

**T.C.
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**RETİNA FUNDUS BİLEŞENLERİNİN GÖRÜNTÜ İŞLEME VE YAPAY
ÖĞRENME İLE TANILAMA YÖNTEMLERİNİN GELİŞTİRİLMESİ**

DOKTORA TEZİ

Buket TOPTAŞ

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Davut HANBAY

TEMMUZ 2022

**T.C
İNÖNÜ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**RETİNA FUNDUS BİLEŞENLERİNİN GÖRÜNTÜ İŞLEME VE YAPAY
ÖĞRENME İLE TANILAMA YÖNTEMLERİNİN GELİŞTİRİLMESİ**

DOKTORA TEZİ

**Buket TOPTAŞ
36173619007**

Bilgisayar Mühendisliği Anabilim Dalı

Tez Danışmanı: Prof. Dr. Davut HANBAY

TEMMUZ 2022

TEŐEKKÜR VE ÖNSÖZ

Bu tez alıőmasının her aőamasında desteęini ve tecrübelerini benden esirgemeyen danıőman hocam Sayın Prof. Dr. Davut HANBAY'a teőekkürlerimi sunarım. Danıőman hocamdan doktora süresi boyunca hem tez araştırma ve uygulaması eęitimi aldım hemde özgün kalmayı, etik kuralları, azimle alıőmayı, akademik hayatın getirdięi kolaylık ve zorlukları öęrendim. Her zaman sabırla bizi dinleyen, özüm odaklı ve destekleyici tavrından dolayı hocama minnettarım.

Tezin daha kapsamlı bir alıőmaya dönüşmesini destekleyen inceleme komitemin abalarını ve yorumlarını da içtenlikle takdir ediyorum.

Hayatımın her aőamasında arkamda duran, eęitimime destek veren, heyecanımı ve hüznümü rahata paylaşabildięim başta Annem ve Babam olmak üzere tüm aile bireylerime teőekkür ediyorum.

En büyük teőekkürü canım eőim Murat TOPTAŐ'a ve oęlum Ahmet Asaf TOPTAŐ'a ediyorum. Desteęi, fedakârlıęı, sabrı ve bana olan inancından dolayı eőime teőekkürlerimi sunuyorum.

Tezin uygulama aőamasında vermiő oldukları destekten dolayı İnönü Üniversitesi BAP birimine teőekkür ediyorum.

Doęrudan veya dolaylı olarak tez sürecinde emeęi geen herkese teőekkür ediyorum.

ONUR SÖZÜ

Doktora tezi olarak sunduđum “Retina Fundus Bileşenlerinin Görüntü İşleme ve Yapay Öğrenme ile Tanılama Yöntemlerinin Geliştirilmesi” başlıklı bu çalışmanın bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın tarafımdan yazıldığına ve yararlandığım bütün kaynakların hem metin içinde hem de kaynakçada yöntemine uygun biçimde gösterilenlerden oluştuđunu belirtir, bunu onurumla doğrularım.

Buket TOPTAŞ



İÇİNDEKİLER

TEŞEKKÜR VE ÖNSÖZ	i
ONUR SÖZÜ	ii
İÇİNDEKİLER.....	iii
ÇİZELGELER DİZİNİ.....	v
ŞEKİLLER DİZİNİ.....	vi
SEMBOLLER VE KISALTMALAR	vii
ÖZET	ix
ABSTRACT	x
1. GİRİŞ.....	1
1.1 Fundus Görüntü Analizi.....	2
1.2 Literatür İncelemesi	5
1.2.1 Optik disk ile ilgili çalışmalar	5
1.2.1.1 OD bölgesinin lokalizasyon tespiti ve bölütlenmesi	5
1.2.1.2 OD bölgesinden glokom hastalığının tespiti	11
1.2.2 Retina damar ağ yapısı ile ilgili çalışmalar	16
1.2.2.1 Retina damar ağ yapısının bölütlenmesi.....	16
1.2.2.2 Retina arter/vein ayrımı	31
1.3 Tezin Amacı.....	36
1.4 Tezin Gerekçesi	37
1.5 Tezde Sunulan Bilimsel Katkıları	37
1.6 Tezin Organizasyonu	38
2. MATERYAL.....	39
2.1 Ön İşlem.....	39
2.1.1 Kontrast sınırlı uyarlamalı histogram eşitleme.....	39
2.1.2 Wiener filtresi	40
2.1.3 Medyan filtresi.....	41
2.2 Özellik Çıkarımı	42
2.2.1 Gradyan tabanlı özellikler	42
2.2.2 Kenar bulma filtreleri	43
2.2.2.1 Roberts filtresi	43
2.2.2.2 Prewitt filtresi	43
2.2.2.3 Sobel filtresi.....	44
2.2.2.4 Canny filtresi	44
2.2.2.5 Marr hildreth operatörü	45
2.2.3 Morfolojik özellikler	46
2.2.4 İstatistiksel özellikler.....	47
2.2.5 Hessian matrisi	48
2.3 Yapay Arı Koloni Algoritması	49
2.4 K-Ortalama Kümeleme	50
2.5 Yapay Sinir Ağı	51
2.6 Evrimsel Sinir Ağı.....	53
2.7 EfficinetNet-B0.....	55
3. KULLANILAN VERİ SETLERİ VE PERFORMANS ÖLÇÜTLERİ.....	57
3.1 Veri Setleri.....	57
3.2 Performans Ölçütleri.....	58
4. YAPILAN UYGULAMA ÇALIŞMALARI	60
4.1 Uygulama 1: Optik Disk ve Optik Kup Lokalizasyonun Tespiti.....	60
4.1.1 YAK tabanlı yeni renk uzayında OD lokalizasyonunun tespiti	60
4.1.1.1 Optimal dönüşüm matrisinin elde edilmesi	63

4.1.1.2 Fundus görüntülerinin yeni renk uzayına taşınması	65
4.1.2 YAK tabanlı yeni renk uzayındaki OD lokalizasyonunun tespit sonucu	68
4.1.3 Önerilen yöntemin performans karşılaştırması.....	69
4.2 Uygulama 2: Piksel Tabanlı Retina Damar Bölütleme.....	72
4.2.1 Piksel tabanlı özellikler ile retina kan damarlarının bölütlenmesi	72
4.2.1.1 Ön işlem aşaması	73
4.2.1.2 Özellik çıkarım aşaması	75
4.2.1.3 Sınıflandırma aşaması	77
4.2.2 Piksel tabanlı özellikler ile retina kan damarlarının bölütlenme sonucu.....	77
4.2.3 Önerilen yöntemin performans karşılaştırması.....	79
4.3 Uygulama 3: Retina Arter/Vein Ayrımı	82
4.3.1 ESA ile retina kan damarlarından arter/vein ayrımı	82
4.3.1.1 Ön işlem aşaması	83
4.3.1.2 Veri hazırlama ve veri çoğaltma aşaması	84
4.3.1.3 Arter/Vein ayrımı için önerilen ağ mimarisi	86
4.3.2 ESA ile retina kan damarlarından arter/vein ayrımının sonuçları	88
4.3.3 Önerilen yöntemin performans karşılaştırması.....	91
4.4 Uygulama 4: Glokomlu ve Sağlıklı Fundus Görüntü Ayrımı.....	92
4.4.1 EfficientNet-B0 ile glokomlu görüntüleri ayrıştırma	92
4.4.2 EfficientNet-B0 ile glokomlu görüntülerin ayrıştırılma sonucu	93
5. SONUÇLAR.....	96
KAYNAKLAR.....	99
ÖZGEÇMİŞ	121

ÇİZELGELER DİZİNİ

Çizelge 2.1	: İstatistiksel özelliklerin tanımı ve formülü.	48
Çizelge 2.2	: EfficientNet-B0 mimarisi	56
Çizelge 4.1	: YAK parametre değerleri.....	64
Çizelge 4.2	: KYM renk uzayından yeni renk uzayına geçiş algoritması.	67
Çizelge 4.3	: Önerilen yöntemin diğer yöntemlerle performans karşılaştırması.	70
Çizelge 4.4	: Her pikselden çıkarılan özellikler.	75
Çizelge 4.5	: Yapay sinir ağı parametreleri.....	77
Çizelge 4.6	: Önerilen yöntemin sonuçları (DRIVE).....	78
Çizelge 4.7	: Önerilen yöntemin sonuçları (STARE).	79
Çizelge 4.8	: Önerilen yöntemin performans karşılaştırması (DRIVE).....	80
Çizelge 4.9	: Önerilen yöntemin performans karşılaştırması (STARE).	80
Çizelge 4.10	: Diğer güncel yöntemlerin çalışma süresi.....	81
Çizelge 4.11	: ESA katman detayları.	87
Çizelge 4.12	: Önerilen yöntemin nicel sonuçları.....	89
Çizelge 4.13	: Önerilen yöntemin diğer yöntemlerle performans karşılaştırması.	91
Çizelge 4.14	: Sabit öğrenme oranı (0.001)	94
Çizelge 4.15	: Her turda azalan öğrenme oranı.....	94
Çizelge 4.16	: ACRIMA veri setini kullanan diğer güncel yöntemler.....	95

ŞEKİLLER DİZİNİ

Şekil 1.1	: Retina fundus görüntüleme kamerası [3].....	2
Şekil 1.2	: Retina lezyonları	3
Şekil 1.3	: Retina bileşenleri (a) Fundus görüntüsü, (b) AÜNT kural bölgesi	4
Şekil 1.4	: Farklı retinalara ait PPA görüntüleri (a) ve (b) [10], (c) [11]	4
Şekil 2.1	: KSUHE bölgeleri.....	40
Şekil 2.2	: Medyan filtre örneği	41
Şekil 2.3	: Sobel filtre örneği	44
Şekil 2.4	: Yapay arı kolonisi.....	50
Şekil 2.5	: Bir yapay sinir hücresi	52
Şekil 2.6	: Evrişim katmanından özellik haritası oluşturma	53
Şekil 2.7	: Maksimum havuzlama katman örneği (a) özellik haritası, (b) maksimum havuzlama sonucu.....	54
Şekil 4.1	: Özellik matrisi için görüntü kesitleri	61
Şekil 4.2	: Uygulama 1 akış şeması	62
Şekil 4.3	: Sırası ile renkli fundus görüntüsü, KSUHE uygulanmış K, Y ve M kanalları	65
Şekil 4.4	: Görüntü boyutunu dönüştürme ve tekrar orijinal haline getirme	66
Şekil 4.5	: Veri seti görüntülerinin yeni renk uzayındaki görünüşleri. İlk satır yeni uzayı, ikinci satır birinci kanal, üçüncü satır ikinci kanal ve son satır üçüncü renk kanalını temsil eder.....	67
Şekil 4.6	: Yeni renk uzayındaki görüntülerin eşikleme sonuçları. İlk satır yeni uzayı, ikinci satır eşiklenmiş görüntüyü, üçüncü satır eşiklenmiş ikili görüntüyü ve son satır morfoloji uygulanmış ikili görüntüyü temsil eder.....	68
Şekil 4.7	: Veri seti görüntüleri üzerinde işaretlenmiş OD aday bölgeleri	69
Şekil 4.8	: Hatalı tespit edilen OD lokalizasyonu. (a) renkli fundus görüntüsü, (b) yeni uzaya taşınmış görüntü, (c) eşikleme sonucu, (d) seçilen OD aday bölgesi....	70
Şekil 4.9	: OD bölgesi net olmayan MESSIDOR veri seti görüntüleri.....	71
Şekil 4.10	: Farklı yoğunluk ve renge sahip MESSIDOR veri seti görüntüleri.....	71
Şekil 4.11	: Uygulama 2 akış şeması	73
Şekil 4.12	: Bir fundus görüntüsüne ait merkezi ışık refleksi.....	74
Şekil 4.13	: Sırası ile fundus görüntüsünün Y kanalı, ışık refleksi yok edilmiş görüntü, KSUHE uygulanmış görüntü ve medyan filtresi uygulanmış son görüntü	74
Şekil 4.14	: Kenar algılama yönteminden çıkarılan özellikler	76
Şekil 4.15	: Bölütlenmiş retina kan damarları. İlk üç sütun DRIVE görüntülerini, son üç sütun ise STARE görüntülerini temsil eder.	79
Şekil 4.16	: Uygulama 3 akış şeması	83
Şekil 4.17	: Ön işlem süreci	84
Şekil 4.18	: Arter ve veinlerden alınan görüntü kesitleri, (a) arter, (b) vein.....	86
Şekil 4.19	: Önerilen ESA mimarisi.....	86
Şekil 4.20	: Orijinal fundus görüntülerinde A/V damarların gösterilmesi. İlk satır, gerçek zemin görüntülerini, ikinci satır, segmentlere ayrılmış A/V damarlarını, üçüncü satır, segmente edilmiş görüntüde yanlış bulunan pikselleri temsil etmektedir.	89
Şekil 4.21	: Son işlem aşamasının görüntülere etkisi. Sırası ile manuel, önerilen yöntem ve önerilen yöntemle son işlem uygulanarak elde edilen A/V damarlarının orijinal görüntü üzerinde gösterilmesi.....	91
Şekil 4.22	: Altı kanallı giriş ekranı. (a) Yeni renk uzayı ve bu uzayın ilk kanalı, (b) orijinal fundus görüntüsü ve bu görüntünün K, Y kanalı, (c) (a)'ya uygulanan gauss görüntü sonucu ve bu görüntünün renk kanalları	93

SEMBOLLER VE KISALTMALAR

AKM	: Aktif Kontur Modeli (Active Contour Model)
AŞ	: Alt Şapka
AÜNT	: Alt Üst Nazal Temporal (Inferior-Superior-Nazal-Temporal)
BDT	: Bilgisayar Destekli Tanı (Computer Aided Diagnosis)
BKY	: Bulanık Kümeleme Yöntemi (Fuzzy Clustering Method)
D	: Doğruluk (Accuracy)
DDB	: Düzeltilmiş Doğrusal Birim (Rectified Linear Units)
DN	: Doğru negatif sayısı (True Negative)
DR	: Diyabetik Retina (Diabetic Rethinopathy)
DP	: Doğru pozitif (True Positive)
EF	: Eşleşen Filtre (Match Filter)
ESA	: Evrişimsel Sinir Ağları (Convolutional Neural Networks)
H	: Hassaslık (Sensitivity)
İB	: İlgi Bölgesi (Region of Interest)
KDKT	: Kare Düzeyinin Kök Toplamı (Root Sum of Squared Level)
KSUHE	: Kontrast Sınırlı Uyarlanabilir Histogram Eşitleme (Contrast Limited Adaptive Histogram Equazation)
KYM	: Kırmızı Yeşil Mavi (Red Green Blue)
LoG	: Gauss'un Lablası (Laplacion of Gauss)
MA	: Mikroanevrizma
NKO	: Nöroretinal Kenar Oranı (Nöroretinal Rim Rate)
OD	: Optik Disk (Optic Disc)
OK	: Optik Kupa (Optic Cup)
OKODO	: Optik Kupanın Optik Diske Oranı (Cup to Disc Ratio)
OKT	: Optik Koherens Tomografi (Optik Coherens Tomografi)
OMS	: Ortalama Mutlak Sapma (Mean Absolute Deviation)
OSB	: Optik Sinir Başı (Optic Nerve Head)
Ö	: Özgüllük (Specificity)
PPA	: Peripapiller Atrofi
RD	: Radon Dönüşümü (Radon Transform)
TBA	: Tam Bağlı Ağlar (Fully Conventional Networks)
TN	: Toplu Normalleşme (Batch Normalization)
ÜÇA	: Üretici Çekişmeli Ağ (Generative Adversarial Network)

ÜŞ	: Üst Şapka
YAK	: Yapay Arı Kolonisi
YN	: Yanlış negatif (False Negative)
YP	: Yanlış pozitif (False Positive)
YSA	: Yapay Sinir Ağı (Artificial Neural Network)
μ	: Arimetik Ortalama



ÖZET

Doktora Tezi

RETİNA FUNDUS BİLEŞENLERİNİN GÖRÜNTÜ İŞLEME VE YAPAY ÖĞRENME İLE TANILAMA YÖNTEMLERİNİN GELİŞTİRİLMESİ

BUKET TOPTAŞ

İnönü Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı

121+X sayfa

2022

Danışman: Prof. Dr. Davut HANBAY

Fundus görüntüleri, gözün retina yapısının görüntülenme şeklidir. Bu görüntülerde gözü ve diğer organları etkileyen birçok hastalığın bilgisi bulunmaktadır. Bu bilgilere erişmek için retina fundus görüntüleri detaylı analiz edilmektedir. Bu analizler, alanında uzman hekimler tarafından bilgisayar destekli tanı sistemleri kullanılarak yapılmaktadır. Bu analiz sürecinin başarısı hekimin bilgi ve deneyimine bağlıdır. Ayrıca, bu süreç karmaşık ve zaman alıcıdır. Teknolojinin gelişmesi ile birlikte daha iyi analiz yapan sistemlere ihtiyaç duyulmaktadır.

Bu tez çalışmasında, retina fundus görüntüleri detaylı olarak incelenmiş ve bu görüntüler üzerinde bilgisayar destekli tanı sistemleri geliştirilmiştir. Bu sistemlerin ilki, retina üzerinde önemli bir konuma sahip olan optik diskin lokalizasyon tespiti üzerine odaklanmıştır. Önerilen sistemde, KYM renk uzayındaki fundus görüntüleri yeni bir renk uzayına taşınmış ve bu renk uzayında optik disk lokalizasyonu tespit edilmiştir. İkinci önerilen sistem, diyabetik retina başta olmak üzere birçok hastalığın tanı ve teşhisinde kullanılan retina kan damarlarının çıkarılmasını sağlayan bir yöntemdir. Önerilen bu yöntemde, fundus görüntülerinden elde edilen piksel tabanlı özellikler ile retina kan damarları bölütlenmiştir. Üçüncü modellenen sistem ise retina kan damarlarının arter/vein ayrımını sağlayan bir sistemdir. Modellenen bu sistemde, retina kan damarlarından alınan görüntü kesitleri tasarlanan evrişimsel bir sinir ağına girdi olarak verilmiştir. Evrişimsel sinir ağı sonucunda bir retina kan damarının arter/vein ayrımı sağlanmıştır. Tasarlanan son sistem ise, fundus görüntülerini glokom veya sağlıklı olarak ayırabilen bir sistemdir. Burada, güncel yöntemlerden biri olan EfficientNet modeli kullanılmıştır.

Önerilen sistemlerin hepsi halka açık olarak sunulan fundus veri setleri üzerinde test edilmiştir. Önerilen bu sistemlerin performans sonuçları, diğer güncel yöntemlerin performans sonuçlarına kıyasla tatmin edici düzeydedir. Geliştirilen sistemler karar destek sistemi olarak hekimlere yardımcı olabilecektir.

Anahtar Kelimeler: Fundus, Retina, Optik Disk, Arter, Vein

ABSTRACT

Phd. Thesis

DEVELOPMENT of DIAGNOSTIC METHODS of RETINA FUNDUS COMPONENTS
with IMAGE PROCESSING and ARTIFICIAL LEARNING

Buket TOPTAŞ

Inonu University
Graduate School of Nature and Applied Sciences
Department of Computer Engineering

121+X papers

2022

Supervisor: Prof. Dr. Davut HANBAY

Fundus images are the process of visualizing the retinal structure of the eye. These images contain information about many diseases that impact the eye and other organs. To obtain this information, retinal fundus images are analyzed thoroughly. These analyzes are made by specialist physicians using computer-aided diagnosis systems. The success of this analysis process depends on the knowledge and experience of the specialist physicians. In addition, it is a time-consuming and complicated process. With the advance of technology, better analysis systems are needed.

In this thesis, retinal fundus images were examined in detail and computer-aided diagnosis systems are developed over these images. The first of these systems focused on localization detection of the optic disc, which has an important position on the retina. In the proposed system, fundus images in RGB color space are moved to new color space and optic disc localization was detected in this color space. The second proposed system is a method that allows the extraction of retinal blood vessels, which is used in the detection and diagnosis of many diseases starting with diabetic retina. In this proposed method, retinal blood vessels are segmented with pixel-based features obtained from fundus images. The third modeled system is a system that is capable of distinguishing between the arteries and veins of the retina blood vessels. In this modeled system, image patches extracted from retina blood vessels are given as inputs to a designed convolutional neural network. The output of the convolutional neural network enables the distinction between the arteries and veins of the retina blood vessels. The last system designed is a system that can distinguish fundus images as glaucoma or healthy. Here, the EfficientNet model, which is one of the current methods, is used.

All of the systems proposed are tested on the fundus datasets which are publicly available. Performance results of all of the proposed systems are satisfactory in the sense that they are competitive with those of state-of-the-art methods used in the literature. As a consequence, developed systems can be used as decision support systems to help physicians.

Keywords: Fundus, Retina, Optik Disk, Arter, Vein

1. GİRİŞ

Teknolojik gelişmeler sağlık alanında büyük ilerlemelere neden olmaktadır. Bu gelişmelerden biri Bilgisayar Destekli Tanı (BDT - Computer Aided Diagnosis (CAD)) sistemleridir. Bu sistemler, insan sağlığını korumak, hastalıkların önüne geçebilmek ve hastalıkları teşhis edebilmek için medikal görüntülerin otomatik analizini gerçekleştirmektedir. Medikal görüntüleme, en yalın hali ile insan vücudunun içyapısının çeşitli yöntemlerle görüntülenmesidir. Bu görüntülerin yorumu alanında uzman radyolog ve hekimler tarafından yapılmaktadır. Medikal görüntülerin karmaşık yapıda olması, hekimlerin ve radyologlarında farklı yorumlama tarzlarına sahip olmasından dolayı her zaman doğru yorumun yapılması mümkün olmamaktadır. Zamanında ve doğru bir şekilde yorumlanamayan bu görüntüler, insan sağlığını tehdit eden problemlerin ilerlemesine ve ciddi boyutlara ulaşmasına sebep olmaktadır. Erken teşhise katkı sağlamak, uzman hekimlere tanı ve tedavi sürecinde zaman kazandırmak için BDT sistemleri medikal görüntü analizinde kullanılmaktadır.

BDT sistemleri, medikal görüntülerin analizini gerçekleştirerek uzman hekimlere yardımcı olmayı amaçlayan sistemlerdir. Teknolojik gelişmelerin ilerlemesi ile bu sistemlerde gelişmektedir. Bu sistemler, uzman hekimlerin uzun uğraşlarla yaptığı medikal görüntü analiz işlemlerini hızlı ve sağlam bir şekilde gerçekleştirirler. BDT sistemlerinin ilgilendiği farklı medikal görüntü analiz alanları vardır. Bu alanlardan biri, insan gözünün retina görüntüsüne ait temel bileşenlerinin ve anormal lezyonlarının analizidir [1].

Retina, insan gözünde görme duyusunun gerçekleştiği kısımdır. Ayrıca, insan vücudunun diğer organlarına ait hayati öneme sahip bilgileri de içermektedir. Göz tansiyonu, yaşa bağlı makula dejenerasyonu, mikroanevrizma gibi göz hastalıklarının yanı sıra diyabet, hipertansiyon, böbrek hastalığı gibi hastalıkların bilgisine de retinada oluşan anormallikler sayesinde ulaşılmaktadır. Retina üzerinde BDT sistemleri geliştirebilmek için retina görüntülerine ihtiyaç duyulmaktadır. Retina görüntüleri, retina katmanlarını gözlemeye izin veren Optik Koherens Tomografi (OKT - Optical Coherence Tomography (OCT)) ve retina dokusunu gözlemlemeye izin veren fundus fotoğraflama yöntemleri ile elde edilmektedir.

[2]. Fundus görüntüleri, BDT sistemlerinde en yaygın kullanılan retina görüntüleridir. Şekil 1.1’de bir fundus kamerası ve görüntüsü verilmiştir.




Şekil 1.1 : Retina fundus görüntüleme kamerası [3].

1.1 Fundus Görüntü Analizi

Fundus görüntüleri retina üzerinde bulunan çeşitli anatomik yapıları ortaya çıkarır. Bu anatomik yapılar; Optik Disk (OD - Optical Disc (OD)), Optik Kup (OK - Optic Cup (OC)), arter/vein damarlar, fovea, makula ve çeşitli lezyonlardır. Bu anatomik yapılarla birlikte sıklıkla bahsedilen bazı kavramlar vardır. Bu kavramlar; Optik Sinir Başı (OSB - Optic Nerve Head (ONH)), Optik Kupun Optik Diske Oranı (OKODO - Cup to Disc Ratio (CDR)), Nöroretinal Kenar Oranı (NKO - Nöroretinal Rim Rate (NRR)) ve Alt-Üst-Nazal-Temporal (AÜNT - Inferior-Superior-Nazal-Temporal (ISNT)) oranı gibi kavramlardır. Şekil 1.2’de bir fundus görüntüsü verilmiştir. Bu görüntü üzerinde çeşitli lezyonlar bulunmaktadır. Bu lezyonlar, retinaya bağlı diyabet hastalığını erken teşhis etmeye yarayan retina bileşenlerinden biridir. Lezyonların çeşitleri hastalığın şiddeti hakkında bilgi vermektedir. Retina içerisindeki mikroanevrizmalar (Microaneurysm - MA’lar), diyabete bağlı retina (Diabetic Rethinopathy - DR) hastalığının bilinen ilk klinik göstergesidir. MA’lar retina kılcal damarlarında genişlemelere sebep olurlar ve dairesel kırmızı noktalar olarak kendilerini gösterirler [4]. Kanamalar (Hemorrhages) aynı MA’lar gibi DR hastalığını erken haber veren retina bileşenlerinden biridir. Eğer retinanın yapısı derin ise kanamalar koyu kırmızı ve yuvarlak benekli olarak görülmektedir. Retinanın yapısı sığ ise kanamalar genellikle parlak kırmızı, çizgisel ve uzun şeritli noktalar olarak görülmektedir [5]. Sert

eksüdalar, DR hastalığının erken habercisi olan lezyonlardan biridir. Parlak renkli, daha keskin sınırları olan, sarı-beyaz nokta grupları olarak retina içinde görünürler [6]. Pamuk yünü lekesi ise yumuşak eksüdalar olarak bilinir ve normalde şeffaf görünümlü retina sinir lifi tabakasına şişmiş bir görünüm verirler.



Şekil 1.2 : Retina lezyonları.

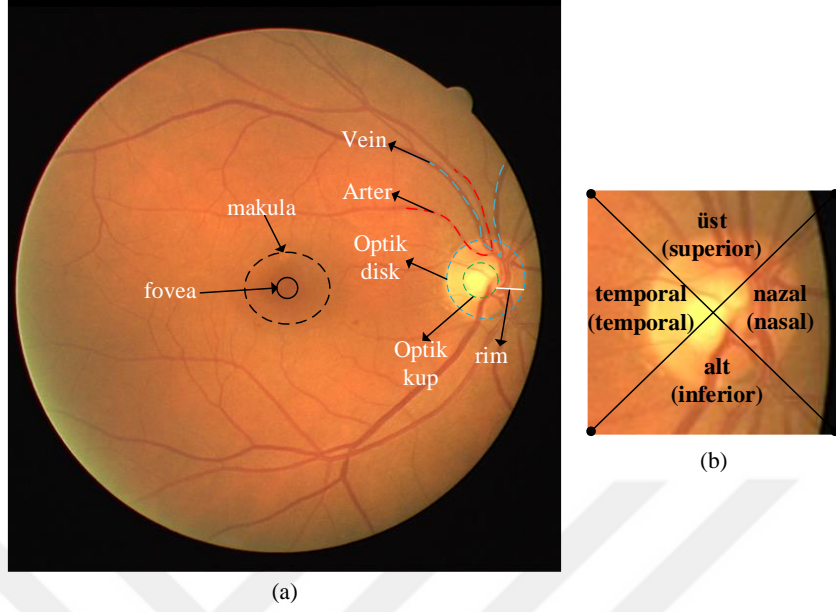
Şekil 1.3.a'da bir retinaya ait temel bileşenlerin işaretlendiği bir fundus görüntüsü verilmiştir. Bu görüntüde en popüler bileşen retina damarlarıdır. Retina damar ağ yapısının otomatik bölütlenmesi ve damarların atardamar/toplardamar (arter/vein) olarak sınıflandırılması retina görüntü uygulamalarında aktif bir araştırma alanıdır. Bu konunun popüler olma sebebi, doğru bölütlenmiş retina damarlarının birçok hastalık hakkında bilgi sağlayıcı olmasından kaynaklanmaktadır.

OD, damarların dağıldığı noktadır. OD ve OK arasındaki ilişki kullanılarak göz tansiyonu olarak bilinen glokom hastalığı hakkında yeterli bilgiye ulaşılmaktadır. OD ve OK arasındaki mesafe NKO ya da rim oranı olarak bilinmektedir. Bu oran, glokom hastalığı hakkında bilgi veren önemli bir özniteliktir.

Makula ve fovea alanı, yaşa bağlı makula dejenerasyonu başta olmak üzere retina fundus görüntü analizinde en çok kullanılan anatomik yapılardan biridir. Makula, optik diskin merkezinde bulunan ve ayrıntılı görüşten sorumlu küçük bir alandır. Fovea, makulanın merkezine konumlanmış oldukça küçük ve hassas bir noktadır. Fovea'ya yakın konumlanmış herhangi bir lezyon kalıcı görme hasarına sebep olabilir [7]. Ayrıca fovea, diğer retina temel bileşenleri gibi DR hastalığının teşhisinde kullanılan bir retina bileşenidir.


Şekil 1.3.b'de genellikle glokom hastalığında kullanılan AÜNT kavramının retina görüntüsü üzerinde gösterimi verilmiştir. AÜNT oranı, sağlıklı bir retina için sırası ile alt (Inferior-(I)), üst (Superior-(S)), nazal (Nasal-(N)) ve temporal (Temporal-(T)) bölgeler

boyunca azalan kalınlık sırasına sahip bir orandır. Bu nedenle sađlıklı bir insanda AÜNT kuralı arasındaki iliřkinin $A > Ü > N > T$ olması beklenmektedir.



Şekil 1.3 : Retina bileşenleri (a) Fundus görüntüsü, (b) AÜNT kural bölgesi.

Optik diskin etrafında bazı parlak ve karanlık pikseller vardır. Bu pikseller OD bölgesinin doğru bölütlenmesini engelleyebilmektedir. Bu piksellerin hepsi peripapiller atrofi (PPA) olarak adlandırılır [8], [9]. Şekil 1.4’de farklı PPA örnekleri verilmiştir. PPA piksellerinin artması ile OD zarar görmeye başlar ve bu durum glokom hastalığına sebep olabilir.



Şekil 1.4 : Farklı retinalara ait PPA görüntüleri (a) ve (b) [10], (c) [11].

1.2 Literatür İncelemesi

Bu tez çalışmasında, retina fundus görüntü analizinde odaklanılan iki çalışma alanından bahsedilmiştir. Bu çalışma alanları, bu bölümün alt başlıkları olarak verilmiştir.

1.2.1 Optik disk ile ilgili çalışmalar

OD ve OK üzerinden elde edilen bilgiler retina görüntü analizinde en temel bilgileri içerir. Optik diskin lokalizasyonunun bulunması, bölütlenmesi, optik kup ile arasındaki oran, rim oranı, AÜNT kuralı, damarların dağılım noktası, makula bölgesinin tahmini gibi bilgilere ulaşmada OD'in önemi büyüktür. Bu nedenle, bu alanda yapılan BDT uygulamaları teknolojik gelişmelerin ilerlemesi ile sürekli kendini yenilemektedir. Bu konu ile ilgili BDT uygulamalarının doğruluk ve sağlamlık için en iyi sonuçları bulmaya hala ihtiyacı vardır. Bu alanda yapılan çalışmalar bu tez kapsamında iki alt başlıkta incelenmiştir. İlk önce, literatürde bulunan OD lokalizasyon ve bölütleme çalışmaları incelenmiştir. Daha sonra, OD ve OK kullanarak glokom hastalığının tespit ve teşhisine yönelik yapılan BDT sistemleri incelenmiştir.

1.2.1.1 OD bölgesinin lokalizasyon tespiti ve bölütlenmesi

Yu ve diğ. OD'in lokalizasyonu ve bölütlemesini gerçekleştirmek için otomatik bir sistem önermişlerdir [12]. OD'in lokalizasyonunu belirlemek için ilk olarak CIElab renk uzayındaki görüntüye şablon eşleştirme uygulanmış ve aday OD konum bölgeleri bulunmuştur. Şablon eşleştirme ile birlikte gelen yanlış pozitif aday bölgelerini kaldırmak için yönlü bir eşleştirme filtresi kullanılmıştır. OD'i bölütlemek için ise görüntü bir ön işlemde geçirilmiştir. Burada görüntünün kırmızı kanalına ait doygunluk değerine bakılmış ve önce kan damarları daha sonra parlak bölgeler görüntüden çıkarılmıştır. Görüntünün son hali üzerinde hibrit bir seviye kümeleme yaklaşımı uygulanarak OD bölgesi bölütlenmiştir. Veri seti olarak MESSIDOR veri seti kullanılmıştır.

Dehghani ve diğ. OD bölgesinin lokalizasyonu için histogram eşleştirme tabanlı bir yöntem sunmuşlardır [13]. İlk önce, görüntülerde oluşan gürültünün etkisini azaltmak için görüntüler üzerine ortalama filtresi uygulanmıştır. Daha sonra, OD bölgesini çıkarmak için 80x80 piksel boyutunda bir pencere tasarlanmıştır. Sonraki adımda, her bir renk bileşeninin histogramını elde etmek için OD bölgesi renk bileşenlerine ayrılmıştır. Son adımda, her bir renk bileşeninin ortalama histogramı şablon olarak kullanılmış ve OD bölgesinin merkezi doğru olarak işaretlenmiştir. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Pourreza-Shahri ve diğ. fundus görüntüleri üzerinde OD bölgesini bölütlemek için Radon Dönüşümü (Radon Transform - RT) aracılığı ile parlaklık bilgisini kullanan bir yöntem önermişlerdir [14]. Yöntemde, fundus görüntüsü ilk önce alt görüntülere bölünmüştür. Her alt görüntüye RD uygulanmıştır. Fundus görüntüleri arasındaki yüksek yoğunluk farklılıkları OD'in radon uzayındaki tepe noktaları ile ilişkilendirilmiştir. Bu işlemler fundus görüntüsünün mavi kanalı üzerinde gerçekleştirilmiştir. Bir eşikten daha yüksek bir tepe değerine sahip olan tüm alt görüntüler, OD'i içeren aday noktaları olarak kabul edilmiştir. Veri seti olarak DRIVE, STARE ve MUMS-DB veri setleri kullanılmıştır.

Harangi ve diğ. OD'in otomatik tespiti için üye algoritmalarına dayalı bir yöntem önermişlerdir [15]. Yöntemde yedi farklı üye algoritması kullanılarak aday OD bölgeleri oluşturulmuştur. İlk önce, üye algoritmaları tarafından olasılık haritaları oluşturulmuştur. Ardından, doğru OD bölgesini bulmak için bu haritaların uygun bir kombinasyonu sağlanmıştır. Bu olasılık haritaları daha sonra birleştirilerek OD bölgesi bulunmuştur. Üye fonksiyonları, OD'in konumu hakkında fazla bilgi edinmek için kullanılmıştır. Veri seti olarak DIARETDB0, DIARETDB1, DRIVE ve MESSIDOR veri setleri kullanılmıştır.

Wang ve diğ. OD bölgesini otomatik bölütleyen bir yöntem önermişlerdir. Yöntemde tüm veri seti görüntüleri aynı boyuta ölçeklendirilmiştir [16]. Ardından, HSI uzayına çevrilen görüntülerin I kanalı üzerinden morfolojik kapama ve fourier korelasyon işlemleri gerçekleştirilmiştir. Buraya kadar olan süreç şablon eşleştirme sürecidir. Şablon eşleştirme yöntemi, OD merkezini yaklaşık olarak bulmak için kullanılmıştır. Daha sonra, seviye kümeleme yöntemi kullanılarak OD bölgesi bölütlenmiştir. Veri seti olarak DRIVE, DIARETDB1 ve DIARETDB0 veri setleri kullanılmıştır.

Ahmed ve diğ. OD'in merkez konumunu tespit etmek için KYM renk uzayındaki fundus görüntüsünün yeşil kanalı üzerinde aday tabanlı bir yöntem önermişlerdir [17]. Yöntemde, OD bölgesindeki piksellerin yoğunlukları ve en yüksek ortalama aday yaklaşımları kullanılmıştır. Her aday nokta için, farklı yarıçaplarda dairesel parçalar çıkarılmış ve her yarıçap için ortalama yoğunluk hesaplanmıştır. Tüm aday noktalar arasındaki ortalama yoğunluk değeri maksimum olarak hesaplanan nokta OD merkezi olarak etiketlenmiştir. Veri seti olarak DRIVE, DIARETDB0, VARIA, VICAVR ve MESSIDOR veri setleri kullanılmıştır.

Dashtbozorg ve diğ. OD bölgesini bölütlemek için kayan bant filtresine dayanan otomatik bir yöntem önermişlerdir [18]. Yöntem, ön işlem adımı ile başlatılmıştır. Ön işlem

adımında bölütlenmiş damarlar görüntüden kaldırılmış ve ardından, kayan bant filtresi uygulanmıştır. Bu filtre, alt örneklenmiş görüntüler üzerinde OD'in yaklaşık merkez konumunu elde etmek için ilk önce düşük çözünürlüklü görüntülere uygulanmıştır. Daha sonra yüksek çözünürlüklü görüntüler üzerinde uygulanmıştır. Böylece, OD bölgesi elde edilmiştir. Veri seti olarak MESSIDOR ve INSPIRE-AVR veri setleri kullanılmıştır.

Mary ve diğ. OD bölgesini bölütlemek için bir sistem tasarlamışlardır. Sistem, üç temel adımı içerir [19]. İlk adım ön işlem adıdır. İkinci adım OD konumunu belirlemek için dairesel Hough dönüşümüdür. Son adım ise OD'i bölütlemek için Gradyan vektör akış algoritmasının kullanımınıdır. OD bölgesinin bölütlenmesi için dokuz farklı Aktif Kontur Modeli (AKM - Active Contour Model (ACM)) Hough dönüşümüne uygulanmıştır. Bölütleme sonuçları ile gerçek zemin arasındaki benzerlik için Hausdorff mesafe ölçütü kullanılmıştır. Veri seti olarak RIM-ONE veri seti kullanılmıştır.

Bharkad ve diğ. OD bölgesinin otomatik bölütlenmesi için bir algoritma sunmuşlardır [20]. Önerilen yöntemde, eş dalgalı düşük geçişli sonlu dürtü yanıtı filtresi kullanılmıştır. Bu filtre, kan damarlarını bastırarak ve OD bölgesini ön plana çıkarmak için tasarlanmıştır. Filtre, en uygun parametre değerleri ile istenilen frekans yanıtına sahip olacak şekilde tasarlanmıştır. OD bölgesinin segmentasyonu, gri tonlamalı morfolojik genişleme ve medyan filtreleme işlemi kullanılarak gerçekleştirilmiştir. Önerilen algoritma DRIVE, DIRATEDB0, DIRATEDB1 ve DRIONS-DB veri setleri üzerinde test edilmiştir.

Tan ve diğ. aynı anda OD, fovea, kan damarları ve arka planı otomatik olarak ayıran 7 katmanlı bir evrişimsel sinir ağı tasarlamışlardır [21]. İlk adım olarak tüm veri seti görüntüleri normalleştirilmiştir. Bu adım, LUV renk uzayına taşıdıkları görüntülerin L kanalı üzerinde gerçekleştirilmiştir. Daha sonra normalleştirilmiş L kanalı tekrar KYM renk uzayına taşınmış ve G kanalı üzerinden işlemler yapılmıştır. İkinci adımda her biri bi-kübik enterpolasyon kullanılarak ölçeklendirilmiş üç kanaldan oluşan bir girişe sahip Evrişimsel Sinir Ağı (ESA- Convolutional Neural Network (CNN)) mimarisi tasarlanmıştır. ESA mimarisi çıktı olarak dörtlü sınıf ayrımını gerçekleştirmiştir. Veri seti olarak DRIVE veri seti kullanılmıştır.

Kamble ve diğ. tek boyutlu taranmış yoğunluk profili analizi kullanarak OD ve foveanın lokalizasyonunu tespit etmek için yeni bir yöntem geliştirmişlerdir [22]. Yöntemde, ilk önce fundus görüntüleri ön işlenmiştir. Ardından, görüntü üzerinde 19 adet tarama çizgisi oluşturulmuştur. Amaç, yatay ve dikey tarama çizgileri aracılığı ile OD'in 'x' ve 'y'

koordinatlarını bulmaktır. Bu tarama çizgileri, yoğunluk profil analizlerinden çıkarılmıştır. Yoğunluk profil analizleri yorumlanarak OD bölgesinin lokalizasyonu işaretlenmiştir. Veri seti olarak, MESSIDOR, DIARETDB0, DIARETDB1, STARE, DRIVE, HEI-MED, HRF ve ONHSD veri setleri kullanılmıştır.

Rodrigues ve diğ. OD'ı tespit etmek için matematiksel morfoloji ve dalgacık dönüşümü kullanarak yeni bir yöntem sunmuşlardır [23]. Yöntemde ayrıca, genetik algoritma ile retina damarları arter ve vein olarak bölütlenmiştir. OD tespiti için renkli fundus görüntüsünün üç kanalına histogram analizi uygulanmıştır. Histogram analizi ile seçilen kanala morfolojik beyaz üst şapka dönüşümü uygulanmıştır. Böylece görüntünün iyileştirilmesi sağlanmıştır. İyileştirilen görüntü, Haar dalgacık ayrıştırmasına gönderilmiş ve beşinci ayrıştırma seviyesinden sonra görüntü tekrar orijinal boyutuna enterpolasyon yapılmıştır. Enterpolasyonlu görüntü ikili görüntüye dönüştürülmüştür. İkili görüntü üzerinde eşikleme ile OD bölütlemesi gerçekleştirilmiştir. Veri seti olarak DRIVE veri seti kullanılmıştır.

NahidReza ve diğ. daire operatörü olarak adlandırılan bir operatör ile OD'in otomatik olarak algılanması için bir yöntem geliştirmişlerdir [24]. Fundus görüntüleri öncelikle ön işleme tabi tutulmuştur. Daha sonra ön işlenen görüntüler üzerinde OD'in yarıçapı tahmin edilmiştir. Yarıçap, görüntü çözünürlüğü ve görüntü görüş alanı kullanılarak tasarlanan matematiksel bir modelle tahmin edilmiştir. Yarıçap kullanılarak, bir operatör tasarlanmıştır. Tasarlanan çoklu yönlendirilmiş daire operatörü, görüntü varyasyonunu tahmin ederek ve maksimum/minimum varyasyon değerine dayalı olarak OD'ı algılamıştır. Veri seti olarak DIARETDB0 ve DIARETDB1 veri setleri kullanılmıştır.

Zhou ve diğ. OD ve OK alanlarını tespit etmek için yeni bir yerel istatistiksel aktif kontur modeli ve öncelikli yapı yöntemi sunmuşlardır [25]. İlk olarak, fundus görüntüleri ön işleme tabi tutulmuştur. Daha sonra ön işlenmiş görüntüler üzerinde OD bölgesinin İlgi Bölgesi (İB- Region of Interest (ROI)) seçilmiştir. Bu seçilen bölge üzerindeki yoğunluk farklılıklarının oluşturduğu olumsuz etkinin üstesinden gelmek için yerel istatistiksel aktif kontur modeli tanıtılmıştır. OD ve OK bölütlemesini birleştirmek için yapı denetimi ile birlikte yerel istatistiksel aktif kontur modeli ve öncelikli yapı modeli oluşturulmuş ve uygulanmıştır. Veri seti olarak RISHTI-GS ve RIM-ONE veri setleri kullanılmıştır.

Naqvi ve diğ. OD bölgesinin sınırlarını tanımlamak için gradyan bağımsız aktif kontür tahminini kullanan bir sistem geliştirmişlerdir [26]. Yöntem, OD'in lokalizasyonu,

homojenizasyonu ve sınır tahminini gerçekleştiren adımları içerir. OD homojenizasyonu, retina damar ağ yapısının iç boyanması ve ardından aktif kontur modeli kullanılarak gradyan bağımsız sınır tahmini ile gerçekleştirilmiştir. Sınır tahmin süreci, gradyan bilgisinden bağımsız hale getirilmiştir. Bu durum başarımın artmasına neden olmuştur. Veri seti olarak MESSIDOR, ONHSD ve DRIONS-DB veri setleri kullanılmıştır.

Thakur ve diğ. fundus görüntülerinde OD ve OK tespiti için kümeleme ve seviye kümeleme yaklaşımına dayalı hibrit bir yöntem önermişlerdir [27]. Uyarlanabilir olarak düzenlenmiş çekirdek tabanlı sezgisel bulanık-c ortalamaları kümeleme tabanlı yaklaşımı seviye kümeleme yaklaşımı ile birleştirilmiştir. Bulanık-c kullanılarak bölümlere ayrılmış bir görüntünün sınırı, seviye kümeleme yaklaşımı için başlangıç sınırı olarak ayarlanmıştır. Veri seti olarak DHRISTI, RIM-ONE ve MESSIDOR veri setleri kullanılmıştır.

Wang ve diğ. OD bölgesini tanımlamak için bir ESA mimarisi önermiştir [28]. Öncelikle OD bölgesinin lokalizasyonunu vurgulamak için fundus görüntülerinden damarlar çıkarılmış ve damarların yoğunluk haritaları oluşturulmuştur. Ardından, önerilen ağ mimarisi bu yoğunluk haritalarını bölümlere ayırmak için kullanılmıştır. Ağ mimarisi sonucunda, iki farklı OD bölütleme sonucuna ulaşılmıştır. Örtüşme stratejisi ile iki bölütleme sonucundan doğru olan sonuç seçilmiş yanlış olan sonuç dışlanmıştır. Derin öğrenme modelinin nihai aday bölgelere uygulanması, optimal OD bölgesinin tanımlanmasını sağlamıştır. Veri seti olarak DIARETDB0, DIARETDB1, DRIONS-DB, DRIVE, MESSIDOR ve ORGIA veri setleri kullanılmıştır.

Liu ve diğ. glokom hastalığının teşhisi için OD ve OK'nın bölütlemesini gerçekleştiren bir yöntem önermişlerdir [29]. Bu yöntem, yarı-denetimli koşullu Üretken Çekişmeli Ağlara (ÜÇA- Generative Adversarial Networks (GAN)) dayanmaktadır. ÜÇA mimarisi, bölütleme ağı, üretici ve ayırıştırıcı yapılardan oluşur. Bölütleme sonuçlarını daha da optimize hale getirmek için Tam Bağlı Ağlar (TBA - Fully Convolutional Network - (FCN)) kullanılmıştır. Veri seti olarak ORIGIA ve REFUGE veri setleri kullanılmıştır.

Pathan ve diğ. iki adımda OD'in bölütlemesini gerçekleştiren otomatik bir yöntem önermişlerdir [30]. İlk adımda, yönlü bir filtre uygulanmış ve kan damarı algılanmıştır. Daha sonra bu kan damarları için dışlama algoritmaları geliştirilmiştir. Bu adım OD bölütlemesini engelleyen kan damarlarından kurtulmak için uygulanmıştır. İkinci adımda, OD'in sınırlarını tespit etmek için uyarlanabilir eşik temelli bir yaklaşım benimsenmiş ve karar ağacı ile sınıflandırılmıştır. OD bölgesi için KYM renk uzayındaki fundus görüntüsünün

kırmızı kanalı üzerinde Prewitt ve Hough dönüşümleri kullanılarak daire bulma işlemi gerçekleştirilmiştir. Daire 45°'lik açılarla 0-360 derece dönderilerek ve matematiksel olarak tanımlanmış kararlar doğrultusunda eşik değeri elde edilmiştir. Nihai sonuca karar ağacı ile ulaşılmıştır. Veri seti olarak KMC ve RIM-ONE veri setleri kullanılmıştır.

Kumara ve diğ. diyabete bağlı retina hastalığının otomatik tespiti için OD ve retina kan damarlarının bölütlenmesini gerçekleştiren bir yöntem sunmuşlardır [31]. Önerilen yöntem sırası ile şu adımları içerir; renkli fundus görüntüsünün ön işlenmesi, kan damarlarının tespit edilmesi, OD bölgesinin bölütlenmesi, fovea alanının lokalizasyonu, özellik çıkarma ve sınıflandırma. Ön işlem adımı ve kan damarlarının çıkarılmasında matematiksel morfolojiden yararlanılmıştır. Optik disk bölütleme de su havzası dönüşümü kullanılmıştır. Su havzası dönüşümü, morfolojik gradyan, işaretleyici kontrollü su havzası bölütleme, erozyon tabanlı gri-ölçek görüntüsünün yeniden yapılandırılması, dilatasyona dayalı gri-ölçek görüntüsünün yeniden yapılandırılması adımlarını kapsamaktadır. Veri seti olarak DIARETDB0 ve DIARETDB1 veri setleri kullanılmıştır.

Jana ve diğ. otomatik OD tespiti ve bölütlemesi için bir yöntem önermişlerdir [32]. Önerdikleri yöntemde ilk önce fundus görüntüleri gri ölçekli görüntüye dönüştürülmüştür. Bu görüntü üzerinde gürültüleri yok etmek için ön işlem adımı uygulanmıştır. Daha sonra, OD'in kenarlarını algılamak için kenar algılama yöntemleri uygulanmıştır. Kenar algılama yönteminden sonra olası OD merkezini bulmak için Hough dönüşümü kullanılmıştır. Nihayetinde, tüm aday OD bölgeleri içerisinde en mükemmel optik disk bölgesini bulmak için denetimli bir makine öğrenme algoritması kullanılmıştır. Veri seti olarak 101 görüntülü DRISHTI-GS veri seti kullanılmıştır.

Tulsani ve diğ. OD ve OK bölütlemesini gerçekleştirerek glokom hastalığının teşhisi için yeni bir yöntem önermişlerdir [33]. Önerilen yöntem, küçük veri setine sahip medikal görüntüler için tasarlanmış bir derin öğrenme modeli olan Unet++'ın kullanılmasına dayanır. Unet++, OD ve OK'ı ayrı ayrı bölümlere ayırma görevi için tasarlanmıştır. En nihayetinde, görüntüleri glokomlu ve glokomsuz olarak sınıflandırmak için de AÜNT kuralı kullanılmıştır. Veri seti olarak, DRISHTI, ORIGA, RIM-ONE ve DRIONS-DB veri setleri kullanılmıştır.

Veena ve diğ. glokom hastalığının otomatik teşhisi için bir derin öğrenme mimarisi olan ESA modelini önermişlerdir [34]. OD ve OK bölütlenmesi için iki farklı ESA mimarisi kullanılmıştır. Öncelikle giriş görüntülerine Gauss filtresi ve görüntü normalizasyonu

uygulanarak bir ön işlem gerçekleştirilmiştir. Daha sonra, renk-doku tanımlayıcı tabanlı morfolojik yaklaşım ön işlenmiş görüntülere uygulanmıştır. Ardından, görüntüden ilgili bölgeleri çıkarmak için bölge tabanlı anlamsal bölütleme yöntemleri uygulanmıştır. Son olarak ESA mimarisi hem OD bölgesi için hem OK bölgesi için ayrı ayrı uygulanmış ve bölütleme sonucunda OKODO oranı hesaplanmıştır. Veri seti olarak, DRISHTI-GS veri seti kullanılmıştır.

Wang ve diğ. optik disk bölütlemesi yapmak için U-net mimarisine dayalı yeni bir ağ tasarımı sunmuşlardır [35]. Klasik U-net mimarisine bir alt-ağ birde kod çözme bloğu entegre edilmiştir. Alt-ağ önemli dokuların tespitini kolaylaştırmak için, kod çözme bloğu da OD alanının kontrastını iyileştirmek için kullanılmıştır. Veri seti olarak, MESSIDOR, ORIGA ve REFUGE veri setleri kullanılmıştır.

1.2.1.2 OD bölgesinden glokom hastalığının tespiti

Glokom, asemptomatik bir göz hastalığıdır. Asemptomatik; belirti göstermeyen hastalık demektir. Bu nedenle glokomun anlaşılması çok zordur ve genellikle “sessiz görüş hırsızı” olarak adlandırılır [36]. Çeşitli nedenlerin ve faktörlerin sebep olduğu glokom türleri bulunmaktadır. Glokom türlerinin hepsi için geçerli olan özellik optik sinir yapısı ve işlevinde olan değişikliklerdir [37]. Glokom hastalığı zamanla “primer açık açılı glokom” ve “açı kapanması glokom” olarak kabul edilen iki tanım altında ele alınmıştır [38]. Açık açılı glokomda kornea ve iris tabakası arasındaki açı açıktır. Açı kapanması glokomda ise kornea ve iris arasındaki açı dar veya kapalıdır. Dünya genelinde 60 milyon insan glokomun her iki türünden de etkilenmekte ve 8.4 milyon insan da glokoma bağlı görme kaybı yaşamaktadır [39]. Glokom hastalığının sinsi ilerleyişi, hekimlerin zaman alıcı mesaisi ve hastalığın tespit edilmesindeki zorluklara çözüm geliştiren çeşitli BDT sistemleri vardır. Bu tez kapsamında bu konu ile ilgili 2010’dan sonra gerçekleştirilen BDT sistemleri incelenmiştir.

Muramatsu ve diğ. OD’i analiz eden ve OKODO oranını otomatik ölçen bir yöntem önermişlerdir [40]. Yöntem, glokom belirtileri olan ve olmayan hastaların stereo görüntülerinden alınan örnekler üzerinde geliştirilmiştir. Keskin bir kenar detektörü ve aktif kontur yöntemi kullanılarak OD bölütlenmiştir. Stereo görüntülerinin eşitsizliğini gidermek için bir derinlik haritası oluşturulmuştur. Derinlik haritası üzerindeki gürültüler ortalama ve ortanca filtreler kullanılarak azaltılmıştır. Ardından, derinlik haritaları üzerinde radyal

yönlerde kenarlar aranarak OK sınırları belirlenmiştir. OD ve OK sınırları belirlendikten sonra OKODO oranı hesaplanmıştır.

Issac ve diğ. OKODO oranı, NKO alanı ve OD bölgesindeki kan damarlarından yola çıkarak glokom hastalığını teşhis edebilen bir yöntem sunmuşlardır [41]. Yöntem, görüntü işleme tabanlı olup görüntülerin kalitesine göre değişmeyen ve gürültülere karşı dayanıklı olarak modellenmiştir. KYM renk uzayındaki fundus görüntüsünün K kanalı kullanılarak OK bölgesi, Y kanalı kullanılarak OD bölgesi bölütlenmiştir. Ardından, OK ve OD bölgeleri bilindiği için orijinal fundus görüntüsünden OKODO, AÜNT ve NKO oranları öznelik olarak çıkarılmıştır. Çıkarılan öznelikler sınıflandırıcılara verilmiş ve sınıflandırma sağlanmıştır.

Panda ve diğ. glokom hastalığındaki yapısal değişikliklerin erken teşhisini sağlayan retina sinir lifi tabakası defekti tespiti yapabilen otomatik bir yöntem sunmuşlardır [42]. Öncelikle, OD bölgesindeki kan damarları bölütlenmiştir. Bölütlenen kan damarları boyanmış ve kontrast sınırlı uyarlanabilir eşikleme (KSUHE - Contrast Limited Adaptive Histogram Equazation (CLAHE)) görüntülere uygulanmıştır. Ön işlenmiş OD bölgesi etrafındaki eş merkezli dairelerden elde edilen 1-B yoğunluk profilleri dalgacık tabanlı yerel minimum analiz uygulanarak bulunmuştur. Kümülatif sıfır sayım yerel ikili model, yönlü diferansiyel enerji, Shannon ve Tsallis entropisi ile birlikte yoğunluk profilinden çıkan özelliklerle bir özellik vektörü oluşturulmuştur. Özellik vektörü retina sinir lifi tabakası defektinin sınır tespiti için rastgele orman sınıflandırıcısına verilmiştir.

Divya ve diğ. fundus görüntüleri üzerinden özellik çıkararak glokom hastalığının teşhisini yapabilen otomatik bir sistem sunmuşlardır [43]. Öncelikle renkli fundus görüntüsünün gri ölçekli görüntüsü elde edilmiş ve renkli fundus görüntüsü renk kanallarına ayrılmıştır. Daha sonra alt bant görüntülerini oluşturmak için 2-B ampirik dalgacık dönüşümü kullanılmıştır. Ayrıştırılmış bileşenler üzerinden kor-entropi çıkarılmıştır. Elde edilen özellikler arasında Student-t ve temel bileşen analizi yöntemi kullanılarak özellik seçimi gerçekleştirilmiştir. Özellikleri glokomlu veya glokomlu değil olarak sınıflandırmak için en küçük kareler destek vektör makinesi kullanılmıştır.

Soorya ve diğ. geometrik özellik tabanlı çerçeve kullanarak OD bölütlemesini gerçekleyen ve böylece glokom hastalığını teşhis edebilen bir model tasarlamışlardır [44]. OD çukurlaşmaya başladığında, OD'ten geçen kan damarları bükülmeye başlar. Yöntem, bu kan damarlarının ilk bükülme noktalarını almıştır. Daha sonra bu noktalar OK sınırını

belirlemek için birbirine bağlanmıştır. Bölütlenen OD ve OK bölgelerinin ardından OKODO oranı hesaplanmış ve fundus görüntülerinin glokom hastalığı içerip içermediği belirlenmiştir.

Al-Bander ve diğ. OD ve OK bölgelerini bölütlemek için derin öğrenme tabanlı bir yöntem önermişlerdir [45]. Yöntemde, DenseNet ağ mimarisi kullanılmıştır. Ön işlemsiz fundus görüntüleri ağa giriş olarak verilmiş ve eğitilmiştir. Daha sonra, ağın test aşamasında ağa hiç görmediği ön işlemlerle veri kümeleri verilmiş ve ilgili bölgelerin bölütlenmesi gerçekleştirilmiştir. OD ve OK bölgesinin bölütlenmesi ile OKODO oranı hesaplanmıştır. OKODO oranı glokom hastalığının teşhisinde kullanılmıştır. Veri seti olarak ORIGA, DRIONS-DB, DRISHTI-GS, ONHSD ve RIM-ONE veri setleri kullanılmıştır.

Gómez-Valverde ve diğ. glokom tespiti için farklı ESA mimarilerinin uygulamasını değerlendiren bir çalışma yapmışlardır [37]. Bu çalışmada, transfer öğrenme yöntemi ile birçok ağ mimarisinin fundus görüntüleri üzerindeki başarısı incelenmiştir. Ağları homojen bir şekilde eğitmek için tüm fundus görüntüleri ön işlenmiştir. Tüm veri setleri için optik disk merkezli ve aynı boyutta standart yamalar kullanılmıştır. Ayrıca, tüm veri girişlerinin aynı merkezli dağılıma sahip olmasını sağlamak için her kanaldaki ortalama çıkarılmıştır. Nihayetinde tüm ESA mimarileri karşılaştırılmış ve performansları değerlendirilmiştir. Veri seti olarak RIM-ONE ve DRISHTI-GS veri setleri kullanılmıştır.

Yu ve diğ. glokom tespiti için özelleştirilmiş bir U-net mimarisi ile optik disk bölütlemesi gerçekleştirmişlerdir [46]. Özelleştirilmiş U-net mimarisi, eğitilmiş ResNet-34 modelinin kodlama katmanlarının klasik U-net kod çözme katmanları ile birleştirilmesi ile elde edilmiştir. Ön işlenmiş fundus görüntüleri veri artırma yöntemleri ile çoğaltılmıştır. Daha sonra model eğitime verilen görüntülerin OD ve OK bölgeleri tespit edilmiştir. Veri seti olarak RIGA, DRISHTI-GS ve RIM-ONE veri setleri kullanılmıştır.

Claro ve diğ. retina fundus görüntü piksellerini glokomlu veya glokomlu değil olarak sınıflandırmak için özellik çıkarma yöntemlerine dayalı bir yöntem önermişlerdir [47]. Özellik çıkarma yöntemleri olarak yerel ikili doku, gri seviye eş oluşum matrisi, yönlendirilmiş gradyanların histogramı, Tamura ve gri seviye koşu uzunluk matrisi, morfoloji ve ESA mimarisi kullanılmıştır. Çıkarılan özellikler kazanç oranına göre seçilmiştir. Seçilen özellikler sınıflandırıcılara verilerek sınıflandırılmıştır. Veri seti olarak DRISHTI, RIM-ONE, HRF, JSIEC ve ACRIMA veri setleri kullanılmıştır.

Mvoulana ve diğ. retina fundus görüntüleri üzerinde OD ve OK bölütlemesi gerçekleştirerek glokom hastalığının tanısı ve teşhisi için otomatik bir yöntem önermişlerdir

[48]. Öncelikle, parlaklık kriteri ve şablon eşleştirme yöntemi kullanılarak OD bölgesi bölütlenmiştir. Ardından, doku tabanlı ve model tabanlı bir yaklaşım kullanılarak OK bölütlemesi gerçekleştirilmiştir. OD ve OK bölütlemesinin ardından OKODO oranı hesaplanmış ve glokomlu hastalar arasında bir glokom taraması yapılmıştır. Veri seti olarak DRIVE, STARE, DIARETDB0, DIARETDB1 ve ROC veri setleri kullanılmıştır.

Shoba ve diğ. glokom hastalığının teşhisi için retina arter ve vein ağlarının kan akışının ayrıntılı hesaplama modelini analiz eden bir yöntem geliştirmişlerdir [49]. Hem arter hem de vein damarlar morfolojik özellikler kullanılarak ön işlenmiştir. Ön işlenen damar yapıları Canny kenar algılama yöntemi ile bölütlenmiştir. Bölütlenen arter ve vein damarlar empedans modelleme yöntemi ile ifade edilmiştir. Damarların tasviri ve hesaplamalı akışkanlar dinamiği analizini içeren ve kanın biyomekanik parametrelerine karar vermek için sonlu eleman analizi kullanılmıştır. Parametrik değerlendirmeden sonra destek vektör makinesi ile glokom hastalığı sınıflandırılmıştır.

Elangovan ve diğ. geliştirilmiş bir Bulanık Kümeleme Yöntemi (BKY - Fuzzy Clustering Method (FCM)) algoritması ile OD ve OK bölütlemesini gerçekleştiren bir yöntem önermişlerdir [50]. Geliştirilmiş BKY algoritması morfolojik yeniden yapılandırma ve üye filtrelemeyi içeren hızlı ve sağlam bir bulanık-c algoritmasıdır. Gri-ölçekli fundus görüntülerinin gri seviye histogramı üzerinden hızlı ve sağlam bir bulanık-c algoritması kullanılarak kümeleme yapılmıştır. Kümelenen piksel gruplarından biri parlak piksellerden oluşan OD bölgesidir. OD bilgilerini içeren ikili görüntü, uygun bir eşik ile bölütlere ayrılmıştır. Bölütlenmiş OD bölgesinden glokom hastalığının erken teşhisi için OKODO oranı hesaplanmıştır. Veri seti olarak RIM-ONE ve DRIONS-DB veri setleri kullanılmıştır.

Martins ve diğ. glokom tanısı koyabilen ve mobil cihazlarda çevrim dışı çalışabilen bir yöntem önermişlerdir [51]. Bölütleme ve sınıflandırma aşamaları için ESA mimarileri kullanılmıştır. Yeni önerdikleri bir ESA modeli ile bölütleme gerçekleştirilmiştir. Bu ağlar glokom güven düzeyi verebilen bir boru hattı oluşturmak için kullanılmıştır. OKODO oranı ve dikey OKODO oranı temel alınarak OK/OD oranı ve sistemin zaman/mekân karmaşıklığı hesaplanmıştır. Veri seti olarak ORIGA, DRISHTI-GS ve RIM-ONE veri setleri kullanılmıştır.

Bisneto ve diğ. ÜÇA algoritması aracılığıyla glokom hastalığının teşhisi üzerine bir yöntem geliştirmişlerdir [52]. Yöntemde, OD bölgesinin bölütlenmesi için üretici çekişmeli ağın eğitimi gerçekleştirilmiştir. Ardından görüntüler son işlem sürecine tabi tutulmuştur.

Bu aşamada bölütlenmiş OD bölgesindeki delikler doldurulmuş ve kontrast iyileştirme yapılmıştır. Daha sonra, taksonomik çeşitlilik indeksi kullanılarak OD bölgesine ait doku özelliklerinin çıkarılması sağlanmıştır. Sınıflandırıcı olarak WEKA programı kullanılmış olup sonuçlar burada doğrulanmıştır. Veri seti olarak, Drishti-GS ve RIM-ONE veri setleri kullanılmıştır.

Pruthi ve diğ. ateşböceği sürü optimizasyon algoritmasını sunmuşlardır [53]. Bu algoritma, retina fundus görüntülerinde OD'in otomatik algılanmasına yardımcı olmak için tasarlanmıştır. OK pikselleri OD bölgesindeki en parlak pikseller olduğu için tüm ışık solucanları en parlak bölge olan OK bölgesine hareket etmiştir. Bu yöntem çeşitli birçok optimizasyon algoritmasında test edilmiştir. Veri seti olarak, RIM-ONE, DRIVE, DIARETDB1, STARE ve DRIONS-DB veri setleri kullanılmıştır.

Nayak ve diğ. glokom hastalığını otomatik tespit edebilmek için evrimsel evrişim ağını kullanmışlardır [54]. Bu ağ özellik çıkarım işlemi için tasarlanmıştır. Ağ katmanlarındaki ağırlıkları iyileştirmek için gerçek kodlu genetik algoritma kullanılmıştır. Ağ mimarisi, sınıflar arası mesafeyi maksimumda tutan ve sınıf içi varyansı minimum düzeye indiren bir ölçüt kullanılarak eğitilmiştir. Nihai özellikler, farklı birçok sınıflandırıcı ile sınıflandırılmış ve sistemin başarısı kanıtlanmıştır.

Mrad ve diğ. glokom hastalığını tespit edebilen bir sistem önermişlerdir [2]. Retina görüntüsü olarak akıllı telefonda yakalanan fundus görüntüleri kullanılmıştır. İB bölgesi fundus görüntülerinden seçilmiş ve görüntüler KSUHE yöntemi ile ön işlenmiştir. Ön işlenmiş İB görüntülerinden kan damarları çıkarılmıştır. Bu aşamada morfolojik işlemlerden faydalanılmıştır. Daha sonra OD bölgesinin lokalizasyonu belirlenmiştir. Ardından OD bölgesinden NKO ve AÜNT kuralı kullanılarak özellik çıkarılmış ve destek vektör makineleri ile sınıflandırılmıştır. Veri seti olarak DRISHTI-DB ve DRIONS-DB veri setleri kullanılmıştır.

Birçok çalışma incelendiğinde fundus görüntüleri üzerinde OD ve OK bölgelerinin tespitinde yaşanan bazı zorlukların olduğu görülmektedir. Bu zorluklar veri seti çeşitliliği, veri doğrulama azlığı, OD ve OK bölgelerinin değişen parlaklık özelliği, fundus görüntülerinin düşük kalitesi, veri aydınlatma sorunları gibi zorluklardır. Bu zorlu durumlar standart bir algılama yönteminin olmasını zorlaştırmaktadır. Bu nedenle, bu alanda yapılan çalışmalar hala popülerliğini korumaktadır.

1.2.2 Retina damar ağ yapısı ile ilgili çalışmalar

Retina fundus görüntüleri damar ağ yapısı ile kaplanmış görüntülerdir. Damarlar çeşitlerine göre atardamar (arter) ve toplardamar (vein) olarak, anatomik yapılarına göre kılcal ve kalın damarlar olarak kategorize edilebilir. Retina kan damarlarında oluşan farklılıklar göz ve göz dışı birçok hastalığın varlığını işaret eden retina kan damar bozukluklarıdır. Kan damarlarının yapısı bozularak retina üzerinde istenmeyen damarlar oluşturur ve ilerleyen süreçte göz içi kanamaları meydana gelir. Bu retina kan damarı bozukluğu DR hastalığının habercisidir. Yüksek kan basıncının retina damarlarında oluşturduğu bozukluk ise hipertansif retinopati hastalığının habercisidir. Bu hastalıkların dışında retina vein oklüzyonu, merkezi retina arter oklüzyonu gibi retina damar ağ yapısının habercisi olduğu başka hastalıklarda bulunmaktadır. Bu hastalıkların tanı ve teşhisi için geliştirilen BDT sistemler bu tez kapsamında iki alt başlıkta incelenmiştir. Bu başlıklardan ilkinde retina damar ağ yapısının bölütlenmesi üzerine yapılan BDT sistemleri incelenmiştir. İkinci olarak da arter/vein damar ayırımı üzerine gerçekleşen BDT sistemleri incelenmiştir.

1.2.2.1 Retina damar ağ yapısının bölütlenmesi

Lupaşcu ve diğ. retina damarlarını bölütlemek için bir yöntem önermişlerdir [55]. Bu yöntemde damar ve damar olmayan pikseller için 41-B özellik vektörü oluşturulmuştur. Özellikler, Gauss ölçek uzayında bölge ve sınırla ilgili olarak 24 özellik, Frangi damarlarından 2 özellik, Lindeberg çıkıntısından 3 özellik, Staal çıkıntılarında 1 özellik, model tabanlı damar olasılığında 1 özellik, Gabor dalgacık dönüşümünden 1 özellik, yoğunluk tabanlı damar olasılığında 1 özellik ve ikinci dereceden algılayıcılardan 8 özelliştir. Özellik vektörü AdaBoost sınıflandırıcı ile eğitilmiş ve daha önce sınıflandırıcıya hiç verilmeyen görüntüler üzerinde test işlemi gerçekleştirilmiştir. Özellik tabanlı AdaBoost sınıflandırıcısının deneysel sonuçları DRIVE veri seti üzerinden elde edilmiştir.

Zhang ve diğ. retina damarlarını doğru bir şekilde elde etmek için Eşleşen Filtre (EF - Match Filter (MF)) tabanlı bir yöntem geliştirmişlerdir [56]. Geliştirdikleri yöntem, orijinal EF ve Gauss'un birinci dereceden türevinden oluşur. Bu yöntem ile bir eşikleme şeması kullanılmış ve bu eşik retina görüntüsünün EF'ye verdiği yanıtı uygulanmıştır. Burada eşik seviyesi, görüntünün gausunun birinci dereceden türev yanıtı ile ayarlanmıştır. Veri seti olarak STARE ve DRIVE veri setleri kullanılmıştır.

Vlachos ve diğ. retina damar ağ yapısını bölütlemek için bir yöntem önermişlerdir [57]. İlk önce, retina görüntüsünün parlaklık ve kontrast değişkenliği dengelenmiştir.

Ardından, başlangıç damar adaylarından en uygun pikseller seçilmiştir. Aday damarlardan başlayarak çizgi izleme süreci başlatılmıştır. Bu süreç, küçük bir piksel grubu ile başlayıp kesit profil koşulu geçersiz hale geldiğinde sona erdirilmiştir. Her piksel için çok ölçekli bir güven tahmini oluşturulmuştur. Çok ölçekli görüntü haritası, damar benzeri yapıların ve parlaklık değişimlerinin algılanmasını önleyerek damar algılamayı kolaylaştırmıştır. Nihayetinde, harita niceleme ve medyan filtreleme, gürültü hatlarının bağlantısını keserek, köprüler ve güven dizisinin doğruluğunu arttırmıştır. Son olarak, morfolojik son işleme adımı ile kalan aykırı değerler kaldırılmıştır. Veri seti olarak DRIVE veri seti kullanılmıştır.

You ve diğ. retina damar ağ yapısını bölütlemek için radyal projeksiyon temelli bir yöntem sunmuşlardır [58]. Öncelikle, retina kan damar görüntülerinin yeşil kanalı alınmış ve bu kanalın tersi kullanılmıştır. Ardından, yeşil kanalın tersi ön işlemde geçirilmiştir. Radyal projeksiyon ile dar damarları içeren damar merkez çizgilerinin lokalizasyonu tespit edilmiştir. Aynı zamanda yarı-denetimli bir yöntemle damarların ana yapıları çıkarılmıştır. Nihayetinde hem radyal projeksiyon ile elde edilen sonuçlar hem yarı-denetimli yöntemle elde edilen sonuçlar birleştirilmiş ve damar bölütleme gerçekleştirilmiştir. Yöntem, DRIVE ve STARE veri setleri üzerinde test edilmiştir.

Bankhead ve diğ. izotropik kırılmamış dalgacık dönüşümü kullanmış ve fundus görüntülerinden kan damarlarını çıkarmışlardır [59]. Bu yöntem de eşik değerini değil dalgacık seviyesinin seçimini değiştirmiş ve kan damarlarını elde etmişlerdir. Elde edilen kan damarlarının dallanma noktaları, bitiş noktaları ve merkez çizgileri belirlenmiştir. Spline uydurma yöntemi ile merkez çizgilerini iyileştirmişlerdir. Bu adımdan sonra, her damarın yoğunluk profilini çıkarmış ve damar kenarlarını belirlemişlerdir. Yöntem, REVIEW ve DRIVE veri setleri üzerinde test edilmiştir.

Fraz ve diğ. fundus görüntüleri üzerinde retina kan damarlarının otomatik bölütlemesini sağlayan bir yöntem önermişlerdir [60]. Önerdikleri yöntemde, morfolojik bit düzlem dilimleme tekniklerini kullanmışlardır. Öncelikle, dört farklı yönde bir Gauss filtresi tasarlanmış. Bu filtrenin birinci türevi kullanılarak damar merkez çizgileri çıkarılmıştır. Retina damarlarının şekil ve oryantasyon haritası, morfolojik olarak damarı geliştirilmiş bir görüntünün bit düzlemlerinin dilimlenmesiyle elde edilmiştir. Geliştirilmiş damar görüntüsü, 21 piksel uzunluğunda 22.5 derecelik açılarla 8 yönde tasarlanan yapısal elementin Üst Şapka (ÜŞ - TopHat (TH)) ve Alt Şapka (AŞ - BotHat (BH)) dönüşümleri sonucunda elde edilmiştir. Bu görüntünün farklı bit düzlemindeki görüntüleri ile damar ağacı elde edilmiştir. Veri seti olarak DRIVE, STARE ve MESSIDOR veri setleri kullanılmıştır.

Nguyen ve diğ. retina kan damarlarını otomatik bölütleyen bir yöntem önermişlerdir [61]. Önerdikleri yöntemde bir hat detektörü tasarlamışlardır. Tasarlanan hat detektörü retina fundus görüntüsünün yeşil kanalının tersi üzerinde çalıştırılmıştır. Bu detektör, $W \times W$ piksel boyutunda bir pencerenin 12 farklı yönde ortalama gri seviyesi olarak hesaplanmıştır. Farklı hat çizgisinden maksimum değere sahip olan çizgi hat detektörü olarak seçilmiştir. Veri seti olarak DRIVE, STARE ve REVIEW veri setleri kullanılmıştır.

Fathi ve diğ. retina kan damarlarının çıkarılması için karmaşık sürekli dalgacık dönüşümüne dayalı yeni bir yöntem önermişlerdir [62]. Öncelikle, retina fundus görüntüleri üzerinde ön işlem gerçekleştirilmiştir. Ön işlem adımında kontrast iyileştirme ve bölge büyütme işlemleri yapılmıştır. Tüm ön işlem adımları yeşil kanalın tersi üzerinde gerçekleştirilmiştir. Ardından, karmaşık sürekli dalgacık dönüşümü kullanılarak damar iyileştirme süreci başlatılmıştır. Nihai damar ağına, uyarlanabilir histogram tabanlı eşikleme işlemi ile uzunluk filtreleme yönteminin birleştirilmesi ile ulaşılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Wang ve diğ. retina fundus görüntüleri üzerinde damarları bölütleyen kapsamlı bir yöntem önermişlerdir [63]. Önerdikleri yöntem ön işlem ve eğitim aşamalarından bağımsız olarak inşa edilmiştir. Yöntem, çok dalgacıklı çekirdekler ile uyumlu filtreleme kullanılarak tasarlanmıştır. Ayrıca, damar lokalizasyonu ve gürültü yok etme işlemleri çok ölçekli hiyerarşik bir ayrıştırma yöntemi ile sağlanmıştır. Bu yöntem, çok dalgacıklı çekirdekler işleminin ardına uygulanmıştır. Nihai adımda, yerel olarak uyarlanabilir eşikleme yöntemi ile ikili damar görüntüleri elde edilmiştir. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Fraz ve diğ. retina damar çapını ölçmek için otomatik bir yöntem sunmuşlardır [64]. Çap ölçümünü gerçekleştirebilmek için retina damar olasılık haritası elde edilmiştir. Elde edilen damar olasılık haritasından merkez çizgileri çıkarılmıştır. Damarın dallanma noktaları ve çapraz geçişleri komşuluk ilişkilerine göre belirlenmiş ve merkez çizgisi görüntüsünden kaldırılmıştır. Böylece damar bölütlerini içeren bir görüntü oluşturulmuştur. Bölütlenmiş görüntüden damarların büyüme yönüne ulaşılmıştır. Kullanılan veri setinde damar ölçülerini belirlemek için manuel bir araç kullanılmış ve bu ölçütler kıyaslama için kullanılmıştır. Veri seti olarak CHASE_DB1 veri seti kullanılmıştır.

Nayebifar ve diğ. retina kan damarlarını tespit ve takip etmek için parçacık filtrelemeye dayalı bir yöntem sunmuşlardır [65]. Bu yöntemde, KYM renk uzayındaki

retina fundus görüntülerinin yeşil kanalı ile mavi kanalı birbiri ile matrissel olarak çarpılmıştır. Ardından, bu işlemin sonucuna medyan filtresi uygulanmıştır. Filtreleme sonucu, olasılık yoğunluk fonksiyonu olarak kullanılmıştır. Daha sonra, OD bölgesindeki başlangıç damar pikselleri tespit edilmiş ve OD lokalizasyonu belirlenmiştir. Bundan sonraki aşamada damar izleme süreci başlatılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Akram ve diğ. retinada istenmeyen damarların oluşumunu tespit eden bir sistem önermişlerdir [66]. Bu sistemde, DR hastalığının ileri evresinde ortaya çıkan kan damarları (neovaskülarizasyon) tespit edilmeye çalışılmıştır. Öncelikle, kullanılan hastalıklı fundus görüntüleri bir ön işlem sürecinden geçirilmiştir. Daha sonra, ön işlenmiş görüntüler üzerinde optik disk lokalizasyonunu gerçekleştirilmiştir. Son olarak dalgacık tabanlı damar iyileştirme ve çok ölçekli eşikleme kullanılarak damar bölütlemesi sağlanmıştır. Normal ve anormal damarların sınıflandırılması için ayrıntılı bir özellik vektörü oluşturulmuştur. Bu özellik vektörü bir sınıflandırıcı ile sınıflandırılmıştır. Veri seti olarak DRIVE, STARE, MESSIDOR ve DIARETDB veri setleri kullanılmıştır.

Li ve diğ. retina damarlarını izlemek için olasılık temelli bir yöntem önermişlerdir [67]. Yöntemde, OD bölgesi temel bileşen analizi yöntemi ile tespit edilmiş ve daha sonra damarlar bölütlenmiştir. Damarları bölütlemek için, gauss filtresi ve yoğunluk-gradyan eş-oluşum matrisi yöntemleri kullanılmıştır. Her bölütlenen damar Bayes teorisi kullanarak takip edilmiştir. Normal damar, çapraz damar ve dallanan damarlar üzerinde sistem ele alınmıştır. Veri seti olarak REVIEW veri seti kullanılmıştır.

Zhao ve diğ. retina damarlarını bölütlemek için seviye kümeleme ve bölge büyütme yaklaşımı tabanlı bir yöntem önermişlerdir [68]. Önerdikleri yöntemde, retina görüntüleri bir ön işleminden geçirilmiştir. Ön işlem sürecinde, KSUHE ve 2-B Gabor dalgacıkları kullanılmıştır. Ön işlenmiş görüntü üzerine damar sınırlarını belirginleştirmek için anizotropik difüzyon filtresi uygulanmıştır. Ardından, retina damarlarını tamamen görüntüden çıkarmak için bölge büyütme ve seviye kümeleme yaklaşımı tabanlı bir AKM yöntemi uygulanmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Franklin ve diğ. sınır ağı kullanarak retina damarlarını bölütleyen bir yöntem önermişlerdir [69]. Önerdikleri yöntemde ilk olarak renkli fundus görüntülerinin ortalamaları hesaplanmış ve gri seviye görüntülere dönüştürülmüştür. Dönüştürme işleminde, renk piksellerinin parlaklık bilgileri korunmuş fakat ton ve doygunluk bilgileri

yok edilmiştir. Dönüştürülmüş görüntüleri Gauss filtresi uygulanmış ve görüntüler düzleştirilmiştir. Ardından, Gabor filtreleme yapılmış ve elde edilen Gabor katsayılarına göre orijinal görüntüler konvüle edilmiştir. Konvüle edilmiş görüntüler üzerinde moment değişmezlikleri kullanılarak damar ve damar olmayan bölgelerden özellikler alınmıştır. Bu özellikler çok katmanlı bir algılayıcı sinir ağına girdi olarak verilmiştir. Veri seti olarak DRIVE veri seti kullanılmıştır.

Franklin ve diğ. retina fundus görüntülerinde damarları bölütlemek için otomatik bir yöntem önermişlerdir [70]. Önerdikleri yöntemde, öncelikle görüntüler ön işlem aşamasından geçirilmiştir. Ön işlem aşamasında renkli fundus görüntüsünün arka planı aritmetik ortalama çekirdek filtresi yoluyla tahmin edilmiş ve renkli görüntü normalleştirilmiştir. Normalleştirilen renkli görüntü gri ölçekli görüntüye dönüştürülmüştür. Gri ölçekli görüntünün parlaklık bilgileri korunmuş renk ve ton bilgileri ortadan kaldırılmıştır. Daha sonra bu gri ölçekli görüntü tekrar KYM renk alanına dönüştürülmüştür. Dönüştürülmüş KYM görüntüleri üzerinde KSUHE kullanılmıştır. Böylece görüntünün kontrastı artırılmıştır. Bu görüntüler çok katmanlı algılayıcı sinir ağı için girdi olarak verilmiş ve retina damarları bölütlenmiştir. Veri seti olarak DRIVE veri seti kullanılmıştır.

Yu ve diğ. retina görüntülerinde damarları çıkarmak için yeni bir yöntem sunmuşlardır [71]. Sunulan yöntemde ilk olarak hareket kontrast yöntemi uygulanmıştır. Bu yöntemde amaç, kan bileşenlerinin hareketini izlemek ve ana damar sınırlarını elde etmek olmuştur. Daha sonra, damar kenarlarını tam olarak vurgulamak için EF kullanılmıştır. Ortaya çıkan görüntüde uzun ve istenmeyen görüntü parçalarını ortadan kaldırmak için köşe/kenar detektörü kullanılmıştır. En son adımda, matematiksel bir morfoloji yöntemi ile damarların tam sınırına ulaşılmış ve gürültüler ortadan kaldırılmıştır. Önerilen yöntemin değerlendirilmesi için kullanılan görüntü seti 89 görüntüden oluşan özel bir veri setidir.

Sigurðsson ve diğ. renkli retina fundus görüntülerinde kan damarlarını çıkarmak için bir yöntem önermişlerdir [72]. Önerdikleri yöntem öznelik vektörüne dayalı denetimsiz bir yöntemdir. Öncelikle, renkli retina görüntüleri histogram eşitleme ve gürültü azaltma işlemlerinden geçirilmiş ve görüntü kalitesi artırılmıştır. Daha sonra, ön işlenmiş görüntüler üzerinde öznelik çıkarımı yapılmıştır. Öznelik çıkarımını lokal minimum tespiti ve kenar tespiti ile sağlanmıştır. Damarların özellikleri, yol açıklığı olarak bilinen ileri morfolojik filtreler ile çıkarılmıştır. Bu öznelikler, bulanık küme teorisine dayalı bir veri birleştirme görevini gerçekleştirmek için kullanılmış ve nihayetinde bir damar olasılık haritası oluşturulmuştur. Veri seti olarak DRIVE veri seti kullanılmıştır.

Zhang ve diğ. retina kan damarlarını izlemek için Bayes teorisine dayalı bir yöntem önermişlerdir [73]. Öncelikle OD bölgesindeki pikseller, temel bileşen analizi yöntemi kullanılarak bulunmuştur. Bulunan bu pikselleri damar izleme yöntemi için başlangıç noktası olarak seçilmiştir. Damarlar, normal, dallanan ve çapraz damar yapılarına göre üç türde incelenerek izlenmiştir. Her izleme adımında, damar kenarları için aday noktaları seçmek üzere bir istatistiksel örnekleme şeması kullanılmıştır. Damar yapısını belirlemek ve aday damar piksellerinden kenar noktalarını çıkarmak için de maksimum posterior kriterine sahip bir Bayes yöntemi uygulanmıştır. Damar izleme sürecinde hem enine kesit hem de boyuna yön boyunca damar yoğunluk profillerinin özellikleri dikkate alınmıştır. Veri seti olarak REVIEW veri seti kullanılmıştır.

Chen ve diğ. retina kan damarlarını bölütleyen bir yöntem ve yeni bir görüntü kayıt yöntemi önermişlerdir [74]. Önerdikleri yöntemde retina damarlarını bölütlemek için ana çatallanma noktası tespit edilmiştir. Bu çatallanma noktası ve ona bağlantılı üç komşudan oluşan çatallanma yapısını eşleştirme kullanılarak damarların bölütlenmesi sağlanmıştır. Görüntü kaydetme kısmında, farklı genişlik, yön ve yoğunluk bilgisine sahip retina damar ağacından vasküler bir ağaç üretilmesi amaçlanmıştır. Bunun için 1 piksel genişliğinde ve tam bağlantılı dallara sahip global grafik tabanlı karar kullanılmıştır. Bu karar, çok ölçekli çıkıntı detektörleri kullanılarak gerçekleştirilmiştir. Veri seti olarak DRIVE veri seti kullanılmıştır.

Wang ve diğ. ESA ve rastgele orman sınıflandırıcısına dayanan bir yöntem geliştirmiş ve retina kan damarlarını bölütlemişlerdir [75]. Önerdikleri yöntem, temelde hiyerarşik öznitelik çıkarma ve topluluk sınıflandırması adımlarından oluşturulmuştur. Retina görüntülerinden çıkarılan öznitelikler, ESA mimarisinin ara çıktılarından elde edilmiş ve böylece retinanın geometrik yapısına ait bilgiler kullanılmıştır. ESA katmanında öğrenilen öznitelikler rastgele orman sınıflandırıcısında beslenmiştir. Bu sınıflandırıcının tahminlerini birleştirmek için 'kazanan hepsini alır' yaklaşımı benimsenmiştir. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Zhang ve diğ. retina görüntülerinde damar ve damar olmayan pikselleri sınıflandırmak için bir yöntem önermişlerdir [76]. Önerdikleri yöntem texton sözlüğü yöntemine dayanmaktadır. Çok ölçekli bir gabor filtre bankası ile önemli damar özelliklerini temsil eden kilit noktaları çıkarılmıştır. İlk olarak bir doğrulama seti kullanılmış ve bu kilit noktaları belirlenmiştir. Ardından, başka bir eğitim setinde texon sözlüğü oluşturan bir K-ortalama kümeleme algoritması bu noktalardan başlangıç noktalarını türetmiştir. Bu

yöntemde, textonlara dolaylı olarak damar veya damar olmayan etiketler atanmıştır. Veri seti olarak DRIVE veri seti kullanılmıştır.

Lázár ve diğ. yeni bir retina damar bölütleme yöntemi sunmuşlardır [77]. Bu yöntemde bir pikselin yönlü yanıtları bir vektör olarak kabul edilmiştir. Komşu piksellerin yanıt vektörü benzerliği ve histeresiz eşikleme şemasını kullanarak bölge büyütme yaklaşımı oluşturulmuştur. Bu yaklaşımı oluşturabilmek için yanıt vektörlerinin istatistiksel ölçümlerinin olduğu bir skor haritası oluşturulmuştur. Ayrıca, OD sınırında meydana gelen parlak yoğunluk geçişlerine duyarsız olan modifiye edilmiş çok ölçekli uyumlu bir filtreleme tekniği de önerilmiştir. Veri seti olarak DRIVE, STARE ve HRF veri setleri kullanılmıştır.

Imani ve diğ. retina kan damarlarını bölütlemek için morfolojik bileşen analizini kullanan yeni bir yöntem önermişlerdir [78]. Önerdikleri yöntemin genel amacı retina lezyonlarının damar pikselleri olarak algılanmasının önüne geçmektir. Morfolojik bileşen analizi algoritması bu amaca hizmet etmesi için tasarlanmıştır. Yöntem, üç temel adımda inşa edilmiştir. Bu adımların ilki ön işlem adıdır. Ön işlem adımında renkli retina görüntülerinin yeşil kanalı üzerinde parlaklık iyileştirme yapılmış ve istenmeyen koyu arka plan görüntüden kaldırılmıştır. Ardından, morfolojik bileşen analizi algoritması ön işlenmiş görüntüler üzerinde uygulanmış ve lezyonlar damarlardan ayrılmıştır. Son adımda morlet dalgacık dönüşümü kullanılmış ve retina kan damarları güçlendirilmiştir. Nihai damar ağına ise uyarlamalı eşikleme yapılarak ulaşılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Fraz ve diğ. verimli retinal görüntü analiz metodu geliştirmek için QUARTZ sistemini sunmuşlardır [79]. QUARTZ sistemi, damar bölütleme, damar genişliğinin ölçümü, damar merkez çizgisi tespiti, yerel damar oryantasyonu, damar kıvrım ölçümü, arter/vein ayrımı ve OD lokalizasyonu gibi retinaya ait nicel ölçümleri yapan modüllerden inşa edilmiştir. Bu sistem için bir ara yüz tasarlanmış ve kullanıcıların hizmetine sunulmuştur. Oluşturdukları bu sistemde damar bölütleme yöntemi olarak çok ölçekli çizgi detektörü ve histerezis morfolojik yeniden yapılandırmaya dayalı denetimsiz bir damar bölütleme algoritması uygulanmıştır. Veri seti olarak DRIVE, STARE, CHASE_DB1, INSPIRE-AVR ve DIARETDB1 veri setleri kullanılmıştır.

Vega ve diğ. dendritik işleme ile lattice sinir ağı kullanarak retina kan damar bölütleme yöntemleri için bir rapor sistemi önermişlerdir [80]. Önerdikleri sistem de görüntüler bir ön işlem sürecinden geçirilmiştir. Ön işlem aşamasında, merkezi ışık refleksi

kaldırılmış ve görüntüler normalize edilmiştir. Normalize edilen retina görüntülerinde kan damarları belirgin hale getirilmiştir. Bu görüntülerden piksel tabanlı 7-B bir özellik vektörü oluşturulmuştur. Özellik çıkarım işlemi, gri seviyeler ve moment değişmezlikleri kullanılarak yapılmıştır. Çıkarılan özellikler, dendritik işleme ile lattice sinir ağı yöntemi ile sınıflandırılmıştır. Son olarak damar pikseli olarak yanlış işaretlenmiş pikseller son işlem adımından geçirilmiştir. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Azzopardi ve diğ. retina görüntülerinden kan damar ağını çıkarmak için COSTFIRE yaklaşımına dayalı B-COSTFIRE yöntemini sunmuşlardır [81]. B-COSTFIRE filtresini görüntüler üzerinde uygulamadan önce retina kan damarlarının kontrastı artırılmış ve retinanın görüş alanı yumuşatılmıştır. Ön işlenmiş görüntülerde yoğunluk değişimini algılamak için Gauss farkı filtresi kullanılmıştır. Önerilen B-COSTFIRE filtresi, Gauss farkı filtrelerinin tepkilerini girdi olarak alacak şekilde tasarlanmıştır. Bu filtre, Gauss farkı filtrelerinin yüksek tepkilerinin ağırlıklı geometrik ortalaması ve çarpımı olarak hesaplanmıştır. Filtre sonucunda bölütlenen retina damarları gerçek zemin görüntüleri ile karşılaştırılmıştır. Veri seti olarak DRIVE, STRARE ve CHASE_DB1 veri setleri kullanılmıştır.

Singh ve diğ. retina kan damarlarını bölütlemek için Gumbel olasılık dağılım fonksiyonu tabanlı bir uyum süzgeci kullanmışlardır [82]. Öncelikle, retina kan damar görüntüleri bir ön işlemde geçirilmiştir. Ön işlem aşamasında, retina kan damar görüntüleri temel bileşen analizi tabanlı bir gri tonlama görüntülerine dönüştürülmüştür. Ardından, KSUHE yöntemi uygulanmış ve gri seviye görüntülerin kontrastı iyileştirilmiştir. Ön işlenmiş görüntüler üzerine Gumbel olasılık dağılım fonksiyonu tabanlı uyum süzgeci uygulanmıştır. Elde edilen görüntüler daha sonra entropi tabanlı optimal eşikleme yönteminden geçirilmiştir. Son adımda aykırı değerler ortadan kaldırılmış ve retina kan damarları bölütlenmiştir. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

GeethaRamani ve diğ. retina kan damarlarını bölütlemek için sıralı bir yöntem önermişlerdir [83]. Bu yöntemde, ilk önce retina kan damarları ön işlem sürecinden geçirilmiştir. Ön işlem süreci, görüntünün kırılması, farklı renk uzaylarına dönüşüm, renk uzaylarından renk kanalı seçme, kontrast iyileştirme, farklı dalga boylarında Gabor filtreleme ve yarım dalga düzeltme işlemlerinin sırası ile uygulanması ile oluşturulmuştur. Daha sonra ön işlenmiş görüntülerden 13-B bir özellik vektörü elde edilmiştir. Bu özelliklerin 1 tanesi yeşil kanal yoğunluğundan elde edilmiş geri kalan 12 özellik Gabor yanıtlarından çıkarılmıştır. Piksellerin damar ya da damar değil olarak sınıflandırılması için

K-ortalama kümeleme yöntemi kullanılmıştır. Nihayetinde retina kan damarları bölütlenmiştir. Son olarak bölütlenmiş görüntülerde istenmeyen yanlış pikseller bir son işlem aşamasından geçirilmiştir ve görüntüden kaldırılmıştır. Veri seti olarak DRIVE veri seti kullanılmıştır.

Christodoulidis ve diğ. retina kan damar ağındaki en küçük damarları bölütlemek için hibrit bir yöntem önermişlerdir [84]. Öncelikle, retina fundus görüntülerinin yeşil kanalı çift ağaçlı karmaşık dalgacık dönüşümünden geçirilerek ön işlenmiştir. Ön işlenmiş görüntüler, çok ölçekli hat detektöründen geçirilmiştir. Ardından, büyük ve orta büyüklükteki damarları ortaya çıkarmak için uyarlamalı eşikleme yöntemi kullanılmıştır. Daha sonra, en küçük damarları belirlemek ve bağlantısı kopmuş damarları birleştirmek için bölütlenmiş görüntüye çok ölçekli tensör oylama çerçevesi yöntemi uygulanmıştır. Bu yöntem, bağlantısı kopmuş damarların değişken mesafelerde yeniden bağlanmasını sağlamıştır. Son işlem adımı ile nihai retina damar ağına ulaşılmıştır.

Sil Kar ve diğ. retina kan damarlarını çıkarmak için yeni bir yöntem önermişlerdir [85]. İlk önce, renkli retina görüntülerinin yeşil kanalı üzerinde merkezi ışık refleksi kaldırılmıştır. Ardından, görüntülerdeki gürültüleri gidermek için eğri dönüşümü kullanılmıştır. Gürültüleri giderilmiş görüntü üzerinde kenar iyileştirme yapılmıştır. Aynı zamanda kurvelet dönüşümün tersi üzerine optimize edilmiş sıralı ayarlanabilir bir yaklaşım uygulanmıştır. İyileştirilmiş kenar görüntüleri ile bu yaklaşım birleştirilmiş ve sonuç görüntüsünden OD kaldırılmıştır. Daha sonra, bir uyum süzgeci ve bulanık entropisi yardımı ile retina kan damarları bölütlenmiştir. Veri seti olarak DRIVE, STARE ve DIARETB1 veri setleri kullanılmıştır.

Kovács ve diğ. retina kan damarlarını çıkarmak için şablon eşleştirme ve sınır yeniden yapılandırmasına dayalı yeni bir yöntem önermişlerdir [86]. Önerdikleri yöntem temelde dört adım üzerine inşa edilmiştir. İlk olarak, tüm işlemlerin İB bölgesinde olması için bir ön işlem prosedürü geliştirilmiştir. İkinci olarak, damar piksellerini oldukça hassas bölütlemek için şablon eşleştirme ve birleştirme süreci tasarlanmıştır. Şablon eşleştirme adımı, damarların merkez çizgilerini çıkarmak için genelleştirilmiş Gabor fonksiyonu tabanlı şablonlar kullanılmıştır. Ardından, eğitim veri tabanlarında ölçülen damar sınırlarının yoğunluk özellikleri yeniden oluşturulmuştur. Damarların görsel özelliklerini temsil etmek için eğitilmiş zayıf bölütleme operatörleri kullanılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Jiang ve diğ. retina kan damar ağını çıkarmak için morfoloji temelli bir yaklaşım sunmuşlardır [87]. Önerdikleri sistemde, ilk olarak retina kan damar görüntüleri gri seviye görüntülere dönüştürülmüştür. Ardından iki paralel aşamada damar ağı çıkarılmış ve kılcac damarlar tespit edilmiştir. Retina damar ağı, morfolojik üst-şapka ve yoğunluk dönüşümü kullanılarak elde edilmiştir. Kılcal damar tespiti için görüntüler 10 derecelik adımlarla 18 derece döndürülmüş ve düşük bağlantılara sahip pikseller ortadan kaldırılmıştır. Elde edilen kan damar ağı ve kılcac damarlar üst üste örtüştürülmüş ve nihai görüntüden gürültüler kaldırılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Dash ve diğ. retina kan damar ağını çıkarmak için eşikleme temelli bir yöntem önermişlerdir [88]. İlk önce renkli retina kan damar görüntülerinin yeşil kanalı üzerinde bir ön işlem yapılmıştır. Ön işlem sürecinde, kontrast sınırlı uyarlanabilir histogram eşitleme ve medyan filtre yöntemi kullanılarak görüntüler iyileştirilmiştir. Ardından, ortalama-c eşikleme yaklaşımını kullanmış ve retina kan damar görüntüleri çıkarılmıştır. Son adımda istenmeyen hatalı piksellerden kurtulmak için morfolojik bir temizleme işlemi yapılmıştır. Veri seti olarak CHASE_DB1 ve DRIVE veri setleri kullanılmıştır.

Neto ve diğ. fundus görüntülerinde kan damarlarını bölütlemek için kabadan inceye bir denetimsiz yaklaşım sunmuşlardır [89]. Öncelikle, renkli retina kan damarı görüntülerinin yeşil kanalının tersi üzerinde bir ön işlem gerçekleştirilmiştir. Yeşil kanalın tersi üzerinde sırası ile Gauss yumuşatma, morfolojik üst şapka dönüşümü ve kontrast iyileştirme adımları uygulanarak ön işlem süreci tamamlanmıştır. Ön işlenmiş görüntü üzerinde kaba damar bölütlemeyi gerçekleştirmek için yerel eşikleme yaklaşımı sunulmuştur. Kaba bölütlemeye ortaya çıkan yapay damarlardan kurtulmak için bir eğrilik haritası oluşturulmuş ve nihai sonuca ulaşılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Zhu ve diğ. retina kan damar görüntülerini bölütlemek için aşırı öğrenme makinesi tabanlı bir yöntem önermişlerdir [90]. Önerilen yöntemde, renkli retina görüntülerinin yeşil kanalı kullanılmıştır. Yeşil kanal görüntüleri üzerinde kan damar piksellerine ait 39-B bir özellik vektörü inşa edilmiştir. Elde edilen özellik vektörü damar piksellerinin yerel özellikleri, morfolojik özellikleri, faz uyumu, Hessian ve vektör alanlarının diverjansından oluşmuştur. Daha sonra, gerçek zemin görüntüleri kullanılarak etiketlenen damar piksellerinden elde edilen özellikler sınıflandırıcıda eğitilmiştir. Daha sonra test verileri ile damar ve damar olmayan piksellerin sınıflandırılması yapılmıştır. Sınıflandırıcı sonucunda

elde edilen ikili damar görüntüleri üzerinde son işlem uygulanarak nihai sonuca ulaşılmıştır. Veri seti olarak DRIVE ve RIS veri setleri kullanılmıştır.

Zhou ve diğ. retina kan damarlarını bölütlemek için koşullu rastgele alan modeli tasarlamışlardır [91]. İlk önce retina kan damar görüntülerinin görüntüleme alanı belirlenmiş ve bu alana ön işlem uygulanmıştır. Burada amaç, görüntüleme alanı ile siyah arka planın yüksek kontrastını yok etmek olmuştur. Ardından, ön işlenmiş görüntülerden görüntü kesitleri alınmış ve bir ESA modeline girdi olarak verilmiştir. Eş zamanlı olarak fundus görüntüsünün yeşil kanalı üzerinde ince kan damarlarını belirginleştirmek için bir filtre tasarlanmıştır. ESA modeli ve filtrenin sonucu yoğun koşullu rastgele alan modelinden geçirilmiş ve retina kan damarlarına ulaşılmıştır. Veri seti olarak DRIVE, STARE, CHASEDB1 ve HRF veri setleri kullanılmıştır.

Ramos ve diğ. retina kan damarlarını bölütlemek için Gabor filtreleri, kesirli türevler ve beklenti maksimizasyonu yöntemlerini kullanarak yeni bir yöntem önermişlerdir [92]. Önerdikleri yöntem, üç temel aşamada gerçekleştirilmiştir. Birinci aşamada renkli fundus görüntüsünün yeşil kanalı kullanılmış ve bu kanal üzerinde alçak geçiren yarıçap filtresi uygulanarak görüntü üzerindeki gürültüler azaltılmıştır. İkinci aşamada, retina kan damarları bölütlenmiştir. Bu aşamada, Gabor filtre bankası ve kesirli sıralı Gauss türev yöntemleri ön işlenmiş görüntü üzerinde uygulanarak bölütlenmiş damar görüntülerine ulaşılmıştır. Son aşamada, istenmeyen damar dışı piksellerden kurtulmak için morfolojik işlemler bölütlenmiş görüntülere uygulanmıştır. Veri seti olarak DRIVE veri seti kullanılmıştır.

Jiang ve diğ. transfer öğrenme yöntemini kullanarak önceden eğitilmiş bir tam evrişimli ağ modeli ile retina kan damarlarını bölütleyen bir sistem önermişlerdir [93]. Önerilen sistem, eğitim ve test aşamasından oluşur. İlk önce hem eğitim hem de test veri kümeleri ön işleme tabi tutulmuştur. Daha sonra, veri çoğaltma teknikleri ile görüntü verileri arttırılmıştır. Bu görüntüler tam evrişimli AlexNet ağında beslenmiş ve ağ tarafından tüm sonuçlar toplanmıştır. Son aşamada, toplanan sonuçlar gürültü giderme teknikleri ile son işlem sürecinden geçirilmiştir. Veri seti olarak DRIVE, STARE, CHASE_DB1 ve HRF veri setleri kullanılmıştır.

Oliveira ve diğ. retina kan damar ağını bölütlemek için sabit dalgacık dönüşümü ve TBA tekniklerini kullanarak bir yöntem önermişlerdir [94]. Önerdikleri yöntemde retina görüntüleri ilk önce sabit dalgacık dönüşümünden geçirilmiştir. Ardından, bu görüntülerden görüntü parçaları elde edilmiştir. Daha sonra, veri çoğaltma teknikleri ile görüntü

parçalarının çeşitliliği ve sayısı artırılmıştır. Bu görüntü parçaları TBA ağına girdi olarak verilmiştir. Görüntü parçalarının bir kısmı eğitim bir kısmı test için kullanılmış ve nihai damar ağına ulaşılmıştır. Veri seti olarak DRIVE, STARE ve CHASE_DB1 veri setleri kullanılmıştır.

Guo ve diğ. çoklu derin evrişimli sinir ağı kullanarak retina kan damarlarının tespitini gerçekleştirmişlerdir [95]. Önerilen modelde, ESA'ya girdi olarak boyutu $64 \times 64 \times 1$ olan bir İB alanı verilmiştir. Ağın çıktısı İB alanındaki piksellerin sınıflandırma sonucu olmuştur. ESA'nın performansını iyileştirmek için artan bir öğrenme stratejisine sahip çoklu derin evrişimli sinir ağı kullanılmıştır. Nihai sınıflandırma sonuçlarına ulaşmak için bu ağın sonuçları üzerinde bir oylama prosedürü oluşturulmuştur. Önerilen yöntem DRIVE ve STARE veri setleri üzerinde test edilmiştir.

Hu ve diğ. ESA modelinin ve tam bağlı koşullu rastgele alanlara dayalı bir retina kan damar ağı çıkarma yöntemi önermişlerdir [96]. İlk önce, çapraz entropi kaybı fonksiyonuna sahip bir ESA modeli tasarlanmış ve görüntü olasılık haritaları üretilmiştir. Çapraz entropi kaybı ile retinada kan damarlarındaki zor örneklerin bulunması amaçlanmıştır. Daha sonra, tam bağlı koşullu rastgele alanlar kullanılmış ve böylece görüntülerde ki gürültü ve kenar bulanıklığı azaltılmıştır. Bu işlemin sonucunda nihai bölütleme sonucuna ulaşılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Jebaseeli ve diğ. hastalıklı retina görüntüleri üzerinde kan damar ağının bölütleme sonucunun kalitesini arttırmak için otomatik bir yöntem önermişlerdir [97]. Yöntemde, retina fundus görüntüleri KSUHE işleminden geçirilerek ön işlenmiştir. Ardından, tandem darbe birleştirilmiş sinir ağı kullanılmış ve ön işlenmiş görüntüler öznitelik vektörü üretecek şekilde eğitilmiştir. Son aşamada, derin öğrenme tabanlı destek vektör makinesi kullanılmış ve damar pikselleri damar olmayan piksellerden ayrılarak sınıflandırılmıştır. Veri seti olarak DRIVE, STARE, REVIEW, HRF ve DRIONS veri setleri kullanılmıştır.

Jebaseeli ve diğ. hastalıklı retina görüntüleri üzerinde kan damarlarının bölütleme sonucunu iyileştirmek için bir yöntem sunmuşlardır [98]. Bu yöntemde, kan damar piksellerini ön plana çıkarmak için KSUHE kullanılmış ve görüntüler ön işlenmiştir. Ön işlenmiş görüntülerin damar ve damar olmayan piksellerinden tandem darbe birleştirilmiş sinir ağı modeli ile özellik vektörü elde edilmiştir. Elde edilen özellik vektörü derin öğrenme tabanlı destek vektör makinesi kullanılarak damar ve damar olmayan piksellere ayrılmıştır. Bu vektör çok sayıda katman kullanmış ve yanlış sınıflandırmadaki hataları azaltmıştır. Bu

vektörünün parametreleri ateşböceği algoritması kullanarak ayarlanmıştır. Veri seti olarak STARE, DRIVE, HRF, REVIEW ve DRIONS veri setleri kullanılmıştır.

Hashemzadeh ve diğ. denetimli ve denetimsiz makine öğrenmesi yöntemlerini birleştirerek fundus görüntülerinde kan damar bölütlemesi için yeni bir yöntem geliştirmişlerdir [99]. KYM uzayındaki fundus görüntüleri YCbCr ve L^*a^*b uzaylarına taşınmış ve bu üç uzaydaki görüntülerden K, Y, L kanalları seçilmiştir. Bu kanallar KSUHE işleminden geçirilmiş ve ön işlenmiştir. Ön işlenmiş görüntüden özellik vektörü elde edilmiştir. Özelliklerin bir kısmı, seçili üç kanalın Gabor sonucunun otomatik eşiklenmesiyle elde edilmiştir. Özelliklerin diğer kısmı ise K kanalının ÜŞ dönüşümü, gölge düzeltmesi ve bit düzeyinde ölçeklendirme yöntemlerinden geçirilmesiyle elde edilmiştir. Özellik boyutu temel bileşen analiz yöntemi ile azaltılmış ve damarların ilk çıkarımı BKY kullanılarak sağlanmıştır. Önerilen sistem DRIVE, STARE ve CHASE_DB1 üzerinde değerlendirilmiştir.

Wang ve diğ. Mahalanobis mesafe ölçümünü kullanarak retina kan damarlarının bölütlenmesini sağlamıştır [100]. Öncelikle arka plan normalizasyonu ve gürültü azaltma teknikleri ile fundus görüntüleri ön işlenmiştir. Ön işlenmiş görüntülerden 100 farklı özellik çıkarılmıştır. Çıkarılan bu özellikler renkli fundus görüntüsünün üç kanalı için belirli bir kural çerçevesinde belirlenmiş ve 300 özellik elde edilmiştir. Daha sonra, öznetelik vektörünün güvenilir boyutlarını etkili bir şekilde ortadan kaldırmak için asimetrik temel bileşen analizi kullanılmıştır. Azaltılan öznetelik vektörü kademeli sınıflandırma ağına verilmiş ve son işlem adımı ile nihai sonuca ulaşılmıştır. Veri seti olarak DRIVE, STARE ve CHASE_DB1 veri setleri kullanılmıştır.

Sazak ve diğ. retina kan damarlarını belirginleştirmek için matematiksel morfolojiye dayalı yeni bir yöntem önermişlerdir [101]. Önerdikleri yöntem, melon şapka dönüşüm yöntemi olarak tanıtılmıştır. Bu yöntem, değişen yarıçaplara sahip bir disk elemanı ve değişen uzunluk ve dönüşe sahip çizgi elemanının uygulama sonuçlarını birleştiren bir yöntemdir. Bu yöntem hem gerçek verilere hem de sentetik verilere uygulanmış ve başarılı sonuçlar aldığı gözlemlenmiştir. Önerilen yöntemin deneysel çalışmaları DRIVE, STARE ve HRF veri setleri üzerinde gerçekleştirilmiştir.

Sun ve diğ. merkezi ışık refleksi gösteren damarların damar genişliğinin ölçümü için bir yöntem önermişlerdir [102]. Önerdikleri yöntemde ilk önce izotropik dalga dönüşümü yöntemi kullanılmış ve damarlar bölütlere ayrılmıştır. Ardından, morfolojik inceltme

algoritması, paralel çizgi modeli düzeltilmesi ve kübik spline uydurma adımları sırayla uygulanmış ve merkez çizgilerinin çıkarılması sağlanmıştır. Daha sonra ölçüm eksenini oluşturulmuştur. Ancak, damar genişliğinin ölçümü için ilk önce K-ortalama algoritması ile damar sınırları belirlenmiş ve daha sonra damar genişliği ölçülmüştür. Veri seti olarak REVIEW veri seti kullanılmıştır.

Orojov ve diğ. fundus görüntülerinde kan damarlarının bölütlenmesi için Mamdani (Tip-2) bulanık kurallarına dayalı kenar tespit tabanlı bir algoritma önermişlerdir [103]. Yöntem, renkli fundus görüntülerinin yeşil kanalı üzerine uygulanmıştır. Retina fundus görüntüsünün yeşil kanalı üzerinde KSUHE ve medyan filtresi uygulanmış ve görüntüler ön işlenmiştir. Ön işlenmiş görüntüler üzerine arka plan dışlaması yapılarak ön plandaki nesnelere algılanması kolaylaştırılmıştır. Ardından, Mamdani bulanık kuralları ön işlenmiş görüntülerin son haline uygulanmış ve kenar tespiti yapılmıştır. Son işlem sürecinden geçirilen kenar görüntüleri ile nihai damar görüntülerine ulaşılmıştır. Veri seti olarak DRIVE, STARE ve CHASE_DB veri setleri kullanılmıştır.

Pachade ve diğ. renkli fundus görüntüleri ve tarama lazer oftalmoskopi görüntüleri üzerinde retina kan damarlarını bölütleyen otomatik bir yöntem önermişlerdir [104]. Renkli fundus görüntüsünün yeşil kanalı ön işlenmiş ve damarlar belirgin hale getirilmiştir. Ardından bu görüntüler üzerinde medyan filtresi ve morfolojik açıklık işlemi uygulanmıştır. Bu adımda elde edilen görüntüler arka plan tahmininden çıkarılmış ve fark görüntüsüne eşik uygulanmıştır. Nihayetinde ikili damar görüntülerine ulaşılmıştır. Veri seti olarak DRIVE, STARE, IOSTAR, RC-SLO ve REVIEW veri setleri kullanılmıştır.

Yang ve diğ. retina kan damar ağının çıkarılması için dört temel adımdan oluşan bir yöntem önermişlerdir [105]. İlk önce, renkli fundus görüntüsünün üç kanalı belirli ağırlıklarla çarpılarak gri ölçekli görüntüye dönüştürülmüştür. İkinci aşamada, istenmeyen sınırlardan kurtulmak için aynalama işlemi ile görüntü yoğunlukları ilgili alan boyunca genişletilmiştir. Üçüncü aşamada, Frangi filtresinin geliştirilmiş bir hali sunulmuştur. Son adımda, bir seviye kümeleme yaklaşımı ile kan damarları bölütlere ayrılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Sun ve diğ. derin öğrenmeye dayalı bir yöntemle retina kan damarlarının bölütlenmesi üzerine bir yaklaşım önermişlerdir [106]. Derin öğrenme modeli olarak U-net modeli kullanılmış ve bu modele dayalı bir bağlamsal bilgi geliştirilerek genişletilmiş evrişimsel ağlar inşa edilmiştir. Ayrıca, arka plan ile kolayca karıştırılabilen küçük kan

damarlarını algılayabilmek, detay iyileştirme ve bağlamsal özellik füzyonu için uzamsal sürekliliğe sahip piramit modülü kullanılmıştır. Önerilen yöntemde, en sık kullanılan Toplu Normalleşme (TN - Batch Normalization (BN)) ile diğer normalleşme türlerinin karşılaştırılması yapılmıştır. Veri seti olarak DRIVE, STARE ve CHASE_DB1 veri setleri kullanılmıştır.

Ramos ve diğ. renkli fundus görüntüsünün yeşil kanalı üzerine Gauss filtresi uygulamışlardır [107]. Filtrelenmiş görüntü iki farklı aşamadan geçirilerek ince ve kalın kan damarlarının bölütlenmesi sağlanmıştır. Gauss uygulanmış görüntüye sırası ile ilk önce optimize edilmiş ÜŞ dönüşümü ve homomorfik filtre uygulanmıştır. Bu adımdan sonra, ince kan damarlarını bulmak için uyum süzgeci ve ardından minimum çapraz entropi eşiği- harris hawks optimizasyonu uygulanmıştır. Kalın damarları bulmak içinse ortanca filtresi ve optimize edilmiş ÜŞ dönüşümü uygulanmıştır. Bölütlenen ince ve kalın damar görüntüleri birleştirilerek bir son işlemde geçirilirmiş ve nihayetinde son ikili damar görüntülerine ulaşılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Tchinda ve diğ. fundus görüntülerinden kan damarlarını çıkarmak için kenar filtrelerine dayalı bir yöntem önermişlerdir [108]. Yöntemde, ilk önce renkli fundus görüntüsünün yeşil kanalı ön işlenmiştir. Ön işlenmiş görüntü üzerinden özellik çıkarılmış ve bu özelliklerden özellik vektörü oluşturulmuştur. Özellik vektörü Canny, Sobel, Robert, Prewitt, Gauss Laplacian gibi kenar algılama filtreleri ve morfolojik filtreler kullanılarak oluşturulmuştur. Çıkarılan özellik vektörü ileri beslemeli bir sinir ağına girdi olarak verilmiştir ve nihayetinde ikili damar görüntülerine ulaşılmıştır. Veri seti olarak DRIVE, STARE ve CHASE_DB1 veri setleri kullanılmıştır.

Yang ve diğ. retina kan damarlarını bölütlemek için yeni bir hibrit görüntü bölütleme yöntemi önermişlerdir [109]. Önerilen yöntemde, kalın ve ince damarları ayrı ayrı bölütlere ayırmak için çok ölçekli bir bölütleme ağı tasarlanmıştır. Bu ağ U-net modeli kullanılarak inşa edilmiştir. İnce ve kalın damarlar arasındaki bölütleme problemine çözüm olması için bir kayıp fonksiyonu tasarlanmıştır. Nihai kan damar görüntülerini elde etmek için ise füzyon ağı önerilmiştir. Füzyon ağı ince ve kalın damarların kaynaştırılmasında görev almıştır. Tüm işlemler ön işlenmiş retina görüntüleri üzerinde gerçekleştirilmiştir. Veri seti olarak DRIVE, STARE ve CHASE_DB1 veri setleri kullanılmıştır.

Balasubramanian ve diğ. retina kan damarlarını bölütlemek için denetimli bir yöntem önermişlerdir [110]. Retina fundus görüntüleri ilk önce medyan filtresinden geçirilmiş ve

görüntüler ön işlenmiştir. Ardından, ortalama yönelimli bir süper piksel yöntemi ön işlenmiş görüntüler üzerine uygulanmıştır. Burada ortalama kaydırma, her veri noktası için pencereyi tanımlamakta ve ardından veri noktası ortalamasını hesaplamaktadır. Bu işlem sonucu elde edilen damar görüntüleri ESA girdisi olarak kullanılmış ve ESA sonucunda bir özellik vektörü oluşturulmuştur. Elde edilen özellikler destek vektör makineleri ile sınıflandırılmış ve nihai damar görüntülerine ulaşılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

Huang ve diğ. retina kan damarlarını iyileştirmek için çok ölçekli uzay-yoğunluk alanı füzyon uyarlamalı filtreleme modelini önermişlerdir [111]. İlk önce renkli fundus görüntüsü gri ölçekli görüntüye dönüştürülmüştür. Gri ölçekli görüntünün yoğunluğu aynalama ile tüm alanlara yayılmıştır. Ardından, arka plan ile damar bölgesini kabaca ayırmak için yoğunluk bilgisi kullanılmış ve böylece damarlar belirginleştirilmiştir. Bu işlemin sonucunda elde edilen görüntüler önerilen filtre modelinden geçirilmiştir. Bu filtrenin sonucunda elde edilen görüntüler Hessian matrisinin öz değerlerine dayalı bir yanıt fonksiyonuna gönderilmiş ve nihai sonuca ulaşılmıştır. Veri seti olarak DRIVE ve STARE veri setleri kullanılmıştır.

1.2.2.2 Retina arter/vein ayrımı

Muramatsu ve diğ. retina arter ve vein çap oranının ölçümü için otomatik bir yöntem sunmuşlardır [112]. Önerilen yöntem, arter ve vein çap oranının ölçüm bölgesinin belirlenmesi için OD bölütleme, retina damar bölütleme, arter/vein ayrımı ve ana damarların çıkarılma süreçlerini içerir. Retina kan damarları, üst şapka dönüşümü ve çift halkalı filtreleme tekniklerinin bir kombinasyonu kullanılarak çıkarılmıştır. OD bölgesi ve yaklaşık disk çapları ise, AKM kullanılarak belirlenmiştir. Arter/vein ayrımı için KYM retina görüntülerinin her bir renk kanalı ve üç renk kanalındaki kontrasta karşılık gelen özelliklerle birlikte altı özellik belirlenmiştir. Daha sonra kademeli öznitelik seçimi kullanılmıştır. Bir öznitelik hariç tutulmuş ve geri kalan beş öznitelik sınıflandırıcıya verilmiştir. Nihayetinde, arter/vein ayrımı gerçekleştirilmiştir. Veri seti olarak DRIVE veri seti kullanılmıştır.

Bhuiyan ve diğ. retina arter ve veinlerin kalibrelerini ölçmek için merkezi retinal arter eşdeğeri ve merkezi retinal vein eşdeğeri ölçütlerini kullanan otomatik bir sistem önermişlerdir [113]. Önerdikleri sistemde, görüntüdeki tüm kenarlar algılanmış ve daha sonra Zone-B bölgesindeki tüm damarlar ayrı ayrı tanımlanmıştır. Zone-B bölgesinin alanı OD merkezini ve yarıçapını elde etmek için hesaplanmıştır. Elde edilen damarların görüntülerini gidermek için kenar profilleri oluşturulmuştur. Profil oluşturma bilgilerine

dayalı olarak, her kenar, OD etrafındaki yönelimine göre birinci kenar veya ikinci kenar olarak tanımlanmıştır. Son olarak, damar kenarlarını gruplandırmak ve her bir damarı tanımlamak için damar morfolojik bilgilerini kullanan bir yöntem uygulanmış ve nihai arter/vein ayrımı sağlanmıştır.

Mirsharif ve diğ. retina görüntülerinde kan damarlarının arter/vein ayrımı için yapısal ve otomatik bir yöntem sunmuşlardır [114]. Önerdikleri yöntem üç temel adımdan oluşturulmuştur. İlk önce retina kan damar görüntüleri bir ön işlem sürecinden geçirilmiştir. Ön işlem adımında histogram eşleştirme algoritmaları kullanılmıştır. Bu algoritmalar genelleştirilmiş histogram eşleştirme, parçalı histogram eşleştirme ve uyarlamalı histogram eşleştirme olmak üzere üç farklı eşleştirme algoritmasıdır. İkinci olarak, ana arterleri damarlardan ayırmak için belirli bir özellik çıkarma işlemi uygulanmıştır. Son olarak da retina damar ağının yapısal özellikleri kullanılarak önceki adımdan elde edilen sonuçları iyileştirmek için bir son işlem uygulanmıştır. Veri seti olarak DRIVE veri seti kullanılmıştır.

Dashtbozorg ve diğ. retina damar ağından çıkarılan bir grafi analiz ederek arter/vein sınıflandırılması için otomatik bir yaklaşım sunmuşlardır [115]. Bu yaklaşım üç temel aşamadan oluşturulmuştur. Birinci aşamada, retina damarlarının merkez hattı çıkarılmıştır. Damarların kesişim ve uç noktaları bulunmuş ve bunlar merkez hattı görüntüsünden çıkarılmıştır. Dolayısı ile her damar parçası arasındaki kesişim graf için bir düğüm olarak temsil edilmiştir. Her damar parçası kesiti ise grafın kenarları olarak temsil edilmiştir. İkinci aşamada, oluşturulan grafın analizi yapılmış ve gürültüler azaltılarak bağlantılar etiketlenmiştir. Son aşamada, özellikler çıkarılmış ve lineer bir sınıflandırıcıya verilmiştir. Nihayetinde arter/vein ayrımı gerçekleştirilmiştir. Veri seti olarak INSPIRE-AVR, DRIVE ve VICAVR veri setleri kullanılmıştır.

Khatakalle ve diğ. tarafından önerilen yöntem retina kan damar görüntülerinin arter/vein ayrımını yapabilen graf tabanlı bir yöntemdir [116]. Bu yöntemde, OD bölgesine yakın bölgedeki retina damarlarının özelliklerinden faydalanılmıştır. Yöntemin ilk adımında damar yapısından bir graf oluşturulmuştur. Oluşturulan grafın düğümü, damarların kesişim noktası ile temsil edilmiştir. Grafın kenarları ise damar bölümleri ile temsil edilmiştir. İkinci adımda, elde edilen graf üzerinde analiz yapılmıştır. Damarlar üzerinden özellikler çıkarılmış ve arter veya vein olan damarlar etiketlenmiştir. Son adımda, çıkarılan özellikler sınıflandırıcıya verilerek arter/vein ayrımı gerçekleştirilmiştir.

Welikala ve diğ. evrişimsel bir sinir ağı ile retina fundus görüntülerinde arter/vein ayrımını gerçekleştiren bir yöntem önermişlerdir [117]. Evrişimsel sinir ağı üç tam bağımlı katman ve üç evrişim katmanından oluşturulmuştur. Renkli fundus görüntüsünün her kanalı için ayrı ayrı bir ön işlem uygulanmış ve bu üç kanal daha sonra birleştirilmiştir. Ön işlem sürecinde, arka plan tahmin edilerek orijinal görüntüden çıkarılmış ve görüntüler üzerinde gölge düzeltilmesi yapılmıştır. Daha sonra, görüntü üzerindeki varyasyonu azaltmak için görüntüler normalleştirilmiş ve bu görüntüler üzerine medyan filtresi ile yoğunluk dönüşümü uygulanmıştır. Ön işlenmiş damar görüntülerinden 31×31 boyutunda görüntü parçaları çıkarılmıştır. Bu görüntü parçaları, damar piksellerini merkezine alacak şekilde oluşturulmuştur. Oluşturulan görüntü yamaları ESA'ya girdi olarak verilmiş ve nihayetinde arter/vein ayrımına ulaşılmıştır. Veri seti olarak UK Biobank veri seti kullanılmıştır.

Xu ve diğ. retina fundus görüntüleri üzerinde arter/vein ayrımını gerçekleştirmek için özellik çıkarım tabanlı bir yöntem sunmuşlardır [118]. Yöntemde, fundus görüntülerine yüksek geçiren bir filtre uygulanmış ve ardından bir arka plan düzenlemesi yapılarak görüntüler ön işlenmiştir. Ön işlenmiş görüntüler üzerinde birinci ve ikinci dereceden yeni birkaç özellik çıkarılmıştır. Çıkarılan özellikler ilk önce eğitim aşamasından geçirilmiş ve bir olabilirlik modeli kurulmuştur. Farklı görüntülerden alınan aynı özellikler test aşamasında bir K-en yakın komşu sınıflandırıcısına verilmiştir. Test aşamasındaki her damar pikseli özellik uzayındaki en yakın k komşuların etiketlerinin ortalaması olarak belirlenmiş ve sınıflandırma sonucunda gri ölçekli bir olasılık görüntüsü elde edilmiştir. Nihayetinde toplu bir oylama süreci ile arter/vein ayrımı gerçekleştirilmiştir. Veri seti olarak DRIVE veri seti kullanılmıştır.

Fan Huang ve diğ. retina damar piksellerinden öznitelik çıkararak fundus görüntüleri üzerinde arter/vein ayrımını gerçekleştiren bir yöntem önermişlerdir [119]. Önerilen yöntemde, fundus görüntüler bir ön işlemde geçirilmiştir. Ön işlem aşamasında, retina fundus görüntülerine görüntü aydınlatma ve normalleştirme işlemleri uygulanmıştır. Ön işlenmiş görüntülerden retina damarları ve damar merkezleri çıkarılmıştır. Her damar merkezi pikselinden toplamda 455 özellik çıkarılmıştır. Bu öznitelikler genetik algoritmaya verilmiş ve öznitelik seçme tekniği ile en iyi performansı veren öznitelikler seçilmiştir. Seçilen öznitelikler daha sonra sınıflandırıcıya verilmiştir. Veri seti olarak DRIVE, INSPIRE-AVR, Nidek, Canon ve Topcon veri setleri kullanılmıştır.

Fan Huang ve diğ. retina kan damar görüntüleri üzerinde piksel düzeyinde arter/vein ayrımını gerçekleştirmek için yoğunluğa dayalı dört yeni özellik önermişlerdir [120].

Fundus görüntüleri düzgün olmayan aydınlatma koşullarından dolayı ilk önce parlaklık değişiminden kurtarılmaya çalışılmıştır. Bunun için parlaklık normalizasyonu, retinex normalleştirme ve yansıma özelliği kullanılmıştır. Bu özellikler retina arterlerini veinlerden ayırt etmede iyi bir performans göstermiştir. Önerilen sistem INSPIRE-AVR, NIDEK ve VICAVR veri setleri üzerinde test edilmiştir.

Wang ve diğ. fundus görüntüleri üzerinde Derinlemesine denetlenen U-net (Ds-U-net) ağ mimarisi temelli arter/vein ayrımı yapabilen bir yöntem önermişlerdir [121]. Veri çeşitliliğini sağlamak için orijinal görüntüler dört yönde rotasyona uğratılmıştır. Hem rotasyonlu görüntüler hem de orijinal görüntüler bir ön işlem sürecinden geçirilmiştir. Ön işlenmiş görüntülerden görüntü yamaları alınmış ve bu yamalar derin ağ mimarisi için girdi olarak kullanılmıştır. Ağ mimarisi sonucunda retina görüntüleri üzerinde arter/vein ayrımı sağlanmıştır. Önerilen yöntem de veri seti olarak INSPIRE-AVR ve DRIVE veri setleri kullanılmıştır.

Hemelings ve diğ. fundus görüntülerinde arter/vein ayrımını gerçekleştirmek için U-net semantik bölütleme mimarisine dayalı bir uygulama sunmuşlardır [122]. Bu uygulama da eş zamanlı olarak hem damar bölütleme hem arter/vein ayrımı gerçekleştirilmiştir. Fundus görüntüleri Gauss filtresi kullanılarak bir ön işlemden geçirilmiştir. Ön işlenmiş retinal görüntüler veri çoğaltma teknikleri kullanılarak çoğaltılmıştır. Çoğaltılmış tüm veriler derin ağ mimarisi için girdi olarak verilmiş ve derin ağ mimarisinin sonucunda arter/vein ayrımına ulaşılmıştır. Önerilen yöntem kıyaslanabilir olsun diye altı farklı bölgede doğruluğu test edilmiştir. Veri seti olarak halka açık olarak sunulan DRIVE ve HRF veri setleri kullanılmıştır.

Girard ve diğ. ESA modeli kullanarak retina damarlarını bölütleme ve bölütlenen damarları arter veya vein olarak ayırabilen bir sistem önermişlerdir [123]. Bu sistemde retina fundus görüntüleri bir ön işlemden geçirilmiştir. Ön işlenmiş görüntüler veri arttırma teknikleri ile çoğaltılmıştır. Veri arttırma sürecinde her orijinal görüntü yamasına, beş ana öz vektör arasından rastgele seçilen bir öz vektörün rastgele bir kısmı eklenmiştir. Elde edilen tüm görüntü verileri önerilen ESA mimarisine verilmiştir. Ardından bir olabilirlik puan yayılım kuralı ile damarlar arter ve vein olarak ayrılmıştır. Bu ayrım bir graf ile temsil edilmiş ve minimum yayılım ağacı kullanılarak yanlış etiketlenmiş arter ya da vein pikselleri düzeltilmiştir. Veri seti olarak MESSIDOR ve DRIVE veri setleri kullanılmıştır.

Galdran ve diğ. bir evrişimsel sinir ağı ile fundus retina piksellerini arka plan, arter, vein veya belirsiz olarak ayıran bir sistem önermişlerdir [124]. Tüm retina fundus görüntüleri bir ön işlemde geçirilmiş ve ön işlenmiş görüntüler 512x512 boyutunda yeniden boyutlandırılmıştır. Ardından evrişimsel bir sinir ağı inşa edilmiş ve yeniden boyutlandırılmış görüntüler sinir ağına girdi olarak verilmiştir. Evrişimsel sinir ağının sonucunda retina fundus görüntüleri üzerinde arter/vein ayrımı gerçekleştirilmiştir. Önerilen sistemde veri seti olarak DRIVE, INSPIRE-AVR, RITE, HRF, STARE ve LES-AV veri setleri kullanılmıştır.

Yang ve diğ. retina kan damarlarını arter veya vein olarak ayırmak için topolojik yapı-kısıtlı bir üretici çekişmeli ağ önermişlerdir [125]. Önerilen ÜÇA modeli retina damarlarının topolojik bilgilerini otomatik tanıyan ve iyileştiren bir model olarak tasarlanmıştır. Topolojik yapı-kısıtlı bir üretici çekişmeli ağ mimarisinde üretici (Ü) olarak dört alt örnekleme ve dört yukarı örnekleme aşamasından oluşan U-net modeli kullanılmıştır. Ayrıca ise beş alt örnekleme katmanından oluşturulmuştur. Topolojik yapı kaybıyla birleştirilen ÜÇA yapısı, arter/vein sınıflandırmasının bağlantısını iyileştiren bir etki göstermiştir. Veri seti olarak DRIVE ve CVDG veri setleri kullanılmıştır.

Shin ve diğ. fundus görüntülerinde kılcal damarları daha iyi sınıflandırmak için damar topoloji tahminine dayalı bir arter/vein sınıflandırma yöntemi önermişlerdir [126]. Topoloji tahmini, damar çatallanma ve dallanma noktaları boyunca damar pikselleri arasında derin öğrenmeye dayalı ikili sınıflandırma olarak uygulanan yinelemeli vasküler bağlantı tahmini olarak kullanılmıştır. Nihayetinde, bütün bir damar grafi alt ağaçlara ayrılmış ve her biri bir oylama yöntemi ile bir bütün olarak atardamar veya toplardamar olarak sınıflandırılmıştır. Veri seti olarak DRIVE ve IOSTAR veri setleri kullanılmıştır.

Sathananthavathi ve diğ. retinal fundus görüntülerinde arter/vein ayrımını gerçekleştirmek için yarasa algoritması ile denetimli bir sınıflandırma yöntemi önermişlerdir [127]. Önerilen yöntemde, renk uzayları kullanılarak yeni bir özellik vektörü oluşturulmuştur. Özellik vektörü 73 adet özellikten oluşturulmuş ve bu özellikler hem istatistik hem de renk bilgilerinden elde edilmiştir. Özellik vektörünün boyutunu azaltmak ve özellik seçme işlemleri için yarasa optimizasyonu kullanılmıştır. Önerilen yöntem veri seti olarak DRIVE, STARE ve IOSTAR veri setlerini kullanmıştır.

Remeseiro ve diğ. retina kan damar görüntülerinde arter/vein ayrımını gerçekleştirmek için çok düzeyli bir eşik uygulayan yeni bir otomatik yöntem önermişlerdir [128]. İlk önce,

OD bölgesi ve kan damarları bölütlenmiştir. Ardından, damar piksellerinin yerel kontrastını hesaplamak için renkli fundus görüntülerinin kırmızı kanalı kullanılmış ve özellik ölçümü uygulanmıştır. Daha sonra, graf oluşturma süreci başlatılmış ve arter/vein ayırımı sonucunu daha sağlam ve güvenilir kılan graf yayılımı gerçekleştirilmiştir. Graf yayılımı, sadece belirsiz olarak etiketlenmiş damar pikselleri için uygulanmıştır. Yöntem DRIVE ve INSPIRE-AVR veri setlerini kullanmıştır.

1.3 Tezin Amacı

En basit tanımı ile fundus görüntüsü, insan gözüne ait retina yapısını fotoğraflayan bir görüntüleme şeklidir. Bu görüntülerin detaylı analizi ile sadece gözü değil diğer organları da etkileyen hastalıkların varlığı ortaya çıkarılmıştır. Bu hastalıklara erken müdahale edebilmek ve oluşturabilecekleri hasarın önüne geçebilmek için bilgisayar destekli tanı sistemleri geliştirilmiştir. Bu sistemler uzman hekimlere yardımcı olan, insan gücünü azaltan ve zamandan tasarruf eden sistemlerdir.

Bu tez çalışmasında temel amaç, fundus görüntü analizini gerçekleştiren bilgisayar destekli tanı sistemleri için sağlam ve güvenilir algoritmalar sunmaktır. Tezin diğer amaçları şöyledir:

- Fundus görüntülerinden anlamlı bilgiler çıkarmak için literatürdeki bilgisayar destekli tanı sistemlerini araştırmak
- Fundus görüntü analizi ile retina bileşenlerinin varlığını tespit etmek ve bu bileşenleri incelemek
- Retina bileşenlerinden biri olan kan damarlarını bölütlemek için sağlam ve güvenilir bir algoritma geliştirmek
- Retina bileşenlerinden biri olan optik diskin konumunu doğru ve hızlı belirlemek
- Retina damarlarının arter ve vein olarak yüksek başarımla ayrılmasını sağlamak
- Fundus görüntüsünün sağlıklı veya glokomlu olarak ayrımını gerçekleştirmek

Bu amaçlar doğrultusunda, optik diskin konumunu tespit eden, retina damar ağ yapısını doğru bölütleyen, retina damarlarının arter/vein ayrımını sağlayan ve glokomlu/sağlıklı fundus görüntülerinin ayrımını gerçekleştiren yöntemler bu tez çalışmasında önerilmiştir. Önerilen yöntemler, veri setinden bağımsız, hızlı ve sağlam sonuçlar üretmektedir.

1.4 Tezin Gerekçesi

Tez kapsamında optik diskin konumu, retina damar ağ yapısı, arter/vein ayrımı ve fundus görüntülerinin glokomlu/sağlıklı ayrımını yapabilen bir algoritma önerilmiştir. Tezin gerekçeleri aşağıdaki gibi verilebilir:

- Fundus görüntüleri için veri çeşitliliği azdır. Bu durum veri doğrulama zorluğunu beraberinde getirmektedir.
- Fundus görüntülerinin düşük kalitede olması ve homojen olmayan aydınlanmaya sahip olması bu alanda yapılan çalışmaların başarısını düşürmektedir.
- Optik disk ve optik kup bölgeleri retinada en parlak bölgelerdir. Ancak, hastalıklı retinalarda parlak lezyon bölgeleri olduğu zaman optik disk bölgelerinin tespiti zorlaşmaktadır.
- Arter/vein ayrımının renksel, dokusal ve morfolojik olarak tutarlı bir ayrımının olmaması bu alanda uygulama geliştirmeyi zorlaştırmaktadır.

Yukarıda belirtilen problemlerin çözümündeki gereksinimler genel olarak şunlardır:

- Fundus görüntülerinin ön işlenerek homojen bir aydınlatma sağlanması
- Doğru ve sağlam optik disk konumunun tespit edilmesi
- Retina damar ağ yapısının bölütleme sonucunun güvenilir olması
- Arter/vein ayrımı için başarısı yüksek ve kabul edilen yöntemlerin olması

Tüm bu nedenlerden dolayı, bu problemlerin giderilme ihtiyacı, tez çalışmasının ortaya çıkma gerekçesini oluşturmuştur. Ayrıca, literatürde yer alan retina fundus görüntü analiz uygulamaları incelendiğinde bu konuda yapılan çalışmaların hızla arttığı görülmektedir. Bu durum, konunun hala popüler bir konu olduğunun göstergesidir. Tez konusunun popülerliği ve çalışma alanına aranan çözümler bu tez konusuna odaklanılmasını sağlamıştır.

1.5 Tezde Sunulan Bilimsel Katkılar

Bu yapılan tez çalışması esnasında birçok uygulama geliştirilmiştir. Bu çalışmalar, bilimsel yayın haline getirilmiştir. Yapılan çalışmalar aşağıda verildiği şekilde özetlenebilir.

1. Uygulama: Bu çalışmada, retina fundus görüntülerinin OD lokalizasyonunu tespit etmek için optimizasyon temelli bir yaklaşım sunulmuştur [129].

2. Uygulama: Yapılan çalışmada, retina kan damarlarından piksel tabanlı özellik çıkarımı yapılmış ve retina kan damar ağı tespit edilmiştir [130]. Ayrıca, retina kan damarlarını tespit etmek için bir hibrit morfolojik yöntem önerilmiştir [131].
3. Uygulama: Yapılan çalışmada, retina kan damarlarını arter ve vein olarak ayırmak için evrimsel sinir ağlarına dayalı bir yöntem önerilmiştir.
4. Uygulama: Yapılan çalışmada, EfficientNet-B0 mimarisini kullanarak bir fundus görüntüsünün sağlıklı ve glokomlu olarak ayrımı yapılmıştır.

Tezin yaygın etkileri proje olarak ele alındığında gerçekleştirilen bilimsel proje şöyledir:

İnönü Üniversitesi BAP biriminin desteği ile “Retinal Görüntü Analizi ile Diyabetik Retinal anevrizmalarının erken teşhisi” [130], [131] isimli proje gerçekleştirilmiştir. Bu projede, retina görüntülerinin detaylı analizi yapılmış ve nihayetinde doktora tezi üretilmiştir.

1.6 Tezin Organizasyonu

Tez çalışmasının birinci bölümünde, tez hakkında temel bilgiler verilmiştir. Diğer bölümlerin organizasyonu aşağıda sunulmuştur:

Bölüm 2’de, bu tez çalışmasında kullanılan materyaller bilimsel olarak açıklanmıştır.

Bölüm 3’de, bu tez çalışmasında kullanılan veri setlerinden ve performans ölçüt parametrelerinden bahsedilmiştir.

Bölüm 4’de, bu tez çalışmasında yapılan uygulamaların detaylı anlatımı yapılmıştır.

Bölüm 5’de, tezin akademik katkıları ve tez çalışmasında yapılan uygulamaların sonuçları verilmiştir. Ayrıca, bu bölümde tezle ilgili çıkarımlar yapılmış ve gelecekteki araştırma planlarından bahsedilmiştir.

2. MATERYAL

2.1 Ön İşlem

Retina fundus görüntüleri homojen olmayan aydınlanma koşullarına ve düşük görüntü kalitesine sahip olabilmektedir. Bu durum, retina bileşenlerinin tespit edilmesini zorlaştırmaktadır. Bu nedenle literatürdeki retina fundus görüntü analiz çalışmalarının çoğunda fundus görüntüleri ilk olarak ön işlemden geçirilmiştir [132], [133]. Ön işlem, bir görüntü iyileştirme sürecidir. Ön işlem sürecinde amaç görüntüyü istenmeyen gürültülerden arındırmak ve görüntü kalitesini arttırmaktır. Bu tez kapsamında fundus görüntülerini ön işlemek için bilinen dört yöntemden faydalanılmıştır. Bu yöntemler bu bölümde alt başlıklar halinde sunulmuştur.

2.1.1 Kontrast sınırlı uyarlamalı histogram eşitleme

Kontrast sınırlı uyarlamalı histogram eşitleme (KSUHE- Contrast Limited Adaptive Histogram Equalization (CLAHE)) yöntemi görüntü iyileştirme amacı ile kullanılan yöntemlerden biridir. Bu yöntem uyarlamalı kontrast geliştirme yönteminin değiştirilmiş bir türüdür. Aralarındaki tek fark, KSUHE yönteminde kümülatif histogram dağılımının hesaplanmasından önce histogram kırpmak için fazladan bir adımın olmasıdır. KSUHE yöntemi önceki çalışmalarda [134]–[136] başarısını kanıtlamış bir yöntemdir. Bu nedenle bu tez çalışmasında kullanılmıştır.

KSUHE yöntemi dijital görüntüyü örtüşmeyen bağlamsal bölgelere böler. Her bölge köşe bölgesi, iç bölge ve sınır bölgesi olmak üzere üç gruptan birine dâhil edilir. Her bölgenin histogramı ayrı olarak hesaplanır. Her bölgenin histogramı, kullanıcı tarafından belirlenen bir kırpma sınırına göre kırpılır. Kırpma sınırı, bağlamsal bölgenin histogramının ortalama yüksekliğinin bir katıdır. $M \times N$ boyutunda bir dijital görüntü için L parametresi histogram parçalarının sayısını ve α parametresi kullanıcı tanımlı kontrast faktörünü temsil etmek üzere kırpma limiti Eşitlik 2.1’de verildiği gibidir [137].

$$n_T = \begin{cases} 1 & \text{if } \frac{\alpha MN}{L} < 1 \\ \frac{\alpha MN}{L} & \text{else} \end{cases}, 0 < \alpha \leq 1 \quad (2.1)$$

Bu işlemin sonucunda elde edilen kontrast sınırlı histogram değerlerinin kümülatif dağılım fonksiyonu gri seviye görüntü haritaları için belirlenir. Her piksel değeri, en yakın dört bölgenin eşlemelerinden elde edilen sonuçların bi-lineer enterpolasyon yöntemi ile


birleştirilmesiyle eşlenir. Şekil 2.1’de a, b, c ve d noktaları her bloğun merkez piksellerini temsil etmektedir. p pikseli ise dört blok tarafından çevrelenen rastgele bir pikseli temsil etmektedir. Eşitlik 2.2 ve Eşitlik 2.3’de verilen bi-lineer enterpolasyon ile haritalanmış piksel elde edilmektedir [138].

$$T(p(i)) = m \cdot (n \cdot T_a \cdot p(i) + (1 - n) \cdot T_b \cdot p(i)) + (1 - m) \cdot (n \cdot T_c \cdot p(i) + (1 - n) \cdot T_d \cdot p(i)) \quad (2.2)$$

$$n = (x_b - x_p) / (x_b - x_a) \quad (2.3)$$

$$m = (y_c - y_p) / (y_c - y_a)$$

Burada $T(\cdot)$ yeniden eşleme fonksiyonunu gösterir; $p(i), (x, y)$ koordinatına sahip rastgele bir piksel i ’nin değeridir. Enterpolasyon adımı, engelleme yapılarını kaldırır. Blokların bağımsız olarak işlenmesi nedeniyle KSUHE, kontrast geliştirme için düşük hesaplama karmaşıklığına ulaşır.



Şekil 2.1 : KSUHE bölgeleri.

KSUHE sonucunda, kullanılan gri değerlerin dağılımı eşitlenir ve böylece görüntünün gizli özellikleri daha görünür hale getirilmiş olur.

2.1.2 Wiener filtresi

Wiener filtresi (WF), mevcut sinyalin spektral özelliklerini kullanarak bu sinyali gürültüden arındırmak için filtreleme görevi görmektedir. Ayrıca bu filtre, minimum ortalama kare hata ölçütlerine dayanan durağan bir işlemi gürültüden arındıran bir filtredir. Wiener filtresi daha önce fundus görüntü analiz uygulamalarında kullanılmış ve başarısını kanıtlamış bir yöntemdir [139].

Durağan bir sinyalin giriş sinyali $x(n)$, saf sinyal $d(n)$ ile $v(n)$ gürültülerinin toplamından oluştuğunu varsayarsak çıkış sinyali $y(n)$, $d(n)$ sinyalinin bir tahmini olmalıdır. Bu nedenle hata sinyali $e(n)$ minimum olmalıdır. Eşitlik 2.4’de $x(n)$ giriş sinyali, Eşitlik 2.5’te ise $e(n)$ hata sinyalinin matematiksel gösterimi verilmiştir [140].

$$x(n) = d(n) + v(n) \quad (2.4)$$


$$e = \min(E(e(n)^2)) \quad (2.5)$$

Burada, $e(n)$ sinyali $y(n)$ çıkış sinyali ile $d(n)$ saf sinyalinin farkıdır.

2.1.3 Medyan filtresi

Medyan filtresi, görüntü işleme ve sinyal işlemede kullanılan ve doğrusal olmayan bir gürültü azaltma filtresidir. Bu filtrenin yanıtı iki aşamada elde edilir. İlk önce filtre tarafından çevrelenen dijital görüntüye ait pikseller sıralanır. Daha sonra, sıralanmış piksellerden ortanca piksel ile mevcut durumdaki merkez pikseli yer değiştirilir. Böylece filtrenin tepkisi elde edilmiş olur. Örneğin, Şekil 2.2.a’da 3×3 boyutundaki bir filtrede yer alan piksel değerleri verilmiştir. Şekil 2.2.b’de bu piksel değerleri sıralanmış ve ortanca piksel belirlenmiştir. Şekil 2.2.c’de ise ‘88’ olan merkez pikseli kaldırılmış ve yerine elde edilen ortanca piksel değeri olan ‘32’ yazılmıştır.

Medyan filtresi, görüntü içindeki ani değişimleri temizlemekte ve tuz-biber gürültüsünde oldukça başarılı sonuçlar üretmektedir. Ayrıca bu filtre, retina fundus görüntü analiz işlemlerinde de sıklıkla tercih edilmektedir [57], [88], [110].



Şekil 2.2 : Medyan filtre örneği.

2.2 Özellik Çıkarımı

Özellik çıkarımı, dijital görüntü işleme uygulamalarında nesnelerin tespitini, bölütlenmesini ve sınıflandırmasını gerçekleştirmek için kullanılan bir tekniktir. Bu tez çalışmasında, piksel tabanlı özellik çıkarımı retina fundus kan damarı bölütlemek için kullanılmıştır. Bu teknik, ilgili nesnenin bir pikselinden veya bu pikselin komşularından elde edilen çeşitli bilgileri kullanarak çıkarılır. Çıkarılan özellikler, beş farklı grup altında toplanmıştır. Bu gruplar bu bölümde alt başlıklar olarak verilmiş olup sırası ile; gradyan tabanlı özellikler, kenar bulma filtreleri, morfolojik özellikler, istatistiksel özellikler ve Hessian matrisidir.

2.2.1 Gradyan tabanlı özellikler

Gradyan, bir skaler alanın yönlü türevi olarak tanımlanabilir. Dijital bir görüntüde gradyan renk yoğunluk değişiminin hangi yönde ne kadar olduğunu belirtmektedir. Bir dijital görüntüde gradyan bilgisi yorumlanarak görüntüye ait birçok bilgi elde edilmektedir. Bir $I(x, y)$ görüntüsünün (x, y) noktasındaki kısmi türevi yani değişimi x yönünde hesaplandığında Eşitlik 2.6 ve y yönünde hesaplandığında Eşitlik 2.7' de verildiği gibidir.

$$G_x = \frac{\partial f(x,y)}{\partial x} = I_x(x, y) = I_x(x + 1, y) - I(x, y) \quad (2.6)$$

$$G_y = \frac{\partial f(x,y)}{\partial y} = I_y(x, y) = I_x(x, y + 1) - I(x, y) \quad (2.7)$$

Gradyanın iki boyutlu sütun vektörü olarak tanımlanması Eşitlik 2.8'de verilmiştir. Eşitlik 2.6 ve Eşitlik 2.7'de verilen yatay ve dikey yöndeki gradyanlar kullanılarak Eşitlik 2.9'da verilen gradyan vektörünün büyüklüğü elde edilmektedir. Gradyan vektörünün büyüklüğü M parametresi ile temsil edilmektedir. Gradyan vektörünün yönü ise Eşitlik 2.10'da verilen matematiksel ifade ile elde edilmektedir.

$$\nabla f = \text{grad}(f) = \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (2.8)$$

$$M = |G(i, j)| = \sqrt{(G_x(i, j))^2 + (G_y(i, j))^2} \quad (2.9)$$

$$\theta = \tan^{-1}\{G_y(i, j)/(G_x(i, j))\} \quad (2.10)$$

2.2.2 Kenar bulma filtreleri

Kenar, dijital bir görüntünün temel özelliğidir. Bir dijital görüntünün kenarları ani gri seviye değişiklikleri olarak tanımlanabilir. Görüntüye ait birçok bilgi görüntünün kenarlarında bulunmaktadır. Farklı kenar filtreleri, farklı koşullarda daha iyi performans gösterdiği için tanımlanmış ve kabul edilmiştir. Kenar filtreleri, daha önceki fundus görüntü analiz uygulamalarında [108], [141]–[143] kullanılmış ve başarısını kanıtlamış yöntemlerdir. Bu tez kapsamında beş farklı kenar filtresi kullanılmış ve bu filtrelerle fundus görüntülerinden piksel tabanlı özellik çıkarımı gerçekleştirilmiştir.

2.2.2.1 Roberts filtresi

Roberts filtresi, dijital bir görüntü üzerinde gradyanın 2 boyutlu uzaysal ölçümünü gerçekleştirir. Diferansiyel operatör olan bu filtre, görüntünün üzerinde 2×2 boyutunda bir maskeyi hareket ettirerek yaklaşık gradyan vektörünü hesaplamaktadır. Görüntü üzerinde hareket ettirilen maske, birinci türevin diferansiyel denklemleri ile elde edilmektedir. Eşitlik 2.11’de Roberts operatörü yatay (G_x) ve dikey (G_y) olarak verilmiştir.

$$G_x = \begin{bmatrix} 1 & 0 \\ 0 & -1 \end{bmatrix}, \quad G_y = \begin{bmatrix} 0 & 1 \\ -1 & 0 \end{bmatrix} \quad (2.11)$$

Bu filtreler görüntüye ayrı ayrı uygulanmaktadır. G_x filtresi, piksellerin kontrastın yüksek olduğu bölgeye ilerlediğini gösterir. G_y filtresi ise aynı işlemleri G_x filtresine göre 90° ’lik açılarla yatay yönde gerçekleştirir.

Bu filtre kenarları bulmada hızlıdır ancak gürültüye karşı duyarlı olmadığı için gürültülü noktaların algılanmasına neden olabilmektedir.

2.2.2.2 Prewitt filtresi

Prewitt filtresi, görüntünün her pikseline ait gradyan vektörünü hesaplamaktadır. Gradyan, görüntü üzerindeki yatay ve dikey maskelerin evrişimi ile elde edilmektedir. Eşitlik 2.12’de verilen yatay (G_x) ve dikey (G_y) yönlerindeki 3×3 boyutundaki maskeler kullanılarak görüntü filtrelenir.

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}, \quad G_y = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \quad (2.12)$$

2.2.2.3 Sobel filtresi

Sobel filtresi, Prewitt filtresine benzer yapıdadır. Boyutu 3x3 olan bu filtrenin Prewitt filtresinden tek farkı, yatay yönde ikinci satırdaki filtre değeri ve dikey yönde ikinci sütundaki filtre değerinin 1 yerine 2 olmasıdır. Eşitlik 2.13’de yatay (G_x) ve dikey (G_y) yönlerdeki Sobel filtresi verilmiştir.

$$G_x = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}, \quad G_y = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \quad (2.13)$$


Sobel filtresinin hesaplanmasına ait bir örnek Şekil 2.3’de verilmiştir. Bu örneğe göre ilgili görüntü üzerinde G_x ve G_y filtreleri uygulanır. Bu uygulama sonuçları elde edildikten sonra gradyan büyüklüğü hesaplanır. Bunun için Eşitlik 2.9’da verilen matematiksel ifadeden yararlanılır. Ardından gradyanın yönü bulunur. Bunun içinde Eşitlik 2.10’da verilen matematiksel ifadeden yararlanılır.

Eşitlik 2.9’ de verilen matematiksel ifadeye göre gradyan büyüklüğü;

$$M = |G(i, j)| = \sqrt{(-90)^2 + (15)^2} = \sqrt{8100 + 225} = 91,24$$

Eşitlik 2.10’ da verilen matematiksel ifadeye göre gradyan vektörünün açısı;

$$\theta = \tan^{-1}\{15/-90\} = -9$$



Şekil 2.3 : Sobel filtre örneği.

2.2.2.4 Canny filtresi

Canny filtresi, diğer kenar filtrelerinden farklı olarak ilk önce görüntüleri yumuşatmaktadır. Görüntüleri yumuşatmak için Eşitlik 2.14’de verilen Gaussian fonksiyonu kullanılır. Yumuşatılmış görüntüler üzerinde G_x ve G_y gradyan değerleri hesaplanır. Bu değerler kullanılarak Eşitlik 2.9’da verilen matematiksel ifade yardımıyla gradyan

büyüklüğü hesaplanır. Gradyan büyüklüğü hesaplandıktan sonra maksimum olmayan noktaların değeri bastırılır. Bu değer, yerel maksimum noktalarında sıfırdır ve kenarları inceltmek için bastırılmıştır. Burada dikkat edilmesi gereken nokta kenarın her zaman gradyan yönüne dik olmasıdır. Son olarak, bazı hatalı kenar noktalarının giderilmesi gerçekleştirilir. Bunun için bir eşik değeri kullanılır ve eşik değerini geçemeyen noktalar arka plana dahil edilir. Eşik adımının doğru ve sağlam olması için çift eşikleme tercih edilir. Çift eşik yönteminde, üç farklı piksel sonucunun elde edilmesi amaçlanır. İlk olarak güçlü piksellere ulaşmak için yüksek eşik kullanılır. Alakasız olarak nitelendirilen piksellere ulaşmak için alçak eşik kullanılır. Her iki eşik arasındaki yoğunluğa sahip tüm piksellerde zayıf olarak belirlenir. Histerezis adımı ile bu zayıf pikseller güçlü piksellere dönüştürülebilir. Bu adımda, güçlü piksellere bağlı zayıf pikseller kenara dahil edilir diğer pikseller görüntüden kaldırılır [144].

$$G(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2+y^2}{2\sigma^2}\right) \quad (2.14)$$

2.2.2.5 Marr hildreth operatörü

Marr-Hildreth operatörü, Gauss'un Lablası (Lablacion of Gauss - LoG) olarak da adlandırılan ve mühendislik uygulamalarında yaygın olarak kullanılan izotropik bir filtredir [145]. Bu filtre, kenar belirleme işlemini gerçekleştirmeden önce görüntüleri gürültüden arındırmak için yumuşatır. Görüntülerin yumuşatılması için Eşitlik 2.14'de verilen Gaussian filtresi kullanılır. Yumuşatılmış görüntülerin kenarları ikinci türevin sıfır geçişleri ile ilişkilendirilir. İkinci türevin sıfır geçişleri her zaman görüntünün kenar noktalarına denk düşmeyebilir. Bu nedenle, LoG doğal görüntülere uygulandığında iyi bir kenar belirleme yöntemi değildir [146]. Gürültüye karşı daha hassas bir yapısı olduğu için LoG filtresi öncesinde her zaman görüntünün yumuşatılması gereklidir. Bu durum bilgi kaybının oluşmasına yol açabilir. Lablacian filtresinin matematiksel ifadesi Eşitlik 2.15'de verilmiş olup LoG filtresinin matematiksel ifadesi ise Eşitlik 2.16'da verilmiştir. Bu matematiksel ifadelerde de görüldüğü gibi Lablacian filtresine Gaussian filtresi eklendiğinde LoG filtresi oluşmaktadır.

$$\nabla^2 = \sum_{i=1}^2 \frac{\partial^2}{\partial x_i^2} \quad (2.15)$$

$$\nabla^2 G = \sum_{i=1}^2 \frac{\partial^2 G}{\partial x_i^2} = G(x) \sum_{i=1}^2 \left(\frac{x_i^2}{\sigma^4} - \frac{1}{\sigma^2} \right) = \frac{1}{2\pi\sigma^6} (\|x\|^2 - 2\sigma^2) e^{-\|x\|^2/2\sigma^2} \quad (2.16)$$

2.2.3 Morfolojik özellikler

Matematiksel morfoloji, görüntü işleme tekniklerinin başarılarını arttırmak için görüntüler üzerinde uygulanan en popüler yöntemlerden biridir. Matematiksel morfolojinin en temel amacı görüntünün yapısını koruyarak görüntüden istenmeyen unsurları kaldırmaktır. Morfolojik işlemler morfolojik operatörler kullanılarak gerçekleştirilir. Morfolojik operatörlerin görüntüler üzerinde uygulanması için ise yapılandırma elemanlarına (Structure Element- SE) ihtiyaç vardır. Bu eleman, disk, kare, çizgi gibi farklı yapılarda ve boyutlarda olabilir. Yapılandırma elemanı hangi şekilde olursa olsun bu elemanın merkez noktasına işlenecek görüntünün her pikseli yerleştirilir.

Morfolojik operatörler temelde iki tanedir. Bunlar dilatasyon ve erozyon operatörleridir. Dilatasyon operatörü genişleme operatörü olarak da bilinir. Erozyon operatörü ise aşınma operatörü olarak bilinmektedir. Dilatasyon operatörünün amacı görüntüde oluşan ayırık bölgeleri birleştirmek ve delikleri doldurmaktır. Bu operatörde SE'nin incelenecek görüntüye denk gelip gelmediğine bakılır. Erozyon operatörü ise bağlantılı nesnelere ayırmada, delikleri genişletmede ve görüntüdeki nesnelere azaltmada kullanılmaktadır. Bu operatörde SE'nin incelenecek görüntünün alt kümesi mi değil mi sorusuna yanıt aranır. A ve B şeklinde verilen iki kümenin iki boyutlu z^2 içinde dilatasyon ve erozyon işlemlerinin matematiksel ifadesi Eşitlik 2.17 ve Eşitlik 2.18'de sırası ile verilmiştir [147].

$$A \oplus B = \{z | [(B)_z \cap A] \subseteq A\} \quad (2.17)$$

$$A \ominus B = \{z | (B)_z \subseteq A\} \quad (2.18)$$

Dilatasyon operatöründen hemen sonra erozyon operatörü kullanılırsa kapama operatörü oluşur. Erozyon operatöründen hemen sonra dilatasyon operatörü kullanılırsa da açma operatörü oluşur. A ve B şeklinde verilen iki kümenin kapama ve açma operatörlerinin matematiksel ifadesi Eşitlik 2.19 ve Eşitlik 2.20'de sırası ile verilmiştir.

$$A \cdot B = (A \oplus B) \ominus B \quad (2.19)$$

$$A \circ B = (A \ominus B) \oplus B \quad (2.20)$$

Bu tez çalışmasında, en popüler morfolojik işlemler arasında olan Üst Şapka (ÜŞ – Tophat (TH)) ve Alt Şapka (AŞ- Bothat (BH)) dönüşümleri kullanılmıştır. Bu dönüşümlerin matematiksel ifadesi sırası ile Eşitlik 2.21 ve Eşitlik 2.22'de verilmiştir. Üst şapka dönüşümü yüksek geçiren bir filtre özelliği sergiler ve görüntünün maskeden daha küçük olan parlak

alanlarını çıkarır. Alt şapka dönüşümü görüntünün arka plan maskesinden daha küçük olan bazı karanlık alanlarında etki gösterir.

$$T_{hat}(I) = I - (I \circ SE) \quad (2.21)$$

$$B_{hat}(I) = (I \cdot SE) - I \quad (2.22)$$

Eşitlik 2.21’de verilen matematiksel ifadeye göre I girdi görüntüsü SE yapılandırma elemanını kullanarak morfolojik kapama işlemini gerçekleştirmektedir. Bu işlemin sonucu I girdi görüntüsünden çıkarılırsa ÜŞ dönüşümü gerçekleşmiş olur. Eşitlik 2.22’de verilen matematiksel ifadeye göre I girdi görüntüsü SE yapılandırma elemanını kullanarak morfolojik açma işlemini gerçekleştirmektedir. Bu işlemin sonucundan I girdi görüntüsü çıkarılırsa AŞ dönüşümü gerçekleşmiş olur.

2.2.4 İstatistiksel özellikler

İstatistiksel özellikler, bir görüntüye ait en temel özelliklerdir. Bu özellikler bir görüntüye ait yapısal ve dokusal özelliklere göre kolaylıkla elde edilebilir. Bu tez kapsamında sekiz farklı istatistiksel özellik kullanılmış olup bu özelliklere ait matematiksel ifadeler Eşitlik 2.23- Eşitlik 2.28 arasında verilmiştir. Bu özelliklerin tanımı ve kullanılan parametrelerinin açıklaması Çizelge 2.1’de verilmiştir.

$$\mu = \frac{1}{n} \sum_{k=1}^n p_k \quad (2.23)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_{k=1}^n (p_i - \mu)^2} \quad (2.24)$$

$$S = \frac{\mu_3}{\sigma^3} \quad (2.25)$$

$$K = \frac{\mu_4}{\sigma^4} \quad (2.26)$$

$$MAD = \frac{\sum |p_i - \mu|}{n} \quad (2.27)$$

$$RSS = \sqrt{\sum_{k=1}^n p^2 k} \quad (2.28)$$

Çizelge 2.1 : İstatistiksel özelliklerin tanımı ve formülü.

Özellik	Açıklama
Aritmetik ortalama (μ)	Aritmetik ortalamada tüm verilerin ($p1, p2, \dots, pk, \dots, pn$) değerleri toplanır. Toplamdan elde edilen sonuç, toplam veri sayısına (n) bölünür. Böylece aritmetik ortalama hesaplanır.
Standart sapma (σ)	Standart sapma, ortalamaya göre dağılımı ölçen bir istatistiktir. Varyansın karekökü olarak bilinir. Veriler ortalamadan daha uzaksa, veri seti içinde daha yüksek bir sapma vardır.
Çarpıklık (Skewness- S)	Verileri asimetrisini ölçmek için kullanılan istatistiksel bir özelliktir. Eğer $S=0$ ise verinin histogram dağılımı simetrik olarak yorumlanır. $S>0$ ise verilerin dağılımı sağa çarpıktır. $S<0$ ise verilerin dağılımı sola çarpıktır.
Basıklık (Kurtosis- K)	Basıklık, dağılımın kuyruklarıyla ilgilidir. Dağılım kuyruklarının normal dağılımın kuyruklarından ne kadar farklı olduğunu tanımlayan bir ölçüdür. Bir dağılımın basıklığı üç kategoride incelenmektedir. Normal dağılıma benzeyen dağılımlarda K mesokurtic olarak kategorize edilir. Eğer K normalden daha büyük ise verilerin dağılımı leptokurtic olarak adlandırılır. Eğer K normalden daha küçük ise verilerin dağılımı platykurtic olarak adlandırılır.
Minimum	Minimum değer, ilgili penceredeki en küçük piksel değeridir.
Maksimum	Maksimum değer, ilgili penceredeki en büyük piksel değeridir.
Ortalama mutlak sapma (OMS-Mean absolute deviation (MAD))	Veri kümesinin OMS'sını, her bir veri ile ortalama arasındaki mesafedir. Veri setindeki değişkenlik hakkında bilgi verir.
Kare düzeyin kök toplamı (KDKT- Root sum of squared level)	KDKT, her bir verinin karesinin alındığı, bu karelerin toplamının hesaplandığı ve daha sonra bu toplamın karekökünün alındığı bir dizi değerle ilgilenir.

2.2.5 Hessian matrisi

Bir görüntünün Hessian'ı, koordinatlara göre görüntü yoğunluğunun ikinci dereceden kısmi türevlerinin matrisi olarak tanımlanır [148]. Bu matris simetrik bir matristir. Yani transpozu kendisine eşit olan matristir. Hessian matrisinin matematiksel ifadesi Eşitlik 2.29'da verilmiştir.

$$H = \begin{bmatrix} \frac{\partial^2 G}{\partial x^2} & \frac{\partial^2 G}{\partial y \partial x} \\ \frac{\partial^2 G}{\partial y \partial x} & \frac{\partial^2 G}{\partial y^2} \end{bmatrix} = \begin{bmatrix} G_{xx} & G_{xy} \\ G_{yx} & G_{yy} \end{bmatrix} \quad (2.29)$$

Burada G_{xx} parametresi, x yönündeki ikinci gradyan görüntüsünü temsil eder. G_{xy} parametresi x yönündeki y parametresine bağlı ikinci gradyan görüntüsünü temsil eder. G_{yy} parametresi, y yönündeki ikinci gradyan parametresini temsil eder. G_{yx} parametresi y yönündeki x parametresine bağlı ikinci gradyan görüntüsünü temsil eder. Hessian matrisindeki ikinci mertebeden kısmi türev bilgisi görüntülerde sıklıkla bulunan yoğunluk ve doku bilgilerinin değişimlerini vermektedir [149]

2.3 Yapay Arı Koloni Algoritması

Yapay Arı Koloni (YAK - Artificial Bee Colony (ABC)), algoritması 2011 yılında Derviş Karaboğa tarafından ortaya çıkarılan sürü tabanlı bir optimizasyon algoritmasıdır [150]. Bu algoritmada işçi (employed), gözcü (onlooker) ve kâşif (scout) arı olmak üzere üç arı türü bulunmaktadır. Algoritmada ilk önce Eşitlik 2.30 kullanılarak rastgele bir yiyecek kaynağı oluşturulur. Daha sonra işçi arılar devreye girer ve Eşitlik 2.31 kullanılarak yiyecek kaynakları güncellenir. İşçi arı, komşuluk ilişkilerini kullanarak yiyecek kaynağı aramaktadır. Bulduğu yiyecek kaynağının yerlerini dans ederek gözcü arılara bildirir.

$$x_{i,j} = x_j^{min} + rand(0,1)(x_j^{max} - x_j^{min}) \quad (2.30)$$

Burada, i parametresi herhangi bir yiyecek kaynağıdır ve $i=1,2,\dots,SN$ olarak ifade edilir. SN parametresi ise yiyecek kaynak sayısıdır. j parametresi optimize edilmiş parametredir ve $j=1,2,\dots,D$ olarak ifade edilir. D ise optimize edilecek parametre sayısıdır. x_j^{max} , j 'inci parametre için üst sınırı temsil etmekte, x_j^{min} ise j 'inci parametre için alt sınırı temsil etmektedir.

$$v_{i,j} = x_{i,j} + \varphi(x_{i,j} - x_{k,j}) \quad (2.31)$$

Burada, j parametresi $[1 D]$ aralığında random olarak üretilen bir tamsayıdır. φ parametresi ise $[-1, 1]$ kapalı aralığında değer alan random bir sayıdır. Ait olunan kaynağın j 'inci parametresi ile komşu kaynağın j 'inci parametreleri arasındaki fark alınır. Bu fark sonucu φ parametresi ile ağırlıklandırılır. Nihayetinde, eğer ait olunan kaynak $x_{i,j}$ ve komşu kaynak $x_{k,j}$ arasındaki fark azalırsa çözümler birbirine benzemeye başlamıştır.


İşçi arı evresinden hemen sonra gözcü arı evresi başlar. Gözcü arılar, kovan içinde bekleyerek işçi arıların dansını izler ve en iyi yiyecek kaynağının yerini öğrenirler. En iyi yiyecek kaynağının yerini öğrenen gözcü arılar kovandan ayrılır ve bu kaynaklara yönelirler. Kovandan çıkan gözcü arılar artık birer işçi arıdır. En iyi yiyecek kaynağı seçmenin birçok

farklı yöntemi bulunur. Bu tez çalışmasında Eşitlik 2.32’de verilen rulet tekerlek yöntemi kullanılmıştır.

$$p_i = \frac{fitness_i}{\sum_{j=1}^{SN} fitness_j} \quad (2.32)$$

Burada $fitness_i$ parametresi, i 'inci kaynağın kalitesini temsil etmektedir. Bu işlemin sonucu [0 1] aralığında üretilen random sayıdan büyükse yiyecek kaynakları güncellenir.

Gözcü arı evresinden sonra, kâşif arılar devreye girer. Kâşif arılar ise, yiyecek kaynağı tamamen bittiğinde ya da yiyecek kaynakları tamamen kötüleşmeye başladığında yeni yiyecek kaynağı bulmaktan sorumludurlar. Tüm bu durumların şekilsel özeti Şekil 2.4’te verilmiştir.



Şekil 2.4 : Yapay arı kolonisi.

2.4 K-Ortalama Kümeleme

Kümeleme, nesnelere benzerliğine göre gruplara ayırma işlemi olarak tanımlanabilir. K-ortalama kümeleme yöntemi [151] ise denetimsiz öğrenme algoritmalarından biridir. K-ortalama kümelemenin amacı önceden belirlenmiş k adet küme sayısına dayalı olarak verileri gruplara ayırmaktır. Algoritma temelde dört adımda inşa edilmiştir. İlk adımda, önceden belirlenen k sayısına göre veriler kümelerine ayrılır ve her kümenin ağırlık merkezi rastgele olarak başlatılır. İkinci adımda, veri kümelerindeki her bir veri ile veri merkezi arasındaki mesafe hesaplanır. Mesafe hesabı için en yaygın kullanılan ölçüt birimi Eşitlik 2.33’de verilen Öklid mesafe ölçütüdür. Üçüncü adımda, her bir veri benzerliğe göre kendine en yakın gruba atanır. Daha sonra, tüm veri noktalarının ortalaması alınarak her bir veri kümesinin merkezi yeniden hesaplanır. Bu adımda küme içi varyans azaltılmış olur.

Dördüncü ve son adımda, küme merkezleri artık değişmiyorsa kümeleme sonlanır. Aksi halde ikinci ve üçüncü adımlar sonlanma kriteri sağlanan kadar devam eder.

$$d = \sqrt{\sum_{i=1}^n (q_i - p_i)^2} \quad (2.33)$$

Burada, d parametresi p ve q noktaları arasındaki Öklid mesafesini temsil eder.

Bu kümeleme yöntemi sayısal verilerle işlem yaptığı için düşük boyutlu sayılar veriler için daha uygundur. Doğru bir k seçimi yapılırsa küme merkezlerinin yakınsaması için daha az sayıda yineleme yapılır. Eğer, k küme sayısı seçimi kötü yapılırsa küme merkezlerinin yakınsaması için yineleme sayısında artış olur. Bu parametresinin kullanıcı tarafından belirlenmesi parametre seçimine bağlı olarak performans düşüklüğüne sebep olabilir.

2.5 Yapay Sinir Ağı

Yapay sinir ağı (YSA- Artificial Neural Network (ANN)), insan beyninin biyolojik yapısını taklit ederek oluşturulmuş bir bilgisayar sistemidir. Temel amacı, insan beyninde olduğu gibi bilgileri alıp paralel olarak işleyebilmek ve işlemler sonucunda doğru bilgiye erişebilmektir. Bir yapay sinir ağı nöron adı verilen ve ayrı birimlerden oluşan katmanlardan meydana gelmektedir. Her nöron birbirine paralel bağlanırken bir sonraki katmana hiyerarşik olarak bağlanmaktadır. Bu katmanlar giriş katmanı, gizli katman ve çıkış katmanlarıdır. Giriş katmanında bulunan her nöronun değeri, girdi nöronu ile gizli nöron arasındaki bağlantıya karşılık gelen bir ağırlıkla çarpılır. Ağırlık değeri, hücreye gelen verinin önemini göstermektedir. Başlangıçta rastgele üretilir ve girdi verisinin etki değerine göre güncellenir. Bu durumun matematiksel ifadesi Eşitlik 2.34'de verilmiştir. Burada her gelen bilgi kendi ağırlıkları ile çarpılarak toplanır. Bu şekilde ağa gelen net girdi hesaplanmış olur. Net girdinin hesaplanması için sadece toplama fonksiyonu değil başka fonksiyonlarda kullanılmaktadır [152]. Bu tez çalışmasında net girdilerin hesaplanması için toplama fonksiyonu kullanılmıştır.

$$netF = \sum_{i=1}^n x_i * w_i \quad (2.34)$$

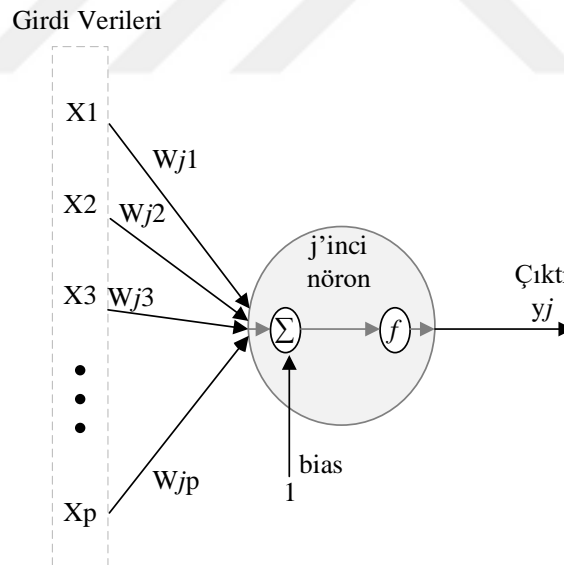
Burada, x parametresi i 'inci nöronu temsil ederken w parametresi i 'inci nöronun ağırlığını temsil etmektedir.

Girdi özellikleri, bir giriş katmanından sonra gizli katmana iletilir. Gizli katmanların sayısı arttıkça çıkış katmanından elde edilen başarı artacaktır. Ancak, gizli katman sayısının fazla olması yüksek hesaplama maliyetine sebep olmaktadır. Her gizli düğüm önceki

katmandan gelen girdilerin vektörü ile nöron j 'ye karşılık gelen ağırlık vektörünün çarpımına artı bir bias değeri eklenerek bulunur. Burada bias değeri toplama fonksiyonuna “doğrusal olmama” özelliği kazandırır. Her bir hücrenin net girdisi belirli matematiksel işlemlerden geçirilerek bir çıktı değeri elde edilir. Bu süreci gerçekleştirme işlemi aktivasyon fonksiyonları ile sağlanır. Yani bu fonksiyon hücreye gelen net girdiye karşılık üretilen çıktıyı belirler. Aktivasyon fonksiyonları probleme göre değişiklik gösterebilen bir fonksiyondur ve genellikle doğrusal olmayan bir fonksiyon seçilir. Bu fonksiyon seçilirken türevi kolay hesaplanabilen fonksiyonlar tercih edilir. Bu tez kapsamında çıkış değeri -1 ile 1 arasında değişen “hiperbolik tanjant sigmoid” fonksiyonu aktivasyon fonksiyonu olarak kullanılmıştır. Buraya kadar anlatılan işlemlerin görsel süreci Şekil 2.5’de verilmiştir [153]. Eşitlik 2.35’de ise kullanılan aktivasyon fonksiyonunun matematiksel ifadesi verilmiştir.

$$F(net) = \frac{e^{net} + e^{-net}}{e^{net} - e^{-net}} \quad (2.35)$$

Doğrusal olmayan aktivasyon gerçekleştirildikten sonra çıktı bir sonraki katmana iletilir. Son olarak, çıktı katmanı, son gizli katmandan değerleri alır ve nihai sonuç değerine dönüştürür.



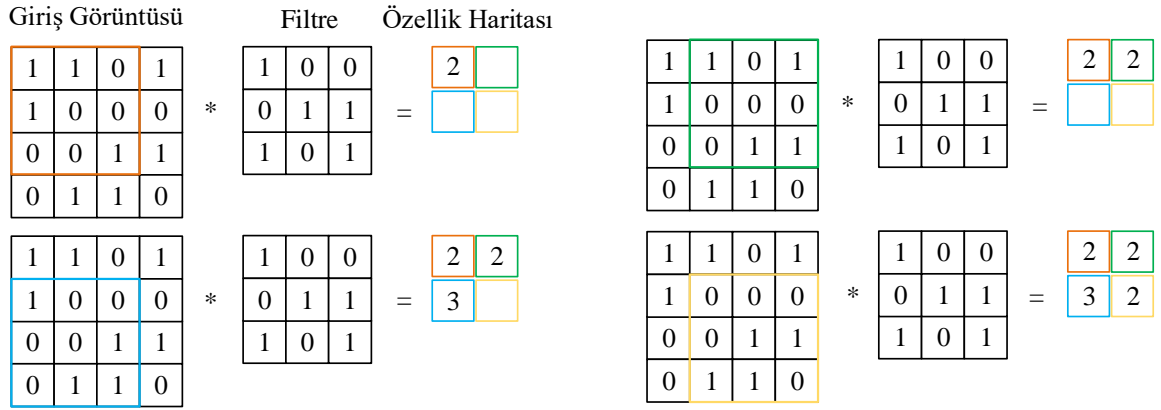
Şekil 2.5 : Bir yapay sinir hücresi.

Yapay sinir ağları ileri ve geri beslemeli olarak iki modele ayrılmaktadır. Bu ayrım sinir ağındaki işaretin akış yönüne göre gerçekleşmektedir [154]. Bu tez çalışmasında, ileri beslemeli bir ağ modeli kullanılmıştır. İleri beslemeli ağ modelinde bir nöronun çıkış değeri diğer nöron için giriş verisi olarak kullanılmakta ve bu şekilde gizli katmanlardan geçen bilgi çıkış katmanına iletilmektedir.

2.6 Evrişimsel Sinir Ağı

Evrişimsel sinir ağı (ESA- Convolutional Neural Network (CNN)), bir derin öğrenme modelidir. Bu modelde, genelde görüntülerden çıkarılan özelliklerin öğrenilmesi, sınıflandırılması ve nesne bölütlenmesi gerçekleştirilmektedir. ESA modeline verilen veriler art arda gelen katmanlardan geçirilir. İlk katman evrişim katmanıdır. Bu katmanı, havuzlama ve tam bağlı katman takip eder. Katmanların miktarı ve kullanım hiyerarşisi çözülmesi gereken probleme göre değişmektedir.

Evrişim (konvolüsyon) katmanı, girdi verisinden özelliklerin ayıklandığı ilk katmandır. Girdi verisi görüntünün sayısı, yüksekliği, genişliği ve derinliğini içeren bir tensördür. Bu katmanda, filtreler girdi verisi üzerinden pikseller boyunca geçirilir. Filtre sonucunda girdi verisinden bir özellik haritası oluşturulmuş olur. Elde edilen özellik haritası kullanılan filtrenin sayısına (derinlik), filtrenin kaç piksellik adımlarla hareket edeceğine (adım büyüklüğü) ve filtrenin görüntüden taşması durumunda görüntü kenarlarının ne kadar sıfırla doldurulacağına (sıfırla genişletme) bağlı olarak değişmektedir. Şekil 2.6'da bir evrişim örneği verilmiştir. Bu örnekte giriş görüntüsü 4×4 ölçülerinde 2-B bir görüntüdür. Filtre (maske, çekirdek) ise 3×3 ölçülerindedir. Bu örnek için adım büyüklüğü değeri 1, sıfır genişletme değeri ise 0 olarak belirlenmiştir.



Şekil 2.6 : Evrişim katmanından özellik haritası oluşturma.

Bu özellik haritalarına, eğitim sürecine hız kazandırmaları için normalleştirme yapılabilir. Normalleştirme işlemi için kabul edilmiş birçok yöntem vardır. Bu yöntemlerden bazıları toplu normalleştirme, katman normalleştirme, örnek normalleştirme ve grup normalleştirmedir. Bu tez çalışmasında Toplu Normalleştirme (TN- Batch Normalization (BN)) yöntemi kullanılmıştır. TN, evrişimli sinir ağlarının verimini artırarak ağın eğitim sürecini hızlandırmaktadır. TN katmanı genellikle evrişim katmanından sonra aktivasyon

katmanından önce kullanılır [155]. Bir önceki katmanın çıktıları kendinden önce gelen katmanın parametrelerinden etkilendiğinde her katmanın girdi dağılımı öğrenme sürecini etkiler. Bu durum iç değişken kayma problemi olarak bilinir. Bu normalleştirme modeli, dâhili iç değişken kayması problemini azaltır ve tasarlanan ağ modelinin karşılaşacağı sorunları kolaylaştırır. Eğitim sırasında bu katmanda, her parti için ayrı ayrı ortalama ve varyans hesaplanır [156].

Özellik haritalarının doğrusallığını bozmak için normalizasyon katmanından sonra genellikle bir aktivasyon katmanı kullanılır. Bu aktivasyon katmanları sigmoid, adım veya düzeltilmiş doğrusal birim gibi çeşitli aktivasyon fonksiyonlarından [157] birini içerebilir. Bu tez çalışmasında aktivasyon fonksiyonu olarak Düzeltilmiş Doğrusal Birim (DDB- Rectified Linear Units- ReLU) kullanılmıştır. DDB, negatif değerlerin elenmesini sağlayarak maksimum sıfır ve giriş değişkeni olarak tanımlanır. Eşitlik 2.36'da v değeri için DDB fonksiyonunun davranışı verilmiştir.

$$DDB(v) = \max(0, v) = \begin{cases} v & v \geq 0 \\ 0 & v \leq 0 \end{cases} \quad (2.36)$$

DDB katmanından çıkan özellik haritaları havuzlama katmanından geçirilerek boyutları azaltılır. Havuzlama katmanı, maksimum, ortalama ve toplam olmak üzere üç çeşittir. Bu tez çalışmasında maksimum havuzlama katmanı kullanılmıştır. Maksimum havuzlama işleminde, filtre görüntü üzerine oturtulur ve filtrenin kapladığı alan boyunca maksimum büyüklükteki piksel değeri alınır. Bu işlem filtre tüm özellik haritası üzerinde gezdirilerek tekrarlanır. Elde edilen piksel değerleri havuzlama katmanı sonucunda boyutu düşürülmüş özellik haritasının değerleridir. Şekil 2.7'de bir özellik haritasına uygulanmış 2 adım büyüklüğüne sahip 2×2 boyutlu bir filtrenin maksimum havuzlama sonucu verilmiştir.

22	32	27	26
10	7	8	13
56	42	69	2
88	17	45	11

(a)

32	27
88	69

(b)

Şekil 2.7 : Maksimum havuzlama katman örneği (a) özellik haritası, (b) maksimum havuzlama sonucu.

Elde edilen nihai özellik haritası vektör haline getirilip (flattening) bir sınıflandırıcıya verilmektedir. Bu aşama için tam bağlı katman kullanılır. Bu katmanda, tek boyutlu vektör olarak düzleştirilen özellikler geleneksel bir sinir ağında nöronların düzenlenme şekline benzer. Yani tam bağlı katmandaki her düğüm, hem önceki hem de sonraki katmandaki her düğüme doğrudan bağlanır [158]. Bir evrimsel sinir ağının aşırı öğrenmesini yani veriyi ezberleme durumunu en aza indirmek için tam bağlı katmanlardan sonra seyreltme katmanı kullanılır. Bu katman tam evrimsel katmandaki bazı düğümlerin unutulmasını yani kaldırılmasını sağlar. Bu katman 0 ile 1 aralığında bir değer kullanarak bu değere göre rastgele düğümü kaldırır. Son olarak bir sınıflandırma kullanılır ve modelin sınıflandırılması sağlanır. Bunun için literatürde kabul edilmiş farklı sınıflandırma yöntemleri vardır [159]. Bu tez çalışmasında yumuşak bağlı (softmax) sınıflandırıcı kullanılmıştır. Bu sınıflandırıcı 0-1 arasında değer üretir ve en yüksek sınıf etiketi modelin tahmin edildiği sınıfı temsil eder. Yumuşak bağlı sınıflandırıcı için çıkış değeri Eşitlik 2.37'de verildiği gibidir.

$$\text{softmax}(x_k) = \frac{\exp(x_k)}{\sum_j^c \exp(x_j)} \quad (2.37)$$

Burada x_k çıkış değeri hesaplanan sınıfı, j sınıf sayısının alt sınırını ve c ise sınıf sayısının üst sınırını temsil eder.

2.7 EfficientNet-B0

EfficientNet, 2019 yılında geliştirilmiş bir derin öğrenme ağ mimarisidir [160]. Bu mimari, derin ağ mimarilerinin performansını önemli ölçüde etkileyen üç terim arasındaki ilişkiyi verir. Bu terimler derinlik, genişlik ve çözünürlüktür. Bu mimaride, bileşik ölçeklendirme yöntemi kullanılmıştır. Bu yöntemin ilk adımında grid arama algoritması bulunur. Bu algoritma, ağın farklı ölçeklendirme boyutları arasında ilişki kurmasını sağlar. Hedeflenen derin öğrenme ağı, belirtilen ölçeklendirme boyutlarıyla başlatılır. Bileşik ölçekleme yöntemi için matematiksel ifadeler Eşitlik 2.38 - 2.40 arasında verilmiştir [161].

$$d = \alpha^\phi, w = \beta^\phi, r = \gamma^\phi \quad (2.38)$$

$$\alpha \cdot \beta^2 \cdot \gamma^2 \approx 2 \quad (2.39)$$

$$\alpha \geq 1, \beta \geq 1, \gamma \geq 1 \quad (2.40)$$

Burada, ϕ parametresi kullanıcı tanımlı bir katsayıyı temsil eder. α, β, γ parametreleri sırasıyla derinlik, genişlik ve çözünürlük için kullanılır. $\phi = 1$ sabit olarak verildiğinde

Eşitlik 2.39 ve Eşitlik 2.40 kısıtları altında en iyi değerlerin $\alpha = 1.20$, $\beta = 1.10$ ve $\gamma = 1.15$ olduğu bulunmuştur. Bu, EfficientNet-B0 modelini oluşturur.

Derinlik, derin öğrenme ağ mimarisinin katman sayısı ile ilgilidir. Derin bir ağ, daha fazla ayrıntıya girerek karmaşık özellikler elde edebilir. Ancak, ağın derinliğini artırmak her zaman arzu edilen bir durum değildir. Çünkü derinlik maliyet artışına ve zaman kaybına neden olacaktır. Ayrıca, artan derinlikte yok olan gradyanlar ile uğraşmak gerekir ve bu durum ağın eğitimini zorlaştırmaktadır. Genişlik, derin ağ mimarisinin katmanlarının boyutu ile ilgilidir. Katmanlardaki nöronların artması ağın genişlemesine neden olur. Çözünürlük, derin öğrenme ağ mimarisinin giriş verilerinin en boy oranı ile ilgilidir. Giriş görüntüsünün yüksek çözünürlüğü, görüntüde ince ayrıntılar içerir. Tan ve diğ. [160], başlangıç modeli olarak bilinen EfficientNet-B0 mimarisini geliştirmiştir. Bu mimarinin parametre değerleri Çizelge 2.2’de verilmiştir.

Çizelge 2.2 : EfficientNet-B0 mimarisi.

Durum	Operatör	Çözünürlük	Kanallar	Katman
1	Conv 3x3	224x224	32	1
2	MBCConv1, k3x3	112x112	16	1
3	MBCConv6, k3x3	112x112	24	2
4	MBCConv6, k3x3	56x56	40	2
5	MBCConv6, k3x3	28x28	80	3
6	MBCConv6, k3x3	14x14	112	3
7	MBCConv6, k3x3	14x14	192	4
8	MBCConv6, k3x3	7x7	320	1
9	Conv 1x1 & Pooling & FC	7x7	1280	1

Bu çizelgede, ağ bir evrişimsel katmanla başlar ve ardından mobil ters çevrilmiş darboğaz katmanları (MBCConv) gelir. Bu katmanlar, bir evrişim katmanının başı ve sonu arasında bir kısa yol oluşturur. Ayrıca, bu katmanlar tüm ağın temelini oluşturur ve iki aşamalı evrişimler [162], ters çevrilmiş artıklar ve doğrusal darboğazlar [163] sunarak onu maliyet açısından verimli ve hızlı hale getirir.

3. KULLANILAN VERİ SETLERİ VE PERFORMANS ÖLÇÜTLERİ

3.1 Veri Setleri

Halka açık bir veri seti olan Damar Çıkarımı için Dijital Retina Görüntü (Digital Retinal Images for Vessel Extraction- DRIVE) veri seti bu tez kapsamında kullanılan veri setlerinden biridir. Bu veri seti Hollanda'da 400 DR hastasına yapılan bir tarama programından oluşturulmuştur. Veri setini oluşturan kişiler 25-90 arasındaki yaş gruplarından seçilmiştir. Veri seti görüntüleri 565x584 piksel boyutunda ve toplam 40 adettir. Bu görüntüler 20 eğitim ve 20 test görüntüleri olarak iki gruba ayrılmıştır. Test seti görüntüleri alanında uzman iki farklı oftalmolog tarafından retina damarlarına bölütlenmiştir. Bu görüntüler gerçek zemin görüntüleri olarak kullanılmıştır. Ayrıca retina fundus görüntülerinin görüş alanı maskeleri oluşturulmuştur [164].

MESSIDOR veri seti, DR hastalığının bilgisayar destekli teşhisine yönelik çalışmaları kolaylaştırmak için halka açık olarak sunulmuş [165] ve bu tez çalışmasında kullanılmıştır. Bu veri seti 45° görüş alanına sahip bir Topcon kamera kullanılarak üç farklı oftalmolog tarafından elde edilmiştir. Toplamda 1200 renkli fundus görüntüsü içerir. Bu görüntüler 1440x960, 2240x1448 ve 2304x1536 olmak üzere üç farklı görüntü boyutunda TIFF formatında oluşturulmuştur. Veri setindeki tüm görüntüler 400 görüntüden oluşan üç gruba bölünmüştür. Her grup kendi içerisinde dört alt gruba ayrılmıştır. Alt gruptaki her 100 görüntüye her görüntü için tıbbi bulgular içeren bir Excel dosyası oluşturulmuştur [166].

DRIONS veri seti, 50° görüş alanına sahip analog bir fundus kamerası kullanılarak elde edilmiştir. Toplamda 110 fundus görüntüsü içerir. Bu görüntülerin boyutu 400x600'dür. Elde edilen görüntüler optik sinir başını merkeze alacak şekilde oluşturulmuştur. Tüm veri seti görüntüleri analog formatta elde edilmiş olup yüksek çözünürlüklü bir tarayıcı ile KYM renk uzayında 8 bit düzeyinde dijitalleştirilmiştir [167].

STARE (Structured Analysis of the Retina- STARE) veri seti [168], 35° görüş alanına sahip bir TopCon TRV-50 fundus kamerası kullanılarak elde edilmiştir. Veri seti görüntüleri KYM renk uzayında 700x605 piksel boyutunda 20 adet renkli retina görüntüsüdür. A. Hoover ve V. Kouznetsova'nın iki manuel damar segmentasyonu mevcuttur. A. Hoover tarafından gerçek zemin olarak kullanılan görüntü piksellerinin %10.4'ü damar olarak işaretlenmiş, V. Kouznetsova tarafından gerçek zemin olarak kullanılan görüntü piksellerinin ise %14.9'u damar olarak işaretlenmiştir.

INSPIRE-AVR veri seti, 30° görüş alanına sahip bir fundus kamerası kullanılarak elde edilmiştir. Görüntülerin boyutu 2392x2048'dir ve görüntüler OD merkezlidir. Toplamda 40 adet yüksek çözünürlüklü fundus görüntüsü vardır. Yarı otomatik bir bilgisayar programı ile alanında uzman iki oftalmolog tarafından her görüntü için iki arter/vein oranının ölçümü oluşturulmuştur. Ayrıca, arteri ve vein damarları manuel bölütlenerek gerçek zemin görüntüleri oluşturulmuştur[169].

LES_AV veri seti halka açık olarak sunulan ve son yıllarda ortaya çıkan bir veri setidir. Bu veri setinde 22 görüntü bulunmaktadır. 21 görüntü için görüntü boyutu 1620x1444 piksel olmasına rağmen bir görüntü için görüntü boyutu 2196x1958 pikseldir. Veri seti klasöründe orijinal fundus görüntüleri, bu orijinal görüntülere ait görüş alanı maskesi, görüntülerin manuel bölütlenmiş arter ve vein damarları ve bölütlenmiş tüm retina damarları bulunmaktadır. Tüm bu görüntüler PNG dosyası olarak kullanıcıya sunulmuştur [170].

ACRIMA veri seti, halka açık bir fundus görüntü veri setidir [171]. Bu veri seti glokom ve sağlıklı fundus görüntülerinden oluşmaktadır. Toplamda 705 fundus görüntüsüne sahiptir. Bu görüntülerde glokomlu görüntülerin sayısı 396'dır. Geriye kalan 309 fundus görüntüsü ise sağlıklı fundus görüntüleridir. Görüntülerin sınıflandırması deneyimli bir glokom uzmanı tarafından yapılmıştır. Bu veri kümesi görüntüleri görüş alanını değil yalnızca OD bölgesini içerir. Tüm görüntüler Topcon TRC retina kamera ile alınmıştır ve 35° görüş alanına sahiptir.

3.2 Performans Ölçütleri

Bu tez çalışmasında, önerilen yöntemlerin performansını ölçebilmek ve bu yöntemleri güncel yöntemlerle karşılaştırabilmek için çeşitli performans ölçütleri kullanılmıştır. Bu performans ölçütleri Hassaslık (H - Sensitivity (Sn)), Özgüllük (Ö - Specificity (Sp)), Doğruluk (D - Accuracy (Acc)), Kesinlik (K - Precision (Pr)) ve F-ölçütü ölçütleridir. Ayrıca Jaccard ve Dice benzerlik indeksleri de performans ölçütü olarak bu tez çalışmasında kullanılmıştır. Bu ölçüt metriklerinin her biri retina fundus görüntülerinin görüş alanı üzerinde hesaplanmıştır. Tez çalışmasında kullanılan performans ölçütlerinin matematiksel ifadesi Eşitlik 3.1 ile Eşitlik 3.5 arasında verilmiştir.

$$\text{Özgüllük (Ö)} = \frac{TN}{FP+TN} \quad (3.1)$$

$$\text{Hassaslık (H)} = \frac{TP}{TP+FN} \quad (3.2)$$

$$\text{Doğruluk (D)} = \frac{TP+TN}{TP+TN+FN+FP} \quad (3.3)$$

$$\text{Kesinlik (K)} = \frac{TP}{TP+FP} \quad (3.4)$$

$$F - \text{ölçütü} = \frac{2*H*K}{H+K} \quad (3.5)$$

Bu matematiksel ifadelerin anlaşılması için TN , TP , FN ve FP parametrelerinin bilinmesi gerekir. TP parametresi, Doğru Pozitif (DP - True Positive (TP)) olarak bilinir. Yani bölütlenmiş retina fundus görüntüsünde damar olarak işaretlenmiş piksel, gerçek zemin görüntüsünde de damar olarak işaretlenmiş ise DP olarak tanımlanır. TN parametresi, Doğru Negatif (DN - True Negative (TN)) olarak bilinir. Yani bölütlenmiş retina fundus görüntüsünde damar dışı olarak işaretlenmiş piksel, gerçek zemin görüntüsünde de damar dışı olarak işaretlenmiş ise DN olarak tanımlanır. FP parametresi, Yanlış Pozitif (YP - False Positive (FP)) olarak bilinir. Yani bölütlenmiş retina fundus görüntüsünde damar olarak işaretlenmiş piksel, gerçek zemin görüntüsünde damar dışı olarak işaretlenmiş ise YP olarak tanımlanır. FN parametresi, Yanlış Negatif (YN - False Negative) olarak bilinir. Yani bölütlenmiş retina fundus görüntüsünde damar dışı olarak işaretlenmiş piksel, gerçek zemin görüntüsünde damar olarak işaretlenmiş ise YN olarak tanımlanır.

Bu tez çalışmasında, önerilen yöntemlerin performans ölçütü hesaplanırken iki bölütlenmiş görüntü arasındaki benzerlik ölçütü de hesaplanmıştır. Bu tez çalışmasında kullanılan benzerlik indeksleri Eşitlik 3.6 ve Eşitlik 3.7’de verilmiştir.

$$J = \frac{|G \cap S|}{|G \cup S|} = \frac{b}{a+b+c} \quad (3.6)$$

$$D = \frac{2|G \cap S|}{|G|+|S|} = \frac{2b}{|a+b|+|b+c|} \quad (3.7)$$

Burada, J parametresi jaccad, D parametresi dice metriğidir. G parametresi gerçek zemin görüntüsünü temsil etmektedir. S parametresi ise önerilen yöntem tarafından bölütlenmiş görüntüyü temsil etmektedir. G ve S görüntülerinin ortak piksellerini b parametresi temsil etmektedir. G görüntüsünün tüm pikselleri a ve b parametrelerinin toplamıdır. S görüntüsünün tüm pikselleri ise b ve c parametrelerinin toplamıdır. Burada, a parametresi G görüntüsünde olup S de olmayan pikselleri temsil eder ve c parametresi tam tersi durumu temsil eder.

4. YAPILAN UYGULAMA ÇALIŞMALARI

Bu tez çalışmasında, retina fundus görüntü analizi gerçekleştirilmiştir. Görüntü analizi retina damarları, OD ve OK üzerinde yapılmıştır. Retinaya ait bu bileşenler DR ve glokom hastalığı başta olmak üzere birçok hastalık için ön bilgi sağlayıcı olmuştur. Bu nedenle retina bileşenleri hala aktif bir araştırma alanına sahiptir. Bu tez çalışmasında, dört farklı uygulama gerçekleştirilmiştir. Bu uygulamalarda yaşanan problemler ve uygulama sonucunda elde edilen çıktılar bu tez çalışmasında sunulmuştur.

Bu tez çalışmasına ait tüm kodlar MATLAB ortamında koşturulmuştur. AMD Ryzen 3 3100 işlemcili, işlemci hızı 3.59 GHz, RAM kapasitesi 32 GB ve 64 bit Windows 10 işletim sistemine sahip bir bilgisayar kullanılmıştır.

4.1 Uygulama 1: Optik Disk ve Optik Kup Lokalizasyonun Tespiti


Optik disk, fundus görüntüleri üzerinde stratejik olarak önemli bir konuma sahiptir ve bu bileşen retina kan damarlarının dağılım noktasıdır. Optik disk lokalizasyonunun doğru tespiti, diğer retina bileşenlerinin bilgisayar destekli teşhisinde önemli bir ipucu sağlamaktadır. Bu nedenle bu uygulamaya yönelme amacı OD bölgesini doğru ve sağlam bir şekilde tespit edilmesi olmuştur.

Bu uygulamada, retina fundus görüntüleri üzerinde OD lokalizasyon tespiti için otomatik bir yöntem önerilmiştir. Önerilen yöntemde, YAK algoritması kullanılmış ve KYM renk uzayındaki fundus görüntüleri yeni bir renk uzayına taşınmıştır. Yeni renk uzayındaki fundus görüntülerine bir eşik uygulanarak optik disk lokalizasyonu tespit edilmiştir. Önerilen yöntem, halka açık olarak sunulan DRIVE, MESSIDOR ve DRIONS veri setleri üzerinde test edilmiştir. Elde edilen sonuçlar, önerilen yöntemin başarılı olduğunu göstermiştir.

4.1.1 YAK tabanlı yeni renk uzayında OD lokalizasyonunun tespit edilmesi

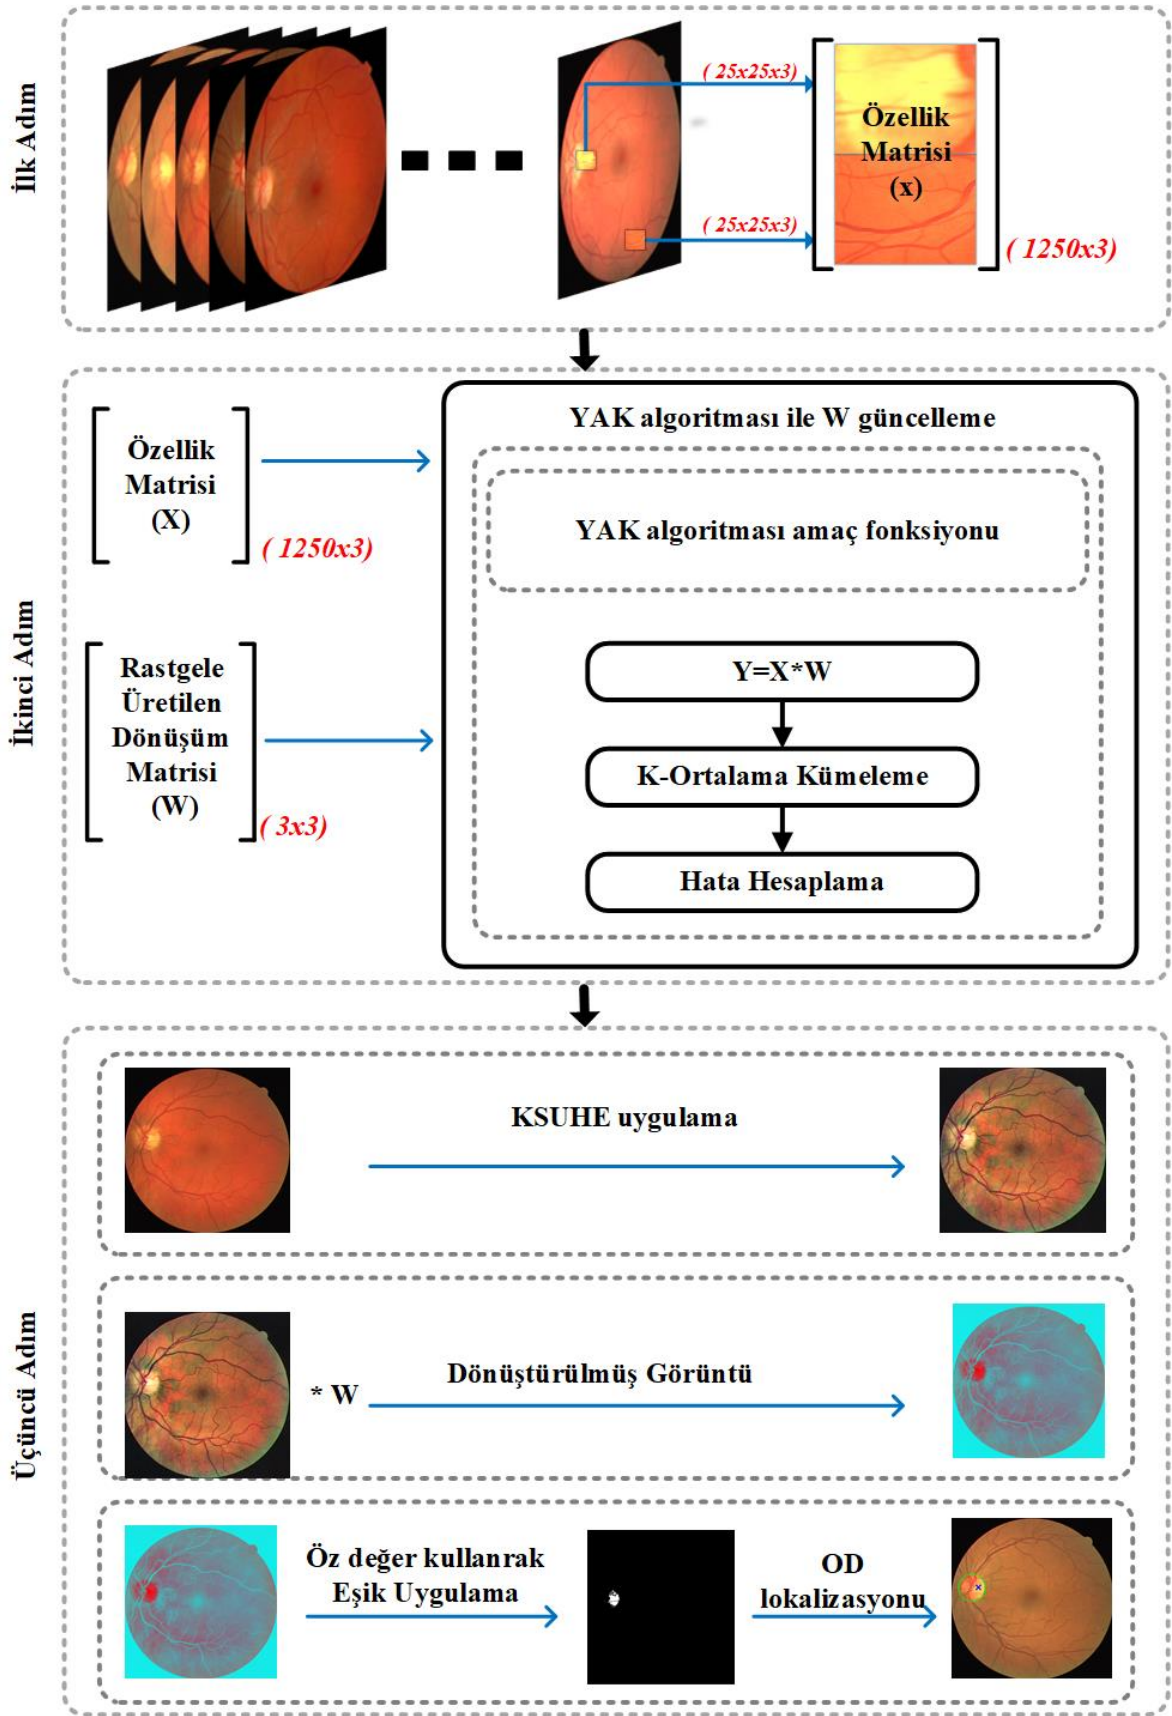
Önerilen yöntemde, KYM renk uzayındaki fundus görüntülerinin OD ve OD olmayan bölgelerinden boyutu 25x25 olan görüntü kesitleri çıkarılır. Aslında, çıkarılan her yama 25x25x3 boyutundadır. Burada üçüncü boyut KYM renk uzayının üç kanalını temsil etmektedir. OD olmayan bölgelerden alınan görüntü kesitleri fundus görüntüsünün OD içermeyen rastgele alanlarından seçilmiştir. Bu rastgele seçim ile farklı varyasyonlarda görüntü parçacıkları elde edilmiş olur. Bu durum, örnekleme alanının genişlemesine katkı

sağlamıştır. $25 \times 25 \times 3$ boyutunda elde edilen görüntü kesitleri yeniden boyutlandırılarak iki boyutlu hale getirilir. İki boyutlu matrisin boyutu 625×3 'dür. Bu boyut dönüştürmenin amacı, dönüşüm matrisinin de iki boyutlu olmasıdır. Hem OD hem de OD olmayan bölgelerden alınan ve iki boyuta dönüştürülen görüntü kesitlerinin renk piksel değerlerinin alt alta gelecek şekilde birleştirilmesi ile 1250×3 'lük bir matris oluşturulur. Bu matris özellik matrisi olarak adlandırılmış olup toplam 500 adet görüntü kesiti kullanılarak elde edilmiştir. Özellik matrisini oluşturmak için alınan görüntü kesitleri Şekil 4.1'de verilmiştir.



Şekil 4.1 : Özellik matrisi için görüntü kesitleri.

Özellik matrisinden başka ikinci bir matris daha oluşturulur. Oluşturulan bu matrisin başlangıç değerleri rastgele seçilir ve boyutu 3×3 olan bu matris dönüşüm matrisi olarak adlandırılır. Dönüşüm matrisi, orijinal fundus görüntüsünün boyutunun dönüşüm sonucunda değişmemesi için 3×3 olarak seçilmiştir. Önerilen yöntemin ilk amacı, dönüşüm matrisini özellik matrisinin değerlerine göre YAK algoritmasını kullanarak güncellemektir. En güncel dönüşüm matrisi ön işlenmiş fundus görüntüleri üzerine uygulanır. Elde edilen görüntüye uygulanan bir eşikleme sonucunda OD lokalizasyonu elde edilmiş olur. Eşikleme sonucunun başarısını arttırmak için son işlem adımları uygulanır. Son işlem adımlarında matematiksel morfolojiden yararlanılmıştır. Önerilen yöntemin akış şeması Şekil 4.2'de verilmiştir.



Şekil 4.2 : Uygulama 1 akış şeması.

4.1.1.1 Optimal dönüşüm matrisinin elde edilmesi

Retina fundus görüntüleri KYM renk uzayındadır. Bu renk uzayında yaşanan görüntü kalitesi problemi ve renk yoğunluklarının ayrıştırılma zorluğundan dolayı fundus görüntüleri yeni bir renk uzayına taşınmıştır. Bu teknik daha önce farklı alanlar içinde uygulanmış ve başarılı sonuçlar elde edilmiştir [172], [173]. Yeni renk uzayını elde etmek için OD ve OD olmayan bölgelerden alınan görüntü kesitleri ile oluşturulan özellik matrisi ve başlangıç değeri rastgele atanan dönüşüm matrisi YAK algoritmasına parametre olarak verilmiştir.

YAK algoritmasında, Eşitlik 2.30'da verilen matematiksel ifade kullanılmış ve ilk popülasyon rastgele başlatılmıştır. Popülasyon başlatıldıktan sonra işçi arı evresi başlatılmıştır. Bu evrede Eşitlik 2.31'de verilen matematiksel ifade kullanılmış ve komşuluk ilişkilerine dayalı yeni gıda kaynakları üretilmiştir. Yeni gıda kaynakları üretildikten sonra maliyet fonksiyonu hesaplanmıştır. Maliyet fonksiyonunun hesaplanması için K-ortalama kümeleme algoritması kullanılmıştır. Kümeleme algoritması parametre olarak Eşitlik 4.1'de verilen matematiksel ifadenin sonucunu alır.

$$Y = X * W \quad (4.1)$$

Burada X parametresi 1250×3 boyutlu özellik matrisini, W parametresi 3×3 boyutlu dönüşüm matrisini temsil etmektedir. Dolayısı ile bu işlemin sonucu matematiksel olarak iki matris çarpımından 1250×3 boyutlu bir matristir. Bu Y matrisin üç renk kanalı için ayrı ayrı K-ortalama kümeleme algoritması kullanılmıştır. Algoritma, matrisin ilk yarısında ve ikinci yarısında ne kadar hata oluştuğunu hesaplar. Matrisin ilk yarısında OD, ikinci yarısında OD olmayan bölgelerin renk piksel değerlerinin olması beklenir. Başka bir deyişle, matrisin ilk yarısında OD, diğer yarısı OD olmayan bölgelere ait piksel değerleri olarak etiketlenmiştir. Kümeleme sonucunda Y matrisinin ilk yarısına ait ilgili renk piksel değerleri OD bölgesine ait değilse hata olarak kabul edilmektedir. Kümeleme sonucunda Y matrisinin ikinci yarısına ait renk piksel değerleri OD olmayan bölgeye ait değilse hata olarak kabul edilmektedir. Nihayetinde toplam hata alınarak algoritmanın maaliyeti hesaplanmaktadır. Kümeleme algoritmasında uzaklık ölçüt birimi olarak Eşitlik 2.33'de verilen Öklid mesafesi tercih edilmiştir. Her renk kanalı için hesaplanan hata değeri Eşitlik 4.2 kullanılarak hesaplanmıştır.

$$E = \sum_{i=1}^3 e_{1i} + e_{2i} \quad (4.2)$$

Burada e_1 ve e_2 parametreleri matrisin ilk ve ikinci yarısından alınan hataların toplamını ifade etmektedir. Bu matrisin ilk yarısı 1 ile 625 arasındaki değerlere karşılık gelen

OD piksellerini, ikinci yarısı 626 ile 1250 arasında denk gelen OD olmayan bölgelerin renk piksel değerlerini temsil etmektedir.

Kümeleme işleminin sonucu yeni üretilen yiyecek kaynağını temsil eder. Eğer, yeni üretilen yiyecek kaynağı mevcut yiyecek kaynağından daha iyiyse, yiyecek kaynağı konumu güncellenir. Burada yiyecek kaynağı olarak bahsedilen aslında dönüşüm matrisidir. İşçi arı evresi popülasyon sayısı kadar bu işlemleri tekrar eder ve yiyecek kaynakları hesaplanır.

Elde edilen yiyecek kaynakları için olasılıklar hesaplanır ve gözcü arı evresi başlatılır. Besin kaynakları seçim olasılıklarına göre belirlenir. Bu çalışmada, Rulet tekerleği yöntemi kullanılarak olasılıksal seçim yapılmıştır. Gözcü arılar komşuluk ilişkilerini kullanarak belirlenen yiyecek kaynaklarına ilerler. Aynı işçi arı evresinde olduğu gibi yeni yiyecek kaynakları için maliyet fonksiyonu hesaplanır. Maliyet fonksiyonuna Eşitlik 4.1’de verilen matematiksel ifadenin sonucu parametre olarak verilir. Eşitlikte verilen X parametresi 1250×3 boyutlu özellik matrisini temsil ederken, W parametresi işçi arı evresinde güncellenmiş 3×3 boyutlu olan yiyecek kaynağını temsil eder. Eğer, bulunan yiyecek kaynağı mevcut yiyecek kaynağından daha iyiyse, yiyecek kaynağı konumu güncellenir. Yiyecek kaynakları daha iyi değilse terk etme sayacı 1 artırılır. Yiyecek kaynaklarının gittikçe kötüye gitmesi veya terk etme sayacının maksimuma ulaşması sonucunda kaşif arı evresi başlatılır. Kaşif arı evresinde, terk etme sayacı sınır değerinden büyükse yeni bir popülasyon oluşturulur ve terk etme sayacı sıfırlanır. En iyi besin kaynağı konumu ezberlenir ve algoritmadan çıkarılır. 500 görüntü kesiti için çalıştırılan YAK algoritması sonucunda en optimal yiyecek kaynağı yani W matrisi elde edilir. Elde edilen W optimal matrisi Eşitlik 4.3’de verilmiştir.

$$W = \begin{pmatrix} -5.2802 & -5.9726 & -1.1628 \\ 6.4346 & -4.6705 & -1.0061 \\ 10.5515 & -7.9098 & -3.7971 \end{pmatrix} \quad (4.3)$$


YAK algoritmasında kullanılan parametrelerin değerleri Çizelge 4.1’de verilmiştir.

Çizelge 4.1 : YAK parametre değerleri.

Parametre	Değer
Karar değişkeni	9
Koloni sayısı	5
Alt limit	-10
Üst limit	10
Maksimum döngü sayısı	50
Hızlandırma katsayısı	0.5

4.1.1.2 Fundus görüntülerinin yeni renk uzayına taşınması

Optimal dönüşüm matrisi ön işlenmiş fundus görüntüsü ile doğrusal olarak çarpılır. Fundus görüntüleri KSUHE yöntemi kullanılarak ön işlenmiştir. KSUHE yöntemi, renkli fundus görüntüsünün her kanalına ayrı ayrı uygulanmıştır. Her kanalın kontrastı farklı olduğu için ön işlem ayrı ayrı olarak her kanala uygulanmıştır. Şekil 4.3’de bir fundus görüntüsünün üç kanalının ön işlem sonuçları verilmiştir.



Şekil 4.3 : Sırası ile renkli fundus görüntüsü, KSUHE uygulanmış K, Y ve M kanalları.

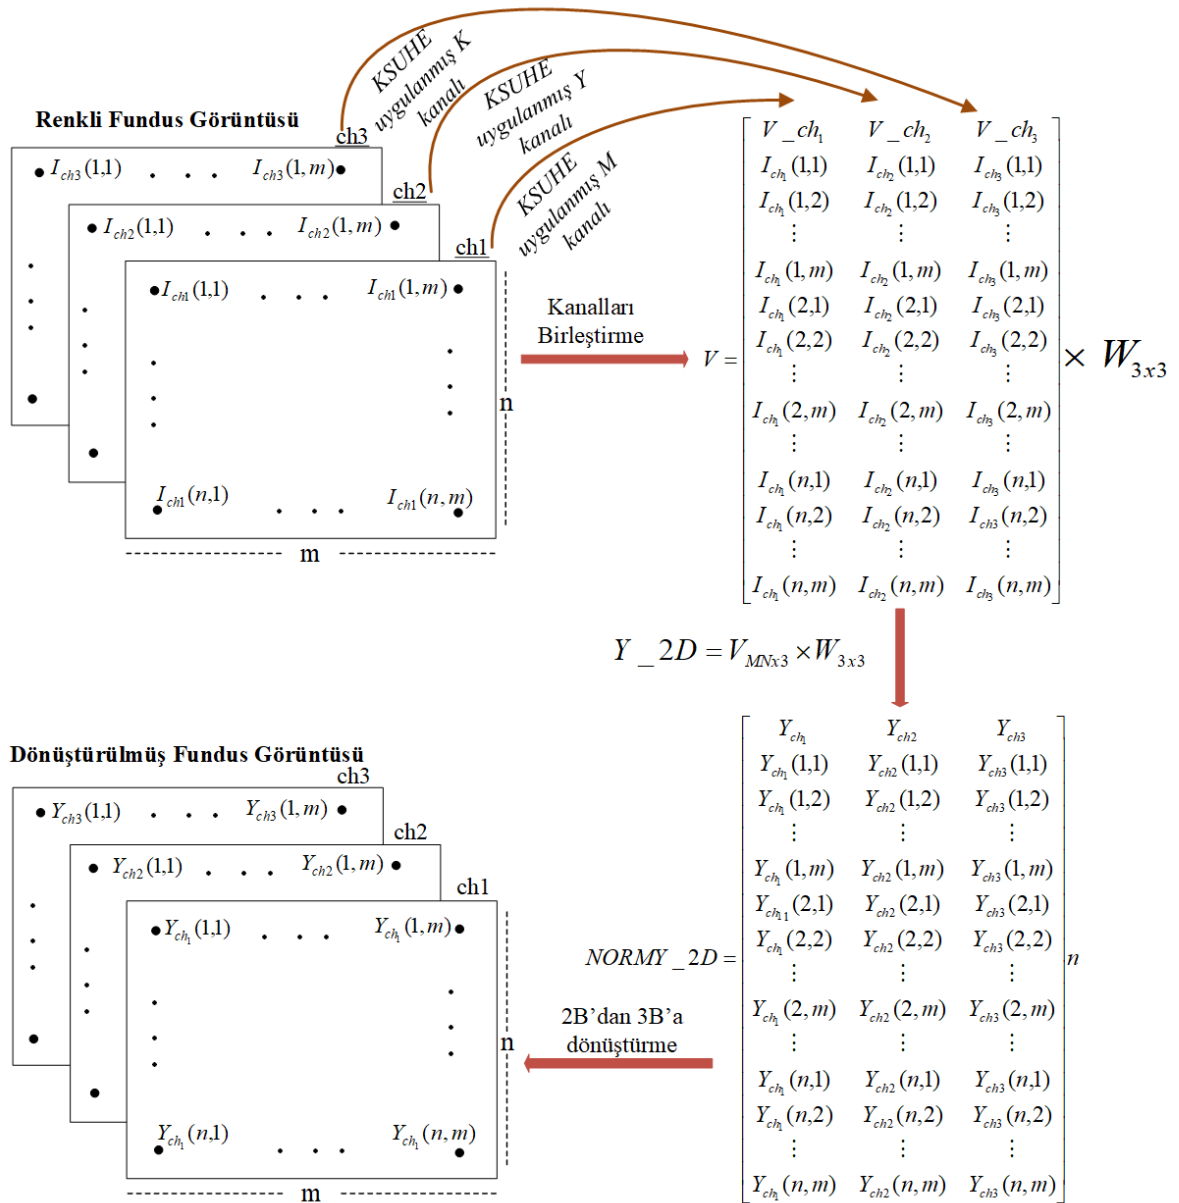
Ön işlenmiş her fundus kanalı vektör haline getirilmiş ve daha sonra bu vektörler birleştirilmiştir. Vektör haline getirilen ön işlenmiş üç kanalın birleştirilmesi ile boyutu $MN \times 3$ olan bir matris elde edilmiştir. Bu matris ile dönüşüm matrisi doğrusal olarak çarpılmıştır. Bu çarpım sonucu yeniden boyutlandırılarak yeni renk uzayındaki fundus görüntüsü elde edilmiştir. Bu işlemlerin görsel anlatımı Şekil 4.4’de verilmiştir. Elde edilen yeni renk uzayındaki fundus görüntüsünün aykırılığını yok etmek için görüntü normalleştirilmiştir. Normalleştirme işlemi için Eşitlik 4.4’de verilen matematiksel ifade kullanılmıştır.

$$NormY_ch_i = \left(\frac{ch_i - min_{norm}}{max_{norm} - min_{norm}} \right) \quad (4.4)$$

Burada, min_{norm} parametresi, ilgili kanalın minimum değerli pikselini temsil eder. max_{norm} parametresi ise ilgili kanalın maksimum değerli pikselini temsil eder. ch_i parametresi ilgili kanalı temsil eder ve $NormY_ch_i$ parametresi normalize edilmiş kanalı temsil eder. Üç kanal olduğu için i parametresi sırası ile 1,2,3 değerini alır. Normalize edilmiş yeni uzaydaki görüntü matrisi Eşitlik 4.5’de verilmiştir.

$$NormY_2D = \begin{bmatrix} NormY_ch_1 \\ NormY_ch_2 \\ NormY_ch_3 \end{bmatrix}_{MN \times 3} \times 255 \quad (4.5)$$

Burada, $NormY_2D$ parametresi $MN \times 3$ boyutunda normalize edilmiş yeni uzaydaki fundus görüntüsüdür.




Şekil 4.4 : Görüntü boyutunu dönüştürme ve tekrar orijinal haline getirme.

Bir fundus görüntüsünün KYM renk uzayından yeni renk uzayına dönüştürülme aşaması Çizelge 4.2’de algoritmik olarak verilmiştir. Halka açık olarak sunulan DRIVE, MESSIDOR ve DRIONS veri setlerine ait görüntü örneklerinin yeni uzaydaki görünümü Şekil 4.5’de verilmiştir. Bu şekile göre, bir fundus görüntüsünün parlak bölgesinin yeni rengi kırmızı olarak görülmüştür. Bu şekilde, renkli görüntülerin üç kanalı sırası ile ikinci, üçüncü ve dördüncü satırlarda peş peşe sunulmuştur. İlk iki sütun görüntüsü DRIVE veri setine, ortadaki iki sütun görüntüsü MESSIDOR veri setine ait olup son iki sütun görüntüsü DRIONS veri setine ait görüntülerdir.

Çizelge 4.2 : KYM renk uzayından yeni renk uzayına geçiş algoritması.

Giriş: KYM fundus Görüntüsü: $I(x, y)$, Dönüşüm matrisi: W
Çıkış: Yeni renk uzayı: $Y(x, y)$


1. **Giriş görüntüsü okuma**
2. $I(x, y) \leftarrow$ KYM fundus görüntüsü
3. $\text{Boyut}(I(x, y)) : m \times n \times 3$
4. **Her kanala KSUHE uygulama**
5. $I(x, y) = \{ch_1(x, y), ch_2(x, y), ch_3(x, y)\}$
6. $\text{Clahe_}ch_1(x, y) \leftarrow$ KSUHE uygulanmış ch_1 kanalı
7. $\text{Clahe_}ch_2(x, y) \leftarrow$ KSUHE uygulanmış ch_2 kanalı
8. $\text{Clahe_}ch_3(x, y) \leftarrow$ KSUHE uygulanmış ch_3 kanalı
9. **Her kanalı vektör haline dönüştürme**
10. $V_ch_1 \leftarrow \text{Clahe_}ch_1$ Kanalının vektörleşmesi $\text{size}(V_ch_1) : MN \times 1$
11. $V_ch_2 \leftarrow \text{Clahe_}ch_2$ Kanalının vektörleşmesi $\text{size}(V_ch_2) : MN \times 1$
12. $V_ch_3 \leftarrow \text{Clahe_}ch_3$ Kanalının vektörleşmesi $\text{size}(V_ch_3) : MN \times 1$
13. **Her kanalın birleştirilmesi**
14.
$$V = \begin{bmatrix} V_ch_1 \\ V_ch_2 \\ V_ch_3 \end{bmatrix}_{MN \times 3}$$
15. **Yeni uzaydaki iki boyutlu görüntü**
16. $Y_2D(x, y) = \text{double}(V) * W$
17. **Normalize edilmiş görüntü**
18. $\text{Norm}Y_2D(x, y) = Y_2D(x, y)$ Görüntüsünün normalize edilmesi
19. **Yeni uzayda orijinal görüntü**
20. $Y(x, y) = \text{Norm}Y_2D(x, y)$ Görüntüsünün orijinal boyuta dönüştürülmesi



Şekil 4.5 : Veri seti görüntülerinin yeni renk uzayındaki görünümleri. İlk satır yeni uzayı, ikinci satır birinci kanalı, üçüncü satır ikinci kanalı ve son satır üçüncü renk kanalını temsil eder.

4.1.2 YAK tabanlı yeni renk uzayındaki OD lokalizasyonunun tespit sonucu

Yeni renk uzayına dönüştürülen görüntüler üzerinde OD bölgesini bulmak için bu görüntülere eşikleme işlemi uygulanmıştır. Eşikleme işlemi öz değerlere dayalı olarak gerçekleştirilmiştir. Eşikleme işleminden sonra morfolojik bir prosedür uygulanarak aday OD bölgesi bulunmuştur. Eşikleme işlemi ilk olarak yeni renk uzayındaki iki boyutlu görünümün öz değerlerini içerir. Bu görüntünün üç öz değeri vardır. Her görüntünün maksimum öz değeri alınmıştır. Eşiklenmiş görüntü, görüntünün mevcut kanalının maksimum öz değeri ile yeni uzaydaki görüntünün çarpılması sonucu elde edilmiştir. Bu eşikleme işlemi sonucunda OD aday bölgesi elde edilmiştir. Şekil 4.6'da DRIVE, MESSIDOR ve DRIONS veri setlerinden alınan çeşitli görüntülere ait eşikleme sonuçları gösterilmektedir. Bu yöntemin temel amacı, yeni renk uzayındaki fundus görüntüsüne eşik uygulayarak OD lokalizasyonunu basit bir şekilde tespit etmektir. Eşiklenmiş görüntüler, siyah beyaz ikili görüntülere dönüştürülmüş ve bu görüntülere matematiksel morfoloji uygulanmıştır. Morfolojik işlemler, birbirini takip eden dört adımdan oluşmaktadır. Birinci adımda, 300 pikselden küçük tüm nesnelere görüntüden kaldırılmıştır. İkinci adımda, yarıçapı 15 piksel olan dairesel bir yapı elemanı oluşturulmuştur. Üçüncü adımda, dilatasyon işlemi uygulanmıştır. Morfolojik işlemlerin son adımında ise OD aday bölgesi işaretlenmiştir.



Şekil 4.6 : Yeni renk uzayındaki görüntülerin eşikleme sonuçları. İlk satır yeni uzayı, ikinci satır eşiklenmiş görüntüyü, üçüncü satır eşiklenmiş ikili görüntüyü ve son satır morfoloji uygulanmış ikili görüntüyü temsil eder.


Aday OD bölgeleri arasında tahmini sonucu elde etmek için her adayın dairesellik değeri incelenir. OD'in geometrik yapısı düşünüldüğünde aslında dairesel bir yapıya

sahiptir. Aday bölgelerin dairesel veya dairesele yakın bir şekile sahip olması beklenir. Bunun için dairesel yapıya uymayan ve daireselliği 0.35'ten küçük olan nesnelere aday bölgeden çıkarılır. Burada 0.35 parametresi, deneysel olarak bulunan ve daireselliği temsil eden bir parametredir. Başka bir deyişle, yaklaşık 100 görüntü üzerinde 0.35'ten küçük nesnelere OD bölgesi olmadığı gözlemlenmiştir. Kalan aday bölgeler için maksimum yuvarlaklık kriterini karşılayan nesne OD bölgesi olarak seçilir. Bir cismin dairesellik değeri Eşitlik 4.6'da verildiği gibi hesaplanır.

$$CV=(4 \times \text{Alan} \times \pi) / (\text{Çevre}^2) \quad (4.6)$$

Burada, CV parametresi dairesellik değerini temsil eder.

İşaretlenmiş aday OD bölgeleri Şekil 4.7'de verilmiştir. Mavi çarpı işareti tespit edilen lokalizasyon noktasını temsil ederken yeşil daire ise fundus görüntüsünün OD bölgesini temsil etmektedir.



Şekil 4.7 : Veri seti görüntüleri üzerinde işaretlenmiş OD aday bölgeleri.


4.1.3 Önerilen yöntemin performans karşılaştırması

Yeni renk uzayındaki fundus görüntülerine uygulanan bir eşikle OD lokalizasyonu kolaylıkla tespit edilmektedir. Bu bölümde, önerilen yöntemin doğruluğunu ve sağlamlığını test etmek için yöntemin diğer güncel yöntemlerle karşılaştırılması yapılmıştır. Karşılaştırma tablosu Çizelge 4.3'de verilmiştir. Yöntemler arasında karşılaştırma ölçütü olarak *Doğruluk* metriği kullanılmıştır.

Çizelge 4.3 : Önerilen yöntemin diğer yöntemlerle performans karşılaştırması.

Yazarlar	Kullanılan veri seti	Görüntü sayısı	Performans ölçütü
[174]	DRIVE	40	0.9250
[175]	MESSIDOR	1200	0.98
[12]	MESSIDOR	1200	0.9908
[176]	DRIVE	40	0.95
[23]	DRIVE	40	1
[26]	DRIONS	110	0.9672
	MESSIDOR		0.98
[177]	DRIVE	40	1
[178]	DRIVE	40	0.90-0.95
Önerilen Yöntem	DRIVE	40	1 (40/40)
	MESSIDOR	1200	0.9442 (1133/1200)
	DRIONS	110	0.9637 (106/110)


Önerilen yöntemde başarısız olarak işaretlenmiş görüntüler vardır. Bu görüntülerden dört tanesi image_065, image_084, image_102 ve image_110 adlı DRIONS veri setine ait görüntülerdir. Bu görüntülerden image_084 görüntüsü OD aday bölgeleri dairesellik değerinden düşük olduğu için başarısız olmuştur. Image_065, image_102 ve image_110 görüntülerinde en az iki aday bölge ortaya çıkmıştır. Bu aday bölgelerden maksimum dairesellik değerine sahip bölge OD bölgesi olarak işaretlenmiş ancak morfolojik işlem adımında aday bölge seçimi yanlış seçilmiştir. Şekil 4.8’de image_065 adlı görüntüsüne ait OD aday bölgeleri beyaz olarak gösterilmiştir. Nihayetinde, morfolojik işlem adımlarının başarı oranını etkilediği görülmüştür. Çizelge 4.3 incelendiğinde DRIVE veri setinden tam başarı elde edilmiştir. MESSIDOR veri setinden 0.9442 oranında bir doğruluk elde edilmiştir.



Şekil 4.8 : Hatalı tespit edilen OD lokalizasyonu. (a) renkli fundus görüntüsü, (b) yeni uzaya taşınmış görüntü, (c) eşikleme sonucu, (d) seçilen OD aday bölgesi.


MESSIDOR veri setindeki bazı görüntüler başarısız olarak işaretlenmiştir. Bu başarısızlık temelde iki probleme dayanmaktadır. İlk olarak, MESSIDOR veri setinde hiç OD bölgesi olmayan görüntüler vardır. Bu durum, başarı oranını olumsuz etkilemiştir. Çünkü OD

bölgesi neredeyse fundus görüntüsünün geri kalanından farklı değildir. Şekil 4.9'da bu görüntülerden bazıları gösterilmiştir.



Şekil 4.9 : OD bölgesi net olmayan MESSIDOR veri seti görüntüleri.

İkinci olarak, MESSIDOR veri setindeki görüntülerin farklı renk ve yoğunluklara sahip olmasıdır. Önerilen bu yöntem, veri kümesinden bağımsız olarak oluşturulmuştur. Ancak, özellik matrisi, 500 görüntü yamasının renk piksel değerleriyle sınırlıdır. Bu nedenle yeni renk uzayında MESSIDOR veri seti görüntülerinde OD bölgesinin renk piksel ayrımı zor olmuştur. Ancak önerilen yöntem, bu değişken veri kümesiyle bile tatmin edici bir başarı elde etmiştir. MESSIDOR veri setinin renk varyasyonu Şekil 4.10'da birkaç görüntü ile sunulmuştur.



Şekil 4.10 : Farklı yoğunluk ve renge sahip MESSIDOR veri seti görüntüleri.

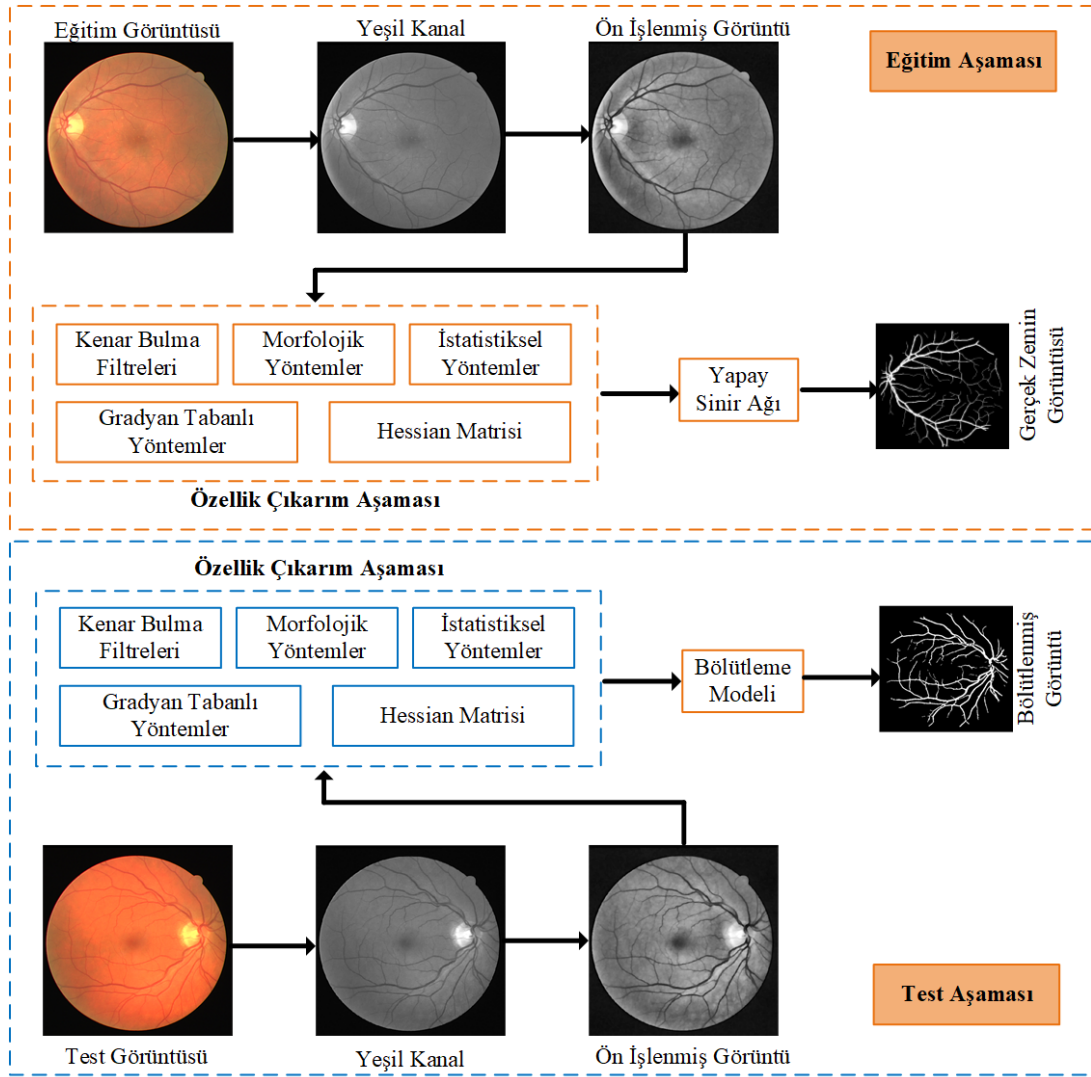
4.2 Uygulama 2: Piksel Tabanlı Retina Damar Bölütleme

Retina fundus görüntüleri üzerinde kan damar analizi yapılarak birçok hastalık bilgisine ulaşılabilir. DR hastalığı, retina kan damar analizi ile anlaşılan hastalıklardan sadece biridir. DR hastalığının erken evrede tespit edilmesi görme kaybının önüne geçilmesi için iyi bir fırsattır. Bu nedenle bu uygulamanın amacı klasik yöntemlerle retina kan damar analizi yaparak retina damarlarını doğru ve sağlam bir şekilde bölütlemek olmuştur. Önerilen uygulamada, retina fundus görüntüleri üzerinde piksel tabanlı öznelik çıkarımı yapılmıştır. Öznelik çıkarımı beş farklı öznelik grubu kullanılarak gerçekleştirilmiştir. Bu öznelik grupları, kenar algılama yöntemleri, morfolojik özellikler, istatistiksel özellikler, gradyan tabanlı özellikler ve Hessian matrisidir.

Önerilen uygulamanın performans değerlendirmesi halka açık olarak sunulan DRIVE ve STARE veri kümesi kullanılarak yapılmıştır. Bu yöntemin başarısı *Doğruluk*, *Hassaslık* ve *Özgüllük* parametreleri kullanılarak elde edilmiştir.

4.2.1 Piksel tabanlı özellikler ile retina kan damarlarının bölütlenmesi

Önerilen yöntemde, retina fundus görüntülerinden piksel tabanlı öznelikler çıkarılmış ve retina kan damarlarının bölütlenmesi sağlanmıştır. Öznelik çıkarma işleminden önce, retina fundus görüntüleri bir ön işlemden geçirilmiştir. Ön işlenmiş görüntüler üzerinden piksel tabanlı özellikler çıkarılmıştır. Her retina kan damar pikseli için 18 boyutlu bir özellik vektörü oluşturulmuştur. Bu özellik vektörü bir YSA'ya girdi olarak verilmiştir. YSA, bu özellik vektörlerine göre eğitilmiş ve ardından DRIVE ve STARE veri setleri üzerinde test edilmiştir. Önerilen yöntemin akış şeması Şekil 4.11'de verilmiştir.



Şekil 4.11 : Uygulama 2 akış şeması.


4.2.1.1 Ön işlem aşaması

Ön işlem aşamasında uygulanan yöntemler, ilgili fundus görüntüsünün görüş alanı üzerinde yani sadece retinal görüntü üzerinde uygulanmış olup bu bölge İB alanı olarak seçilmiştir. Burada amaç, sonraki işlem adımlarını hızlandırmak için ilgili alan dışındaki koyu pikselleri görüntüden çıkarmaktır. Retina görüntülerinde İB alanını belirlemek için DRIVE veri kümesi içerisinde verilen maske görüntüleri kullanılmıştır. Ancak, STARE veri kümesinde hazır maske görüntüleri verilmediği için bu veri setine ait İB alanı manuel olarak oluşturulmuştur.

Retina fundus görüntülerinde, düzgün olmayan aydınlanma koşulları ve düşük kalite problemi bulunmaktadır. Bu nedenle, retina kan damarlarının bölütlenmesinden önce fundus görüntüleri ön işlemden geçirilmiştir. Ön işlem aşaması sonucunda elde edilen görüntüler


bölütleme sonucuna önemli ölçüde katkı sağlamıştır. Ön işlem aşaması retina görüntüsünün yeşil kanalı üzerinde gerçekleştirilmiştir. Bu aşama da uygulanan yöntemler sırası ile morfolojik açma işlemi, KSUHE ve medyan filtrelemedir.

Morfolojik açma işlemi, farklı ışık yoğunluğu nedeni ile oluşan merkezi ışık reflekslerini ortadan kaldırmak için uygulanmıştır. Normalde, bir kan damarının sadece iki kenarı ve bir merkez çizgisi vardır. Ancak, merkezi ışık refleksi içeren bir kan damarında iki ayrı damar varmış gibi bir görüntü oluşur. Bu hatalı görünümü ortadan kaldırmak için fundus görüntüsünün yeşil kanalı üzerine morfolojik açma işlemi uygulanmıştır. Burada kullanılan yapısal eleman yarıçapı 2 olan bir diskdir. Şekil 4.12’de bir ışık refleksi görüntüsü verilmiştir.



Şekil 4.12 : Bir fundus görüntüsüne ait merkezi ışık refleksleri.

Merkezi ışık refleksinden arındırılan görüntü üzerine KSUHE algoritması uygulanmıştır. Bu yöntem, nesnelere ve görüntünün arka planı arasındaki kontrastı arttırmada etkili olduğu için kullanılmıştır. KSUHE sonucunda retina damarları ve arka plan arasındaki kontrast artmış olur. KSUHE uygulanmış görüntüye Medyan filtresi uygulanarak görüntü yumuşatılır ve ön işlem aşaması sonlanır. Bir fundus görüntüsünün yeşil kanalına uygulanan ön işlem süreci Şekil 4.13’de verilmiştir.



Şekil 4.13 : Sırası ile fundus görüntüsünün Y kanalı, ışık refleksi yok edilmiş görüntü, KSUHE uygulanmış görüntü ve medyan filtresi uygulanmış son görüntü.

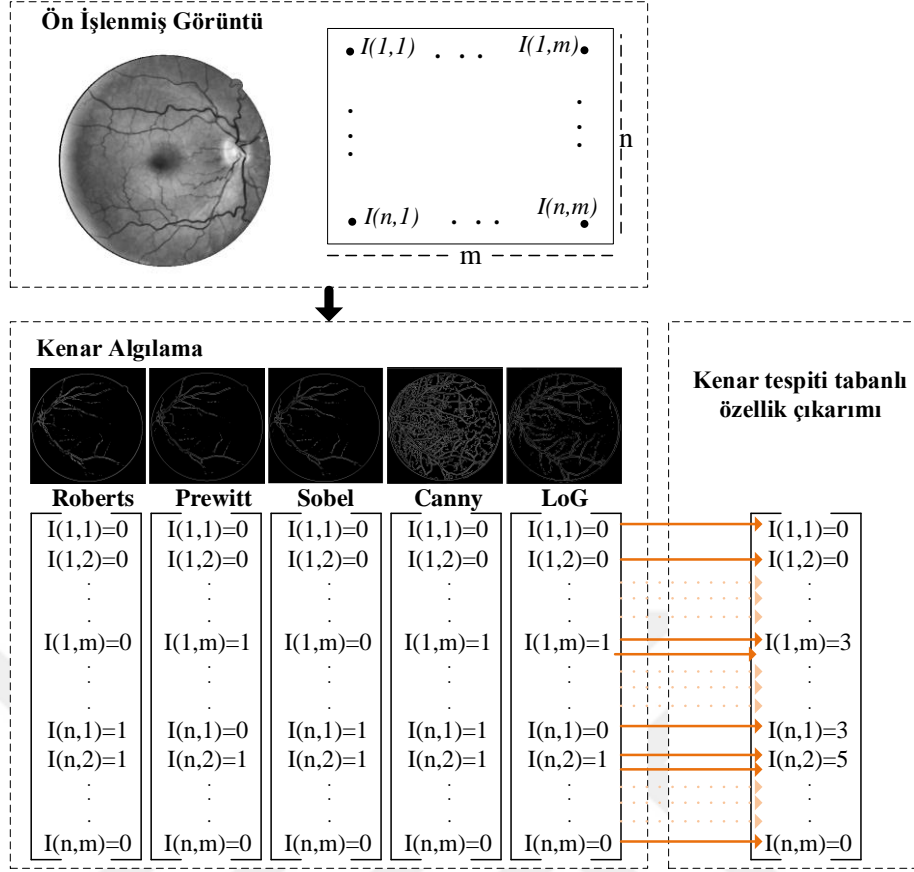
4.2.1.2 Özellik çıkarım aşaması

Önerilen yöntemin bu aşamasında bir fundus görüntüsüne ait her pikselden 18 adet özellik çıkarılmıştır. Damar olan piksellerin etiketlemesi 1, damar olmayan piksellerin etiketlenmesi ise 0 olarak belirlenmiştir. Bir pikselden çıkarılan özellikler Çizelge 4.4’de verildiği gibidir.

Çizelge 4.4 : Her pikselden çıkarılan özellikler.

Özellik (Boyutu)	Özellik Türleri
Kenar Algılama (1)	Birleştirme (Roberts, Prewitt, Sobel, Canny, Log)
Morfolojik (2)	Üst-şapka dönüşümü, Alt-şapka dönüşümü
İstatistiksel (8)	Ortalama, Minimum, Maksimum, Çarpıklık, Standart sapma, Ortalama mutlak hata, Kare toplamının karekökü
Gradyan Tabanlı (4)	X yönünde birinci türev, Y yönünde birinci türev, Gradyan büyüklüğü, Gradyan yönü
Hessian Matrisi (3)	Gradyan X’in ikinci türevi, Gradyan Y’nin ikinci türevi, X yönünde Y’nin Gradyanı, Y Yönünde X’in Gradyanı

Bir retina kan damarını, fundus görüntüsü üzerinde ayırt etmenin en iyi yöntemlerinden biri damarların kenarlarını çıkarmaktır. Bu tez çalışmasında beş farklı kenar algılama yöntemi kullanılmıştır. Kenar algılama yöntemleri, matematiksel bir birleştirme işleminden geçirilerek tek bir özellik olarak sunulmuştur. Beş farklı kenar algılama yönteminin hepsi retina fundus görüntüleri üzerine uygulanmıştır. Bu yöntemlerin hepsinde de kenar olarak kabul edilen bir özellik varsa o pikselin özelliği 5 olarak kabul edilmiştir. Böylece, nihai özellik vektöründe kan damar olasılığı vurgulanmıştır. Ayrıca, özelliklerin sınıflandırılma sürecinde bu özellikleri temsil eden tek bir özelliğin kullanılması eğitim sürecini hızlandırmaktadır. Buraya kadar anlatılan kenar algılama yöntemlerinden özellik çıkarım süreci Şekil 4.14’de verilmiştir.



Şekil 4.14 : Kenar algılama yönteminden çıkarılan özellikler.

Morfolojik süreçler, görüntünün ön ve arka plan arasındaki ayrımını ortaya çıkarmada oldukça etkilidir. Fundus görüntülerinin arka plan yoğunluk seviyesi üzerinde minimum etkisi olan kan damarlarına netlik sağlamak için üst şapka ve alt şapka dönüşümleri özellik çıkarım aşamasında kullanılmıştır. Morfolojik işlemler için yapısal element olarak çizgi operatörü belirlenmiştir. Bu yapısal elementin uzunluğu 11 pikseldir. Bu piksel boyutu, yaklaşık en büyük çap değeri aralığının [60] yarısına denk gelmektedir. Retina piksellerinden çıkarılan özelliklerden bir diğeri ise istatistiksel özelliklerdir. İstatistiksel özellikler, her retina pikselinden sekiz özellik olarak çıkarılmıştır. Bu özellikleri çıkarmak için 21×21 piksel boyutunda bir pencere oluşturulmuştur. Bu pencere, fundus görüntüsünün İB alanı içerisinde gezdirilmiş ve pencerenin değdiği her alandan sekiz özellik çıkarılmıştır. Bu sekiz özellik pencerenin içerisinde bulunan piksellerin merkez pikselinin özelliği olarak ayarlanmıştır. Merkez pikseller, ilgili pencerenin istatistiksel özelliğini temsil eder. Bu özellikler bu tez çalışmasının ikinci bölümünde tanıtılmıştır. Fundus görüntülerindeki kan damarı görüntülerinin istatistiksel değeri arka plandan oldukça farklıdır. Bu keskin fark nedeniyle, istatistiksel özellikler özellik çıkarım aşamasına dâhil edilmiştir. Gezdirilen pencerenin 21×21 boyutunda seçilmesine önceki çalışmalardan esinlenerek karar verilmiştir.

[60]. Bu boyut yaklaşık olarak en büyük damarların çap aralığındadır. Retina kan damarları ve arka plan arasında yoğunluk farkı bulunmaktadır. Bu nedenle, damar ile damar olmayan pikseller arasında bir gradyan olduğundan şüphelenilmektedir. Gradyan özellik vektörünün büyüklüğü, damar yönüne dik yönde maksimumdur. Bu nedenle gradyan vektörü öznelik vektörüne dâhil edilmiş ve buradan da dört öznelik çıkarılmıştır. İkinci türevlerin sıfır geçişlerini vurguladığı bilgisine dayanarak Hessian matrisi de öznelik çıkarım aşamasında kullanılmıştır. Hessian matrisinin değerleri, retina kan damarlarının sıfır geçiş bilgisine erişmek için kullanılmıştır.

4.2.1.3 Sınıflandırma aşaması

Her pikselden çıkarılan özellikler damar ve damar değil olarak işaretlenmiştir. Bu işaretlenmiş verilerin bir kısmı ile yapay sinir ağı eğitilmiştir. Verilerin geri kalan kısmı ile de test işlemi gerçekleştirilmiştir. Bu tez çalışmasında kullanılan yapay sinir ağ girdi katmanı, çıktı katmanı ve iki gizli katmandan oluşmaktadır. Giriş katmanına, retina kan damarı görüntülerinin her pikselinden çıkarılan 18-B özellik vektörü verilmiştir. Birinci ve ikinci gizli katmanlarda, bir aktivasyon fonksiyonu olarak hiperbolik tanjant sigmoid gizli katmanlar için kullanılmış olup çıkış katmanı için sigmoid fonksiyonu kullanılmıştır. Bu fonksiyonun avantajı, türevinin dik olmasından dolayı daha çok değer alabiliyor olmasıdır. Bu durum, bu fonksiyonun daha hızlı öğrenme gerçekleştireceğini göstermektedir. Yapay sinir ağı yapısı olarak bu tez çalışmasında ileri beslemeli sinir ağı kullanılmıştır. Bu çalışmada kullanılan yapay sinir ağı için diğer tüm parametreler Çizelge 4.5’de verilmiştir.

Çizelge 4.5 : Yapay sinir ağı parametreleri.

Parametreler	Değerler
Giriş katmanındaki nöron sayısı	18
Çıkış katmanındaki nöron sayısı	1
Gizli katmandaki nöron sayısı	10,4
İterasyon sayısı	400
Öğrenme oranı	0.01
Momentum oranı	0.001
YSA mimarisi	İleri beslemeli
Aktivasyon fonksiyonu	Hiperbolik tanjant sigmoid
Performans fonksiyonu	Ortalama kare hata
Öğrenme algoritması	Levenberg-Marquardt

4.2.2 Piksel tabanlı özellikler ile retina kan damarlarının bölütlenme sonucu

Önerilen yöntemin performans sonuçları halka açık olarak sunulan DRIVE ve STARE veri setleri üzerinden alınmıştır. Önerilen beş özellik grubundan en uzun çalışma süresine

sahip grup istatistiksel özellikler olmuştur. Bu özellik grubu DRIVE veri seti için ortalama 2195 s’de tamamlanmıştır. Morfolojik işlemler için bu süreç 540 s, gradyan tabanlı özellikler için 550 s ve Hessian matrisi için 1567 s’dir. Bu özellikler, retina kan damar ayırımında kullanılan klasik özelliklerdir. Elde edilen sonuçlar, karmaşık yöntemlerden daha iyi sonuç vermiştir. Bu yöntemde dikkat edilmesi gereken bir nokta sınıf dengesizliğine rağmen yöntemin başarılı sonuç üretmesidir. Çünkü DRIVE veri seti için damar olmayan pikseller damar piksellerinin yaklaşık 7 katıdır. STARE veri seti için ise bu oran yaklaşık 9 kattır. Önerilen yöntem DRIVE veri seti için 20 eğitim ve 20 test görüntüsünden oluşmaktadır. STARE veri seti için bu oran 10 eğitim görüntüsü ve 10 test görüntüsü olarak belirlenmiştir. Yöntemin DRIVE veri seti için test sonuçları Çizelge 4.6’da verilmiştir.

Çizelge 4.6 : Önerilen yöntemin sonuçları (DRIVE).


Görüntü Numarası	Hassashk	Özgüllük	Doğruluk	Jacc.	Dice	Çalışma Zamanı (s)
01_test	0.8020	0.9775	0.9625	0.6470	0.7856	32.0259
02_test	0.8730	0.9740	0.9469	0.6918	0.8178	32.0587
03_test	0.8564	0.9644	0.9559	0.6028	0.7521	33.7486
04_test	0.8798	0.9716	0.9648	0.6511	0.7887	32.9376
05_test	0.8915	0.9660	0.9608	0.6132	0.7603	34.2792
06_test	0.9046	0.9601	0.9564	0.5794	0.7337	31.3810
07_test	0.8582	0.9687	0.9607	0.6132	0.7602	32.6636
08_test	0.8578	0.9646	0.9580	0.5573	0.7157	31.5808
09_test	0.8963	0.9667	0.9628	0.5714	0.7273	33.0012
10_test	0.8497	0.9723	0.9641	0.6115	0.7589	31.5112
11_test	0.8151	0.9726	0.9602	0.6173	0.7634	32.8934
12_test	0.8476	0.9707	0.9662	0.6097	0.7576	34.4857
13_test	0.8798	0.9633	0.9572	0.5982	0.7486	34.1442
14_test	0.7664	0.9793	0.9621	0.6201	0.7655	34.2562
15_test	0.7024	0.9840	0.9612	0.5944	0.7456	33.9075
16_test	0.8600	0.9716	0.9633	0.6358	0.7773	32.0855
17_test	0.8467	0.9674	0.9597	0.5721	0.7278	33.8561
18_test	0.7814	0.9756	0.9615	0.5952	0.7462	33.5583
19_test	0.8320	0.9831	0.9709	0.6983	0.8224	34.0188
20_test	0.7998	0.9786	0.9666	0.6164	0.7627	32.1597
Ortalama	0.8400	0.9716	0.9618	0.6148	0.7609	33.0277

Çizelge 4.6’da verilen sayısal ifadelerle göre DRIVE veri setinde ortalama doğruluk 0.9618 ve çalışma süresi yaklaşık 33 saniyedir. Yöntemin STARE veri seti için test sonuçları Çizelge 4.7’de verilmiştir. Bu çizelgeye göre STARE veri setinde ortalama doğruluk oranı 0.9456 ve çalışma süresi yaklaşık 40 saniyedir.

Çizelge 4.7 : Önerilen yöntemin sonuçları (STARE).

Görüntü Numarası	Hassashk	Özgüllük	Doğruluk	Jacc.	Dice	Çalışma Zamanı (s)
Im0001.ah	0.6380	0.9782	0.9462	0.5275	0.6906	40.5045
Im0002.ah	0.5611	0.9790	0.9437	0.4569	0.6272	40.4365
Im0003.ah	0.3784	0.9904	0.9070	0.3568	0.5229	41.2735
Im0004.ah	0.7936	0.9596	0.9522	0.4268	0.5983	41.2045
Im0005.ah	0.5654	0.9727	0.9250	0.4688	0.6384	40.9699
Im0044.ah	0.6163	0.9842	0.9512	0.5309	0.6935	41.0432
Im0077.ah	0.6852	0.9911	0.9589	0.6369	0.7781	40.9554
Im0081.ah	0.6948	0.9922	0.9633	0.6478	0.7863	41.2177
Im0082.ah	0.8189	0.9892	0.9749	0.7327	0.8457	41.0351
Im0139.ah	0.5567	0.9872	0.9337	0.5107	0.6761	40.4080
Ortalama	0.6308	0.9824	0.9456	0.5296	0.6860	40.9048

Önerilen yöntemin DRIVE ve STARE veri setleri üzerinde retina kan damarlarının bölütlenmesi Şekil 4.15’de verilmiştir. Bu şekilde ilk üç sütundaki görüntüler DRIVE veri setine, son üç sütundaki görüntüler ise STARE veri setine aittir. İlk satır, orijinal fundus görüntülerini, ikinci satır gerçek zemin görüntülerini ve son satır ise bölütleme sonuçlarını temsil etmektedir.



Şekil 4.15 : Bölütlenmiş retina kan damarları. İlk üç sütun DRIVE görüntülerini, son üç sütun ise STARE görüntülerini temsil eder.

4.2.3 Önerilen yöntemin performans karşılaştırması

Bu bölümde, önerilen yöntemin doğruluğunu ve sağlamlığını test etmek için yöntemin diğer güncel yöntemlerle karşılaştırılması yapılmıştır. DRIVE veri seti için karşılaştırma tablosu Çizelge 4.8’de verilmiştir. STARE veri seti için karşılaştırma tablosu ise Çizelge 4.9’da verilmiştir. Yöntemler arasında karşılaştırma ölçütü olarak *Hassashk*,

Özgüllük ve Doğruluk performans metrikleri kullanılmıştır. Çizelge 4.9 yorumlanırken dikkat edilmesi gereken bir nokta vardır. Bu nokta, STARE veri seti için İB alanının manuel olarak oluşturulmasıdır. İB alanı aslında görüş alanıdır. Bu durum mukayese için az da olsa dengesizliğe neden olabilir. Ama büyük ölçüde bir sorun değildir.

Çizelge 4.8 : Önerilen yöntemin performans karşılaştırması (DRIVE).

Yıl	Yöntem	Hassashk	Özgüllük	Doğruluk.
2013	Odstrcilik ve diğ. [179]	0.7807	0.9712	0.9473
2013	Wang ve diğ. [63]	---	---	0.9461
2015	Roychowdhury ve diğ. [180]	0.739	0.978	0.949
2015	Azzopardi ve diğ. [81]	0.7655	0.9704	0.9442
2016	Maharjan ve diğ. [181]	0.6411	0.9625	0.9349
2017	Zhu ve diğ. [90]	0.7140	0.9868	0.9607
2017	Dash ve diğ. [88]	0.719	0.976	0.955
2019	Yan ve diğ. [182]	0.7631	0.9820	0.9538
2019	Sazak ve diğ. [101]	0.718	0.981	0.959
2019	Khan ve diğ. [183]	0.7696	0.9651	0.9506
2019	Lin ve diğ. [184]	0.7632	---	0.9536
2020	Tamim ve diğ. [185]	0.7542	0.9843	0.9607
2020	Kushol ve diğ. [186]	0.7588	0.9748	0.9456
2020	Orujov ve diğ. [103]	0.838	0.957	0.939
2020	Shukla ve diğ. [187]	0.7015	0.9836	0.9476
2021	Tchinda ve diğ. [108]	0.7352	0.9775	0.9480
2021	Dikkala ve diğ. [188]	0.6340	0.9803	0.9476
	Önerilen Yöntem	0.8400	0.9716	0.9618

Çizelge 4.8’de önerilen yöntemin DRIVE veri seti üzerinden elde edilen sonuçları 17 farklı güncel yöntemle kıyaslanmıştır. Çizelge 4.9’da ise önerilen yöntemin STARE veri seti üzerinden elde edilen sonuçları 12 farklı güncel yöntemle kıyaslanmıştır.

Çizelge 4.9 : Önerilen yöntemin performans karşılaştırması (STARE).

Yıl	Yöntem	Hassashk	Özgüllük	Doğruluk
2000	Hoover ve diğ. [168]	0.6747	0.9384	0.9348
2006	Soares ve diğ. [189]	0.7207	0.9747	0.9479
2011	You ve diğ. [58]	0.7260	0.9756	0.9479
2016	Maharjan ve diğ. [181]	0.6162	0.9615	0.9353
2019	Yan ve diğ. [182]	0.7735	0.9857	0.9638
2019	Sazak ve diğ. [101]	0.730	0.979	0.962
2019	Khan ve diğ. [183]	0.7521	0.9812	0.9513
2020	Tamim ve diğ. [185]	0.7806	0.9825	0.9632
2020	Kushol ve diğ. [186]	0.7798	0.9746	0.9528
2020	Orujov ve diğ. [103]	0.8342	0.8806	0.865
2020	Shukla ve diğ. [187]	0.7023	0.9863	0.9573
2021	Tchinda ve diğ. [108]	0.7265	0.9759	0.9548
	Önerilen Yöntem	0.6308	0.9824	0.9456

Önerilen yöntemde, iki veri seti için çapraz eğitim/test işlemi yapılmıştır. STARE veri seti üzerinde eğitilen verilerin DRIVE veri seti üzerinde test edilmesi ile 0.9563 oranında bir doğruluk ölçütü hesaplanmıştır. DRIVE veri seti üzerinde eğitilen verilerin STARE veri seti üzerinde test edilmesi ile bu oran 0.9431 olarak ölçülmüştür.

Önerilen yöntemin, performans karşılaştırılmasında kullanılan diğer güncel yöntemlerin çalışma zamanları Çizelge 4.10'da verilmiştir.

Çizelge 4.10 : Diğer güncel yöntemlerin çalışma süresi.

Yazar	Kullanılan Yöntem	Çalışma Zamanı
[179]	Uyum süzgeci	3,22 sn. (Bir görüntünün ortalama hesaplama süresi (DRIVE ve STARE))
[63]	Hiyerarşik ayrıştırma yöntemleri	3.5 dk. (yedi ayrıştırma içeren bir görüntüyü işlemek için.)
[180]	Uyum süzgeci	2,45 sn. (DRIVE) 3,9587 s (STARE)
[81]	COSFIRE filtresi	10 sn. (DRIVE ve STARE'den tek bir görüntü)
[181]	Denetimli ve denetimsiz bir yöntem	~25 dk. (eğitim) ve ~5 sn. (test) (DRIVE ve STARE)
[90]	Piksel tabanlı özellik	Ortalama 12.1602 sn (DRIVE)
[88]	Ortalama-C eşikleme	1,66 sn. (DRIVE)
[182]	Derin öğrenme	---
[101]	Morfolojik	3,8 sn. (Ortalama DRIVE hesaplama süresi) 4,9 sn. (Ortalama hesaplama süresi STARE)
[183]	Hat detektörü	18,0 sn (DRIVE ve STARE)
[184]	Derinlemesine Denetimli ve Sorunsuz Düzenlenmiş Ağ	12 sa. (tek bir GPU üzerinde bir modeli eğitmek) 0,3 sn. (test)
[185]	Denetimli öğrenme	---
[186]	Bendlet dönüşümü	---
[103]	Kontur tespiti tabanlı bir yöntem	~1010 ms (DRIVE ve STARE için ortalama yürütme süresi)
[187]	Yerel bir kovaryans matrisinin kesirli filtre ve özdeğer haritası	1.416 sn. (Anormal STARE)
[108]	Klasik kenar algılama filtreleri ve sinir ağı	---
[188]	Morfolojik	30 s (DRIVE'da görüntü başına yaklaşık işlem süresi)
	Önerilen Yöntem	~ 20 dk. (eğitim) ve ~ 8 sn. (test) (DRIVE ve STARE)

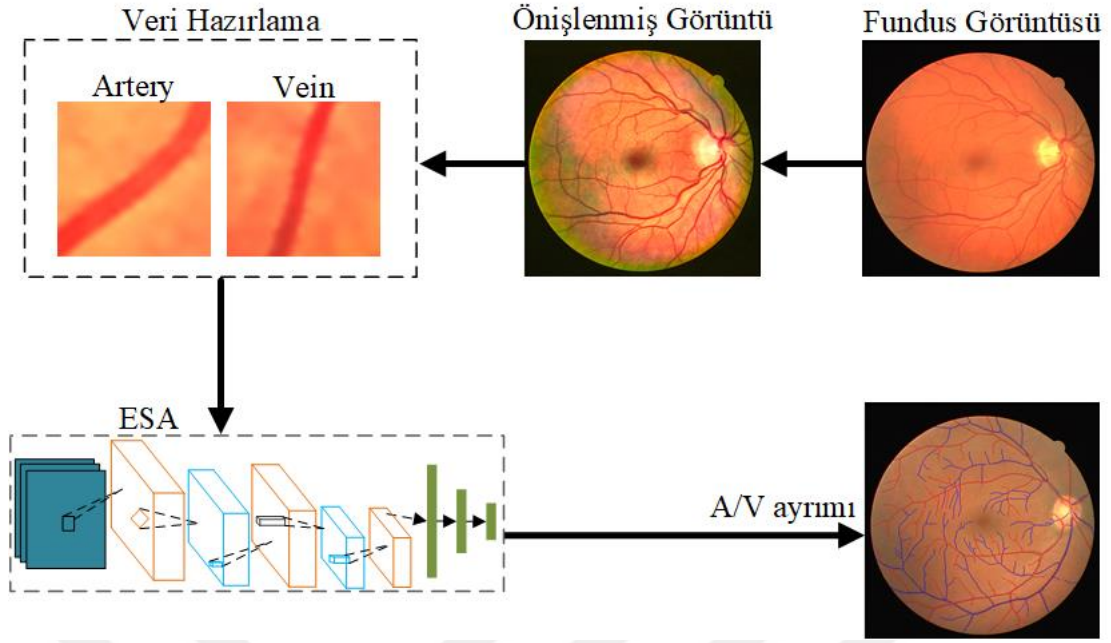
4.3 Uygulama 3: Retina Arter/Vein Ayrımı

Retina kan damarları arter ve vein damarlarından oluşur. Bu damarların hızlı ve sağlam tespiti ile birçok hastalığın erken teşhisi yapılabilir. Bu tez çalışmasında, retina kan damarlarını arter ve veinler olarak ayırmak için bir yöntem önerilmiştir. Retina kan damarlarının arter/vein ayrımının sağlanması çeşitli sebeplerden dolayı zordur. Bundan dolayı bu alanda yapılan uygulamalar kısıtlı yöntemlere dayanmaktadır. Bu yöntemin yapılma amacı, arter/vein ayrımını bir derin öğrenme mimarisi ile sağlamaktır.

Önerilen uygulama, ön işleme adımı, veri hazırlama adımı ve ESA mimarisi ile sınıflandırma adımından oluşmaktadır. ESA mimarisinin katman yapısı arter ve vein ayrımını gerçekleştirmek için özel olarak tasarlanmıştır. Nihayetinde, kan damarı piksellerinin arter damarlarına mı vein damarlarına mı ait olduğuna karar verilmiştir. Önerilen yöntemin performans sonuçları, DRIVE, INSPIRE ve LES_AV veri seti üzerinde test edilmiştir. Yöntemin başarısının sonucu *Hassaslık*, *Özgüllük* ve *Doğruluk* ölçüt parametreleri kullanılarak gerçekleştirilmiştir.

4.3.1 ESA ile retina kan damarlarından arter/vein ayrımı

Önerilen yöntemde, retina fundus görüntüleri ilk olarak bir ön işlemden geçirilmiştir. Veri setinde olan düşük kaliteli, homojen olmayan aydınlanmaya sahip görüntüler başarı sonucunu azaltmakta ve güvenilmez sonuçlar üretmektedir. Bu nedenle, ön işleme adımına ihtiyaç duyulmuştur. Daha sonra, ön işlenmiş görüntülerin arter ve vein damarlarından görüntü kesitleri alınarak veri hazırlama aşaması başlatılmıştır. Veri hazırlama aşamasında eğitim, doğrulama ve test işlemleri için arter ve vein pikselleri etiketlenmiştir. Etiketlenmiş veriler, önerilen ESA mimarisine girdi olarak verilmiştir. ESA modelini kullanmadaki amacımız, önceki birçok çalışmada bu ağ modelinin başarılı sonuçlar üretmiş olmasıdır [123], [190]. ESA mimarisinde, etiketlenmiş giriş verilerine eğitim ve doğrulama adımları uygulanır ve daha sonra test adımına geçilerek retina kan damarı görüntülerinin arter/vein ayrımı gerçekleştirilir. Önerilen yöntem, DRIVE, INSPIRE ve LES_AV veri setleri üzerinde test edilmiştir. Yöntemin akış şeması Şekil 4.16'de verilmiştir.




Şekil 4.16 : Uygulama 3 akış şeması.

4.3.1.1 Ön işlem aşaması

Tasarlanan ESA mimarisinin girdi verileri $32 \times 32 \times 3$ boyutunda küçük görüntü kesitleridir. ESA mimarisi, bu küçük görüntü kesitlerindeki istenmeyen özelliklerden etkilenir ve bunları yeterince düzeltemez. Bu nedenle, ağ mimarisini oluşturmadan önce fundus görüntüleri ön işlenmiştir.

Renkli fundus görüntüsünün K ve Y kanalları ayrı ayrı olarak ön işleme tabi tutulmuştur. Fundus görüntüsünün K kanalı arter/vein ayrımı için önemlidir çünkü merkezi refleks en iyi K kanalında görülür [191]. Merkezi refleks, arter/vein ayrımı için kullanılan belirgin özelliklerden biridir ve arter damarlarda daha geniş, vein damarlarda daha dardır. Fundus görüntüsünün Y kanalı retinal fundus kan damarı görüntülerinde en az gürültünün olduğu kanaldır. Y kanalı, birçok retina kan damarı bölütleme çalışmasında kullanılarak başarısını kanıtlamıştır [81], [192]. Bu nedenle ilk önce K ve Y kanallarına KSUHE uygulanmış, ardından elde edilen görüntüler Wiener filtresinden geçirilmiştir. KSUHE, görüntü-içi aydınlatma sorunlarını ortadan kaldırma amacı ile kullanılmıştır. Wiener filtresi ise görüntüdeki parazitleri gidermesi amacıyla kullanılmıştır [193]. Ardından, orijinal retinal fundus görüntüsü üzerindeki gölgeleme etkisini ortadan kaldırmak için KYM renk görüntüsüne düz alan düzeltilmesi uygulanmıştır. Elde edilen sonuç görüntüsü orijinal fundus görüntüsünden tekrar çıkarılmıştır. Ortaya çıkan görüntünün üçüncü kanalına KSUHE uygulanarak görüntü içi aydınlatma sorunları ortadan kaldırılmıştır. Bu görüntünün ikinci

kanalı, ön işleme tabi tutulmuş K kanalı ve ön işleme tabi tutulmuş Y kanalı birleştirilerek ön işleme aşaması tamamlanmıştır. Şekil 4.17’de ön işleme aşamasının görsel süreci verilmiştir.




Şekil 4.17 : Ön işlem süreci.

4.3.1.2 Veri hazırlama ve veri çoğaltma aşaması

Bu bölümde önerilen ESA mimarisinin girdileri hazırlanmıştır. Bu girdiler, retina kan damar görüntülerinin merkez çizgisi çevresinden elde edilmiştir. Retina kan damarlarının merkez çizgisi, gerçek zemin görüntüleri kullanılarak elde edilmiştir. Gerçek zemin görüntüleri, arter ve vein olarak etiketlenen görüntülerdir. Bu görüntülere morfolojik 'thin' algoritması uygulanır ve merkez çizgileri elde edilir. Ön işlenmiş retina kan damarı

görüntülerinin merkez çizgisi çevresinden $32 \times 32 \times 3$ boyutunda görüntü kesitleri çıkarılır. Burada üçüncü boyut, üç kanallı görüntüyü temsil etmektedir. Görüntü kesiti boyutunun 32×32 olarak seçilmesinin nedeni, bu boyutun daha önceki çalışmalarda tatmin edici sonuçlar vermiş olmasıdır [194]. DRIVE, INSPIRE ve LES-AV veri kümeleri için hem arterlerden hem de veinlerden görüntü kesitleri çıkarılmıştır.

Derin öğrenme mimarisinin çok fazla veri ile ilgilendiği bilinmektedir. Bu bilgiye dayanarak eğer ESA giriş verileri yeterli değilse, ağ mimarisi ya eğitilemez ya da aşırı öğrenme problemi ile karşı karşıya kalır. Eğitim girdi verileri yeterli olmadığı için bahsedilen problemle karşılaşmak olasıdır ve bu nedenle girdi verilerine veri çoğaltma işlemi uygulanmıştır. Veri çoğaltma olarak rastgele dikey ve yatay yansıma işlemleri uygulanmıştır. Bu işlemler, veri görüntüsünün yatay ve dikey ekseninde yansımasının alınmasını ifade etmektedir. DRIVE veri kümesindeki görüntülerin boyutu 584×565 pikseldir. DRIVE veri kümesi için ESA girdi verisi oluşturulurken, damar genişliği 2 pikselden az olan damarlar ve tüm damar pikselleri olarak iki ayrı veri kümesi oluşturulmuştur. Tüm kan damarı pikselleri için elde edilen ESA girdi verisinin sayısı yaklaşık 600.000'dir. Genişliği 2 pikselden az olan damarlar çıkarıldığında, ESA girdi verisinin sayısı yaklaşık 400.000'dir. INSPIRE veri setindeki görüntülerin boyutu ise 2048×2392 pikseldir. Buradan elde edilen ESA girdi verisi sayısı ise yaklaşık 1.100.000'dir. LES_AV veri setindeki görüntülerin boyutu ise 1444×1620 pikseldir. Buradan elde edilen ESA girdi verisi sayısı yaklaşık olarak 618.000'dir. Şekil 4.18'de arter ve vein kan damarlarından alınan görüntü kesitleri ve bu görüntü kesitlerinin veri çoğaltma ile elde edilen görüntüleri verilmiştir.

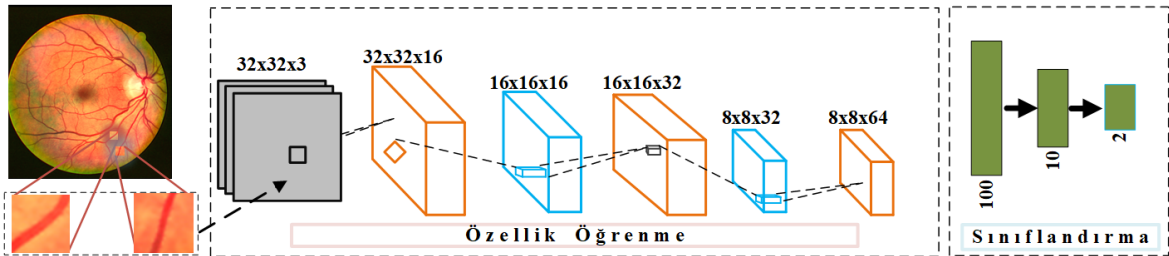


Şekil 4.18 : Arter ve veinlerden alınan görüntü kesitleri, (a) arter, (b) vein .

Veri hazırlama aşamasında oluşturulan görüntüler, eğitim, doğrulama ve test verileri olarak bölünmüştür. Her bir veri setinden çıkarılan tüm görüntüler, rastgele olarak %80 eğitim verisi ve %20 test verisi olarak ayrılmıştır. Daha sonra eğitim verileri %90 eğitim ve %10 doğrulama verisi olarak yeniden bölünmüştür. Burada önemli olan nokta, belirli bir ayırımın olmamasıdır. Görüntü yamaları rastgele seçilir ve belirlenen oranlara göre bölünür. Bu, önerilen sistemin başarılı yönlerinden biridir. Rastgeleliğe rağmen, elde edilen sonuçlar tatmin edici düzeydedir.

4.3.1.3 Arter/Vein ayırımı için önerilen ağ mimarisi

Önerilen ESA mimarisi, ikili sınıflandırma problemini çözmek için oluşturulmuştur. Bu ağ mimarisi, küçük boyutlu girdiler üzerinde iyi bir sınıflandırma performansı sağladığı için oluşturulmuştur. Daha derin bir ağ, deneylerdeki hesaplama yükünü arttıracığı için tercih edilmemiştir. Şekil 4.19’da önerilen ESA mimarisi verilmiştir. Bu mimaride gri renkli blok giriş verisini, turuncu renkli blok evrişim katmanını, mavi renkli blok havuzlama katmanını ve yeşil renkli blok tam bağlı katmanı temsil etmektedir.



Şekil 4.19 : Önerilen ESA mimarisi.

Şekil 4.19’da önerilen ESA mimarisinin detayları şöyledir:

- İlk katman, 32x32 boyutunda üç kanallı giriş görüntülerini içerir.
- İkinci katman, 3x3 piksel çekirdek boyutuna ve 16 özellik haritasına sahip bir evrişim katmanıdır. Girdi görüntüleri ilk önce bu katmana verilmiştir. Bu katmandaki değerler normalizasyon katmanı (NL) tarafından normalleştirilmiştir. Normalleştirme katmanında toplu normalleştirme yöntemi kullanılmıştır. Doygunluğu önlemek için NL katmanından sonra DDB kullanılmıştır. Toplu normalleştirme ve DDB, her evrişim katmanından sonra sırayla uygulanmıştır.
- Üçüncü katman, parametre ve hesaplama miktarını azaltmak için, 2 piksel adımlı 3x3 piksel çekirdek boyutuyla maksimum havuzlama katmanıdır.
- Ardından bir evrişim katmanı, bir maksimum havuzlama katmanı ve bir evrişim katmanı sırasıyla uygulanmıştır.
- Sınıflandırma aşamasında tam bağlı üç katman kullanılmıştır. Tam bağlı üç katman sırasıyla 100, 10 ve 2 nöron içermektedir. İlk iki tam bağlantılı katmanı sırasıyla DDB ve seyretme (dropout) katmanları takip etmektedir. Seyretme katmanı, ağ içindeki bazı bağlantıları kaldırmak için kullanılmıştır. 100 nöronlu tam bağlı katman için 0.5 oranında rastgelelik belirlenmiştir. 10 nörona indirilen tam bağlı katman için 0.2 oranlı rastgelelik belirlenmiştir. Bu katman sayesinde bazı nöronlar unutulmuş ve aşırı uyum önlenmiştir. Belirlenen oranlar önerilen mimari için en optimal sonucun elde edildiği oranlar olduğu için tercih edilmiştir. Son katman, ikili sınıflandırma probleminden dolayı 2 sınıf içermektedir. Özellik öğrenme ile ilgili diğer katmanların detayları Çizelge 4.11’de verilmiştir.


Çizelge 4.11 : ESA katman detayları.

Katman	Çıktı Boyutu	Filtre Boyutu	Adım
Giriş	32x32x3	-	-
Evrişim	32x32x16	3x3x3	1
Maksimum Havuzlama	16x16x16	3x3	2
Evrişim	16x16x32	3x3x3	1
Maksimum Havuzlama	8x8x32	3x3	2
Evrişim	8x8x64	3x3x3	3
Tam Bağlı	100	-	-
Tam Bağlı	10	-	-
Tam Bağlı	2	-	-

Evrişimli ve tam bağı katmanlardan oluşan ESA mimarisi parametreleri, momentumlu (SGDM) optimize edici stokastik gradyan inişi kullanılarak eğitilmiştir. SGDM algoritması, her yinelemede gradyanı kontrol eder ve ESA eğitim parametrelerini günceller. Yineleme değıştikçe, mini parti adı verilen alt küme de değışir. Önerilen yöntemde mini parti boyutu 256 olarak belirlenmiştir. Böylece model aynı anda 256 veriyi işleyebilecek ve zamandan tasarruf edebilecektir. Öğrenme oranı 0.01’de başlatılmış ve her turda 0.9 ile çarpılarak azaltılmıştır. Öğrenme hızı çok önemli bir hiper parametredir. Bu parametre büyükse minimum noktaya ulaşamaz. Çok küçükse, model çok yavaş öğrenir ve zamandan tasarruf edilemez. Eğitim 30 turda gerçekleştirilmiş ve her turda görüntüler karıştırılmıştır.

4.3.2 ESA ile retina kan damarlarından arter/vein ayırımının sonuçları

Önerilen yöntem DRIVE, INSPIRE ve LES_AV veri setleri üzerinde test edilmiştir. Tüm veri seti görüntüleri ön işlemlili ve ön işlemsiz görüntüler üzerinde deęerlendirilmiştir. DRIVE veri seti için performans deęerlendirmesi iki şekilde yapılmıştır. İlk olarak tüm damar piksellerinde arter/vein ayırımı yapılmış ve deęerlendirilmiştir. İkinci olarak, genişlięi 2 pikselden az olan damarlar kaldırılmış ve arter/vein ayırımı deęerlendirilmiştir. Damar genişlięi 2 pikselden az olan retina kan damarlarının renk piksel deęerlerini arka plandan ayırt etmek çok zordur. Çizelge 4.12’de tüm performans sonuçları nicel olarak verilmiştir. Arter vein damarlarına ait gerçek zemin görüntüleri ve bölütlenmiş arter ve vein görüntüleri Şekil 4.20’de verilmiştir. Bu şekilde, ilk sütunda DRIVE, ikinci sütunda INSPIRE ve son sütunda LES_AV veri kümesine ait görüntüler bulunmaktadır. Ayrıca, bu şekilde arterler kırmızı, veinler ise mavi renk ile gösterilmiştir. Daha detatlı bir görünüm için görüntü yamaları görselde büyütülerek verilmiştir.



Şekil 4.20 : Orijinal fundus görüntülerinde A/V damarların gösterilmesi. İlk satır, gerçek zemin görüntülerini, ikinci satır, segmentlere ayrılmış A/V damarlarını, üçüncü satır, segmente edilmiş görüntüde yanlış bulunan pikselleri temsil etmektedir.

Çizelge 4.12 : Önerilen yöntemin nicel sonuçları.

Veri seti	Kullanılan görüntü	Hassaslık	Özgüllük	Doğruluk
DRIVE	Ön işlenmiş görüntünün tüm pikselleri	0.8967	0.9244	0.9110
DRIVE	Ön işlenmiş görüntünün 2 pikselden daha az olan pikselleri kaldırılmış görüntü	0.9705	0.9771	0.9741
DRIVE	Ön işlenmeyen görüntünün tüm pikselleri	0.8670	0.9218	0.8945
DRIVE	Ön işlenmeyen görüntünün 2 pikselden daha az olan pikselleri kaldırılmış görüntü	0.9523	0.9717	0.9627
INSPIRE	Ön işlenmiş görüntünün tüm pikselleri	0.9709	0.9586	0.9654
INSPIRE	Ön işlenmeyen görüntünün tüm pikselleri	0.9601	0.9663	0.9612
LES_AV	Ön işlenmiş görüntünün tüm pikselleri	0.9514	0.9547	0.9531
LES_AV	Ön işlenmeyen görüntünün tüm pikselleri	0.9575	0.9389	0.9481


Bu çizelgeye göre, üç veri seti arasında en yüksek sonuç önceden işlenmiş görüntülerden elde edilmiştir. Elde edilen sonuçların sağlamlığını artırmak için test işlemi

10 kez çalıştırılmış ve ortalama sonuç elde edilmiştir. Buraya kadar elde edilen sonuçlarda bir son işlem süreci yoktur. Ancak, sonuç görüntülerinde aynı damar üzerinde arter ve vein pikselleri bir arada görülmüştür. Bu piksel türleri kararsız pikseller olarak isimlendirilmiştir. Bu pikseller, hataya neden olmakta ve performansı düşürmektedir. Bu nedenle bu süreçten sonrası için bir son işlem süreci uygulanmıştır. Bu süreçte yapılan işlemler Eşitlik 4.7’de verilmiştir. Bu matematiksel ifadeye göre tüm damar alanları bölütlenmiş görüntüde farklı nesnelere olarak düşünülmektedir. Damarların farklı nesne olarak düşünülmesi için damarları birbirine bağlayan düğümler görüntüden çıkarılmıştır. Böylece, bağlantısız her damar bir nesne olarak kabul edilmiştir. Her nesne içindeki toplam arter ve vein piksellerinin olasılığı hesaplanmıştır. Bir damar pikselinin arter olma olasılığı yüksekse, o nesne içindeki tüm damar pikselleri arter olarak işaretlenmiştir. Vein pikselleri içinde aynı durum geçerlidir.

$$\begin{aligned} \text{Eğer } P_{arter} \geq P_{vein} \quad O(i,j) &== \text{Arter} \\ \text{Değilse } P_{arter} < P_{vein} \quad O(i,j) &== \text{Vein} \end{aligned} \quad (4.7)$$

Burada O , bölütlenmiş görüntüdeki her damar nesnesini temsil eder. i ve j parametreleri piksel değerini temsil eder. P_{arter} parametresi, O nesnesindeki piksellerin arter olma olasılığıdır. P_{vein} parametresi, O nesnesindeki piksellerin damar olma olasılığıdır.

Şekil 4.21’de DRIVE veri setinin bir görüntüsüne uygulanan son işlem adımı verilmektedir. Burada, ilk satırdaki görüntü yamaları birinci fundus görüntüsüne, ikinci satırdaki görüntü yamaları ikinci fundus görüntüsüne ve üçüncü satırdaki görüntü yamaları üçüncü fundus görüntüsüne aittir. Kararsız pikseller, Eşitlik 4.7’de verilen matematiksel ifade uygulanarak kararlı hale getirilmiştir. Son işleme aşaması (yani Eşitlik 4.7), DRIVE veri setinin 20 test görüntüsüne uygulanmış ve ortalama başarı 0,0369 oranında artmıştır.



Şekil 4.21 : Son işlem aşamasının görüntülere etkisi. Sırası ile manuel, önerilen yöntem ve önerilen yönteme son işlem uygulanarak elde edilen A/V damarlarının orijinal görüntü üzerinde gösterilmesi.

4.3.3 Önerilen yöntemin performans karşılaştırması

Bu bölümde, önerilen yöntemin doğruluğunu ve sağlamlığını doğrulamak için yöntemin diğer güncel yöntemlerle karşılaştırılması yapılmıştır. Karşılaştırma tablosu Çizelge 4.13’de verilmiştir. Yöntemler arasında karşılaştırma ölçütü olarak *Doğruluk* metriği kullanılmıştır.

Çizelge 4.13 : Önerilen yöntemin diğer yöntemlerle performans karşılaştırması.

Yazar (yıl)	Veri seti	Hassaslık	Özgüllük	Doğruluk
[118] (2017)	DRIVE	---	---	0.923
[120] (2018)	DRIVE	0.709	0.738	0.72
	INSPIRE-AVR	0.896	0.913	0.92
[123] (2019)	DRIVE	0.863	0.866	0.865
[195] (2019)	AV_DRIVE	0.966	0.929	0.947
	INSPIRE-AVR	0.969	0.966	0.968
[125] (2020)	AV_DRIVE	0.918	0.930	0.943
[196] (2020)	LES_AV	0.942	0.909	0.921
	DRIVE	0.886	0.927	0.908
[197] (2020)	LES_AV	0.944	0.946	0.946
Önerilen yöntem	DRIVE- tüm damar pikselleri	0.896	0.924	0.911
	Genişliği 2 pikselden büyük damarlar	0.970	0.977	0.974
	INSPIRE-AVR	0.970	0.958	0.965
	LES_AV	0.951	0.954	0.953

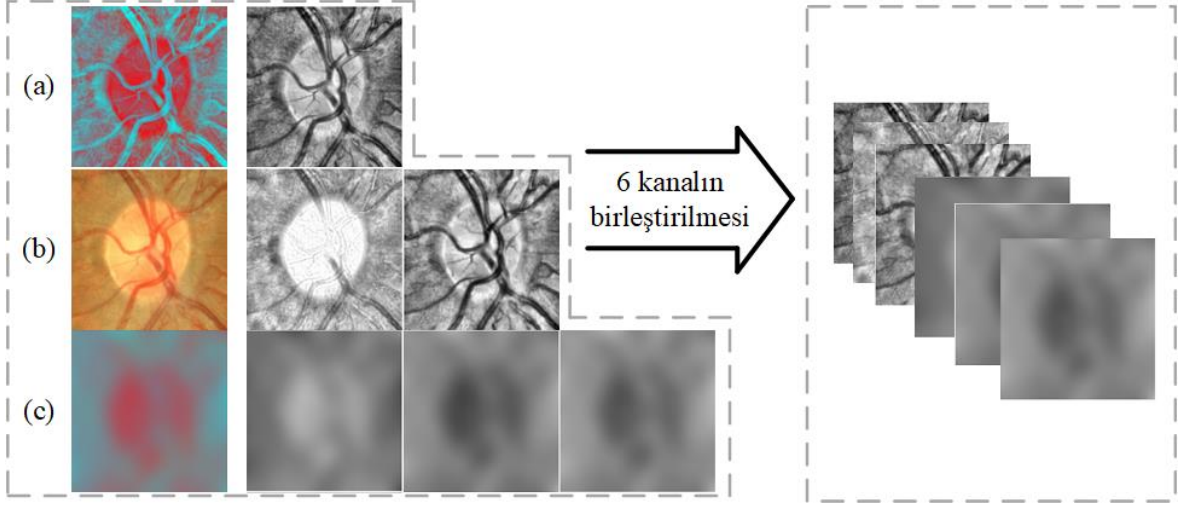
4.4 Uygulama 4: Glokomlu ve Sağlıklı Fundus Görüntü Ayrımı

Glokom, sessiz görüş hırsız olarak bilinen bir göz hastalığıdır. Bu hastalığın BDT sistemleri ile tespiti bölütleme ya da sınıflandırma yöntemleri ile sağlanmaktadır. Bölütleme yöntemlerinde, OD ve OK bölgelerinin bölütlenmesi yapılır. Bu iki bölgenin bölütlenmesi ile özellik çıkarım süreci başlar. Ancak, bu işlemler maliyetlidir. Dahası, hastalığın başlangıç evrelerinde ya da sağlıklı bir fundus görüntüsünde OK bölgesini OD bölgesinden ayırmak zor bir işlemdir. Bu nedenle, bu tez kapsamında glokom ve sağlıklı fundus ayrımı sınıflandırma işlemi ile yapılmaktadır.

Önerilen uygulamada, güncel yöntemlerden biri olan EfficientNet-B0 modeli kullanılmıştır. Önerilen yöntem, halka açık olarak sunulan ACRIMA veri seti üzerinde test edilmiştir.

4.4.1 EfficientNet-B0 ile glokomlu görüntüleri ayrıştırma

Önerilen yöntemde, EfficientNet-B0 modeli için altı katmanlı bir girdi görüntüsü hazırlanmıştır. Bu girdi görüntüsünün ilk kanalı, bu tez çalışmasında önerilen yeni renk uzayına ait görüntünün birinci kanalıdır. Bu kanal, OD bölgesini fundus görüntüsünde daha görünür hale getirdiği için tercih edilmiştir. OD bölgesi, glokom hastalığı hakkında önemli bilgiler sağlayan bir bölgedir. Bu nedenle, yeni renk uzayının ilk kanalı bu yöntemde kullanılmıştır. Girdi görüntüsünün ikinci kanalı, orijinal fundus görüntünün KSUHE uygulanmış K kanalıdır. Üçüncü kanalı ise, orijinal fundus görüntüsünün KSUHE uygulanmış Y kanalıdır. Bu iki renk kanalı önceki birçok çalışmada kullanılmış ve başarısını kanıtlamış renk kanallarıdır [41], [81]. OD bölgesinde kırmızı renk tonu yoğundur bu nedenle K kanalı bu bölgeyi temsil etmede etkilidir. Y kanalı ise retina damalarını en iyi ortaya çıkaran orijinal renk kanalıdır. OD bölgesi, retina kan damarlarının dağılım noktasıdır. Bu nedenle, buradaki ana damarları görünür kılmak için Y kanalı kullanılmıştır. Girdi görüntüsünün son üç kanalı ise Gauss uygulanarak yumuşatılmış yeni renk uzayının üç kanalıdır. Son üç kanalın tercih edilme amacı, gürültülerden arındırılmış yeni renk uzayında kan damarlarını bastırarak OD bölgesini ortaya çıkarmaktır. Buraya kadar anlatılanların görsel özeti Şekil 4.22’de verilmiştir.



Şekil 4.22 : Altı kanallı giriş ekranı. (a) Yeni renk uzayı ve bu uzayın ilk kanalı, (b) orijinal fundus görüntüsü ve bu görüntünün K, Y kanalı, (c) (a)'ya uygulanan gauss görüntü sonucu ve bu görüntünün renk kanalları.

Önerilen yöntemin bir sonraki aşaması veri arttırma aşamasıdır. Bilindiği gibi derin öğrenme, büyük veri setlerinde daha etkili sonuçlar üretmektedir. Ancak, çoğu zaman veri kümeleri sınırlı düzeydedir. Bu durumda, veri arttırma tekniklerini kullanmak gerekir. Bu tekniklerin amacı, veri sayısını çeşitlendirmek ve arttırmaktır. Bu veri arttırma yöntemleri; döndürme, ölçekleme, çevirme, kırpma ve renk uzayı dönüştürme gibi işlemlerdir. Önerilen bu yöntemde, ACRIMA veri kümesi için döndürme işlemi kullanılmıştır. Bu süreçte her bir fundus görüntüsü 0-9 derecelik açılarla döndürülür. Bu veri arttırma tekniği bu uygulamada deneysel olarak en iyi başarımın sağlandığı tekniktir. Bu teknik, diğer fundus çalışmalarında da kullanılmış ve başarısını kanıtlanmıştır [198]. Veri çoğaltma sonrası ACRIMA veri setinin glokomlu fundus görüntü sayısı 3960 olarak hesaplanmıştır. Sağlıklı fundus görüntülerinin sayısı ise 3090'a yükseltilmiştir. Toplamda 7050 görüntü elde edilmiştir.

4.4.2 EfficientNet-B0 ile glokomlu görüntülerin ayrıştırılma sonucu

Veri çoğaltma teknikleri ile elde edilen 7050 adet görüntü eğitim, doğrulama ve test işlemleri için üç gruba bölünmüştür. Glokomlu görüntülerin 2440 tanesi eğitim için, 610 tanesi doğrulama için, 910 tanesi ise test işlemi için kullanılmıştır. Sağlıklı fundus görüntülerinin ise 1600 tanesi eğitim için, 400 tanesi doğrulama için ve 1090 tanesi test işlemi için kullanılmıştır. Elde edilen veriler, modele girdi olarak verilmeden önce modelin hiper parametreleri ayarlanmıştır. Burada, öğrenme parametrelerinin optimizasyonu için SGDM kullanılmıştır. İlk öğrenme oranı ise iki şekilde kullanılmıştır. İlk olarak, öğrenme oranının değeri 0.001 olarak ayarlanmıştır. Bu oran ağ eğitimi boyunca sabit tutulmuştur.

Eđitim, farklı tur sayılarında 0.001 öğrenme oranı ile tamamlanmıştır. İkinci olarak, ilk öğrenme oran 0.001'den başlatılır. Bu oran her turda 0.9 ile çarpılır. Böylece, ilk öğrenme oranı her turda azaltılır ve ađa verilir. Derin ađ mimarisi, aşırı öğrenmeyi engellemek için her turda karıştırılmıştır. Mini parti parametresi, çoklu girdileri parça parça işlemek içindir. Bu yöntemde mini parti boyutu değeri 32 olarak ayarlanmıştır. Böylece modelin eğitimi her yinelemede bu parti boyutunda yapılmış olur. Önerilen yöntemin sonuçları, bahsedilen öğrenme oranlarının farklı turlarda çalıştırılması ile elde edilmiştir. Elde edilen bu sonuçların değeri, Çizelge 4.14 ve Çizelge 4.15'de verilmiştir.

Çizelge 4.14 : Sabit öğrenme oranı (0.001).

Performans Ölçütü	Maksimum Tur Sayısı		
	10	25	50
Dođruluk	0.9235	0.9650	0.9465
Hassaslık	0.8890	0.9375	0.9118
Özgüllük	0.9562	0.9904	0.9795
Kesinlik	0.9505	0.9890	0.9769
F-ölçütü	0.9187	0.9626	0.9432
Eđitim Süresi (s)	1551	3949	8054

Çizelge 4.15 : Her turda azalan öğrenme oranı.

Performans Ölçütü	Maksimum Tur Sayısı		
	10	25	50
Dođruluk	0.9655	0.9775	0.9750
Hassaslık	0.9394	0.9577	0.9498
Özgüllük	0.9895	0.9953	0.9981
Kesinlik	0.9879	0.9945	0.9978
F-ölçütü	0.9630	0.9757	0.9732
Eđitim Süresi (s)	1562	3829	7613

Bu çizelgelerde, en yüksek performans metriđi koyu renk ile belirtilmiştir. Buna göre, en yüksek dođruluk oranı her 25 turda azalan öğrenme oranı için 0.9775 olarak belirlenmiştir. Bu çizelgeye göre, en iyi tur sayısının 25-50 tur arasında olduđu yorumu çıkmaktadır. Elde edilen bu performans sonuçları, güncel diđer yöntemlerle performans ölçütlerine göre karşılaştırılmıştır. Bu karşılaştırma tablosu Çizelge 4.16'da verilmiştir.

Çizelge 4.16 : ACRIMA veri setini kullanan diğer güncel yöntemler.

Yazar	Yöntem(ler)	Veri Çoğaltma	Performans Ölçütleri	
[198]	ESA	G:3960 S:3090	<i>D</i> : 0.9664 <i>Ö</i> : 0.9739	<i>H</i> : 0.9607 <i>K</i> : 0.9774
[199]	ResNet-152	G:2976 S: 2400	EAA [*] : 0.77 <i>Ö</i> : 0.83	<i>D</i> : 0.48
[200]	UCSD ve UTokyo	Uygulanmamış	EAA [*] : 0.86	
[201]	OKODO ve geleneksel yöntemler	Uygulanmamış	<i>D</i> : 0.9461 <i>Ö</i> : 0.9500	<i>H</i> : 0.9457
Önerilen Yöntem	EfficientNet-B0	G:3960 S:3090	<i>D</i> : 0.9775 <i>K</i> : 0.9945 F- ölçütü: 0.9757	<i>H</i> : 0.9577 <i>Ö</i> : 0.9953

* Eğri altındaki alan (EAA- Area Under The Curve (Auc))

Bu çizelgede verilen nicel sonuçlar, önerilen yöntemin doğru bir yöntem olduğunun kanıtıdır. Bu yöntem, ACRIMA veri setini kullanarak glokom ve sağlıklı fundus ayırımı yapan diğer güncel yöntemler arasında başarılı sonuçlar üretmiştir.

5. SONUÇLAR

Bu tez çalışmasında, fundus görüntülerinin retina bileşenlerine odaklanılmıştır. Bu bileşenlerden optik disk, retina damarları ve retina arter/vein damarlarının tanı ve teşhisini sağlayan literatürdeki mevcut yöntemler araştırılmıştır. Bu yöntemlerde karşılaşılan problemler analiz edilmiş ve analizler doğrultusunda bilgisayar destekli tanı sistemleri geliştirilmiştir. Yapılan ilk çalışmada, fundus görüntülerinde optik disk bileşeninin lokalizasyon tespiti gerçekleştirilmiştir. İkinci çalışmada, retina damar ağ yapısını bölütleyen piksel tabanlı bir yöntem geliştirilmiştir. Üçüncü çalışmada ise retina damarlarının arter/vein ayrımını sağlamak için bir çalışma yapılmıştır. Son çalışmada ise bir fundus görüntüsünün sağlıklı veya glokomlu olarak ayrımını sağlayan bir yöntem geliştirilmiştir.

Yapılan ilk çalışmada, OD bölgesinin lokalizasyonu tespit edilmiştir. Bunun için YAK algoritması kullanılmış ve KYM renk uzayındaki fundus görüntüleri yeni bir renk uzayına taşınmıştır. Yeni renk uzayında OD bölgesine ait renk pikselleri daha baskın bir hale getirilmiştir. Ardından, bir öz değer eşikleme yöntemi kullanılmış ve yeni renk uzayındaki fundus görüntülerine uygulanmıştır. Nihayetinde OD bölgesi otomatik olarak tespit edilmiştir. Bu yöntemin performans sonuçları DRIVE, DRIONS ve MESSIDOR veri setleri üzerinde elde edilmiştir. Performans sonuçlarına göre DRIVE veri setinde %100, DRIONS veri setinde %96,37 ve MESSIDOR veri setinde %94,42 doğruluk oranı elde edilmiştir. Ayrıca, bu yöntemin performans değerlendirmesi aynı veri setini kullanan güncel yöntemlerin sonuçları ile karşılaştırılarak elde edilmiştir. Karşılaştırma sonuçları yorumlandığında, elde edilen sonuçlar tatmin edici seviyededir. Bu çalışmanın sonucunda OD lokalizasyon bilgisine erişilmektedir. Bu bilgi, OD segmentasyonu, makula, fovea ve retina damarları gibi diğer retina bileşenlerine erişimi kolay hale getirir. Ancak, kullanılan veri seti görüntülerinde OD bölgesi ağırlıkla parlak alanlardan oluştuğu için elde edilen renk uzayının parlak pikselleri ön plana çıkarma ihtimali vardır. Bu bir dezavantaj olarak yorumlanabilir. Çünkü parlak OD rengine sahip olmayan retina görüntülerinde OD lokalizasyonunun yanlış tespit edilebilir. Bu nedenle, gelecekte bu eksikliğin üstesinden gelmek için yeni algoritmalar geliştirilmelidir.

Yapılan ikinci çalışmada, retina kan damarlarını tespit etmek için damar piksellerinden 18-B özellik çıkarılmış ve çıkarılan özellikler ileri beslemeli bir YSA ile sınıflandırılmıştır. Nihayetinde, retina kan damar ağının bölütlenmesi gerçekleştirilmiştir.

Önerilen yöntem halka açık olarak sunulan DRIVE ve STARE veri setleri üzerinde test edilmiştir. Önerilen yöntemin performansı, DRIVE veri seti için 0.9618 doğruluk oranına, STARE veri seti için 0.9456 doğruluk oranına sahiptir. Bu yöntem, diğer güncel yöntemlerle karşılaştırıldığında elde edilen sonuçların umut verici olduğu görülmektedir. Yöntem, veri setinden bağımsız olarak geliştirilmiş ve farklı damar yapılarında da (geniş, uzun ve dallanan damarlar gibi) tatmin edici sonuçlar vermiştir. Yöntemin performans değerlendirmesi ayrıca Jaccard ve Dice benzerlik ölçütleri ile de değerlendirilmiştir. DRIVE veri seti için elde edilen Jaccard ve Dice sonuçları sırası ile 0.6148 ve 0.7609'dur. STARE veri seti için elde edilen Jaccard ve Dice sonuçları sırası ile 0.5196 ve 0.6860'dır. Önerilen yöntemin başarısını desteklemek için ayrıca k-kat çapraz doğrulama kullanılmıştır. Burada k değeri 10'dur. DRIVE veri seti için doğruluk, hassaslık ve özgüllük için standart sapma değeri sırasıyla 0.0023, 0.0240, 0.0014'tür. STARE veri kümesi için bu değerler sırası ile 0.0024, 0.0290 ve 0.0025'dir. Önerilen yöntem, popüler bir alan olan derin öğrenme yöntemlerine göre zaman verimliliği sağladığı için avantajlıdır. Performansı ve zaman verimliliğini arttırmak için gelecekte yapılacak çalışmalar ile yeni damar piksel özellikleri bulunabilir.

Yapılan üçüncü çalışmada, bir derin öğrenme ağ mimarisi kullanılarak retina kan damarlarının arter/vein ayrımı sağlanmıştır. Önerilen ağ mimarisinin başarısı, önerilen ön işlem yöntemi ile arttırılmıştır. Derin öğrenme yaklaşımı olarak, genellikle ikili sınıflandırma problemlerinde kullanılan ESA mimarisi tercih edilmiştir. Yöntem veri setinden bağımsız olarak oluşturulmuş ve son işlem adımı uygulanmamıştır. Bu durum yöntemin başarılı yönlerinden biridir. ESA mimarisine girdi olarak hazırlanan verilerin eğitim, test ve doğrulama olarak ayrılma şekli yöntemin diğer başarılı yönlerinden biridir. Çünkü tüm ESA girdi verileri, önce eğitim ve test verileri olarak rastgele bölünmüştür. Eğitim verileri %80 ve test verileri %20 oranında belirlenmiştir. Daha sonra eğitim verileri rastgele olarak %90 eğitim ve %10 doğrulama olarak tekrar bölünmüştür. Böylece rastgele bir ayırım yapılmıştır. Rastgelelik, rastgele seçilen görüntüler üzerinde önerilen ESA mimarisinin sağlamlığını ortaya koymaktadır. ESA mimarisi sonucunda elde edilen eğitim ağı test verilerine uygulanmıştır. Burada rastgele verilerle elde edilen sonuç 10 kez çalıştırılmıştır. Farklı veriler ile çalışan ağın 10 kez çalışması sonucunda ortaya çıkan sonuçlar tatmin edici düzeydedir. Yöntemin performans sonuçları halka açık olarak sunulan DRIVE, INSPIRE ve LES_AV veri setleri üzerinde test edilmiştir. DRIVE veri seti için sistemin performans değerlendirmesi iki şekilde sağlanmıştır. İlk olarak tüm retina damar pikselleri ile arter/vein ayrımı sağlanmış ve 0.9110 doğruluk değeri elde edilmiştir. İkinci

olarak genişliği 2 pikselden az olan damarlar görüntüden kaldırılarak sistemin performansı test edilmiştir ve 0.9741 doğruluk oranı elde edilmiştir. INSPIRE veri seti için doğruluk oranı 0.9654 ve LES_AV veri seti için doğruluk oranı 0.9531 olarak hesaplanmıştır.

Yapılan dördüncü çalışmada, bir fundus görüntüsünün glokomlu veya sağlıklı olarak ayrımı yapılmıştır. Bu ayırım, EfficientNet-B0 mimarisi kullanılarak yapılmıştır. Çalışmanın performansı, 2019 yılında paylaşılan ACRIMA veri seti üzerinde test edilmiştir. Çalışmanın değerlendirilmesi altı farklı performans ölçütü ile sağlanmıştır. EfficientNet-B0 mimarisinin ilk öğrenme oranı 0.001 değerinden başlatılmış ve her 25 turda azalacak şekilde ayarlanmıştır. KYM renk uzayındaki orijinal fundus görüntüleri, iki ayrı çalışma ile test edilmiştir. Bu çalışmalar aynı parametrelere sahip EfficientNet-B0 mimarisi ile gerçekleştirilmiştir. İlk olarak, orijinal fundus görüntüleri doğrudan EfficientNet-B0 mimarisine girdi olarak uygulanmış ve test edilmiştir. Bu test işleminden elde edilen sonuçlar 0.9610 değerine sahip doğruluk ölçütü, 0.9315 değerine sahip hassaslık ölçütü 0.9884 değerine sahip özgüllük ölçütü, 0.9868 değerine sahip kesinlik ölçütü ve 0.9584 değerine sahip F-ölçütüdür. İkinci olarak, orijinal fundus görüntüleri altı katmanlı girdi görüntüsü olarak hazırlanarak EfficientNet-B0 mimarisine uygulanmıştır. Elde edilen sonuçların matematiksel değeri doğruluk ölçütü için 0.9975, hassaslık ölçütü için 0.9577, özgüllük ölçütü için 0.9953, kesinlik ölçütü için 0.9945 ve F-ölçütü için 0.9757 olarak hesaplanmıştır. Glokomlu ve sağlıklı fundus ayrımı için EfficientNet-B0 mimarisine verilen girdi görüntülerinin altı katmanlı olarak sunulması ile görüntünün detayları ağın hiyerarşisi içerisinde korunmuştur. Ayrıca, bu yöntem, ilk uygulamada önerilen yeni renk uzayının başarısını kanıtlar niteliktedir.

Gelecekteki çalışmalarda, retina görüntüleri analizi yapılırken bu tezde önerilen yöntemler geliştirilebilir. Optik disk lokalizasyonu için, dönüşüm matrisi güncel veri setleri kullanılarak daha da geliştirilebilir. Damar bölütlenmesi için yeni piksel tabanlı özellikler sunulabilir. Arter/vein ayrımı için yeni yöntemler geliştirmeye çalışılabilir. Glokomlu görüntülerin ayrımını sağlamak için yeni özellikler elde edilmeye çalışılabilir.

KAYNAKLAR

- [1] **Qureshi, I., Ma, J., & Abbas, Q.** (2019), Recent Development on Detection Methods for the Diagnosis of Diabetic Retinopathy, *Symmetry (Basel)*, 11 (6), 749, doi: <https://doi.org/10.3390/sym11060749>.
- [2] **Mrad, Y., Elloumi, Y., Akil, M., & Bedoui, M. H.** (2021). A Fast and Accurate Method for Glaucoma Screening from Smartphone-Captured Fundus Images, *Irbm*, doi: 10.1016/j.irbm.2021.06.004.
- [3] **Roletschek, R.** (2017). Wikimedia Commons: Fundus kamera by Ralf Roletschek / Wikipedia. <https://commons.wikimedia.org/wiki/File:2010-12-07-funduskamera-by-RalfR-02.jpg>.
- [4] **Yadav, D., Karn, A. K., Giddalur, A., Dhiman, A., Sharma, S., & Yadav, A. K.** (2021). Microaneurysm detection using color locus detection method, *Measurement*, 176 (109084), doi: <https://doi.org/10.1016/j.measurement.2021.109084>.]
- [5] **Wu, J., Zhang, S., Xiao, Z., Zhang, F., Geng, L., Lou, S., & Liu, M.** (2019). Hemorrhage detection in fundus image based on 2D Gaussian fitting and human visual characteristics, *Optics & Laser Technology, Opt. Laser Technol.*, 110, 69–77, doi: <https://doi.org/10.1016/j.optlastec.2018.07.049>.]
- [6] **Guo, S., Wang, K., Kang, H., Liu, T., Gao, Y., & Li, T.** (2020). Bin loss for hard exudates segmentation in fundus images, *Neurocomputing*, 392, 314–324, doi: <https://doi.org/10.1016/j.neucom.2018.10.103>.
- [7] **Huang, Y., Zhong, Z., Yuan, J., & Tang, X.** (2020). Efficient and robust optic disc detection and fovea localization using region proposal network and cascaded network, *Biomed. Signal Process. Control*, 60 (101939), 1746–8094, doi: <https://doi.org/10.1016/j.bspc.2020.101939>.
- [8] **Li, H., Kang, J., Feng, Y., Xu, J., & Li, H.** (2018) Automatic segmentation of PPA in retinal images, in *13th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, 2018, 1791–1796.
- [9] **Han, J. C., Ko, H., Kim, S. H., Rhee, T., Nam, S. W., Hwang, S., Lee, G., Sung, J., Song, Y., & Kee, C.** (2017). Heritability of the morphology of optic nerve head and surrounding structures: The Healthy Twin Study, *PLoS One*, 12 (11), doi:

<https://doi.org/10.1371/journal.pone.0187498>.

- [10] **Sun, J., Wang, J., You, R., & Wang, Y.** (2018). Is the Retinal Vasculature Related to β -Peripapillary Atrophy in Nonpathological High Myopia? An Optical Coherence Tomography Angiography Study in Chinese Adults, *J. Ophthalmol.*, doi: <https://doi.org/10.1155/2018/7895238>.
- [11] **Teng, C. C., De Moraes, C. G. V., Prata, T. S., Tello, C., Ritch, R., & Liebmann, J. M.** (2010). β -Zone parapapillary atrophy and the velocity of glaucoma progression, *Ophthalmology*, 117 (5), 909–915, doi: <https://doi.org/10.1016/j.ophtha.2009.10.016>.
- [12] **Yu, H., Barriga, E. S., Agurto, C., Echegaray, S., Pattichis, M. S., Bauman, W., & Soliz, P.** (2012). Fast Localization and Segmentation of Optic Disk in Retinal Images Using Directional Matched Filtering and Level Sets, *IEEE Trans. Inf. Technol. Biomed.*, 16 (4), 644–657, doi: 10.1109/TITB.2012.2198668.
- [13] **Dehghani, A., Moghaddam, H. A., & Moin, M. S.** (2012). Optic disc localization in retinal images using histogram matching, *EURASIP J. Image Video Process. Vol.*, 19, doi: <https://doi.org/10.1186/1687-5281-2012-19>.
- [14] **Pourreza-Shahri, R., Tavakoli, M., & Kehtarnavaz, N.** (2014). Computationally efficient optic nerve head detection in retinal fundus images, *Biomed. Signal Process. Control.*, 11, 63–73.
- [15] **Harangi, B., & Hajdu, A.** (2015). Detection of the optic disc in fundus images by combining probability models, *Comput Biol Med.*, 65, 10–24, doi: 0.1016/j.combiomed.2015.07.002.
- [16] **Wang, C., & Kaba, D.** (2015). Level Set Segmentation of Optic Discs from Retinal Images, *J. Med. Bioeng.*, 4 (3), 2013–220, doi: 10.12720/jomb.4.3.213-220.
- [17] **Ahmed, M. I., & Amin, M. A.** (2015). High speed detection of optical disc in retinal fundus image, *SIViP*, 9, 77–85, doi: <https://doi.org/10.1007/s11760-012-0412-3>.
- [18] **Dashtbozorg, B., Mendonça, A. M., & Campilho, A.** (2015). Optic disc segmentation using the sliding band filter, *Comput. Biol. Med.*, 56, 1–12, doi: 10.1016/j.combiomed.2014.10.009.
- [19] **Mary, M. C. V. S., Rajsingh, E. B., Jacob, J. K. K., Anandhi, D., Amato, U., & Selvan, S. E.** (2015). An empirical study on optic disc segmentation using an active contour model, *Biomed. Signal Process. Control*, 18, 19–29, doi:

10.1016/j.bspc.2014.11.003.

- [20] **Bharkad, S.** (2017). Automatic segmentation of optic disk in retinal images, *Biomed. Signal Process. Control*, 31, 483–498, doi: <https://doi.org/10.1016/j.bspc.2016.09.009>.
- [21] **Tan, J. H., Acharya, U. R., Bhandary, S. V., Chua, K. C., & Sivaprasad, S.** (2017). Segmentation of optic disc, fovea and retinal vasculature using a single convolutional neural network, *J. Comput. Sci.*, 20, 70–79, doi: 10.1016/j.jocs.2017.02.006.
- [22] **Kamble, R., Kokare, M., Deshmukh, G., Hussin, F. A., & Mériaudeau, F.** (2017). Localization of optic disc and fovea in retinal images using intensity based line scanning analysis, *Comput. Biol. Med.*, 87, 382–396, doi: 10.1016/j.combiomed.2017.04.016.
- [23] **Rodrigues, L. C., & Marengoni, M.** (2017). Segmentation of optic disc and blood vessels in retinal images using wavelets, mathematical morphology and Hessian-based multi-scale filtering, *Biomed. Signal Process. Control*, 36, 39–49, doi: 10.1016/j.bspc.2017.03.014.
- [24] **Reza, M. N.** (2018). Automatic detection of optic disc in color fundus retinal images using circle operator, *Biomed. Signal Process. Control*, 45, 274–283, doi: 10.1016/j.bspc.2018.05.027.
- [25] **Zhou, W., Yi, Y., Gao, Y., & Dai, J.** (2019). Optic Disc and Cup Segmentation in Retinal Images for Glaucoma Diagnosis by Locally Statistical Active Contour Model with Structure Prior, *Comput. Math. Methods Med.*, 2019, doi: 10.1155/2019/8973287.
- [26] **Naqvi, S. S., Fatima, N., Khan, T. M., Rehman, Z. U., & Khan, M. A.** (2019). Automatic optic disk detection and segmentation by variational active contour estimation in retinal fundus images, *Signal, Image Video Process.*, 13 (6), 1191–1198, doi: 10.1007/s11760-019-01463-y.
- [27] **Thakur, N., & Juneja, M.** (2019). Optic disc and optic cup segmentation from retinal images using hybrid approach, *Expert Syst. Appl.*, 127, 308–322, doi: 10.1016/j.eswa.2019.03.009.
- [28] **Wang, L., Liu, H., Lu, Y., Chen, H., Zhang, J., & Pu, J.** (2019). A coarse-to-fine deep learning framework for optic disc segmentation in fundus images, *Biomed.*

Signal Process. Control, 51, 82–89, doi: 10.1016/j.bspc.2019.01.022.

- [29] **Liu, S., Hong, J., Lu, X., Jia, X., Lin, Z., Zhou, Y., ... & Zhang, H.** (2019). Joint optic disc and cup segmentation using semi-supervised conditional GANs, *Comput. Biol. Med.*, 115, doi: <https://doi.org/10.1016/j.compbimed.2019.103485>.
- [30] **Pathan, S., Kumar, P., Pai, R., & Bhandary, S. V.** (2020). Automated detection of optic disc contours in fundus images using decision tree classifier, *Biocybern. Biomed. Eng.*, 40, 52–64, doi: 10.1016/j.bbe.2019.11.003.
- [31] **Kumar, S., Adarsh, A., Kumar, B., & Singh, A. K.** (2020). An automated early diabetic retinopathy detection through improved blood vessel and optic disc segmentation, *Opt. Laser Technol.*, 121, doi: 10.1016/j.optlastec.2019.105815.
- [32] **Jana, S., Parekh, R., & Sarkar, B.** (2021). A semi-supervised approach for automatic detection and segmentation of optic disc from retinal fundus image, in *Handbook of Computational Intelligence in Biomedical Engineering and Healthcare*, 2021, 65–91. doi: 10.1016/b978-0-12-822260-7.00012-1.
- [33] **Tulsani, A., Kumar, P., & Pathan, S.** (2021). Automated segmentation of optic disc and optic cup for glaucoma assessment using improved UNET++ architecture, *Biocybern. Biomed. Eng.*, 41 (2), 819–832, doi: 10.1016/j.bbe.2021.05.011.
- [34] **Veena, H. N., Muruganandham, A., & Kumaran, T. S.** (2021). A novel optic disc and optic cup segmentation technique to diagnose glaucoma using deep learning convolutional neural network over retinal fundus images, *J. King Saud Univ. - Comput. Inf. Sci.*, doi: 10.1016/j.jksuci.2021.02.003.
- [35] **Wang, L., Gu, J., Chen, Y., Liang, Y., Zhang, W., Pu, J., & Chen, H.** (2021). Automated segmentation of the optic disc from fundus images using an asymmetric deep learning network, *Pattern Recognit.*, 112, doi: 10.1016/j.patcog.2020.107810.
- [36] **Alkozi, H. A., Navarro, G., Franco, R., & Pintor, J.** (2020). Melatonin and the control of intraocular pressure, *Prog. Retin. Eye Res.*, 75, doi: 10.1016/j.preteyeres.2019.100798.
- [37] **Gómez-Valverde, J. J., Antón, A., Fatti, G., Liefers, B., Herranz, A., Santos, A., ... & Ledesma-Carbayo, M. J.** (2019). Automatic glaucoma classification using color fundus images based on convolutional neural networks and transfer learning, *Biomed. Opt. Express*, 10 (2), 892, doi: 10.1364/boe.10.000892.

- [38] **Foster, P. J., Buhrmann, R., Quigley, H. A., & Johnson, G. J.** (2002). The definition and classification of glaucoma in prevalence surveys, *Br. J. Ophthalmol.*, 86, 238–242, doi: 10.1136/bjo.86.2.238.
- [39] **Quigley, H. A.**, (2011). Glaucoma, *Lancet*, 377, 1367–1377, doi: [https://doi.org/10.1016/S0140-6736\(10\)61423-7](https://doi.org/10.1016/S0140-6736(10)61423-7).
- [40] **Muramatsu, C., Fujita, H., Nakagawa, T., Sawada, A., Yamamoto, T., & Hatanaka, Y.** (2011). Automated determination of cup-to-disc ratio for classification of glaucomatous and normal eyes on stereo retinal fundus images., *J. Biomed. Opt.*, doi: <https://doi.org/10.1117/1.3622755>.
- [41] **Issac, A., Sarathi, M. P., & Dutta, M. K.** (2015). An adaptive threshold based image processing technique for improved glaucoma detection and classification, *Comput. Methods Programs Biomed.*, 122 (2), 229–244, doi: 10.1016/j.cmpb.2015.08.002.
- [42] **Panda, R., Puhan, N. B., Rao, A., Padhy, D., & Panda, G.** (2018). Automated retinal nerve fiber layer defect detection using fundus imaging in glaucoma, *Comput. Med. Imaging Graph.*, 66, 56–65, doi: 10.1016/j.compmedimag.2018.02.006.
- [43] **Divya, L., & Jacob, J.** (2018). Performance analysis of glaucoma detection approaches from fundus images, *Procedia Comput. Sci.*, 143, 544–551, doi: 10.1016/j.procs.2018.10.429.
- [44] **Soorya, M., Issac, A., & Dutta, M. K.** (2018). An automated and robust image processing algorithm for glaucoma diagnosis from fundus images using novel blood vessel tracking and bend point detection, *Int. J. Med. Inform.*, 110, 52–70, doi: 10.1016/j.ijmedinf.2017.11.015.
- [45] **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 (Basel)*, 10 (4), doi: <https://doi.org/10.3390/sym10040087>.
- [46] **Yu, S., Xiao, D., Frost, S., & Kanagasingam, Y.** (2019). Robust optic disc and cup segmentation with deep learning for glaucoma detection, *Comput. Med. Imaging Graph.*, 74, 61–71, doi: 10.1016/j.compmedimag.2019.02.005.
- [47] **Claro, M., Veras, R., Santana, A., Araujo, F., Silva, R., Almeida, J., & Leite, D.** (2019). An hybrid feature space from texture information and transfer learning for

- glaucoma classification, *J. Vis. Commun. Image Represent.*, 64, doi: <https://doi.org/10.1016/j.jvcir.2019.102597>.
- [48] **Mvoulana, A., Kachouri, R., & Akil, M.** (2019). Fully automated method for glaucoma screening using robust optic nerve head detection and unsupervised segmentation based cup-to-disc ratio computation in retinal fundus images, *Comput. Med. Imaging Graph.*, 77, doi: 10.1016/j.compmedimag.2019.101643.
- [49] **Shoba, S. G., & Therese, A. B.** (2020). Detection of glaucoma disease in fundus images based on morphological operation and finite element method, *Biomed. Signal Process. Control*, 62, doi: 10.1016/j.bspc.2020.101986.
- [50] **Elangovan, P., Nath, M. K., & Mishra, M.** (2020). Statistical Parameters for Glaucoma Detection from Color Fundus Images, *Procedia Comput. Sci.*, 171, 2675–2683, doi: 10.1016/j.procs.2020.04.290.
- [51] **Martins, J., Cardoso, J. S., & Soares, F.** (2020). Offline computer-aided diagnosis for Glaucoma detection using fundus images targeted at mobile devices, *Comput. Methods Programs Biomed.*, 192, doi: <https://doi.org/10.1016/j.cmpb.2020.105341>.
- [52] **Bisneto, T. R. V., de Carvalho Filho, A. O., & Magalhães, D. M. V.** (2020). Generative adversarial network and texture features applied to automatic glaucoma detection, *Appl. Soft Comput. J.*, 90, doi: <https://doi.org/10.1016/j.asoc.2020.106165>.
- [53] **Pruthi, J., Khanna, K., & Arora, S.** (2020). Optic Cup segmentation from retinal fundus images using Glowworm Swarm Optimization for glaucoma detection, *Biomed. Signal Process. Control*, 60, doi: 10.1016/j.bspc.2020.102004.
- [54] **Nayak, D. R., Das, D., Majhi, B., Bhandary, S. V., & Acharya, U. R.** (2021). ECNet: An evolutionary convolutional network for automated glaucoma detection using fundus images, *Biomed. Signal Process. Control*, 67, doi: 10.1016/j.bspc.2021.102559.
- [55] **Lupascu, C. A., Tegolo, D., & Trucco, E.** (2010). FABC: Retinal vessel segmentation using AdaBoost, *IEEE Trans. Inf. Technol. Biomed.*, 14 (5), 1267–1274, doi: 10.1109/TITB.2010.2052282.
- [56] **Zhang, B., Zhang, L., Zhang, L., & Karray, F.** (2010). Retinal vessel extraction by matched filter with first-order derivative of Gaussian, *Comput. Biol. Med.*, 40 (4), 438–445, doi: 10.1016/j.compbiomed.2010.02.008.

- [57] **Vlachos, M., & Dermatas, E.** (2010). Multi-scale retinal vessel segmentation using line tracking, *Comput. Med. Imaging Graph.*, 34 (3), 213–227, doi: 10.1016/j.compmedimag.2009.09.006.
- [58] **You, X., Peng, Q., Yuan, Y., Cheung, Y. M., & Lei, J.** (2011). Segmentation of retinal blood vessels using the radial projection and semi-supervised approach, *Pattern Recognit.*, 44 (10–11), 2314–2324, doi: 10.1016/j.patcog.2011.01.007.
- [59] **Bankhead, P., Scholfield, C. N., McGeown, J. G., & Curtis, T. M.** (2012). Fast retinal vessel detection and measurement using wavelets and edge location refinement, *PLoS One*, 7 (3), doi: 10.1371/journal.pone.0032435.
- [60] **Fraz, M. M., Barman, S. A., Remagnino, P., Hoppe, A., Basit, A., Uyyanonvara, B., ... & Owen, C. G.** (2012). An approach to localize the retinal blood vessels using bit planes and centerline detection, *Comput. Methods Programs Biomed.*, 108 (2), 600–616, doi: 10.1016/j.cmpb.2011.08.009.
- [61] **Nguyen, U. T., Bhuiyan, A., Park, L. A., & Ramamohanarao, K.** (2013). An effective retinal blood vessel segmentation method using multi-scale line detection, *Pattern Recognit.*, 46 (3), 703–715, doi: 10.1016/j.patcog.2012.08.009.
- [62] **Fathi, A., & Naghsh-Nilchi, A. R.** (2013). Automatic wavelet-based retinal blood vessels segmentation and vessel diameter estimation, *Biomed. Signal Process. Control*, 8 (1), 71–80, doi: 10.1016/j.bspc.2012.05.005.
- [63] **Wang, Y., Ji, G., Lin, P., & Trucco, E.** (2013). Retinal vessel segmentation using multiwavelet kernels and multiscale hierarchical decomposition, *Pattern Recognit.*, 46 (8), 2117–2133, doi: 10.1016/j.patcog.2012.12.014.
- [64] **Fraz, M. M., Remagnino, P., Hoppe, A., Rudnicka, A. R., Owen, C. G., Whincup, P. H., & Barman, S. A.** (2013). Quantification of blood vessel calibre in retinal images of multi-ethnic school children using a model based approach, *Comput. Med. Imaging Graph.*, 37 (1), 48–60, doi: 10.1016/j.compmedimag.2013.01.004.
- [65] **Nayebifar, B., & Moghaddam, H. A.** (2013). A novel method for retinal vessel tracking using particle filters, *Comput. Biol. Med.*, 43 (5), 541–548, doi: 10.1016/j.compbiomed.2013.01.016.
- [66] **Akram, M. U., Khalid, S., Tariq, A., & Javed, M. Y.** (2013). Detection of neovascularization in retinal images using multivariate m-Medoids based classifier,

- Comput. Med. Imaging Graph.*, 37, 346–357, doi: 10.1016/j.compmedimag.2013.06.008.
- [67] **Li, H., Zhang, J., Nie, Q., & Cheng, L.** (2013). A retinal vessel tracking method based on Bayesian theory, in *Proceedings of the 2013 IEEE 8th Conference on Industrial Electronics and Applications, ICIEA 2013*, 2013, 232–235. doi: 10.1109/ICIEA.2013.6566372.
- [68] **Zhao, Y. Q., Wang, X. H., Wang, X. F., & Shih, F. Y.** (2014). Retinal vessels segmentation based on level set and region growing, *Pattern Recognit.*, 47 (7), 2437–2446, doi: 10.1016/j.patcog.2014.01.006.
- [69] **Franklin, S. W., & Rajan, S. E.** (2014). Retinal vessel segmentation employing ANN technique by Gabor and moment invariants-based features, *Appl. Soft Comput. J.*, 22, 94–100, doi: 10.1016/j.asoc.2014.04.024.
- [70] **Franklin, S. W., & Rajan, S. E.** (2014). Computerized screening of diabetic retinopathy employing blood vessel segmentation in retinal images, *Biocybern. Biomed. Eng.*, 34 (2), 117–124, doi: 10.1016/j.bbe.2014.01.004.
- [71] **Yu, L., Qi, Y., Xia, M., & Xuan, L.** (2014). Retinal vessel extraction by means of motion contrast, matched filter and combined corner-edge detector, *Opt. Commun.*, 318, 17–25, doi: 10.1016/j.optcom.2013.12.048.
- [72] **Sigurðsson, E. M., Valero, S., Benediktsson, J. A., Chanussot, J., Talbot, H., & Stefánsson, E.** (2014). Automatic retinal vessel extraction based on directional mathematical morphology and fuzzy classification, *Pattern Recognit. Lett.*, 47, 164–171, doi: 10.1016/j.patrec.2014.03.006.
- [73] **Zhang, J., Li, H., Nie, Q., & Cheng, L.** (2014). A retinal vessel boundary tracking method based on Bayesian theory and multi-scale line detection, *Comput. Med. Imaging Graph.*, 38 (6), 517–525, doi: 10.1016/j.compmedimag.2014.05.010.
- [74] **Chen, L., Huang, X., & Tian, J.** (2015). Retinal image registration using topological vascular tree segmentation and bifurcation structures, *Biomed. Signal Process. Control*, 16, 22–31, doi: 10.1016/j.bspc.2014.10.009.
- [75] **Wang, S., Yin, Y., Cao, G., Wei, B., Zheng, Y., & Yang, G.** (2015). Hierarchical retinal blood vessel segmentation based on feature and ensemble learning, *Neurocomputing*, 149 (PB), 708–717, doi: 10.1016/j.neucom.2014.07.059.

- [76] **Zhang, L., Fisher, M., & Wang, W.** (2015). Retinal vessel segmentation using multi-scale textons derived from keypoints, *Comput. Med. Imaging Graph.*, 45, 47–56, doi: 10.1016/j.compmedimag.2015.07.006.
- [77] **Lázár, I., & Hajdu, A.** (2015). Segmentation of retinal vessels by means of directional response vector similarity and region growing, *Comput. Biol. Med.*, 66, 209–221, doi: 10.1016/j.compbiomed.2015.09.008.
- [78] **Imani, E., Javidi, M., & Pourreza, H. R.** (2015). Improvement of retinal blood vessel detection using morphological component analysis, *Comput. Methods Programs Biomed.*, 118 (3), 263–279, doi: 10.1016/j.cmpb.2015.01.004.
- [79] **Fraz, M. M., Welikala, R. A., Rudnicka, A. R., Owen, C. G., Strachan, D. P., & Barman, S. A.** (2015). QUARTZ: Quantitative analysis of retinal vessel topology and size - An automated system for quantification of retinal vessels morphology, *Expert Syst. Appl.*, 42 (20), 7221–7234, doi: 10.1016/j.eswa.2015.05.022.
- [80] **Vega, R., Sanchez-Ante, G., Falcon-Morales, L. E., Sossa, H., & Guevara, E.** (2015). Retinal vessel extraction using Lattice Neural Networks with dendritic processing, *Comput. Biol. Med.*, 58, 20–30, doi: 10.1016/j.compbiomed.2014.12.016.
- [81] **Azzopardi, G., Strisciuglio, N., Vento, M., & Petkov, N.** (2015). Trainable COSFIRE filters for vessel delineation with application to retinal images, *Med. Image Anal.*, 19 (1), 46–57, doi: 10.1016/j.media.2014.08.002.
- [82] **Singh, N. P., & Srivastava, R.** (2016). Retinal blood vessels segmentation by using Gumbel probability distribution function based matched filter, *Comput. Methods Programs Biomed.*, 129, 40–50, doi: 10.1016/j.cmpb.2016.03.001.
- [83] **GeethaRamani, R., & Balasubramanian, L.** (2016). Retinal blood vessel segmentation employing image processing and data mining techniques for computerized retinal image analysis, *Biocybern. Biomed. Eng.*, 36 (1), 102–118, doi: 10.1016/j.bbe.2015.06.004.
- [84] **Christodoulidis, A., Hurtut, T., Tahar, H. B., & Cheriet, F.** (2016). A multi-scale tensor voting approach for small retinal vessel segmentation in high resolution fundus images, *Comput. Med. Imaging Graph.*, 52, 28–43, doi: 10.1016/j.compmedimag.2016.06.001.
- [85] **Kar, S. S., & Maity, S. P.** (2016). Retinal blood vessel extraction using tunable

- bandpass filter and fuzzy conditional entropy, *Comput. Methods Programs Biomed.*, 133, 111–132, doi: 10.1016/j.cmpb.2016.05.015.
- [86] **Kovács, G., & Hajdu, A.** (2016). A self-calibrating approach for the segmentation of retinal vessels by template matching and contour reconstruction, *Med. Image Anal.*, 29, 24–46, doi: 10.1016/j.media.2015.12.003.
- [87] **Jiang, Z., Yopez, J., An, S., & Ko, S.** (2017). Fast, accurate and robust retinal vessel segmentation system, *Biocybern. Biomed. Eng.*, 37 (3), 412–421, doi: 10.1016/j.bbe.2017.04.001.
- [88] **Dash, J., & Bhoi, N.** (2017). A thresholding based technique to extract retinal blood vessels from fundus images, *Futur. Comput. Informatics J.*, 2 (2), 103–109, doi: 10.1016/j.fcij.2017.10.001.
- [89] **Neto, L. C., Ramalho, G. L., Neto, J. F. R., Veras, R. M., & Medeiros, F. N.** (2017). An unsupervised coarse-to-fine algorithm for blood vessel segmentation in fundus images, *Expert Syst. Appl.*, 78, 182–192, doi: 10.1016/j.eswa.2017.02.015.
- [90] **Zhu, C., Zou, B., Zhao, R., Cui, J., Duan, X., Chen, Z., & Liang, Y.** (2017). Retinal vessel segmentation in colour fundus images using Extreme Learning Machine, *Comput. Med. Imaging Graph.*, 55, 68–77, doi: 10.1016/j.compmedimag.2016.05.004.
- [91] **Zhou, L., Yu, Q., Xu, X., Gu, Y., & Yang, J.** (2017). Improving dense conditional random field for retinal vessel segmentation by discriminative feature learning and thin-vessel enhancement, *Comput. Methods Programs Biomed.*, 148, 13–25, doi: 10.1016/j.cmpb.2017.06.016.
- [92] **Aguirre-Ramos, H., Avina-Cervantes, J. G., Cruz-Aceves, I., Ruiz-Pinales, J., & Ledesma, S.** (2018). Blood vessel segmentation in retinal fundus images using Gabor filters, fractional derivatives, and Expectation Maximization, *Appl. Math. Comput.*, 339, 568–587, doi: 10.1016/j.amc.2018.07.057.
- [93] **Jiang, Z., Zhang, H., Wang, Y., & Ko, S. B.** (2018). Retinal blood vessel segmentation using fully convolutional network with transfer learning, *Comput. Med. Imaging Graph.*, 68, 1–15, doi: 10.1016/j.compmedimag.2018.04.005.
- [94] **Oliveira, A., Pereira, S., & Silva, C. A.** (2018). Retinal vessel segmentation based on Fully Convolutional Neural Networks, *Expert Syst. Appl.*, 112, 229–242, doi:

10.1016/j.eswa.2018.06.034.

- [95] **Guo, Y., Budak, Ü., & Şengür, A.** (2018). A novel retinal vessel detection approach based on multiple deep convolution neural networks, *Comput. Methods Programs Biomed.*, 167, 43–48, doi: 10.1016/j.cmpb.2018.10.021.
- [96] **Hu, K., Zhang, Z., Niu, X., Zhang, Y., Cao, C., Xiao, F., & Gao, X.** (2018). Retinal vessel segmentation of color fundus images using multiscale convolutional neural network with an improved cross-entropy loss function, *Neurocomputing*, 309, 179–191, doi: 10.1016/j.neucom.2018.05.011.
- [97] **Jebaseeli, T. J., Durai, C. A. D., & Peter, J. D.** (2019). Segmentation of retinal blood vessels from ophthalmologic Diabetic Retinopathy images, *Comput. Electr. Eng.*, 73, 245–258, doi: 10.1016/j.compeleceng.2018.11.024.
- [98] **Jebaseeli, T. J., Durai, C. A. D., & Peter, J. D.** (2019). Retinal blood vessel segmentation from diabetic retinopathy images using tandem PCNN model and deep learning based SVM, *Optik (Stuttg.)*, 199, doi: 10.1016/j.ijleo.2019.163328.
- [99] **Hashemzadeh, M., & Azar, B. A.** (2019). Retinal blood vessel extraction employing effective image features and combination of supervised and unsupervised machine learning methods, *Artif. Intell. Med.*, 95, 1–15, doi: 10.1016/j.artmed.2019.03.001.
- [100] **Wang, X., Jiang, X., & Ren, J.** (2019). Blood vessel segmentation from fundus image by a cascade classification framework, *Pattern Recognit.*, 88, 331–341, doi: 10.1016/j.patcog.2018.11.030.
- [101] **Sazak, Ç., Nelson, C. J., & Obara, B.** (2019). The multiscale bowler-hat transform for blood vessel enhancement in retinal images, *Pattern Recognit.*, 88, 739–750, doi: 10.1016/j.patcog.2018.10.011.
- [102] **Sun, G., Liu, X., Wang, S., Gao, L., & Liu, M.** (2019). Width measurement for pathological vessels in retinal images using centerline correction and k-means clustering, *Meas. J. Int. Meas. Confed.*, 139, 185–195, doi: 10.1016/j.measurement.2019.03.005.
- [103] **Orujov, F., Maskeliūnas, R., Damaševičius, R., & Wei, W.** (2020). Fuzzy based image edge detection algorithm for blood vessel detection in retinal images, *Appl. Soft Comput. J.*, 94, doi: 10.1016/j.asoc.2020.106452.
- [104] **Pachade, S., Porwal, P., Kokare, M., Giancardo, L., Meriaudeau, F.** (2020).

- Retinal vasculature segmentation and measurement framework for color fundus and SLO images, *Biocybern. Biomed. Eng.*, 40 (3), 865–900, doi: 10.1016/j.bbe.2020.03.001.
- [105] **Yang, J., Lou, C., Fu, J., & Feng, C.** (2020). Vessel segmentation using multiscale vessel enhancement and a region based level set model, *Comput. Med. Imaging Graph.*, 85, doi: 10.1016/j.compmedimag.2020.101783.
- [106] **Sun, M., Li, K., Qi, X., Dang, H., & Zhang, G.** (2021). Contextual information enhanced convolutional neural networks for retinal vessel segmentation in color fundus images, *J. Vis. Commun. Image Represent.*, 77, doi: 10.1016/j.jvcir.2021.103134.
- [107] **Ramos-Soto, O., Rodríguez-Esparza, E., Balderas-Mata, S. E., Oliva, D., Hassanien, A. E., Meleppat, R. K., & Zawadzki, R. J.** (2021). An efficient retinal blood vessel segmentation in eye fundus images by using optimized top-hat and homomorphic filtering, *Comput. Methods Programs Biomed.*, 201, doi: 10.1016/j.cmpb.2021.105949.
- [108] **Tchinda, B. S., Tchiotsop, D., Noubom, M., Louis-Dorr, V., & Wolf, D.** (2021). Retinal blood vessels segmentation using classical edge detection filters and the neural network, *Informatics Med. Unlocked*, 23, doi: 10.1016/j.imu.2021.100521.
- [109] **Yang, L., Wang, H., Zeng, Q., Liu, Y., & Bian, G.** (2021). A hybrid deep segmentation network for fundus vessels via deep-learning framework, *Neurocomputing*, 448, 168–178, doi: 10.1016/j.neucom.2021.03.085.
- [110] **Balasubramanian, K., & Ananthamoorthy, N. P.** (2021). Robust retinal blood vessel segmentation using convolutional neural network and support vector machine, *J. Ambient Intell. Humaniz. Comput.*, 12 (3), 3559–3569, doi: 10.1007/s12652-019-01559-w.
- [111] **Huang, M., Feng, C., Li, W., & Zhao, D.** (2021). Vessel enhancement using Multi-scale Space-Intensity domain Fusion Adaptive filtering, *Biomed. Signal Process. Control*, 69, doi: 10.1016/j.bspc.2021.102799.
- [112] **Muramatsu, C., Hatanaka, Y., Iwase, T., Hara, T., & Fujita, H.** (2011). Automated selection of major arteries and veins for measurement of arteriolar-to-venular diameter ratio on retinal fundus images, *Comput. Med. Imaging Graph.*, 35

- (6), 472–480, doi: 10.1016/j.compmedimag.2011.03.002.
- [113] **Bhuiyan, A., Kawasaki, R., Lamoureux, E., Ramamohanarao, K., & Wong, T. Y.** (2013). Retinal artery-vein caliber grading using color fundus imaging, *Comput. Methods Programs Biomed.*, 111 (1), 104–114, doi: 10.1016/j.cmpb.2013.02.004.
- [114] **Mirsharif, Q., Tajeripour, F., & Pourreza, H.** (2013). Automated characterization of blood vessels as arteries and veins in retinal images, *Comput. Med. Imaging Graph.*, 37 (7–8), 607–617, doi: 10.1016/j.compmedimag.2013.06.003.
- [115] **Dashtbozorg, B., Mendonça, A. M., & Campilho, A.** (2013). An automatic graph-based approach for artery/Vein classification in retinal images, *IEEE Trans. Image Process.*, 23 (3), 1073–1083, doi: 10.1109/TIP.2013.2263809.
- [116] **Khatakalle, R.R., & Shekokar, R.** (2017). Artery and Vein Classification in Retinal Images using Graph Based Approach. *International Journal of Advanced Research in Computer and Communication Engineering*, 6, 170-173. doi: 10.17148/ijarce.2017.6335.
- [117] **Welikala, R. A., Foster, P. J., Whincup, P. H., Rudnicka, A. R., Owen, C. G., Strachan, D. P., & Barman, S. A.** (2017). Automated arteriole and venule classification using deep learning for retinal images from the UK Biobank cohort, *Comput. Biol. Med.*, 90, 23–32, doi: 10.1016/j.compbiomed.2017.09.005.
- [118] **Xu, X., Ding, W., Abramoff, M. D., & Cao, R.** (2017). An improved arteriovenous classification method for the early diagnostics of various diseases in retinal image, *Comput. Methods Programs Biomed.*, 141, 3–9, doi: 10.1016/j.cmpb.2017.01.007.
- [119] **Huang, F., Dashtbozorg, B., Tan, T., & ter Haar Romeny, B. M.** (2018). Retinal artery/vein classification using genetic-search feature selection, *Comput. Methods Programs Biomed.*, 161, 197–207, doi: 10.1016/j.cmpb.2018.04.016.
- [120] **Huang, F., Dashtbozorg, B., & Romeny, B. M.** (2018). Artery/vein classification using reflection features in retina fundus images, *Mach. Vis. Appl.*, 29 (1), 23–34, doi: 10.1007/s00138-017-0867-x.
- [121] **Wang, Z., Lin, J., Wang, R., & Zheng, W.** (2019). Retinal artery/vein classification via rotation augmentation and deeply supervised U-net segmentation, *PervasiveHealth Pervasive Comput. Technol. Healthc.*, 71–76, doi: 10.1145/3354031.3354050.

- [122] **Hemelings, R., Elen, B., Stalmans, I., Van Keer, K., De Boever, P., & Blaschko, M. B.** (2019). Artery–vein segmentation in fundus images using a fully convolutional network, *Comput. Med. Imaging Graph.*, 76, doi: 10.1016/j.compmedimag.2019.05.004.
- [123] **Girard, F., Kavalec, C., & Cheriet, F.** (2019). Joint segmentation and classification of retinal arteries/veins from fundus images, *Artif. Intell. Med.*, 94, 96–109, doi: 10.1016/j.artmed.2019.02.004.
- [124] **Galdran, A., Meyer, M., Costa, P., & Campilho, A.** (2019). Uncertainty-aware artery/vein classification on retinal images, in *Proceedings - International Symposium on Biomedical Imaging*, 2019, 2019-April, 556–560. doi: 10.1109/ISBI.2019.8759380.
- [125] **Yang, J., Dong, X., Hu, Y., Peng, Q., Tao, G., Ou, Y., ... & Yang, X.** (2020). Fully Automatic Arteriovenous Segmentation in Retinal Images via Topology-Aware Generative Adversarial Networks, *Interdiscip. Sci. Comput. Life Sci.*, 12 (3), 323–334, doi: 10.1007/s12539-020-00385-5.
- [126] **Shin, S. Y., Lee, S., Yun, I. D., & Lee, K. M.** (2021). Topology-aware retinal artery–vein classification via deep vascular connectivity prediction, *Appl. Sci.*, 11 (1), 1–14, doi: 10.3390/app11010320.
- [127] **Sathananthavathi, V., & Indumathi, G.** (2021). BAT optimization based Retinal artery vein classification, *Soft Comput.*, 25 (4), 2821–2835, doi: 10.1007/s00500-020-05339-z.
- [128] **Remeseiro, B., Mendonça, A. M., & Campilho, A.** (2021). Automatic classification of retinal blood vessels based on multilevel thresholding and graph propagation, *Vis. Comput.*, 37 (6), 1247–1261, doi: 10.1007/s00371-020-01863-z.
- [129] **Toptaş, B., Toptaş, M., & Hanbay, D.** (2022). Detection of Optic Disc Localization from Retinal Fundus Image Using Optimized Color Space. *Journal of Digital Imaging*, 1-18.
- [130] **Toptaş, B., & Hanbay, D.** (2021). Retinal blood vessel segmentation using pixel-based feature vector. *Biomedical Signal Processing and Control*, 70, 103053. doi: 10.1016/j.bspc.2021.103053.
- [131] **Toptaş, B., & Hanbay, D.** (2022). Retina Kan Damarlarını Çıkarmak için Eşikleme

Temelli Morfolojik Bir Yöntem, *Ömer Halisdemir Üniversitesi Mühendislik Bilim. Derg.*, 11 (1), 10–16, doi: 10.28948/ngumuh.900696.

- [132] **Ali, A., Zaki, W. M. D. W., Hussain, A., & Halim, W. H. W. A.** (2021). Retinal Width Estimation of High-Resolution Fundus Images for Diabetic Retinopathy Detection, in *Proceedings - 2020 IEEE EMBS Conference on Biomedical Engineering and Sciences, IECBES 2020*, 2021, 460–465. doi: 10.1109/IECBES48179.2021.9398752.
- [133] **Joshi, S., & Karule, P. T.** (2020). Mathematical morphology for microaneurysm detection in fundus images, *Eur. J. Ophthalmol.*, 30 (5), 1135–1142, doi: 10.1177/1120672119843021.
- [134] **Bibi, I., Mir, J., & Raja, G.** (2020). Automated detection of diabetic retinopathy in fundus images using fused features, *Phys. Eng. Sci. Med.*, 43 (4), 1253–1264, doi: 10.1007/s13246-020-00929-5.
- [135] **Shelar, M., Gaitonde, S., Senthilkumar, A., Mundra, M., & Sarang, A.** (2021). Detection of Diabetic Retinopathy and its Classification from the Fundus Images, in *2021 International Conference on Computer Communication and Informatics, ICCCI 2021*, 2021, 1–6. doi: 10.1109/ICCCI50826.2021.9402347.
- [136] **Aurangzeb, K., Aslam, S., Alhusein, M., Naqvi, R. A., Arsalan, M., & Haider, S. I.** (2021). Contrast Enhancement of Fundus Images by Employing Modified PSO for Improving the Performance of Deep Learning Models, *IEEE Access*, 9, 47930–47945, doi: 10.1109/ACCESS.2021.3068477.
- [137] **Joseph, J., Sivaraman, J., Periyasamy, R., & Simi, V. R.** (2017). An objective method to identify optimum clip-limit and histogram specification of contrast limited adaptive histogram equalization for MR images, *Biocybern. Biomed. Eng.*, 37 (3), 489–497, doi: 10.1016/j.bbe.2016.11.006.
- [138] **Chang, Y., Jung, C., Ke, P., Song, H., & Hwang, J.** (2018). Automatic Contrast-Limited Adaptive Histogram Equalization with Dual Gamma Correction, *IEEE Access*, 6, 11782–11792, doi: 10.1109/ACCESS.2018.2797872.
- [139] **Alwazzan, M. J., Ismael, M. A., & Ahmed, A. N.** (2021). A Hybrid Algorithm to Enhance Colour Retinal Fundus Images Using a Wiener Filter and CLAHE, *J. Digit. Imaging*, 34 (3), 750–759, doi: 10.1007/s10278-021-00447-0.

- [140] **Manju, B. R., & Sneha, M. R.** (2020). ECG Denoising Using Wiener Filter and Kalman Filter, *Procedia Comput. Sci.*, 171, 273–281, doi: 10.1016/j.procs.2020.04.029.
- [141] **Chaichana, T., Yoowattana, S., Sun, Z., Tangjitkusolmun, S., Sookpotharom, S., & Sangworasil, M.** (2008). Edge detection of the optic disc in retinal images based on identification of a round shape, in *2008 International Symposium on Communications and Information Technologies, ISCIT 2008*, 2008, 670–674. doi: 10.1109/ISCIT.2008.4700277.
- [142] **Ilayarajaa, K. T., & Logashanmugam, E.** (2020). Retinal Blood Vessel Segmentation using Morphological and Canny Edge Detection Technique, in *2020 International Conference on System, Computation, Automation and Networking, ICSCAN 2020*, 2020, 1–5. doi: 10.1109/ICSCAN49426.2020.9262446.
- [143] **Dandekar, N., Kulkarni, J., Raut, R., & Raut, K.** (2021). Extracting Features from the fundus image using Canny edge detection method for Pre-Detection of Diabetic Retinopathy, *VIVA-Tech Int. J. Res. Innov.*, 1 (4), 13–18.
- [144] **Biswas, R., & Sil, J.** (2012). An Improved Canny Edge Detection Algorithm Based on Type-2 Fuzzy Sets, *Procedia Technol.*, 4, 820–824, doi: 10.1016/j.protcy.2012.05.134.
- [145] **Marr, D., & Hildreth, E.** (1980). Theory of edge detection, *Proc. R. Soc. London - Biol. Sci.*, 207 (1167), 187–217, doi: 10.1098/rspb.1980.0020.
- [146] **ŞENEL, H. G.** (2007). Kenar Bulma İçin Topolojik Gradyan İşleçleri, *Eskişehir Osmangazi Üniversitesi Mühendislik ve Mimar. Fakültesi Derg.*, 20 (2), 135–158, doi: <https://dergipark.org.tr/tr/pub/ogummf/issue/30184/325737>.
- [147] **Rafael C. Gonzalez & Richard E. Woods.** (2006). *Digital Image Processing (3rd Edition)*. 2007. [Online]. Available: <http://dl.acm.org/citation.cfm?id=1076432>
- [148] **Lakemond, R., Sridharan, S., & Fookes, C.** (2012). Hessian-based affine adaptation of salient local image features, *J. Math. Imaging Vis.*, 44 (2), 150–167, doi: 10.1007/s10851-011-0317-8.
- [149] **Alpaslan, N., Hanbay, K., Hanbay, D., & Talu, M. F.** (2014). A novel texture classification method based on Hessian matrix and principal curvatures, *In 2014 22nd Signal Processing and Communications Applications Conference (SIU)* (pp. 160-

- 163). IEEE. doi: 10.1109/siu.2014.6830190.
- [150] **Karaboga, D., & Akay, B.** (2011). A modified Artificial Bee Colony (ABC) algorithm for constrained optimization problems, *Appl. Soft Comput. J.*, 11 (3), 3021–3031, doi: 10.1016/j.asoc.2010.12.001.
- [151] **MacQueen, J.** (1967). Some methods for classification and analysis of multivariate observations, in *Proceedings of the fifth Berkeley symposium on mathematical statistics and probability*, 1967, 1 (14), 281–297.
- [152] **Çelik, Ö.** (2018). A Research on Machine Learning Methods and Its Applications, *J. Educ. Technol. Online Learn.*, 1 (3), 25–40.
- [153] **Yan, H., Jiang, Y., Zheng, J., Peng, C., & Li, Q.** (2006). A multilayer perceptron-based medical decision support system for heart disease diagnosis, *Expert Syst. Appl.*, 30 (2), 272–281, doi: 10.1016/j.eswa.2005.07.022.
- [154] **Aşkın, D., İskender, İ., & Mamızadeh, A.** (2011). Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi, *Gazi Üniv. Müh. Mim. Fak. Der.*, 26 (4), 905–913.
- [155] **Ioffe, S., & Szegedy, C.** (2015). Batch normalization: Accelerating deep network training by reducing internal covariate shift, in *32nd International Conference on Machine Learning, ICML 2015*, 2015, 1, 448–456.
- [156] **Thakkar, V., Tewary, S., & Chakraborty, C.** (2018). Batch Normalization in Convolutional Neural Networks - A comparative study with CIFAR-10 data, *Proc. 5th Int. Conf. Emerg. Appl. Inf. Technol. EAIT 2018*, 1–5, doi: 10.1109/EAIT.2018.8470438.
- [157] **Meltek, S., & Çetiner, H.** (2021). *Matlab ortamında derin öğrenme uygulamaları*. İksad yayınevi.
- [158] **Albawi, S., Mohammed, T. A., & Al-Zawi, S.** (2017). Understanding of a convolutional neural network, in *Proceedings of 2017 International Conference on Engineering and Technology, ICET 2017*, 2018, 2018-Janua, 1–6. doi: 10.1109/ICEngTechnol.2017.8308186.
- [159] **Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., ... & Chen, T.** (2018). Recent advances in convolutional neural networks, *Pattern Recognit.*, 77, 354–377, doi: 10.1016/j.patcog.2017.10.013.

- [160] **Tan, M., & Le, Q.** (2019). EfficientNet: Rethinking model scaling for convolutional neural networks, *36th Int. Conf. Mach. Learn. ICML 2019*, 2019-June, 10691–10700.
- [161] **Gupta, N., Garg, H., & Agarwal, R.** (2021). A robust framework for glaucoma detection using CLAHE and EfficientNet, *Vis. Comput.*, doi: 10.1007/s00371-021-02114-5.
- [162] **Chollet, F.** (2017). Xception: Deep Learning with Depthwise Separable Convolutions, *Comput. Vis. Pattern Recognit.*, abs/1610.0.
- [163] **Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L. C.** (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks, *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, 4510–4520, doi: 10.1109/CVPR.2018.00474.
- [164] **Staal, J., Abràmoff, M. D., Niemeijer, M., Viergever, M. A., & Van Ginneken, B.** (2004). Ridge-based vessel segmentation in color images of the retina, *IEEE Trans. Med. Imaging*, 23 (4), 501–509, doi: 10.1109/TMI.2004.825627.
- [165] <https://www.adcis.net/en/third-party/messidor/>.
- [166] **Decencière, E., Zhang, X., Cazuguel, G., Lay, B., Cochener, B., Trone, C., ... & Klein, J. C.** (2014). Feedback on a publicly distributed image database: The Messidor database, *Image Anal. Stereol.*, 33 (3), 231–234, doi: 10.5566/ias.1155.
- [167] **Carmona, E. J., Rincón, M., García-Feijóo, J., & Martínez-de-la-Casa, J. M.** (2008). Identification of the optic nerve head with genetic algorithms, *Artif. Intell. Med.*, 43 (3), 243–259, doi: 10.1016/j.artmed.2008.04.005.
- [168] **Hoover, A. D., Kouznetsova, V., & Goldbaum, M.** (2000). Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response, *IEEE Trans. Med. Imaging*, 19 (3), 203–210, doi: 10.1109/42.845178.
- [169] **Niemeijer, M., Xu, X., Dumitrescu, A. V., Gupta, P., Van Ginneken, B., Folk, J. C., & Abramoff, M. D.** (2011). Automated measurement of the arteriolar-to-venular width ratio in digital color fundus photographs, *IEEE Trans. Med. Imaging*, 30 (11), 1941–1950, doi: 10.1109/TMI.2011.2159619.
- [170] **Orlando, J. I., Barbosa Breda, J., Keer, K. V., Blaschko, M. B., Blanco, P. J., & Bulant, C. A.** (2018). Towards a glaucoma risk index based on simulated hemodynamics from fundus images, *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, 11071 LNCS, 65–73, doi:

10.1007/978-3-030-00934-2_8.

- [171] **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, *Biomed. Eng. Online*, 18 (1), [Online]. Available: <http://www.embase.com/search/results?subaction=viewrecord&from=export&id=L626824418%0Ahttp://dx.doi.org/10.1186/s12938-019-0649-y>
- [172] **Toptaş, B., & Hanbay, D.** (2020). A new artificial bee colony algorithm-based color space for fire/flame detection, *Soft Comput.*, 24 (14), 10481–10492, doi: 10.1007/s00500-019-04557-4.
- [173] **Khatami, A., Mirghasemi, S., Khosravi, A., Lim, C. P., & Nahavandi, S.** (2017). A new PSO-based approach to fire flame detection using K-Medoids clustering, *Expert Syst. Appl.*, 68, 69–80, doi: 10.1016/j.eswa.2016.09.021.
- [174] **Rangayyan, R. M., Zhu, X., & Ayres, F. J.** (2009). Detection of the optic disc in images of the retina using gabor filters and phase portrait analysis, *IFMBE Proc.*, 22, 468–471, doi: 10.1007/978-3-540-89208-3_111.
- [175] **Toman, H., Kovacs, L., Jonas, A., Hajdu, L., & Hajdu, A.** (2012). Generalized weighted majority voting with an application to algorithms having spatial output, *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, 7209, 56–67, doi: 10.1007/978-3-642-28931-6_6.
- [176] **Lupascu, C. A., Tegolo, D., & Di Rosa, L.** (2008). Automated detection of optic disc location in retinal images, in *Proceedings - IEEE Symposium on Computer-Based Medical Systems*, 2008, 17–22. doi: 10.1109/CBMS.2008.15.
- [177] **Rangayyan, R. M., Zhu, X., Ayres, F. J., & Ells, A. L.** (2010). Detection of the optic nerve head in fundus images of the retina with gabor filters and phase portrait analysis, *J. Digit. Imaging*, 23 (4), 438–453, doi: 10.1007/s10278-009-9261-1.
- [178] **Zhu, X., Rangayyan, R. M., & Ells, A. L.** (2010). Detection of the optic nerve head in fundus images of the retina using the hough transform for circles, *J. Digit. Imaging*, 23 (3), 332–341, doi: 10.1007/s10278-009-9189-5.
- [179] **Odstrcilik, J., Kolar, R., Budai, A., Hornegger, J., Jan, J., Gazarek, J., ... & Angelopoulou, E.** (2013). Retinal vessel segmentation by improved matched filtering: Evaluation on a new high-resolution fundus image database, *IET Image*

- Process.*, 7 (4), 373–383, doi: 10.1049/iet-ipr.2012.0455.
- [180] **Roychowdhury, S., Koozekanani, D. D., & Parhi, K. K.** (2015). Iterative Vessel Segmentation of Fundus Images, *IEEE Trans. Biomed. Eng.*, 62 (7), 1738–1749, doi: 10.1109/TBME.2015.2403295.
- [181] **Anil, M.** (2016). Blood vessel segmentation from retinal images, (Yüksek lisans tezi) University of Eastern Finland.
- [182] **Yan, Z., Yang, X., & Cheng, K. T.** (2018). A three-stage deep learning model for accurate retinal vessel segmentation. *IEEE journal of Biomedical and Health Informatics*, 23(4), 1427-1436
- [183] **Khan, M. A., Mir, N., Sarirete, A., & Carmichael, J. N.** (2019). Thin Vessel Detection and Thick Vessel Edge Enhancement to Boost Performance of Retinal Vessel Extraction Methods, *Procedia Comput. Sci.*, 163, 618–638, doi: 10.1016/j.procs.2019.12.144.
- [184] **Lin, Y., Zhang, H., & Hu, G.** (2018). Automatic Retinal Vessel Segmentation via Deeply Supervised and Smoothly Regularized Network, *IEEE Access*, 7, 57717–57724, doi: 10.1109/ACCESS.2018.2844861.
- [185] **Tamim, N., Elshrkawey, M., Abdel Azim, G., & Nassar, H.** (2020). Retinal blood vessel segmentation using hybrid features and multi-layer perceptron neural networks, *Symmetry (Basel)*, 12 (6), doi: 10.3390/SYM12060894.
- [186] **Kushol, R., Kabir, M. H., Abdullah-Al-Wadud, M., & Islam, M. S.** (2020). Retinal blood vessel segmentation from fundus image using an efficient multiscale directional representation technique Bendlets, *Math. Biosci. Eng.*, 17 (6), 7751–7771, doi: 10.3934/MBE.2020394.
- [187] **Shukla, A. K., Pandey, R. K., & Pachori, R. B.** (2020). A fractional filter based efficient algorithm for retinal blood vessel segmentation, *Biomed. Signal Process. Control*, 59, doi: 10.1016/j.bspc.2020.101883.
- [188] **Dikkala, U., Joseph, M. K., & Alagirisamy, M.** (2021). A comprehensive analysis of morphological process dependent retinal blood vessel segmentation, in *International Conference on Computing, Communication, and Intelligent Systems (ICCCIS) A*, 2021, 510–516.
- [189] **Soares, J. V., Leandro, J. J., Cesar, R. M., Jelinek, H. F., & Cree, M. J.** (2006).

- Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification, *IEEE Trans. Med. Imaging*, 25 (9), 1214–1222, doi: 10.1109/TMI.2006.879967.
- [190] **Girard, F., & Cheriet, F.** (2017). Artery/vein classification in fundus images using CNN and likelihood score propagation, *2017 IEEE Glob. Conf. Signal Inf. Process. Glob. 2017 - Proc.*, 2018-Janua, 720–724, doi: 10.1109/GlobalSIP.2017.8309054.
- [191] **Kondermann, C., Kondermann, D., & Yan, M.** (2007). Blood vessel classification into arteries and veins in retinal images, *Med. Imaging 2007 Image Process.*, 6512, 651247, doi: 10.1117/12.708469.
- [192] **Ricci, E., & Perfetti, R.** (2007). Retinal blood vessel segmentation using line operators and support vector classification, *IEEE Trans. Med. Imaging*, 26 (10), 1357–1365, doi: 10.1109/TMI.2007.898551.
- [193] **Saleh, M. D., & Eswaran, C.** (2012). An efficient algorithm for retinal blood vessel segmentation using h-maxima transform and multilevel thresholding, *Comput. Methods Biomech. Biomed. Engin.*, 15 (5), 517–525, doi: 10.1080/10255842.2010.545949.
- [194] **Huang, F., Tan, T., Dashtbozorg, B., Zhou, Y., & Romeny, B. M. T. H.** (2020). From Local to Global: A Graph Framework for Retinal Artery/Vein Classification, *IEEE Trans. Nanobioscience*, 19 (4), 589–597, doi: 10.1109/TNB.2020.3004481.
- [195] **Srinidhi, C. L., Aparna, P., & Rajan, J.** (2019). Automated Method for Retinal Artery/Vein Separation via Graph Search Metaheuristic Approach, *IEEE Trans. Image Process.*, 28 (6), 2705–2718, doi: 10.1109/TIP.2018.2889534.
- [196] **Kang, H., Gao, Y., Guo, S., Xu, X., Li, T., & Wang, K.** (2020). AVNet: A retinal artery/vein classification network with category-attention weighted fusion, *Comput. Methods Programs Biomed.*, 195, doi: 10.1016/j.cmpb.2020.105629.
- [197] **Raj, P. K., Manjunath, A., Kumar, J. H., & Seelamantula, C. S.** (2020). Automatic Classification of Artery/Vein from Single Wavelength Fundus Images, in *Proceedings - International Symposium on Biomedical Imaging*, 2020, 2020-April, 1262–1265. doi: 10.1109/ISBI45749.2020.9098580.
- [198] **Elangovan, P., & Nath, M. K.** (2021). Glaucoma assessment from color fundus images using convolutional neural network, *Int. J. Imaging Syst. Technol.*, 31 (2),

955–971, doi: 10.1002/ima.22494.

- [199] **Serte, S., & Serener, A.** (2019). A Generalized Deep Learning Model for Glaucoma Detection, *3rd Int. Symp. Multidiscip. Stud. Innov. Technol. ISMSIT 2019 - Proc.*, doi: 10.1109/ISMSIT.2019.8932753.
- [200] **Christopher, M., Nakahara, K., Bowd, C., Proudfoot, J. A., Belghith, A., Goldbaum, M. H., ... & Zangwill, L. M.** (2020). Effects of study population, labeling and training on glaucoma detection using deep learning algorithms, *Transl. Vis. Sci. Technol.*, 9 (2), 1–14, doi: 10.1167/tvst.9.2.27.
- [201] **Almeida-Galárraga, D., Benavides-Montenegro, K., Insuasti-Cruz, E., Lovato-Villacís, N., Suárez-Jaramillo, V., Tene-Hurtado, D., ... & Villalba-Meneses, G. F.** (2021). Glaucoma detection through digital processing from fundus images using MATLAB, *Proc. - 2021 2nd Int. Conf. Inf. Syst. Softw. Technol. ICI2ST 2021*, 39–45, doi: 10.1109/ICI2ST51859.2021.00014.

ÖZGEÇMİŞ

Ad-Soyad : **Buket TOPTAŞ**

ÖĞRENİM DURUMU:

- **Lisans** : 2014, İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği
- **Yüksek Lisans** : 2017, İnönü Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği, Donanım Anabilim Dalı

MESLEKİ DENEYİM:

- 2015-2016 Ankara da özel bir firmada mobil program geliştirici olarak çalışmıştır.
- 2016-2017 İstanbul da özel bir firma da bilgisayar mühendisi olarak görev yapmıştır.
- 2019-... Bandırma Onyedü Eylül Üniversitesi Mühendislik ve Doğa Bilimleri Fakültesi Bilgisayar Mühendisliği bölümünde araştırma görevlisi olarak çalışmaktadır.

DOKTORA TEZİNDEN TÜRETİLEN ÇALIŞMALAR

Toptaş, B., Toptaş, M., & Hanbay, D. (2022). Detection of Optic Disc Localization from Retinal Fundus Image Using Optimized Color Space. *Journal of Digital Imaging*, 1-18.

Toptaş, B., & Hanbay, D. (2021). Retinal blood vessel segmentation using pixel-based feature vector. *Biomedical Signal Processing and Control*, 70, 103053. doi: 10.1016/j.bspc.2021.103053.

Toptaş, B., & Hanbay, D. (2022). Retina Kan Damarlarını Çıkarmak için Eşikleme Temelli Morfolojik Bir Yöntem, *Ömer Halisdemir Üniversitesi Mühendislik Bilim. Derg.*, 11 (1), 10–16, doi: 10.28948/ngumuh.900696.