örtüşen									
Inception V3+Bi-LSTM	Glokom	73	467	46	165	60,62	51,50	31,33	21,12	
	Normal	467	73	165	46	51,50	60,62	64,40	85,93	
	Ortalama					56,06	56,06	47,865	53,525	71,19
	Örtüşen									
DenseNet201+Bi-LSTM	Glokom	116	415	98	122	48,74	80,90	51,33	54,21	
	Normal	415	116	122	98	80,90	48,74	79,05	77,28	
	Ortalama					64,82	64,82	65,19	65,745	73,36
	Örtüşen									
Resnet50+RO	Glokom	0	513	0	238	0	100	NaN	NaN	
	Normal	513	0	238	0	100	0	81,17	68,31	
	Ortalama					50,0	50,0	81,17	68,31	68,30
	Örtüşen									

Tablo 4.23'nin devamı

Resnet50+KNN	Örtüşen								
	Glokom	0	513	0	238	0	100	NaN	NaN
	Normal	513	0	238	0	100	0	81,17	68,31
	Ortalama					50,0	50,0	81,17	68,31 68,30
Resnet50+DVM	Örtüşen								
	Glokom	0	513	0	238	0	100	NaN	NaN
	Normal	513	0	238	0	100	0	81,17	68,31
	Ortalama					50,0	50,0	81,17	68,31 68,30
VGG19+RO	Örtüşen								
	Glokom	88	479	34	150	36,97	93,37	48,89	72,13
	Normal	479	88	150	34	93,37	36,97	83,23	76,15
	Ortalama					65,17	65,17	66,06	74,14 75,50
VGG19+KNN	Örtüşen								
	Glokom	84	466	47	173	32,68	90,84	43,30	64,12
	Normal	466	84	173	47	90,84	32,68	80,90	72,93
	Ortalama					61,76	61,76	62,1	68,52 73,23
VGG19+DVM	Örtüşen								
	Glokom	70	483	30	168	29,41	94,15	41,42	70
	Normal	483	70	168	30	94,15	29,41	82,99	74,19
	Ortalama					61,78	61,78	72,09	72,09 74,67
Inception V3+KNN	Örtüşen								
	Glokom	81	487	26	157	34,03	94,93	46,96	75,70
	Normal	487	81	157	26	94,93	34,03	84,18	75,62
	Ortalama					64,48	64,48	65,57	75,66 75,63
Inception V3+DVM	Örtüşen								
	Glokom	70	483	30	168	29,41	94,15	41,42	70
	Normal	483	70	168	30	94,15	29,41	82,99	74,19
	Ortalama					61,78	61,78	62,205	72,09 73,63
DenseNet201+RO	Örtüşen								
	Glokom	98	469	44	140	41,18	91,42	51,58	69,01
	Normal	469	98	140	44	91,42	41,18	83,60	77,01
	Ortalama					66,3	66,3	67,59	73,01 76,92
DenseNet201+knn	Örtüşen								
	Glokom	98	469	44	140	41,18	91,42	51,58	69,01
	Normal	469	98	140	44	91,42	41,18	83,60	77,01
	Ortalama					66,3	66,3	67,59	73,01 73,33
DenseNet201+DVM	Örtüşen								
	Glokom	87	480	33	151	36,55	93,57	48,60	72,50
	Normal	480	87	151	33	93,57	36,55	83,92	76,07
	Ortalama					65,06	65,06	66,26	74,285 75,50

4.5 Tartışma

Çalışma kapsamında önerilen optik disk segmentasyon yöntemi, DRISHTI-GS1 üzerindeki diğer çalışmalarla ortalama duyarlılık, özgülük, doğruluk, DICE skoru ve Jaccard metriklerine göre karşılaştırılmış ve sonuçlar Tablo 4.24'te sunulmuştur. Doğruluk metriği segmentasyon yöntemlerinin genel doğruluğunu yansıtmaktadır. Bizim yöntemimiz %99,39'luk bir doğruluk oranı elde etmiştir ki bu oran AL-Bander ve arkadaşları (2018) tarafından elde edilen %99,69 doğruluk oranına çok yakın ve bunun dışındaki diğer çalışmalardan daha yüksektir. Bu hem GKO yönteminin hem

de AL-Bander ve ark. (2018)'nin yaklaşımının veri setindeki ilgili özellikleri doğru bir şekilde tanımlamada üstün performans sergilediğini göstermektedir. Örtüşme değerlendirmesi açısından, DICE skoru özellikle önemlidir ve çalışmamız %94,15'lik bir DICE skoru göstermiştir; bu skor Tadisetty (2023)'nin %94,3 ve AL-Bander vd. (2018)'nin %94,9'luk skorlarıyla karşılaştırıldığında rekabetçidir. Yöntemimiz %90,40 Jaccard indeksi göstermiştir ki bu da listelenen çalışmalar arasında en yükseğidir, %90,4 ile AL-Bander ve ark. (2018) ile eşleşmektedir. Bunun yanı sıra, Tadisetty (2023) (jackard=%89,3) ve Ramani vd. (2020) (jackard=%88,43) gibi diğer çalışmaları önemli ölçüde aşmaktadır. Duyarlılık açısından çalışmamız 96,04'lük bir skor elde ederek 95,78 duyarlılık değerini rapor eden Gao vd. (2020)'den az da olsa daha yüksek performans göstermiştir. Bu değer, yöntemimizin tıbbi görüntülemelerde kritik önem taşıyan gerçek pozitif vakaları tespit etmede etkili olduğunu göstermektedir. En yüksek skoru özgüllük metriğinde 99,98 ile elde ettik ve yöntemimizin hedef olmayan alanları doğru bir şekilde belirleme ve böylece yanlış pozitifleri en aza indirme konusundaki olağanüstü yeteneğini gösterdik.

Bu karşılaştırmadan elde edilen sonuçlar, DRISHTI-GS1 veri seti üzerinde farklı segmentasyon yöntemlerinin çeşitli yeteneklerini göstermektedir. Çalışmamız, özellikle duyarlılık ve özgüllük açısından önceki çalışmaların performans ölçütleriyle eşleşmekle kalmayıp onları aşmaktadır.

Tablo 4.24 DRISHTI-GS1 veri seti üzerinde segmentasyon için farklı yöntemlerin karşılaştırılması

Çalışmalar	R	S	ACC	DICE	JACCARD
Gao vd. (2020)	95,78	97,83	97,64	-	-
Samawi vd.(2020)	-	-	97,3	-	-
Tadisetty (2023)	-	-	-	94,3	89,3
Sevastopolsky (2017)				85	
AL-Bander vd.(2018)	-	-	99,69	94,9	90,4
Ramani vd. (2020)	95,28	99,43	99,31	88,43	-
Önerilen metot	96,04	99,58	99,39	94,15	90,40

Literatürde bu çalışmada kullanılan veri setlerine dayanarak Glokom'u sınıflandıran farklı çalışmalar bulunmaktadır. Ancak, yazarların bu soruna yaklaşma biçimlerinde farklılıklar vardır. Bazı çalışmalar farklı görüntü bölme oranları kullanırken, diğerleri farklı katlamalarla çapraz doğrulamayı tercih etmiştir. Bu tez çalışmasında hem k-kat hem de dışarıda tutma doğrulama yaklaşımları kullanılmıştır. Tablo 4.25'te bu tez

çalışmasındaki veri setlerini kullanan önceki çalışmalar sunulmuştur. Bu tablodaki çalışmalardan hiçbiri hem kırpılmış (iki aşamalı) hem de kırılmamış görüntüler (tek aşamalı) için dışarda tutma ve k-Kat çapraz doğrulama yöntemlerini birlikte kullanmamıştır.

DRISHTI-GS1 veri seti üzerinde elde edilen sonuçlar önceki çalışmalarla karşılaştırıldığında, bu çalışmanın ana başarısı Swin Transformer algoritmasının %100 sınıflandırma doğruluğuna sahip olması ve Normal ve Glokom görüntüleri doğru bir şekilde sınıflandırmasıdır. Bu da Swin Transformer'ın negatif ve pozitif sonuçları kesin olarak tahmin edebildiği anlamına gelmektedir. Önceki çalışmaların, hatta dışarda tutma veya çapraz doğrulama kullananların bile metriklerinin hiçbirinde bu kadar yüksek bir seviyeye ulaşamadığını belirtmek gerekir. Bu bulgular, yaklaşımımızı ve yaklaşımımızın kırılmamış DRISHTI-GS1 veri setinde doğru Glokom tespit etme potansiyelini vurgulamaktadır. Üç katlı çapraz doğrulamada en yüksek sınıflandırma doğruluğu yine Swin Transformer ile elde edilmiştir ($acc=\%88,18$). Bu modelin özgüllük değeri $\%74,19$ iken duyarlılık $\%94,29$ 'dur. Bu sonuçlar diğer çalışmalarla karşılaştırıldığında Alagirisamy (2021) ve Chaudhary vd. (2023)'nin çalışmalarından biraz daha düşüktür.

ORIGA veri seti üzerinde elde edilen dışarda tutma doğrulama sonuçları, farklı modeller kullanan önceki çalışmalarla karşılaştırıldığında, Swin Transformer'ın kırpılmış görüntüler için $\%96,15$ doğrulukla önemli ölçüde daha yüksek bir sınıflandırma performansına sahip olduğunu göstermektedir. Bu da Swin Transformer modelinin Glokom sınıflandırması için sağlamlığını göstermektedir. Swin Transformer modeli ORIGA veri setine uygulandığında Glokom'u $\%95,05$ ($R=0,9505$) oranında doğru sınıflandırmıştır. Bu oran sağlıklı görüntüler için $\%100$ 'dür ($S=1$). Sonuçlar, Swin Transformer mimarisinin Glokom vakalarını doğru bir şekilde tespit etme yeteneğini vurgulamaktadır. Beş katlı çapraz doğrulamada, InceptionV3 kullanılarak ORIGA veri seti için elde edilen doğruluk değeri $\%93,84$ 'tür. Bu doğruluk değeri önceki çalışmalara göre oldukça yüksektir.

Tablo 4.25 Sınıflandırma sonuçlarının önceki çalışmaların sonuçlarıyla karşılaştırılması

Çalışma	Metotlar	ACC	R	S	P	F1	Veriseti	Split	Kırpılmış ROI
Elangovan vd. (2021)	CNN with 18 layers	86,62	92,31	48,15	92,38	-	DRISHTI-GS1	Hold-out	Not Applied
		78,32	58,06	92,44	84,36	-	ORIGA		
Elangovan vd. (2021)	VGG-19	91,50	98,09	49,17	92,87	-	DRISHTI-GS1	Hold-out	Not Applied
	ResNet-101	80,50	68,60	88,80	81,20	-	ORIGA		
Sreng (2020)	ShuffleNet(P1)	86,67	-	-	-	-	DRISHTI-GS1	Hold-out	Segmentation using DeepLabv3+ MDCNN
	MobileNet(P1)	81,54	-	-	-	-	ORIGA		
	Inception +DVM(P2)	91,53	-	-	-	-	DRISHTI-GS1		
	ResNet+DVM(P2)	78,97	-	-	-	-	ORIGA		
	Ensemble of P1	85,19	-	-	-	-	DRISHTI-GS1		
		88,86	-	-	-	-	ORIGA		
	Ensemble of P2	92,06	-	-	-	-	DRISHTI-GS1		
		85,26	-	-	-	-	ORIGA		
Diaz-Pinto vd. (2019)	Xception architecture	75,25	74,19	71,43	-	-	DRISHTI-GS1	10-Kat	Not apply
Guo vd. (2018)	random forest classifier + smote	76,9	79,9	73,8	-	-	ORIGA	Hold-out	segmented OD regions using U-net
Chen vd. (2014)	CNN a with 6 layers	78,02	55,66	93,56	85,8	-	DRISHTI-GS1	Hold-out	Not Applied
		86,86	98,7	67,6	85,21	-	ORIGA		
Alagirisamy (2021)	linear vector quantizer-artificial neural network	95,05	95,71	93,55	-	-	DRISHTI-GS1	Hold-out	ROI extraction with micro textures feature extraction
		85,38	83,33	86,10	-	-	ORIGA		
Pranathi vd. (2018)	dynamic support vector machine	85,5	-	-	-	-	ORIGA	10 Kat	Not applied
Chaudhary vd. (2023)	image processing 2D-FBSE-EWT	99	97	100	-	-	DRISHTI-GS1	5-Kat	Cropped histogram matching method
		92,3	91,9	94,8	-	-	ORIGA		
Bu Çalışma	Swin Transformer	100	100	100	100	100	DRISHTI-GS1	Hold-out	Uncropped
	Swin Transformer	88,18	94,29	74,19	87,19	85,49		3-Kat	Uncropped
	Swin Transformer	96,15	95,05	100	100	97,46	ORIGA	Hold-out	Cropped
	InceptionV3	93,84	97,10	84,52	92,88	91,77		5-Kat	Uncropped

5. SONUÇ

Bu son bölümde, bu tezde elde edilen sonuçlara ilişkin değerlendirmeler sunulmaktadır. Bu tez çalışmasında, retina görüntülerinde optik diskin segmentasyonu için kullanılan yöntemlerin yanı sıra Glokom'un sınıflandırılması için kullanılan çeşitli metodolojiler kısaca açıklanmakta ve araştırmadan elde edilen temel bulgular tartışılmaktadır.

Çalışmada ORIGA ve DRISHTI-GS1 olmak üzere iki dengesiz veri setinin yanı sıra bu ikisini birleştiren bir füzyon veri seti de kullanılmıştır. Bu dengesizliği gidermek için ORIGA ve DRISHTI-GS1 veri kümelerini birleştiren füzyon veri seti oluşturulmuştur. Bu füzyon veri seti, sınıflandırma için daha çeşitli bir örnek kümesi sağlamıştır. Segmentasyon görevi için ise sadece DRISHTI-GS1 veri seti kullanılmıştır. Ancak sınıflandırma görevi için ORIGA, DRISHTI-GS1 ve füzyon veri kümeleri olmak üzere üç veri setinden de yararlanılmıştır.

OD segmentasyonu için, yani Glokom teşhisi bağlamında OD'nin otomatik tespiti ve segmentasyonu için GKO algoritması kullanılmıştır. Temel adımlar arasında gri tonlamaya dönüştürme, morfolojik işlemler uygulama ve OD bölgesini iyileştirmek için gri tonlamalı bir maske kullanma gibi giriş görüntülerinin ön işlemden geçirilmesi yer almaktadır. Bu işlemlerden sonra, OD'nin genel kontrastını ve görünürlüğünü iyileştirmek için histogram eşitleme gerçekleştirilmektedir. Bunun yanı sıra, OD'yi arka plandan izole etmek için segmentasyon eşikliğini optimize etmek üzere GKO algoritması kullanılmaktadır. Bölütlenmiş OD bölgesini iyileştirmek için ise morfolojik işlemler gibi işlem sonrası teknikler uygulanmaktadır. Son olarak, bölütleme sonuçları yer gerçeği verileriyle karşılaştırılıp; duyarlılık, özgüllük, doğruluk, Jaccard indeksi ve Dice katsayısı gibi çeşitli metrikler kullanılarak performans değerlendirilmektedir. GKO, %96,04 duyarlılık, %99,58 özgüllük ve %99,39 doğruluk ile güçlü bir performans elde etmiştir. Dice katsayısı %94,15 ve Jaccard indeksi %90,4'tür. Rapor edilen ölçümler, bu yöntemin Glokom'un otomatik teşhisinde kritik bir bileşen olan optik diskin doğru ve güvenilir tespiti için umut verici bir teknik olduğunu göstermektedir.

Glokom teşhisi bağlamında retinal görüntülerin sınıflandırılması için çalışmada iki yaklaşım önerilmiştir: Birincisi, sınıflandırma modellerini eğitmek için retina görüntülerini olduğu gibi kullanan tek aşamalı bir yaklaşımdır. İkincisi, ilk olarak optik disk bölgesini giriş görüntülerinden bulmak ve kırmak için YOLO nesne algılama algoritmasını kullanan iki aşamalı bir yaklaşımdır. İki aşamalı yaklaşımda, kırılan optik disk görüntüleri daha sonra iki farklı sınıflandırma modeline beslenmiştir. Model 1, özellik çıkarma ve sınıflandırma için DenseNet201, VGG19, ResNet50, InceptionV3 ve Swin Transformer gibi derin öğrenme tabanlı mimarileri kullanırken; Model 2, önceden eğitilmiş CNN modellerinden çıkarılan özellikler ile beslenen Bi-LSTM, RO, K-NN ve DVM gibi diğer makine öğrenimi algoritmalarını kullanır.

Bölüm 4'te verilen sonuçlara dayanarak, retina görüntüleri kullanılarak Glokom teşhisi görevi için üç farklı veri setinde Model 1 (derin öğrenme tabanlı) ve Model 2 (Bi-LSTM ve makine öğrenimi) olmak üzere iki sınıflandırma modelinin temel bulgu sonuçları ve karşılaştırması aşağıdaki bölümde sunulmuştur.


5.1 Tüm Modeller Arasında En İyi Sonuçlar

Swin Transformer modeli, DRISHTI-GS1 veri setinde kırılmamış görüntülerle en yüksek doğruluğa (%100) ve dışarda tutma yöntemi kullanılarak ORIGA (kırılmış görüntülerle %96,15) ve Fusion (kırılmış görüntülerle %92,72) veri kümelerinde önemli doğruluğa ulaşarak öne çıkmaktadır. Ayrıca, k-kat çapraz doğrulama kullanılarak, kırılmamış görüntülerde Swin Transformer modeli DRISHTI-GS1 veri setinde %88,88 ve ORIGA veri setinde %94,83 doğruluk elde ederek üstün performans göstermektedir. Bunun yanı sıra, Fusion veri setinde, VGG19 kullanılarak %93,76 doğrulukla en yüksek performans elde edilmiştir. Bu sonuçlar, Swin Transformer'ın her üç veri setinde de yüksek doğruluk elde etme yeteneği, onu daha fazla araştırma ve verilen görevde potansiyel bir umut verici bir model haline getirmektedir.


5.2 Kırpılmış ve Kırılmamış Görüntüler Arasında Karşılaştırma

Şekil 5.1 ve 5.2'de de görüldüğü üzere kırpılmış ve kırılmamış DRISHTI-GS1 ve ORIGA veri setlerinde Swin Transformer haricindeki modellerin çoğu dışarda tutma doğrulama yaklaşımı ile kırpılmış girdiler için daha iyi performans göstermektedir. Bunun yanı sıra, VGG19 modeli kırılmamış girdilerle daha iyi performans göstermektedir. Fusion veri seti için ise DenseNet201 modeli kırılmamış girdilerle daha iyi performans göstermektedir.

Bu istisnalara rağmen, kırpılmış görüntüler ile beslenen modeller genel olarak daha iyi bir performans sergileyerek vakaların çoğunda farklı veri kümeleri ve modeller arasında daha tutarlı sonuçlar ortaya koymaktadır.




Şekil 5.1 Model 1'in kırpılmış görüntüler üzerinde hold-out doğrulaması ile elde ettiği en iyi doğruluk değerleri




Şekil 5.2 Model 1'in kırılmamış görüntüler üzerinde hold-out doğrulaması ile elde ettiği en iyi doğruluk değerleri

Şekil 5.3 ve Şekil 5.4'te gösterildiği gibi ORIGA veri setinde k-kat çapraz doğrulama kullanıldığında, kırılmamış girdilerin VGG19 modeli hariç daha yüksek doğruluğa sahip olduğu, kırılmamış girdileri alan çoğu modelin kırılmış girdileri alan modellerden daha iyi performans gösterdiği görülmektedir. Ancak bu fark çok fazla değildir. Fusion veri seti için, Inception V3 modeli hariç, kırılmış görüntüler kırılmamış girdilerden daha iyi performans göstermiştir. DRISHTI-GS1 veri setinde, kırılmamış girdiler, özellikle ResNet50 ve Inception V3 modelleri için çoğu durumda kırılmış girdilerden daha iyi performans göstermiştir.



Şekil 5.3 Model 1'in kırılmış görüntüler üzerinde çapraz doğrulama ile elde ettiği en iyi doğruluk değerleri



Şekil 5.4 Model 1'in kırılmamış görüntüler üzerinde çapraz doğrula ile elde ettiği en iyi doğruluk değerleri

Genel olarak, kırılmış görüntüler kırılmamış görüntülerden daha iyi performans gösterme eğilimindedir. Bununla birlikte, girdi olarak kırılmış veya kırılmamış görüntülerin kullanılması arasındaki seçim, belirli veri setine ve kullanılan derin öğrenme mimarisine bağlıdır.

5.3 Model-1 ve Model-2 Arasındaki Karşılaştırma

Model-1 ve Model-2 arasındaki karşılaştırmalı analiz, Model-2'nin Model-1'e kıyasla üç veri setinde önemli bir iyileştirme sağlamadığını ortaya koymaktadır. Bununla birlikte, Model-2'nin Model-1'den daha iyi performans gösterdiği birkaç durum vardır, ancak iyileştirmeler nispeten küçüktür. Örneğin, DRISHTI-GS1 veri setinde, Model-2'deki kırılmış görüntülerle beslenen DenseNet201+RO modeli (acc=%95,24), yine kırılmış görüntülerle beslenen Model-1'deki en iyi performans gösteren modelden (acc=%90,48) önemli ölçüde daha yüksek bir doğruluk elde etmiştir. Benzer şekilde, Fusion veri setinde, Model-2 birkaç özel durumda, özellikle de kırılmış görüntüler kullanıldığında Model-1'den biraz daha iyi performans gösterse de iyileştirmeler nispeten küçüktür ve Model-1 hala üç veri seti arasında en iyi genel performansı korumaktadır.

Bu araştırmanın temel bulgusu, diğer son teknoloji yöntemlerle karşılaştırıldığında, GKO yaklaşımının DRISHTI-GS1 veri setinde çok güçlü bir performans elde ettiğini

ve yüksek duyarlılık, özgüllük ve doğruluk sergilediğini göstermektedir. Bununla birlikte, Dice katsayısında en iyi performans gösteren yönteme kıyasla küçük bir fark vardır ve Jaccard endeksi mevcut en iyi çalışma sonucu ile eşleşmektedir.

Sınıflandırma yaklaşımları dışarda tutma ve k-kat doğrulama kullanarak yüksek doğruluk değerleri elde etmiştir. Dengesiz veri setleri ile çalışırken, modelin görüntülerin çoğunu daha fazla sayıda örneğe sahip sınıfa tahmin etme eğiliminde olduğu çalışma kapsamında gözlemlenmiştir.



KAYNAKLAR

- Abbas, Q. (2017). Glaucoma-deep: detection of glaucoma eye disease on retinal fundus images using deep learning. *International Journal of Advanced Computer Science and Applications*, 8(6).
- Abdullah, A. S., Özok, Y. E., & Rahebi, J. (2018). A novel method for retinal optic disc detection using bat meta-heuristic algorithm. *Medical & biological engineering & computing*, 56, 2015-2024.
- Abdullah, A. S., Rahebi, J., Özok, Y. E., & Aljanabi, M. (2020). A new and effective method for human retina optic disc segmentation with fuzzy clustering method based on active contour model. *Medical & biological engineering & computing*, 58, 25-37.
- Abed, S.; Al-Oraifan, D.; Safar, A. (2019) Optic disc detection using fish school search algorithm based on FPGA. *Journal of Engineering Research*. 7. 161-177.
- Abramoff, M. D., Garvin, M. K., & Sonka, M. (2010). Retinal imaging and image analysis. *IEEE reviews in biomedical engineering*, 3, 169-208.
- Adak, C., Karkera, T., Chattopadhyay, S., & Saqib, M. (2023). Detecting severity of diabetic retinopathy from fundus images using ensembled transformers. *arXiv preprint arXiv:2301.00973*.
- Akita, K., & Kuga, H. (1982). A computer method of understanding ocular fundus images. *Pattern Recognit.*, 15(6), 431-443.
- Akyol, K., Şen, B., & Bayır, Ş. (2016). Automatic detection of optic disc in retinal image by using keypoint detection, texture analysis, and visual dictionary techniques. *Computational and mathematical methods in medicine*, 2016(1), 6814791.
- Alagirisamy, M. (2021). Micro statistical descriptors for glaucoma diagnosis using neural networks. *International Journal of Advances in Signal and Image Sciences*, 7(1), 1-10.
- Alghamdi, M., & Abdel-Mottaleb, M. (2021). A comparative study of deep learning models for diagnosing glaucoma from fundus images. *IEEE access*, 9, 23894-23906.
- Aljohani, A., & Aburasain, R. Y. (2024). A hybrid framework for glaucoma detection through federated machine learning and deep learning models. *BMC Medical Informatics and Decision Making*, 24(1), 115.
- Al-Bander, B., Al-Nuaimy, W., Al-Tae, M. A., & Zheng, Y. (2017, March). Automated glaucoma diagnosis using deep learning approach. In *2017 14th International Multi-Conference on Systems, Signals & Devices (SSD)* (pp. 207-210). IEEE.

- Al-Bander, B., Williams, B. M., Al-Nuaimy, W., Al-Tae, M. A., Pratt, H., & Zheng, Y. (2018). Dense fully convolutional segmentation of the optic disc and cup in colour fundus for glaucoma diagnosis. *Symmetry*, 10(4), 87.
- Al-Roomi, S. A., & Al-Shayegi, M. (2016). Effective optic disc detection method based on swarm intelligence techniques and novel pre-processing steps. *Applied Soft Computing*, 49, 146-163.
- Arshad, H., Khan, M. A., Sharif, M. I., Yasmin, M., Tavares, J. M. R., Zhang, Y. D., & Satapathy, S. C. (2022). A multilevel paradigm for deep convolutional neural network features selection with an application to human gait recognition. *Expert Systems*, 39(7), e12541.
- Arsyan, A. R., & Al Maki, W. F. (2022). Classification of glaucoma using invariant moment methods on k-nearest neighbor and random forest models. *Building of Informatics, Technology and Science (BITS)*, 3(4), 466-472..
- An, W., Wang, H., Sun, Q., Xu, J., Dai, Q., & Zhang, L. (2018). A PID controller approach for stochastic optimization of deep networks. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 8522-8531).
- Bajwa, M. N., Malik, M. I., Siddiqui, S. A., Dengel, A., Shafait, F., Neumeier, W., & Ahmed, S. (2019). Two-stage framework for optic disc localization and glaucoma classification in retinal fundus images using deep learning. *BMC medical informatics and decision making*, 19, 1-16.
- Balasubramanian, S., Sagar, A. V., Saradhi, G. V., & Chandrasekaran, V. (2008). Automatic localization and segmentation of blood vessels, optic disc, and macula in digital fundus images. *Advances in Communication Systems and Electrical Engineering*, 543-564.
- Bharkad, S. (2017). Automatic segmentation of optic disk in retinal images. *Biomedical Signal Processing and Control*, 31, 483-498
- Chaudhary, P. K., & Pachori, R. B. (2021). Automatic diagnosis of glaucoma using two-dimensional Fourier-Bessel series expansion based empirical wavelet transform. *Biomedical Signal Processing and Control*, 64, 102237.
- Chaudhary, P. K., Jain, S., Damani, T., Gokharu, S., & Pachori, R. B. (2023). Detection of Primary and Secondary Glaucoma Using 2D-FBSE-EWT From Different Fundus Image Modalities. *Authorea Preprints*.
- Chen, X. W., & Lin, X. (2014). Big data deep learning: challenges and perspectives. *IEEE access*, 2, 514-525.
- Cole, E. D., Novais, E. A., Louzada, R. N., & Waheed, N. K. (2016). Contemporary retinal imaging techniques in diabetic retinopathy: a review. *Clinical & experimental ophthalmology*, 44(4), 289-299.

- Devarajan, D., Ramesh, S. M., & Gomathy, B. (2020). A metaheuristic segmentation framework for detection of retinal disorders from fundus images using a hybrid ant colony optimization. *Soft Computing*, 24(17), 13347-13356.
- Diaz-Pinto, A., Morales, S., Naranjo, V., Köhler, T., Mossi, J. M., & Navea, A. (2019). CNNs for automatic glaucoma assessment using fundus images: an extensive validation. *Biomedical engineering online*, 18, 1-19.
- Elangovan, P., & Nath, M. K. (2021). Glaucoma assessment from color fundus images using convolutional neural network. *International Journal of Imaging Systems and Technology*, 31(2), 955-971.
- Elangovan, P., & Nath, M. K. (2021). Performance analysis of optimizers for glaucoma diagnosis from fundus images using transfer learning. In *Machine Learning, Deep Learning and Computational Intelligence for Wireless Communication: Proceedings of MDCWC 2020* (pp. 507-518). Springer Singapore.
- Fan, R., Alipour, K., Bowd, C., Christopher, M., Brye, N., Proudfoot, J. A., ... & Zangwill, L. M. (2023). Detecting glaucoma from fundus photographs using deep learning without convolutions: transformer for improved generalization. *Ophthalmology science*, 3(1), 100233.
- Gao, J., Jiang, Y., Zhang, H., & Wang, F. (2020). Joint disc and cup segmentation based on recurrent fully convolutional network. *PLoS One*, 15(9), e0238983.
- Gou, L., Wu, S., Yang, J., Yu, H., & Li, X. (2022). Gaussian guided IoU: A better metric for balanced learning on object detection. *IET Computer Vision*, 16(6), 556-566.
- Gu, Z., Li, Y., Wang, Z., Kan, J., Shu, J., & Wang, Q. (2023). Classification of diabetic retinopathy severity in fundus images using the vision transformer and residual attention. *Computational Intelligence and Neuroscience*, 2023(1), 1305583.
- Guo, F., Mai, Y., Zhao, X., Duan, X., Fan, Z., Zou, B., & Xie, B. (2018). Yanbao: a mobile app using the measurement of clinical parameters for glaucoma screening. *IEEE Access*, 6, 77414-77428.
- Guo, F., Li, W., Tang, J., Zou, B., & Fan, Z. (2020). Automated glaucoma screening method based on image segmentation and feature extraction. *Medical & Biological Engineering & Computing*, 58, 2567-2586.
- Haouli, I. E., Hariri, W., & Seridi-Bouchelaghem, H. (2023, September). Exploring Vision Transformers for Automated Glaucoma Disease Diagnosis in Fundus Images. In *2023 International Conference on Decision Aid Sciences and Applications (DASA)* (pp. 520-524). IEEE.
- Hayashi, J., Kunieda, Takamitsu, Cole, Joshua, Soga, Ryusuke, Hatanaka, Yuji & Lu, Miao & Hara, Takeshi & Fujita, Hiroshi. (2001). A Development of Computer-Aided Diagnosis System using Fundus Images. *Virtual Systems and MultiMedia, International Conference*. (pp. 429-438). IEEE Berkeley, CA, USA.

- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- Hoover, A., & Goldbaum, M. (2003). Locating the optic nerve in a retinal image using the fuzzy convergence of the blood vessels. *IEEE transactions on medical imaging*, 22(8), 951-958.
- Hwang, E. E., Chen, D., Han, Y., Jia, L., & Shan, J. (2023). Multi-Dataset Comparison of Vision Transformers and Convolutional Neural Networks for Detecting Glaucomatous Optic Neuropathy from Fundus Photographs. *Bioengineering*, 10(11), 1266.
- Juneja, M., Thakur, S., Uniyal, A., Wani, A., Thakur, N., & Jindal, P. (2022). Deep learning-based classification network for glaucoma in retinal images. *Computers and Electrical Engineering*, 101, 108009.
- Joshi, S., Partibane, B., Hatamleh, W. A., Tarazi, H., Yadav, C. S., & Krah, D. (2022). Glaucoma detection using image processing and supervised learning for classification. *Journal of Healthcare Engineering*, 2022(1), 2988262
- Joshi, V. M., Ghongade, R. B., Joshi, A. M., & Kulkarni, R. V. (2022). Deep BiLSTM neural network model for emotion detection using cross-dataset approach. *Biomedical Signal Processing and Control*, 73, 103407.
- Komaki, G. M., & Kayvanfar, V. (2015). Grey Wolf Optimizer algorithm for the two-stage assembly flow shop scheduling problem with release time. *Journal of computational science*, 8, 109-120.
- Kim, M., Han, J. C., Hyun, S. H., Janssens, O., Van Hoecke, S., Kee, C., & De Neve, W. (2019). Medinoid: computer-aided diagnosis and localization of glaucoma using deep learning. *Applied Sciences*, 9(15), 3064
- Kumar, B. V., Zhang, S., Wu, T., Prakash, J., Zhou, L., & Li, K. (2022). A novel JAYA algorithm for optic disc localisation in eye fundus images. *International Journal of Computational Vision and Robotics*, 12(3), 324-342.
- Lalonde, M., Beaulieu, M., & Gagnon, L. (2001). Fast and robust optic disc detection using pyramidal decomposition and Hausdorff-based template matching. *IEEE transactions on medical imaging*, 20(11), 1193-1200.
- Li, L., Xu, M., Wang, X., Jiang, L., & Liu, H. (2019). Attention based glaucoma detection: A large-scale database and CNN model. *In Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 10571-10580).
- Khan, S., Naseer, M., Hayat, M., Zamir, S. W., Khan, F. S., & Shah, M. (2022). Transformers in vision: A survey. *ACM computing surveys (CSUR)*, 54(10s), 1-41.

- Maas, A. L., Qi, P., Xie, Z., Hannun, A. Y., Lengerich, C. T., Jurafsky, D., & Ng, A. Y. (2017). Building DNN acoustic models for large vocabulary speech recognition. *Computer Speech & Language*, 41, 195-213.
- Maetschke, S., Antony, B., Ishikawa, H., Wollstein, G., Schuman, J., & Garnavi, R. (2019). A feature agnostic approach for glaucoma detection in OCT volumes. *PloS one*, 14(7), e0219126.
- Mallick, S., Paul, J., Sengupta, N., & Sil, J. (2022, November). Study of different transformer based networks for glaucoma detection. In *TENCON 2022-2022 IEEE Region 10 Conference (TENCON)* (pp. 1-6). IEEE.
- Martinez-Perez, M. E., Witt, N., Parker, K. H., Hughes, A. D., & Thom, S. A. (2019). Automatic optic disc detection in colour fundus images by means of multispectral analysis and information content. *PeerJ*, 7, e7119.
- Mirjalili, S., Mirjalili, S. M., & Lewis, A. (2014). Grey wolf optimizer. *Advances in engineering software*, 69, 46-61.
- Mohan, N. J., Murugan, R., Goel, T., & Roy, P. (2022, September). Vit-dr: Vision transformers in diabetic retinopathy grading using fundus images. In *2022 IEEE 10th region 10 humanitarian technology conference (R10-HTC)* (pp. 167-172). IEEE.
- Mosavi, M. R., Khishe, M., & Ghamgosar, A. (2016). Classification of sonar data set using neural network trained by gray wolf optimization. *Neural Network World*, 26(4), 393.
- Pan, S. J., & Yang, Q. (2009). A survey on transfer learning. *IEEE Transactions on knowledge and data engineering*, 22(10), 1345-1359.
- Patton, N., Aslam, T. M., MacGillivray, T., Deary, I. J., Dhillon, B., Eikelboom, R. H., & Constable, I. J. (2006). Retinal image analysis: concepts, applications and potential. *Progress in retinal and eye research*, 25(1), 99-127.
- Pranathi, K., Pingili, M., & Mamatha, B. (2023, March). Fundus Image Processing for Glaucoma Diagnosis Using Dynamic Support Vector Machine. In *International Conference on Communications and Cyber Physical Engineering 2018* (pp. 551-558). Singapore: Springer Nature Singapore.
- Priyadharsini, R., Beulah, A., & Sharmila, T. S. (2018). Optic disc and cup segmentation in fundus retinal images using feature detection and morphological techniques. *Current science*, 115(4), 748-752.
- Pruthi, J., Arora, S., & Khanna, K. (2018). Metaheuristic techniques for detection of optic disc in retinal fundus images. *3D Research*, 9(4), 47.
- Ramani, R. G., & Shanthamalar, J. J. (2020). Improved image processing techniques for optic disc segmentation in retinal fundus images. *Biomedical Signal Processing and Control*, 58, 101832.

- Samawi, H. J., Al-Sultan, A. Y., & Al-Saadi, E. H. (2020, April). Optic disc segmentation in retinal fundus images using morphological techniques and intensity thresholding. *In 2020 International Conference on Computer Science and Software Engineering (CSASE)* (pp. 302-307). IEEE.
- Sarraf, S., & Tofighi, G. (2016). Classification of alzheimer's disease using fmri data and deep learning convolutional neural networks. *arXiv preprint arXiv:1603.08631*.
- Saxena, A., Vyas, A., Parashar, L., & Singh, U. (2020). A glaucoma detection using convolutional neural network. *In 2020 international conference on electronics and sustainable communication systems (ICESC)* (pp. 815-820). IEEE.
- Serte, S., & Serener, A. (2019, October). A generalized deep learning model for glaucoma detection. *In 2019 3rd International symposium on multidisciplinary studies and innovative technologies (ISMSIT)* (pp. 1-5). IEEE.
- Sevastopolsky, A. (2017). Optic disc and cup segmentation methods for glaucoma detection with modification of U-Net convolutional neural network. *Pattern Recognition and Image Analysis*, 27, 618-624.
- Shaikha, H. K., & Sallow, A. B. (2019, April). Optic Disc Detection and Segmentation in Retinal Fundus Image. *In 2019 International Conference on Advanced Science and Engineering (ICOASE)* (pp. 23-28). IEEE.
- Singh, P. B., Singh, P., Dev, H., Tiwari, A., Batra, D., & Chaurasia, B. K. (2023). Glaucoma Classification using Light Vision Transformer. *EAI Endorsed Transactions on Pervasive Health and Technology*, 9.
- Sinthanayothin, C., Boyce, J. F., Cook, H. L., & Williamson, T. H. (1999). Automated localisation of the optic disc, fovea, and retinal blood vessels from digital colour fundus images. *British journal of ophthalmology*, 83(8), 902-910.
- Sivaswamy, J., Krishnadas, S. R., Joshi, G. D., Jain, M., & Tabish, A. U. S. (2014, April). Drishti-gs: Retinal image dataset for optic nerve head (onh) segmentation. *In 2014 IEEE 11th international symposium on biomedical imaging (ISBI)* (pp. 53-56). IEEE
- Sonti, K., & Dhuli, R. (2023). A new convolution neural network model “KR-NET” for retinal fundus glaucoma classification. *Optik*, 283, 170861.
- Subbarayudu, Y., Reddy, G. V., Kumar, M. R., Naik, M. A., Nagini, R. V. S. S., & Singh, B. (2024). An efficient novel approach for glaucoma classification on retinal fundus images through machine learning paradigm. *In MATEC Web of Conferences* (Vol. 392, p. 01108). EDP Sciences.
- Sreng, S., Maneerat, N., Hamamoto, K., & Win, K. Y. (2020). Deep learning for optic disc segmentation and glaucoma diagnosis on retinal images. *Applied Sciences*, 10(14), 4916.

- Sun, R., Li, Y., Zhang, T., Mao, Z., Wu, F., & Zhang, Y. (2021). Lesion-aware transformers for diabetic retinopathy grading. *In Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition* (pp. 10938-10947).
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. (2015). Going deeper with convolutions. *In Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 1-9).
- Tadisetty, S., Chodavarapu, R., Jin, R., Clements, R. J., & Yu, M. (2023). Identifying the edges of the optic cup and the optic disc in glaucoma patients by segmentation. *Sensors*, 23(10), 4668.
- Thakur, N., & Juneja, M. (2019). Optic disc and optic cup segmentation from retinal images using hybrid approach. *Expert Systems with Applications*, 127, 308-322.
- Thakoor, K. A., Li, X., Tsamis, E., Sajda, P., & Hood, D. C. (2019). Enhancing the accuracy of glaucoma detection from OCT probability maps using convolutional neural networks. *In 2019 41st annual international conference of the IEEE engineering in medicine and biology society (EMBC)* (pp. 2036-2040). IEEE.
- Tobin, K. W., Chaum, E., Govindasamy, V. P., & Karnowski, T. P. (2007). Detection of anatomic structures in human retinal imagery. *IEEE transactions on medical imaging*, 26(12), 1729-1739.
- URL-1 (2020). <https://www.mskcc.org/cancer-care/patient-education/about-ocular-melanoma> Erişim tarihi: 05/12/2020
- URL-2 (2024). <https://www.baeldung.com/cs/bidirectional-vs-unidirectional-lstm> Erişim tarihi: 05/05/2024
- Veiga, D., Pereira, C., Ferreira, M., Gonçalves, L., & Monteiro, J. (2014). Quality evaluation of digital fundus images through combined measures. *Journal of Medical Imaging*, 1(1), 014001-014001.
- Yao, Z., Yuan, Y., Shi, Z., Mao, W., Zhu, G., Zhang, G., & Wang, Z. (2022). FunSwin: A deep learning method to analysis diabetic retinopathy grade and macular edema risk based on fundus images. *Frontiers in physiology*, 13, 961386.
- Yu, S., Xiao, D., Frost, S., & Kanagasingam, Y. (2019). Robust optic disc and cup segmentation with deep learning for glaucoma detection. *Computerized Medical Imaging and Graphics*, 74, 61-71.
- Zafar, A., Ahmad, J., Addo, R. T., & Akhter, S. (2016). Progress of controlled drug delivery systems in topical ophthalmology: focus on nano and micro drug carriers. *Ocular Drug Delivery: Advances, Challenges and Applications*, 131-163.
- Zhao, S., Wu, Y., Tong, M., Yao, Y., Qian, W., & Qi, S. (2022). Cot-xnet: contextual transformer with xception network for diabetic retinopathy grading. *Physics in Medicine & Biology*, 67(24), 245003.

- Zahoor, M. N., & Fraz, M. M. (2017). Fast optic disc segmentation in retinal images using polar transform. In *Medical Image Understanding and Analysis: 21st Annual Conference, MIUA 2017, Edinburgh, UK, July 11–13, 2017, Proceedings* 21 (pp. 38-49). Springer International Publishing.
- Zhang, S., Yang, L. T., Feng, J., Wei, W., Cui, Z., Xie, X., & Yan, P. (2021). A tensor-network-based big data fusion framework for cyber–physical–social systems (CPSS). *Information Fusion*, 76, 337-354.
- Zhang, Z., Yin, F. S., Liu, J., Wong, W. K., Tan, N. M., Lee, B. H., ... & Wong, T. Y. (2010, August). Origa-light: An online retinal fundus image database for glaucoma analysis and research. In *2010 Annual international conference of the IEEE engineering in medicine and biology* (pp. 3065-3068). IEEE.
- Wainberg, M., Merico, D., DeLong, A., & Frey, B. J. (2018). Deep learning in biomedicine. *Nature biotechnology*, 36(9), 829-838.
- Wang, B., Hu, S. J., Sun, L., & Freiheit, T. (2020). Intelligent welding system technologies: *State-of-the-art review and perspectives*. *Journal of Manufacturing Systems*, 56, 373-391.
- Wassel, M., Hamdi, A. M., Adly, N., & Torki, M. (2022, August). Vision transformers based classification for glaucomatous eye condition. In *2022 26th International Conference on Pattern Recognition (ICPR)* (pp. 5082-5088). IEEE.
- Welfer, D., Scharcanski, J., Kitamura, C. M., Dal Pizzol, M. M., Ludwig, L. W., & Marinho, D. R. (2010). Segmentation of the optic disk in color eye fundus images using an adaptive morphological approach. *Computers in Biology and Medicine*, 40(2), 124-137.
- Wei, Y., Chen, Z., Zhao, C., Tu, Y., Chen, X., & Yang, R. (2021). A BiLSTM hybrid model for ship roll multi-step forecasting based on decomposition and hyperparameter optimization. *Ocean Engineering*, 242, 110138.
- Wu, J., Hu, R., Xiao, Z., Chen, J., & Liu, J. (2021). Vision Transformer-based recognition of diabetic retinopathy grade. *Medical Physics*, 48(12), 7850-7863.