

KIRIKKALE ÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI  
DOKTORA TEZİ



İSTATİSTİKSEL KENAR ALGILAMA TABANLI OPTİK DİSK TESPİTİ VE  
ŞEKİL ÖZNİTELİKLERİ İLE DİYABETİK RETİNOPATİ HASTALIĞININ  
SINIFLANDIRILMASI

Yunus KÖKVER

ARALIK 2019

**Bilgisayar Mühendisliđi Anabilim Dalında** Yunus KÖKVER tarafından hazırlanan İSTATİSTİKSEL KENAR ALGILAMA TABANLI OPTİK DİSK TESPİTİ VE ŞEKİL ÖZNİTELİKLERİ İLE DİYABETİK RETİNOPATİ HASTALIđININ SINIFLANDIRILMASI adlı Doktora Tezinin Anabilim Dalı standartlarına uygun olduğunu onaylarım.

Doç. Dr. Atilla ERGÜZEN  
Anabilim Dalı Başkanı

Bu tezi okuduđumu ve tezin **Doktora Tezi** olarak bütün gereklilikleri yerine getirdiđini onaylarım.

Doç. Dr. Halil Murat ÜNVER  
Danışman

Başkan : Prof. Dr. Sevgi YURT ÖNCEL \_\_\_\_\_  
Üye (Danışman) : Doç. Dr. Halil Murat ÜNVER \_\_\_\_\_  
Üye : Doç. Dr. Atilla ERGÜZEN \_\_\_\_\_  
Üye : Doç. Dr. Necaattin BARIŞCI \_\_\_\_\_  
Üye : Doç. Dr. Hüseyin POLAT \_\_\_\_\_

18/12/2019

Bu tez ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu Doktora derecesini onaylamıştır.

Prof. Dr. Recep ÇALIN  
Fen Bilimleri Enstitüsü Müdürü



**Aileme**

## ÖZET

### İSTATİSTİKSEL KENAR ALGILAMA TABANLI OPTİK DİSK TESPİTİ VE ŞEKİL ÖZNETELİKLERİ İLE DİYABETİK RETİNOPATİ HASTALIĞININ SINIFLANDIRILMASI

KÖKVER, Yunus

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Bilgisayar Mühendisliği Anabilim Dalı, Doktora tezi

Danışman: Doç. Dr. Halil Murat ÜNVER

Aralık 2019, 108 sayfa

Diyabetik Retinopati (DR), körlüğe sebebiyet veren retinal bir hastalıktır. DR'nin erken evresinde meydana gelen mikroanevrizma lezyonlarının doğru ve erken tespiti, hastalığın derecelendirilmesinde çok önemli bir yere sahiptir. Bu çalışmada mikroanevrizma lezyonlarının tespiti dört aşamada ele alınmıştır. Birinci aşamada Optik diskin (OD) tespiti için literatürde daha önce denenmemiş olan Uyarlanmış Robust Rank- Order Test tabanlı istatistiksel kenar belirleme algoritması başarılı bir şekilde uygulanmıştır. İkinci aşamada retinal kan damarlarının tespiti yapılmış, üçüncü aşamada fovea ve makula bölgesi tespit edilmiş ve son aşamada ise resimlere ait şekil öznitelikleri kullanılarak mikroanevrizma lezyonları sınıflandırılmış ve literatürdeki benzer çalışmalarla kıyaslandığında çalışmanın başarılı sonuçlar verdiği görülmüştür.

**Anahtar kelimeler:** Diyabetik Retinopati, Mikroanevrizma Lezyonlarının Tespiti, Uyarlanmış Robust Rank Order, Optik Disk Tespiti, Karar Ağacı, Naive Bayes, K-En Yakın Komşu, Destek Vektör Makineleri, Çok Katmanlı Algılayıcı

## ABSTRACT

### STATISTICAL EDGE DETECTION BASED OPTIC DISC DETERMINATION AND CLASSIFICATION OF DIABETIC RETINOPATHY DISEASE WITH SHAPE FEATURES

KÖKVER, Yunus

Kırıkkale University

Graduate School of Natural and Applied Sciences

Department of Computer Engineering, Ph. D. Thesis

Supervisor: Assoc. Prof. Dr. Halil Murat ÜNVER

December 2019, 108 pages

Diabetic Retinopathy (DR) is a retinal disease that causes blindness. Accurate and early detection of microaneurysm lesions in the early stage of DR has an important role in the grading of the disease. In this study, the detection of microaneurysm lesions were discussed in four stages. In the first step, the Adaptive Robust Rank- Order Test based statistical edge detection algorithm, which has not been tried in the literature before, has been successfully applied for the detection of optic disc (OD). Retinal blood vessels were detected in the second stage, fovea and macular region were detected in the third stage and microaneurysm lesions were classified by using the shape features of the images in the last stage, the results were found to be successful when compared with similar studies in the literature.

**Key Words :** Diabetic Retinopathy, Detection of Microaneurysm Lesions, Adaptive Robust Rank Order, Optic Disc Detection, Decision Tree, Naive Bayes, K-Nearest Neighbor, Support Vector Machines, Multilayer Perceptron

## TEŐEKKÖR

Tezimin hazırlanması esnasında hiçbir yardımını esirgemeyen tez yöneticisi hocam, Sayın Doç. Dr. Halil Murat ÖNVER başta olmak üzere, üzerimde emeđi bulunan tüm hocalarıma ve arkadaşlarıma, beni yetiřtirip bu günlere getiren aileme teőekkürü bir borç bilirim.

Bu uzun süreçte her zaman yanımda desteđini hissettiđim eőime ve neőe kaynađım Yusuf Alper'e ayrıca teőekkür ederim.



## İÇİNDEKİLER DİZİNİ

	<u>Sayfa</u>
<b>ÖZET</b> .....	i
<b>ABSTRACT</b> .....	ii
<b>TEŞEKKÜR</b> .....	iii
<b>İÇİNDEKİLER DİZİNİ</b> .....	iv
<b>ŞEKİLLER DİZİNİ</b> .....	vii
<b>ÇİZELGELER DİZİNİ</b> .....	ix
<b>KISALTMALAR DİZİNİ</b> .....	x
<b>1. GİRİŞ</b> .....	1
1.1. Tezin Amacı.....	1
1.2. Tezin Organizasyonu.....	2
<b>2. LİTERATÜR ÇALIŞMASI</b> .....	3
2.1. OD Lokalizasyonu Literatürü.....	3
2.2. OD Segmentasyonu Literatürü.....	6
2.3. Retinal Kan Damarlarının Segmentasyonu Literatürü.....	8
2.4. Mikroanevrizma Lezyonlarının Tespiti Literatürü.....	11
<b>3. MATERYAL VE YÖNTEM</b> .....	15
3.1. Kullanılan Veri Setleri.....	15
3.1.1. DRIVE.....	15
3.1.2. DIARETDB0.....	15
3.1.3. DIARETDB1.....	16
3.2. Gözün Yapısı.....	16
3.3. Görme Olayı.....	18
3.4. Retina Görüntüleri.....	18
3.5. Retinal Hastalıklar.....	20
3.6. Diyabetik Retinopati.....	21
3.6.1. Diyabetik Retinopati Lezyonları.....	21
3.6.1.1. Mikroanevrizma.....	22
3.6.1.2. Hemoraji.....	22
3.6.1.3. Vitroz Hemoraji.....	23

3.6.1.4. Sert Eksuda .....	24
3.6.1.5. Pamuk/Yün Lekeleri .....	25
3.6.1.6. IRMA .....	26
3.6.1.7. Neovaskülarizasyon .....	26
3.6.2. Diyabetik Retinopati Evreleri .....	27
3.7. DR Lezyonlarının ve Retinaya Ait Anatomik Yapıların Tespitinde Kullanılan Yöntemler .....	28
3.7.1. Görüntü Önişleme .....	28
3.7.2. Öznitelik Çıkartımı .....	34
3.7.3. Sınıflandırma .....	38
3.7.3.1. Destek Vektör Makineleri .....	38
3.7.3.2. Yapay Sinir Ağları .....	42
3.7.3.3. Naive Bayes Sınıflandırıcısı .....	45
3.7.3.4. Karar Ağacı .....	46
3.7.3.5. k-En Yakın Komşu Sınıflandırıcı .....	47
3.8. Başarı Değerlendirmesi ve Analiz Yöntemleri .....	52
<b>4. ARAŞTIRMA BULGULARI VE TARTIŞMA</b> .....	<b>55</b>
4.1. Optik Diskin Tespiti .....	55
4.1.1. Resim Önişleme Adımları .....	57
4.1.1.1. Yeşil Kanal Çıkartımı .....	57
4.1.1.2. Kontrast Sınırlamalı Adaptif Histogram Eşitleme .....	58
4.1.2. Resmin Ortalama Parlaklık Düzeyinin Hesaplanması .....	60
4.1.3. İstatistik Tabanlı Kenar Belirleme Algoritmasının Uygulanması .....	63
4.1.4. Çembersel Hough Dönüşümü .....	67
4.1.5. Optik Diskin Tespiti Sonuçları .....	69
4.2. Retina Kan Damarlarının Tespiti .....	75
4.2.1. 2 Boyutlu Gabor Filtresi .....	75
4.3. Makula ve Fovea Bölgesinin Tespiti .....	77
4.4. Mikroanevrizma Lezyonlarının Sınıflandırılması .....	79
4.4.1. Hesaplanan Şekil Öznitelikleri .....	80
4.4.2. Mikroanevrizma Lezyonlarının Sınıflandırma Sonuçları .....	84
<b>5. SONUÇ VE ÖNERİLER</b> .....	<b>91</b>
<b>KAYNAKLAR</b> .....	<b>93</b>





## ŞEKİLLER DİZİNİ

<b><u>SEKİL</u></b>	<b><u>Sayfa</u></b>
3.1. Kornea ve Sklera'nın Yapısı .....	17
3.2. Damar Tabakanın Yapısı .....	18
3.3. Oftalmoskop Cihazı İle Çekilmiş Bir Retina Yapısı.....	19
3.4. Dijital Oftalmoskop Cihazları.....	20
3.5. (a) Sağlıklı Bir Bireyin Görüşü, (b) DR Hastalığına Sahip Bireyin Görüşü .....	21
3.6. Mikroanevrizma Lezyonu Örneği.....	22
3.7. Hemoraji Lezyonu Örneği .....	23
3.8. Vitroz Hemoraji Lezyonu Örneği .....	24
3.9. Sert Eksuda Lezyonu Örneği .....	25
3.10. Yumuşak Eksuda Lezyonu Örneği .....	25
3.11. IRMA Lezyonu Örneği.....	26
3.12. Neovaskülarizasyon Lezyonu Örneği.....	26
3.13. DR'nin aşamalarını temsil eden dört farklı fundus görüntüsü .....	28
3.14. Lineer Olarak Ayrılabilen Verilerin Görünümü .....	39
3.15. Veriler Arasındaki Muhtemel En Büyük Boşluk.....	40
3.16. Lineer olarak ayrılamaması durumunda iki sınıflı veriler ve ayırıcı hiper düzlemler.....	41
3.17. Lineer olmayan DVM'lerde sınıflandırma işlemi .....	42
3.18. Bir Sinir Ağının Genel Yapısı.....	43
3.19. Sigmoid Aktivasyon Fonksiyonunun Grafiği .....	44
4.1. OD Tespiti Aşamaları .....	57
4.2. Farklı Retinal Görüntüler ve Yeşil Kanal Çıkartımı Sonuçları .....	58
4.3. (a) DRIVE veri tabanından alınan orijinal sağlıklı retina görüntüsü (b) a Görüntüsüne KSAHE uygulanmış görüntü (c) DIARETDB0 veri tabanından alınan orijinal hastalıklı retina görüntüsü (d) c Görüntüsüne KSAHE uygulanmış görüntü .....	60
4.4. Ortalama Parlaklık Düzeyinin Hesaplanması Blok Diyagramı .....	62

4.5.	Belirlenen eşik değerin üzerinde kalan piksellerden oluşan görüntüler. (a) Sağlıklı retinal görüntü; (b) Hastalıklı Retinal Görüntü.....	63
4.6.	Beyaz piksellerin X bölgesini temsil ettiği ve mavi piksellerin maskedeki Y bölgesini temsil ettiği sekiz farklı kenar senaryosu. ....	64
4.7.	Uyarlanmış Robust Rank- Order Test Tabanlı Kenar Belirleme Algoritmasının uygulanması (a) Sağlıklı Retinal Görüntü; (b) Hastalıklı Retinal Görüntü .....	67
4.8.	Çembersel Hough Dönüşümü uygulanmış retina görüntüsü (a) Sağlıklı Retina Görüntüsü; (b) Hastalıklı Retina Görüntüsü.....	68
4.9.	Retinal Görüntüden Damar Tespiti Süreci (a) DRIVE'dan alınan sağlıklı retina görüntüsü (b) (a) Görüntüsünden elde edilen sonuç görüntü (c) DIARETDB0'dan alınan hastalıklı retina görüntüsü (d) (c) Görüntüsünden elde edilen sonuç görüntü .....	76
4.10.	Retinal Görüntülerden Maske Oluşturma Süreci; (a) DRIVE'dan alınan sağlıklı retina görüntüsü (b) (a) Görüntüsünden elde edilen sonuç görüntü (c) DIARETDB0'dan alınan hastalıklı retina görüntüsü (d) (c) Görüntüsünden elde edilen sonuç görüntü.....	77
4.11.	Makula bölgesinin tespiti.....	79

## ÇİZELGELER DİZİNİ

<u>ÇİZELGE</u>	<u>Sayfa</u>
3.1. Diyabetik Retinopati Tespiti Çalışmalarında Kullanılan Ön İşleme Teknikleri .....	30
3.2. Diyabetik Retinopati Tespiti Çalışmalarında Kullanılan Öznitelik Değerleri.....	35
3.3. Lineer olmayan DVM'lerde kullanılan çekirdek fonksiyonları .....	42
3.4. DR Tespiti Çalışmalarında Kullanılan Sınıflandırıcılar .....	49
3.5. İki Sınıflı Bir Model İçin Karmaşıklık Matrisi .....	52
4.1 OD Tespitinde Kullanılan Veri Tabanları ve Özellikleri.....	69
4.2 OD Tespiti İçin Önerilen Yöntemin Doğruluk ve Ortalama Mutlak Mesafe Bilgileri .....	70
4.3. OD Tespit Sonuçlarının Literatürdeki Benzer Çalışmaların Sonuçları ile Karşılaştırmalı Analizi .....	71
4.4. Mikroanevrizma Lezyonlarını Sınıflandırmak İçin Kullanılan Şekil Öznitelikleri ve Açıklamaları.....	81
4.5. Mikroanevrizma Tespiti İçin Kullanılan Veri Setleri ve Özellikleri .....	84
4.6. Karar Ağacı Sınıflandırıcısı İçin Karmaşıklık Matrisi.....	85
4.7. Naive Bayes Sınıflandırıcısı İçin Karmaşıklık Matrisi .....	85
4.8. k-NN Sınıflandırıcısı İçin Karmaşıklık Matrisi .....	86
4.9. DVM Sınıflandırıcısı İçin Karmaşıklık Matrisi .....	86
4.10. ÇKA Sınıflandırıcısı İçin Karmaşıklık Matrisi .....	87
4.11. Sınıflandırıcıların Performans Değerlendirmesi .....	87
4.12. Mikroanevrizma Lezyonlarının Sınıflandırma Performanslarının Karşılaştırması .....	88

## KISALTMALAR DİZİNİ

DR	Diyabetik Retinopati
OD	Optik Disk
MA	Mikroanevrizma
SGVF	Denetimli Gradyan Vektör Akışı
GVF	Gradyan Vektör Akışı
DRIVE	Digital Retinal Images for Vessel Extraction
STARE	Structured Analysis of the Retina
MESSIDOR	Methods to Evaluate Segmentation and Indexing Techniques in the Field of Retinal Ophthalmology
CNN	Evrişimsel Sinir Ağı
TBA	Temel Bileşen Analizi
ASM	Aktif Şekil Modeli
ÇHD	Çembersel Hough Dönüşümü
GPU	Grafik İşleme Birimi
DDA	Doğrusal Diskriminant Analizi
YSA	Yapay Sinir Ağı
MLP	Çok Katmanlı Algılayıcı
DVM	Destek Vektör Makinesi
k-NN	k-En Yakın Komşu
ELM	Ekstrem Öğrenme Makinesi
RO	Rasgele Orman
FOV	Görüş Alanı
DIARETDB0	Standard Diabetic Retinopathy Database Calibration Level 0
DIARETDB1	Standard Diabetic Retinopathy Database Calibration Level 1
KA	Karar Ağacı
ROC	Alıcı İşlem Karakteristiği

TP	Dođru Pozitif
FP	Yanlıř Pozitif
FN	Yanlıř Negatif
TN	Dođru Negatif
KSAHE	Kontrast Sınırlamalı Adaptif Histogram Eřitlemesi
RRO	Robust Rank – Order



# 1. GİRİŞ

Görüntü işleme ve sınıflandırma algoritmaları son zamanlarda göz hastalıkları da dahil olmak üzere, çeşitli hastalıkların teşhisi için yaygın olarak kullanılmaktadır. Diyabetik retinopati (DR) lezyonlarını efektif bir şekilde tespit edebilmek için bilgisayar tabanlı görüntüleme araçları kullanılmaktadır. Lezyonların erken tespiti, hastaların gözünde büyük bir hasar meydana gelmeden önce tedavi olabilmelerine imkân tanımaktadır. DR hastalığına yapılacak otomatik bir derecelendirme sistemi ise daha hızlı ve daha etkili bir tanıya izin verip, hastanın görme derecesini koruyarak, körlüğün önüne geçmek için önlemlerin erken alınabilmesine olanak sağlamaktadır. Aynı zamanda bu otomatik derecelendirme sistemleri, tıp uzmanlarına yardımcı olarak hata olasılığını minimum düzeye indirmektedir.

Dijital fundus görüntülerinden DR değerlendirmesi, günümüzde araştırmacıların, mikroanevrizmalar, hemorajiler, sert ve yumuşak eksudalar, neovaskülarizasyonlar gibi hastalığın belirli lezyon gruplarını saptamak için çeşitli teknik, yöntem ve yaklaşımlar bulmaya odaklandığı ortak bir çalışma alanı haline gelmiştir [1]. Lezyonları saptayabilmek için retinal görüntüye ait optik disk (OD) alanının, fovea ve makula bölgesinin, kan damarlarının tespit edilebilmesi de yine araştırmacıların son dönemdeki ilgi alanlarından. Hastalığın aşamalarını takip etmek için vereceği destek ve hekimlerin karar vermesini hızlandırması gibi avantajlarından dolayı otomatik tespit sistemleri önem kazanmaktadır.

## 1.1. Tezin Amacı

DR lezyonlarının tespit edilebilmesi için retina görüntüsüne ait anatomik yapıların bilinmesi gerekir. Bu yapılar, OD, kan damarları ve fovea/makula bölgeleridir.

Bu tez çalışmasının ilk amacı, retina fundus görüntülerinden anatomik yapıların tespit edilmesidir. Bu bağlamda, OD'in yüksek başarı oranı ile tespit edilebilmesi için, bu alanda literatürde daha önce uygulanmamış olan istatistik tabanlı bir kenar belirleme algoritması kullanılmış ve başarılı sonuçlar alınmıştır. Diğer anatomik yapıların tespiti

için ise literatürde başarısı kanıtlanmış ve sık kullanılan yöntemler kullanılarak başarılı tespitler elde edilmiştir.

Tezin bir diğer amacı ise, DR hastalığının ilk evrelerinde ortaya çıkan mikroanevrizma (MA) lezyonlarını otomatik olarak tespit etmek ve göz üzerinde önemli bir hasar meydana gelmeden önleminin alınmasını sağlamaktır. Bu bağlamda literatürde sık kullanılan veri setleri kullanılarak, önışleme adımlarının ardından resimlere ait şekil öznitelikleri kullanılarak sınıflandırma işlemleri yapılmış ve umut verici sonuçlar elde edilmiştir.

## **1.2. Tezin Organizasyonu**

Tezin ikinci bölümünde retinal görüntülerin anatomik yapılarından OD'in lokalizasyonu ve segmentasyonu, retinal damarların segmentasyonu, fovea ve makula bölgelerinin tespitleri ile ilgili literatür çalışmalarına yer verilmiş, ardından DR hastalığının ilk belirtilerinden olan MA lezyonlarının otomatik tespiti ile ilgili literatür çalışmalarına değinilmiştir.

Üçüncü bölümde, kullanılan veri setleri tanıtılmış, gözle ilgili teknik bilgiler verilmiş, retina görüntüleri ve retinal hastalıklardan DR tanıtılmış, DR lezyonları ve retinaya ait anatomik yapıların tespitinde kullanılan yöntemlerden bahsedilmiştir.

Dördüncü bölümde OD'in tespiti, retina kan damarlarının tespiti, makula ve fovea bölgesinin tespiti, MA lezyonlarının sınıflandırılması konuları adım adım ve detaylı bir şekilde anlatılmış ve elde edilen sonuçlar literatürdeki benzer çalışmalarla kıyaslanarak önerilen sistemin artıları ve eksileri tartışılmıştır.

Tezin son bölümünde ise elde edilen sonuçlardan bahsedilmiş ve ileride yapılabilecek çalışmalar için öneriler sunulmuştur.



## 2. LİTERATÜR ÇALIŞMASI

İster retina görüntülerinden kan damarları tespit edilmek istensin, ister fovea ve diğer anatomik yapılar tespit edilmek istensin, isterse retinal bir hastalığın teşhisi yapılmaya çalışılsın, çalışmaya başlangıç noktası her zaman OD'tir. Dolayısıyla OD'in lokalizasyonu retina görüntülerinin otomatik analizi ve retinal hastalıkların tespit edilmesinde en temel ve ön adımdır [2]. Dolayısıyla DR hastalığının teşhisi için yapılacak olan literatür çalışmasına da OD'in tespiti çalışmalarından başlamak doğru olacaktır.

OD'in tespitiyle alakalı literatürde önerilen birçok çalışma mevcuttur. Bu çalışmalar temelde iki kategoride incelenmektedir. İlk kategori, OD'in lokalizasyonu ile ilgili çalışmalardır. Retinal görüntüden OD'in yerinin saptanması, OD'in lokalizasyonu olarak adlandırılır. İkinci kategori ise, OD bölgesinin segmentasyonu ile ilgili çalışmalardır. OD'in segmentasyonu, retinal görüntülerden OD'in gerçek bölgesini ortaya çıkarma işlemidir.

### 2.1. OD Lokalizasyonu Literatürü

Walter ve arkadaşları (2002) yayınladıkları çalışmada DR hastalığının bilgisayar destekli tanısı için eksudaları saptamak amacıyla bir yaklaşım sunmuşlardır [3]. Bu yaklaşımda başta OD tespiti yapabilmek için morfolojik filtreleme teknikleri ve watershed dönüşümü kullanmışlardır. Algoritma, küçük bir veri seti ile test edilmiş ve performans bakımından değerlendirilmiştir. Ortalama duyarlılık %92,8 ve ortalama tahmin değeri %92,4 olarak bulunmuştur.

Ravishankar ve arkadaşları (2009), OD'in yaklaşık yerini, retina fundus görüntüleri içerisindeki başlıca kan damarlarını tespit ettikten sonra, en kalın damarların kesişimini bularak OD'in yaklaşık yerini bulmaya çalışmışlardır [4]. Geliştirilen yaklaşım, farklı kontrast, ışık ve hastalık aşamasındaki 516 retina görüntüsünden oluşan bir veri setinde kapsamlı bir şekilde değerlendirilmiş ve OD lokalizasyonu için %97,1'lik bir doğruluk oranı vermiştir.

Pereira ve arkadaşları (2013), OD lokalizasyonu yapabilmek amacıyla, görüntü işleme için farklı amaçlarla uygulanan bazı karınca türlerinin toplanma davranışından esinlenen bir optimizasyon algoritması olan karınca kolonisi algoritması kullanarak, anizotropik difüzyon tabanlı bir yöntem önermişlerdir. Sonuç olarak, farklı büyüklük ve patolojiler içeren retina fundus görüntülerinden oluşan veri setinin çoğunda OD'yi doğru bir şekilde tespit edebilmişlerdir [5].

Hsiao ve arkadaşları (2012), OD lokalizasyonu için yeni bir aydınlatma düzeltme işlemi kullanmışlar ve ardından segmentasyon işlemi için ise denetimli gradyan vektör akış (supervised gradient vector flow snake - SGVF snake) modelini kullanmışlardır [6]. Geleneksel gradyan vektör akış (gradient vector flow snake - GVF) yöntemi damar tıkanıklığı resim içerisinde bulanık kalmış OD sınırları sebebiyle çok etkili bir yöntem değildir. Bu sebepten ötürü SGVF snake yöntemi denenmiş ve bu yaklaşım açık erişimli olan DRIVE (Digital Retinal Images for Vessel Extraction) ve STARE (Structured Analysis of the Retina) isimli iki adet veri seti için değerlendirilmiştir. Deneysel sonuçlara göre ise iki veri setindeki retina fundus görüntülerinden %95'inin doğru bir şekilde OD lokalizasyonunun yapıldığı ve %91'inin OD sınırlarının SGVF snake modeli ile doğru bir şekilde segmente edildiği görülmüştür.

Welfer ve arkadaşları (2013), OD merkezini ve OD sınırını belirleyebilmek amacıyla adaptif morfolojik tabanlı bir yöntem önermişler ve önerdikleri bu yöntemi açık erişimli DRIVE ve DIARETDB1 veri tabanlarına uygulamış ve diğer yöntemlerin başarı oranlarıyla kıyaslamışlardır [7]. Önerdikleri yöntemle OD merkezini sırasıyla DRIVE veri seti için %100 ve DIARETDB1 veri seti için %97,75 oranında doğru tespit edebilmişlerdir.

Harangi ve Hajdu (2015) yayınladıkları çalışmalarında OD lokalizasyonu yapabilmek amacıyla bireysel algoritmaların kombinasyonuna dayalı bir tespit yöntemi önermişlerdir [8]. OD ve sınırlarını tespit edebilmek için olasılık modellerinin birleştirilmesine dayalı olan bu modelde, Axiomatic ve Bayesian yaklaşımlarını kullanarak OD'in lokalizasyonunun doğruluğunu daha da artırmışlardır.

Abed ve arkadaşları (2016) tarafından etkili ve hızlı bir OD lokalizasyonu için sürü zekâsı teknikleri uygulanmıştır. OD tespiti için, sürü zekâsı olarak adlandırılan doğadan ilham alan algoritmaların, geleneksel tespit algoritmalarına kıyasla hız ve doğruluk açısından açık üstünlüğe sahip olduğu bu çalışmada gösterilmiştir [9]. Çalışmada beş adet popüler sürü zekâsı algoritmasına odaklanılmıştır. Bunlar; yapay arı kolonisi algoritması, parçacık sürüsü optimizasyonu, yarasa algoritması, guguk arama algoritması ve ateş böceği algoritmasıdır. Bu beş adet sürü zekâsı algoritması probleme uygulanarak performansları karşılaştırılmıştır. En iyi sonucu ateş böceği algoritması vermiştir. Çalışmada ayrıca arka plan çıkarma tabanlı OD algılama (Background Subtraction-based Optic Disc Detection - BSODD) isimli bir ön işleme yaklaşımı geliştirilmiştir.

Kamble ve arkadaşları (2017) yayınladıkları çalışmada, OD ve foveanın hızlı ve doğru bir şekilde lokalizasyonu için bir boyutlu taranmış yoğunluk profil analizi kullanmışlardır [10]. Önerilen yöntem, OD'in lokalizasyonu için hem zaman hem de frekans alanı bilgilerini etkin bir şekilde kullanmış, MESSIDOR (Methods to Evaluate Segmentation and Indexing Techniques in the field of Retinal Ophthalmology) isimli açık erişimli veri seti üzerinde uygulanmış ve 1200 adet görüntüden 1197 tanesi %99,75 doğruluk oranı ve 0,52 saniyelik bir ortalama hesaplama süresiyle başarıyla tespit edilebilmiştir.

Zou ve arkadaşları (2018) yayınladıkları çalışmalarında OD konumunu elde etmek için görüntünün yoğunluğuna ve retina kan damarlarının parabolik yerleşimine dayalı bir çerçeve önermişlerdir [11]. Bu çerçevede ilk olarak, görüntü yoğunluğu ile bir OD aday bölgesi elde edilir, ardından aday bölge doğrulama modeli ile doğrulanır. Doğrulama geçilirse, bölgenin karşılık gelen konumu OD merkezi olarak belirlenir. Aksi halde OD, retina ana kan damarlarının parabol bağlanması, yerleşim konumu ve yer değiştirmesi ile bulunur. Önerilen yöntem açık erişimli STARE, DRIVE, DIARETDB0 ve DIARETDB1 veri setleriyle değerlendirilmiş ve doğruluk oranı sırasıyla %96,3, %100, %100 ve %100 olarak hesaplanmıştır.

Al-Bander ve arkadaşları (2018), OD ve foveanın yerlerinin eşzamanlı olarak tespit edilebilmesini bir regresyon problemi olarak ele almışlar ve bir derin çok ölçekli sıralı

evrişimsel sinir ağı (CNN) tasarlamış ve eğitmişlerdir [12]. Geliştirdikleri ağın performansını değerlendirebilmek için açık erişimli MESSIDOR ve KAGGLE veri setlerini kullanmışlar ve OD merkezini saptamadaki başarısını sırasıyla %97 ve %96,7 olarak hesaplamışlar ve aynı zamanda bir retinal görüntünün OD ve fovea lokalizasyonunu ortalama 0,007 saniye gibi çok kısa bir sürede yapılabilmışlerdir.

## 2.2. OD Segmentasyonu Literatürü

Lowell ve arkadaşları (2004) yayınladıkları çalışmada, düşük çözünürlükteki retina görüntülerinden OD lokalizasyonu ve OD alanının segmentasyonu için bir algoritma önermişlerdir [13]. Bunun için, özelleştirilmiş bir şablon eşleştirme modeli ile OD lokalizasyonu ve deforme edilebilir bir kontur modeli ile de OD segmentasyonu yapılmıştır. Geliştirilen yöntem, özel olarak oluşturulmuş bir veri setinden rastgele seçilen 100 adet retina görüntüsü üzerinden değerlendirilmiş ve yöntemin %83'lük bir doğruluk oranıyla OD segmentasyonunu düzgün bir şekilde gerçekleştirdiği görülmüştür.

Li ve Chutatape (2004) yayınladıkları çalışmalarında, OD yerini belirleyebilmek amacıyla Temel Bileşen Analizi (TBA) kullanmış, segmentasyon işlemi için ise Geliştirilmiş Aktif Şekil Modeli (ASM) yaklaşımı kullanarak model tabanlı etkin bir OD tespiti yapmışlardır. OD lokalizasyonu için yöntemin başarısı %99 olarak ölçülürken, segmentasyon başarısı ise %94 olarak bulunmuştur [14].

Zhu ve arkadaşları (2010) yayınladıkları çalışmalarında, OD tespiti ve OD segmentasyonu yapabilmek için bir yöntem önermişlerdir. Önerilen yöntem, Sobel operatörlerini kullanarak kenar algılama ve Hough dönüşümü kullanılarak OD çevresinin algılanmasını içermektedir. Önerilen yöntem açık erişimli DRIVE veri seti ile değerlendirilmiştir [15]. Performans değerlendirmesinde FROC (Free-response receiver operating characteristics) analizi kullanılmış ve başarı oranı %90 olarak bulunmuştur.

Sarathi ve arkadaşları (2016) yayınladıkları çalışmalarında, OD'in hızlı ve tam otomatik olarak tespit edilmesi ve doğru bir şekilde segmente edilebilmesi için yeni

bir teknik ortaya koymuşlardır [16]. OD merkezinin lokalizasyonu için OD çevresindeki damarların doğru bir şekilde boyanarak elimine edilmesine dayalı bir metodoloji ortaya koymuşlar, ardından OD segmentasyonu için adaptif eşik tabanlı bölge büyütme tekniği uygulamışlardır. Önerilen teknik, açık erişimli MESSIDOR ve DRIVE veri setleri ile değerlendirilmiş ve sırasıyla %89 ve %87 oranında bir başarı sağlamıştır. Önerilen teknik ayrıca, yerel bir göz hastanesinden elde edilen sağlıklı ve patolojik görüntüleri içeren etiketli bir veri kümesi üzerinde, ortalama %91'lik bir segmentasyon başarısı göstermiştir.

Dai ve arkadaşları (2017) yayınladıkları çalışmalarında, çoklu enerjileri olan değişimsel modele dayanarak retina fundus görüntülerinde OD'yi otomatik olarak bölütleme için farklı bir yöntem sunmuşlardır [17]. İlk olarak, OD merkezini lokalize etmek için başlangıç sınır eğrisinin Çembersel Hough Dönüşümü (ÇHD) ile tahmin edildiği seyrek kodlama tabanlı bir teknik tasarlanmış, ardından OD segmentasyonu bir enerji minimizasyonu problemi olarak kabul edilmiş ve eğriyi OD sınırına ulaştırmak için üç enerji terimini birleştiren bir değişimsel model önerilmiştir.

Bharkad (2017) yayınladığı çalışmasında, retinal görüntüde OD'in yerini saptamak amacıyla uygun eşik değerini hesaplaması için alçak geçiren bir Sonlu Dürtü Tepkili (an equiripple low pass finite impulse response - FIR) filtre tasarlamıştır [18]. Morfolojik işlemler ve medyan filtreleme ile OD bölgesini düzenleyerek segmentasyon yapmıştır. Önerilen algoritmayı DRIVE, DIARETDB0, DIRATEDB1 ve DRIONS isimli dört adet açık erişimli veri seti üzerinde test etmiş ve sırasıyla %100, %96,92, %98,98 ve %100'lük başarı oranlarına ulaşmıştır.

Li ve arkadaşları (2018) yayınladıkları çalışmalarında, OD segmentasyonunun performansını geliştirmek için OD sınırının koordinatları ile bunların OD segmentasyonu için çevreleyen görsel görünümleri arasında bir dizi denetimli iniş yönünü öğrenmeyi önermişler ve yöntemi altı veri seti için değerlendirmişlerdir [19]. Bu veri setlerinden alınan deneysel sonuçlar, yöntemin OD segmentasyonunu geliştirdiğini ve benzer çalışmalardan üstünlüklerini göstermektedir.

### 2.3. Retinal Kan Damarlarının Segmentasyonu Literatürü

Dijital fundus görüntülerinden retinal kan damarlarının çıkartımı için bugüne kadar birçok algoritma ve yöntem önerilmiştir. Bunlar ayrı ayrı kullanılabilirken, hibrit bir şekilde de kullanımı önerilen çalışmalar olmuştur. Damar çıkartımı için kullanılan algoritmalar farklı şekillerde kategorilendirilmiştir. En yaygın kategorizasyon model tabanlı yaklaşımlar, görüntü işleme tabanlı yaklaşımlar, filtre algoritmaları tabanlı ve makine öğrenmesi ile ilgili yapılan metotlardır [20], [21].

Filtreleme algoritmaları içinden retina damarlarının segmentasyonu için en çok eşleştirilmiş filtrenin kullanıldığı görülmüştür. Özellikle radar sistemlerinde ve x-ray görüntülerde eşleştirilmiş filtre sıkça kullanılır ve bu alanlarda başarılıdır.

Retinadaki damarların çıkartımı ile ilgili literatürdeki ilk çalışma 1989 yılına dayanmaktadır. Chaudhuri ve arkadaşlarının yapmış olduğu bu çalışmada makine öğrenmesi ile birlikte eşleştirilmiş filtre kullanılmıştır [22].

Chanwimaluang ve arkadaşlarının (2003) yayınladıkları çalışmalarında, kan damarlarının segmentasyonu dört aşamada yapılmıştır: Birinci aşamada eşleştirilmiş filtre yöntemi kullanılmış, ikinci aşamada yerel entropi tabanlı eşikleme yöntemi, üçüncü aşamada uzunluk filtreleme ve son aşamada ise vasküler kesişme tespiti yöntemleri kullanılarak yaklaşık 2,5 dakikada 20 adet retina resminin segmentasyon işlemi tamamlanmıştır [23].

Hoover ve arkadaşları (2000) yayınladıkları çalışmalarında, damar ağını segmente edebilmek için yerel ve global damar özneliklerini birlikte kullanmışlar ve eşleştirilmiş filtre yöntemi ile kan damarlarını çıkartabilmişlerdir [24].

Cinsdikici ve Aydın'ın (2009) yayınladıkları çalışmalarında, eşleştirilmiş filtreleme yöntemi kullanılmış, fakat özellikle kılcal damarların çıkarılmasıyla ilgili problemler yaşandığı için yeni bir yaklaşım olarak eşleştirilmiş filtrenin yanında karınca kolonisi algoritması önerilmiştir. DRIVE veri setinin kullanıldığı çalışmada, karınca kolonisi

algoritması ve eşleştirilmiş filtre tabanlı melez bir yöntem literatüre kazandırılmıştır [25].

Al-Rawi ve arkadaşları (2007) ise DRIVE veri setinden 20 adet retina görüntüsü kullanarak yine eşleştirilmiş filtreleme yöntemini geliştirerek kullandıkları ve daha efektif bir damar segmentasyonu yaptıkları çalışmalarını önermişlerdir [26].

Retina damarlarının segmentasyonunda kullanılan bir diğer yöntem ise morfolojidir. Küme teorisi, rastgele fonksiyonlar ve topolojiye dayalı analiz ve süreç yönetimidir. Matematiksel morfoloji kavramı genellikle sayısal görüntüleri analiz etmek, resimden bilgi çıkarmak, şekil inceltmek veya kalınlaştırmak, görüntüyü onarmak, doku tespiti yapmak gibi birçok işlem için kullanılmaktadır [27]. Morfolojik işlemler kullanılarak yapılan çalışmalar aşağıda özetlenmiştir:

Mendonca ve Campilho (2006) yaptıkları çalışmada morfolojik yeniden yapılandırma ile damar segmentasyonunu gerçekleştirmişlerdir. Özgüllük ve hassasiyet değerleri literatürdeki benzer çalışmalardan daha iyi sonuç vermiştir. DRIVE veri seti üzerinde 2,5 dakikada segmentasyon işlemi tamamlanırken, STARE veri setinde ise 3 dakikadan az bir sürede başarılı bir şekilde damar çıkartımları tamamlanabilmiştir [28].

Zana and Klein (2001) ise matematiksel morfoloji ve eğrilik değerlendirme yöntemi kullanarak retina damarlarını bölütlemişlerdir. Çalışmada ayrıca gürültü azaltma ve gauss yöntemleri de kullanılmıştır. Çalışmada damar çıkartımı, hastalık teşhisinin otomatize edilmesinde ilk aşama olarak nitelendirilmiştir [29].

Damar segmentasyonunda kullanılan bir diğer yöntem ise makine öğrenmesidir. Makine öğrenmesi, problemin modellenmesini bulunduğu ortamdan edindiği verilere göre yapabilen algoritmalara verilen genel bir isimdir. Medikal görüntüler üzerinde sıklıkla kullanılır ve damar segmentasyonu çalışması için de önerilen birçok çalışma mevcuttur. Makine öğrenmesi kullanılarak yapılan çalışmalar aşağıda özetlenmiştir:

Niemeijer ve arkadaşları (2004) geliştirdikleri makine öğrenmesi tabanlı sınıflandırma yöntemi sonuçları ile, klasik dört tane yöntemin sonuçlarını karşılaştırmışlardır. Bu yöntemler; eşleştirilmiş filtre, bölge büyütme yaklaşımı, yerel eşik yaklaşımı ve matematiksel morfoloji yaklaşımıdır. DRIVE veri seti kullanılarak elde edilen sonuçların, diğer dört çalışmadan daha iyi olduğunu ortaya koymuşlardır [30].

Staal ve arkadaşları (2004) yayınladıkları çalışmalarında, makine öğrenmesi yöntemlerinden denetimli öğrenme metodları ile k- en yakın komşu sınıflandırıcısını birlikte kullanmışlar ve elde ettikleri sonuçların, karşılaştırdıkları diğer iki kural tabanlı yöntemin sonuçlarından anlamlı derecede daha iyi olduğunu ortaya koymuşlardır [31].

Garg ve arkadaşları (2007) yayınladıkları çalışmalarında, retinal kan damarlarını çıkartmak için makine öğrenmesinin denetimsiz metodlarını önermişlerdir. Eğrilik tabanlı bir yöntem sunulan çalışmada, bölge büyütme yöntemi modifiye bir şekilde kullanılmış, 2004 ve 2006 yılları arasında yapılmış denetimli öğrenme metodları ile karşılaştırılmış ve çalışmanın üstün tarafları ön plana çıkarılmıştır [32].

Sinthanayothin ve arkadaşları (1999) yayınladıkları çalışmalarında, 112 tane retina görüntüsü üzerinde çok katmanlı algılayıcı ağ kullanarak tanımladıkları girdileri, temel bileşen analizi yaparak türetmişler ve kan damarlarını tespit etmişlerdir. Çalışmada ayrıca resimler bir ön işlemden geçirilerek en iyileştirme çalışması yapılmıştır [33].

Martinez ve arkadaşları (2007) yayınladıkları çalışmalarında, otomatik segmentasyon işlemi için çok parçalı öznitelik çıkarımına dayalı bir yöntem önermişler ve patolojik damarlar da dahil olmak üzere bölgeyi izole ederek başarılı bir damar çıkartımı yapabilmüşlerdir [34].

Li ve arkadaşlarının (2016) önerdikleri yöntem denetimli bir çapraz model öğrenme yaklaşımıdır. Damar segmentasyonu için geniş ve derin bir yapay sinir ağı önerilmiş ve efektif bir eğitim stratejisi sunulmuştur [35].



Krause ve arkadaşları (2016), görüntü ön işleme adımlarının ardından CUDA kullanarak GPU'larda (Grafik İşleme Birimi) uygulamış ve paralel olarak işleyip hızlı bir sistem ortaya koyarak damar segmentasyonu gerçekleştirmişlerdir [36].

Barkana ve arkadaşları (2017) bulanık mantık kümeleri, destek vektör makineleri, yapay sinir ağları ve sınıflayıcı füzyonu ile retinal damar çıkartımında tanımlayıcı istatistiksel özelliklerin performanslarının analizlerini yapmışlardır. Deneysel sonuçlar istatistiksel özelliklerin segmentasyon işleminde etkili olduğunu, kural tabanlı ve denetimli sınıflandırıcılarda kullanılabileceğini doğrulamıştır [37].

Frucci ve arkadaşları (2016) yayınladıkları çalışmalarında, Severe ismi verdikleri yeni bir denetimsiz öğrenme metodunu önermişlerdir. Retinal kan damarlarını bölütlemek için kullandıkları bu yöntemi benzer çalışmalarla karşılaştırmışlar ve performans açısından daha iyi sonuçlar verdiğini gözlemlemişlerdir [38].

Ramani ve arkadaşları (2016) yaptıkları damar segmentasyonu çalışmasında hibrit bir yöntem önermişlerdir. Denetimli ve denetimsiz öğrenme metodlarının kullanıldığı çalışma, görüntü sonrası işleme tekniklerinin ardışık uygulamasıyla son bulmuştur. Öznitelik vektörü üzerinde temel bileşen analizi uygulanmış, ardından piksel gruplama için k-means algoritması kullanılarak kan damarları tespiti yapılmıştır. Algoritmanın başarı oranı ise %95,36 olarak bulunmuştur [39].

#### **2.4. Mikroanevrizma Lezyonlarının Tespiti Literatürü**

MA'ların zamanında tespiti ve tedavisi, DR gibi görmeyi tehdit eden göz hastalıklarının gelişimini önlemek için kritik bir adımdır. Bununla birlikte, fundus görüntülerinden MA'ların saptanması, düşük görüntü kontrastı, diğer kırmızı lezyonların yanıltıcı ipuçları ve görüntüleme koşullarının büyük çeşitliliği nedeniyle oldukça zorlayıcı bir görevdir.

MA lezyonlarının tespiti geçmişten günümüze birçok araştırmacının ilgi odağında olmuş ve bu alanda literatürde önerilen birçok çalışma mevcuttur. Bu çalışmaların bir bölümü aşağıda özetlenmiştir:

Streeter ve Cree (2003) yayınladıkları çalışmalarında, MA tespiti için Top-Hat dönüşümü, Eşleştirilmiş Filtre ve Doğrusal Diskriminant Analizi (DDA) yöntemleri, yöntemin başarısını değerlendirmek için ise FROC analizi kullanmışlardır [40]. Yerel bir veri seti kullanılarak yapılan çalışmanın duyarlılığı ise %56 olarak hesaplanmıştır.

Akram ve arkadaşları (2013) yayınladıkları çalışmalarında, MA lezyonlarını tespit edebilmek amacıyla üç aşamalı bir yöntem önermişlerdir [41]. İlk aşamada MA'lar için tüm olası aday bölgeler çıkarılmış, ikinci aşamada sınıflandırma için şekil, renk, yoğunluk ve istatistiklere bağlı öznelik vektörleri oluşturulmuş, üçüncü aşamada ise Gauss Karışım Modeli ve Destek Vektör Makinesi (DVM) kullanılarak hibrit bir sınıflandırıcı sunulmuştur. DIARETDB0 ve DIARETDB1 veri setlerinin kullanıldığı çalışmada duyarlılık %98,64 ve özgüllük %99,69 olarak hesaplanmıştır.

Roychowdhury ve arkadaşları (2014) yayınladıkları çalışmalarında, DR'nin derecesini belirleyebilmek için DREAM ismini verdikleri bir yöntem geliştirmişlerdir [42]. MESSIDOR ve DIARETDB1 veri setleri kullanılarak yapılan çalışmada Gauss Karışım Modeli, k-en yakın komşu (kNN), destek vektör makinesi (DVM) ve AdaBoost gibi sınıflandırıcılar, retinopati lezyonlarının sınıflandırılması için analiz edilmiş, sınıflandırmada en iyi sonucu veren algoritmalar sırasıyla Gauss Karışım Modeli ve kNN olmuştur.

Ren ve arkadaşları (2017) yayınladıkları çalışmalarında, MA sınıflandırma performansını artırmak amacıyla Ekstrem Öğrenme Makinesi (ELM) ve Topluluk Temelli Öğrenme yöntemleri kullanmışlardır [43]. Dengesiz veri sorunlarının üstesinden gelmek için üç topluluk tabanlı uyarlanabilir SMOTE algoritması önermişler ve algoritmaların performansını, sınıf dengesizliği sınıflandırmasında ve yanlış pozitif azaltmada en yeni yaklaşımlarla karşılaştırmışlardır. E-optha veri setinin kullanılarak geliştirilen çalışmada Duyarlılık %96,1 ve Özgüllük ise %82,1 olarak hesaplanmıştır. Çalışmanın temel sonucu, ASOBoost yönteminin en iyi sınıflandırma performansı ve genelleme kabiliyeti elde etmesidir.

Rocha ve arkadaşları (2012) yayınladıkları çalışmalarında, retinal görüntüdeki hem kırmızı lezyonları, hem de parlak lezyonları tespit edebilmek için görsel kelime

sözlüğü oluşturmuşlardır [44]. Sınıflandırma algoritması olarak DVM'nin kullanıldığı çalışmada RetiDB ve Messidor veri setleri kullanılmıştır. 687 normal retina görüntüsü, 245 parlak lezyon (sert ve yumuşak eksuda) içeren görüntü, 191 kırmızı lezyon (MA ve hemoraji) içeren görüntü, 109 hem kırmızı lezyon, hem de parlak lezyon içeren görüntü analizi sonucunda Duyarlılık %90 ve Özgüllük ise %60 olarak hesaplanmıştır.

Niemeijer ve arkadaşları (2005) yayınladıkları çalışmalarında, MA lezyonlarının tespiti için ilk olarak piksel sınıflandırmasına dayanan yeni bir kırmızı lezyon adayı tespit sistemi önermişler, ardından tespit edilen aday nesnelere, kNN sınıflandırıcısı kullanarak sınıflandırmışlardır [45]. Yerel bir veri seti kullanılarak test edilen çalışmanın sonucunda Duyarlılık %100 ve Özgüllük ise %87 olarak hesaplanmıştır.

Orlando ve arkadaşları (2018) yayınladıkları çalışmalarında, DR'nin en erken belirtisi olan kırmızı lezyonları (hem MA'ları, hem de hemorajileri gruplayan genel bir terim) sınıflandırabilmek için hem derin öğrenme, hem de alan bilgisini birleştirmeye dayanan yeni bir yöntem önermişlerdir [46]. Bir evrimsel sinir ağı (CNN) tarafından öğrenilen özellikler, el yapımı özellikler dahil edilerek artırılmış, daha sonra bir Rasgele Orman (RO) sınıflandırıcısı kullanılarak gerçek lezyon adayları tanımlanmıştır. Messidor veri seti kullanılarak test edilen çalışmanın sonucunda Duyarlılık %91,02 olarak hesaplanmıştır.

Fleming ve arkadaşlarının (2006) yayınladıkları çalışmada, MA tespiti için geliştirilen otomatik yöntemler tanıtılmış ve görüntü kontrast iyileştirmesinin MA'lar ve retinada meydana gelen diğer noktaları birbirinden ayırt etme yeteneğini nasıl geliştirebileceği gösterilmiştir [47]. Yerel bir veri seti üzerinde yapılan çalışmada sınıflandırma algoritması olarak kNN kullanılmış ve çalışmanın sonucunda Duyarlılık %85,4 ve Özgüllük ise %83,1 olarak hesaplanmıştır.

Dai ve arkadaşları (2018) yayınladıkları çalışmalarında, MA tespiti için metin/görüntü madenciliği tabanlı bilgisayar destekli tanı sistemi sunmuşlardır [48]. Bunun için derin öğrenme tabanlı hücresel sinir ağları ile metin/görüntü madenciliği yöntemlerini hibrit bir şekilde kullanmışlar ve MA lezyonlarını yüksek bir doğruluk oranı ile sınıflandırmayı başarmışlardır. DIARETDB1 veri seti kullanılarak test edilen

çalışmanın sonucunda Hassasiyet %99,7 ve Duyarlılık ise %87,8 olarak hesaplanmıştır.

Kar ve Maity (2018) yayınladıkları çalışmalarında DR lezyonlarını otomatik olarak sınıflayabilmek için dört aşamalı bir şema önermektedirler [49]. Birinci aşamada OD ve damarlar tespit edilmiş ve retina görüntüsünden çıkarılmış, ikinci aşamada ön işleme adımları ile koyu lezyonlar retina arka planından ayırt edilmiş, üçüncü aşamada aday bölgelerin segmentlere ayrılma eşiklerini belirleyen bulanık fonksiyonların parametrelerinin optimal değerlerini belirlemek için diferansiyel evrim algoritması kullanılmış ve dördüncü aşamada ise yanlış tespit edilen aday pikselleri hariç tutmak için morfoloji tabanlı son işleme yöntemleri uygulanmıştır. DIARETDB1, MESSIDOR, DRIVE, STARE ve ROCh veri setleri kullanılarak test edilen çalışmanın sonucunda MA tespiti için Duyarlılık %95,23 ve Özgüllük ise %95,12 olarak hesaplanmıştır.

### 3. MATERYAL VE YÖNTEM

DR lezyonlarının teşhisi ile birlikte, retinaya ait anatomik yapıların tespitini yaparken kullanılan veri setleri ve yöntemler, göz ve göz hastalıkları ile ilgili teknik bilgiler ve DR ile ilgili detaylı bilgiler bu kısımda anlatılmıştır.

#### 3.1. Kullanılan Veri Setleri

DR ve retinaya ait diğer anatomik yapıların tespitinde sıklıkla kullanılan, bu çalışmanın da hem OD tespitinde hem de DR tespitinde kullanılan veri setleri DRIVE, DIARETDB0 ve DIARETDB1'dir. Önerilen yöntem bu üç adet halka açık veri setinden alınan retina fundus görüntüleri üzerinde test edilmiştir.

##### 3.1.1. DRIVE

DRIVE (Digital Retinal Images for Vessel Extraction) veri seti, retinal görüntülerde kan damarlarının segmentasyonu üzerine karşılaştırmalı çalışmalara olanak sağlamak için kurulmuştur. Hollanda'da bir DR tarama programından elde edilen 40 adet görüntü, 25-90 yaşları arasındaki 400 denekten rastgele seçilmiştir. 33 resimde herhangi bir hastalık belirtisi yokken, 7 görüntüde ise DR tespit edilmiştir. Resimler JPEG formatındadır. Görüntüler, 45 derecelik görüş alanına (Field of View- FOV) sahip bir Canon CR5 non-mydratic 3CCD kamera kullanılarak elde edilmiştir. Görüntülerin boyutu [584 x 565] pikseldir [31].

##### 3.1.2. DIARETDB0

DIARETDB0 (Standard Diabetic Retinopathy Database Calibration Level 0) veri seti dijital görüntülerden DR tespitini ölçmek ve geliştirilen yöntemlerin performanslarını karşılaştırmak için kurulmuştur. Veri seti 130 renkli fundus görüntüden oluşmaktadır. Bunlardan 20'si normal ve 110'u DR belirtileri içeren görüntülerdir. Görüntüler, 50 derecelik görüş alanı (Field of View- FOV) ile yakalanmıştır. Veri seti tanı

yöntemlerinin genel performanslarını değerlendirmek için kullanılmaktadır. Görüntülerin boyutu [1152 x 1500] pikseldir [50].


### **3.1.3. DIARETDB1**

DIARETDB1 (Standard Diabetic Retinopathy Database Calibration Level 1) veri seti DR tespitini ölçmek için oluşturulmuş halka açık bir veri tabanıdır. DR tespiti için farklı yöntemlerin karşılaştırılabileceği bir veri setidir. Bu veri seti, 84'ü DR hastalığının en azından hafif proliferatif olmayan işaretlerini (MA) içerdiği 89 renkli fundus görüntüsünden oluşmuştur. Geri kalan 5 resim ise herhangi bir şekilde DR belirtisi göstermeyen sağlıklı resim olarak kabul edilmiştir. Resimler Nikon F5 fundus kamerası ile ve 50 derecelik görüş alanı (Field of View- FOV) ile kayıt altına alınmıştır. Görüntülerin boyutu [1152 x 1500] pikseldir [51].

## **3.2. Gözün Yapısı**

En genel haliyle göz, görmeyi sağlayan küre biçiminde bir organ olup, kemikler ile çevrili olan göz çukurunda yer alır. Gözün üç katmanı vardır. Bunlar: Sert Tabaka (en dış tabaka), damar tabaka (orta tabaka) ve ağ tabakadır (en iç tabaka).

Sert tabaka aynı zamanda sklera veya göz akı olarak da anılır. Gözün en dış kısmında bulunması ve sert olmasından dolayı, gözü dış etmenlerden korumakla görevlidir. Bu tabaka içerisinde, gözü dış etkenlerden koruyan ve gelen ışığın kırılmasını sağlayan kornea da yer almaktadır. Gözün ön kısmındaki saydam tabaka kornea, beyaz görünen kısım ise skleradır.




Şekil 3.1 Kornea ve Sklera'nın Yapısı

Gözün ikinci katmanı olan damar tabaka hemen skleranın iç kısmında bulunur ve içerisinde kan damarları bulunmaktadır. Bu tabakanın görevi, içerisinden geçen kan damarları ile gözü beslemektir. Bu tabaka bir insanda birim alan başına en çok kanlanma olan tabakadır. İç tabakadaki retinanın gün boyu faaliyetlerinin yürütülebilmesi için bu gereklidir.

Gözün en iç tabakası olan ağ tabakanın diğer bir adı retinadır. Retina, gözde görmeyi sağlayan yapıdır. Görme işlemini gerçekleştiren ışığa duyarlı sinir hücreleri ve yaklaşık 130 milyon reseptör, ağ tabakasında bulunur. Önce korneadan, ardından lensten kırılarak retina üzerine düşen ışık, burada bulunan sinir hücreleri tarafından elektrokimyasal enerjiye dönüştürülerek, optik sinir aracılığıyla beyne iletilir.

Gözün katmanları ve genel yapısı Şekil 3.2'de görülmektedir.



Şekil 3.2 Damar Tabakanın Yapısı

### 3.3. Görme Olayı

Işık ışınları cisimlerden yansıyarak öncelikle saydam tabakaya gelip, burada kırılır. Ardından kırılan ışınlar göz bebeğine gelir. Daha sonra göz merceğinde tekrar kırılarak retina (ağ tabakası) üzerine düşer. Retina üzerinde bulunan sarı leke üzerinde ters bir görüntü meydana gelir. Oluşan bu görüntü, görme reseptörleri tarafından algılanır ve görme sinirleri ile beyindeki görme merkezine iletilir. Oluşan ters görüntü, görme merkezinde düz olarak algılanır ve bu şekilde görme işlemi gerçekleşmiş olur.

### 3.4. Retina Görüntüleri

Alman bilim insanı Von Helmholtz tarafından 1850 yılında geliştirilen oftalmoskop cihazı ile retina resimleri resmedilebilmektedir. Retina bölgesindeki damarlar, optik disk, fovea ve makula gibi yapılar oftalmoskop cihazı vasıtasıyla incelenip, olası bir hastalığa karşı tedavi yöntemi belirlenebilmektedir. Şekil 3.3'de oftalmoskop cihazı ile çekilmiş örnek bir retina yapısı görülmektedir.





Şekil 3.3 Oftalmoskop Cihazı İle Çekilmiş Bir Retina Yapısı

Retinal hastalıkların belirlenebilmesi ve hastalığa karşı tedavi planlaması yapılabilmesi için retina görüntülerinden faydalanılmaktadır. Bu sayede kan damarlarındaki kaçak, tıkanıklık, makula bölgesindeki anormallikler vs. daha rahat saptanabilmektedir. Oftalmoskop cihazı ile resmedilen retina görüntüsünde OD alanının sol tarafta bulunması sol göze ait retina görüntüsü olduğu, OD alanının sağ tarafta bulunması ise sağ göze ait retina görüntüsü olduğu anlamına gelmektedir.

Bazı dijital oftalmoskop cihazları Şekil 3.4’de gösterilmiştir.



Şekil 3.4 Dijital Oftalmoskop Cihazları

### 3.5. Retinal Hastalıklar

Günümüzde en sık rastlanan retinal hastalıklar;

- Diyabet hastalığına bağlı diyabetik retinopati
- Epiretinal membran (Maküler pucker)
- Makula deliği
- Retinal ven (toplardamar) tıkanıklıkları
- Retinal arter (atardamar) tıkanıklıkları
- Yaşa bağlı makula dejenerasyonu (sarı nokta hastalığı)
- Retina yırtığı ve retina dekolmanı

olarak bilinmektedir. Bu hastalıkların en sık görüleni ise, DR'dir.

### 3.6. Diyabetik Retinopati

DR, retinada MA'lar, kanamalar (hemorajiler), pamuk yünü lekeleri, parlak noktalar (eksüdalar), venöz boncuklanma, mikrovasküler anormallikler, neovaskülarizasyon içeren lezyonlar ve damarla ilgili anomaliler ile karakterize bir diyabet hastalığı komplikasyonudur [52].

Diyabetik makulapati, DR merkezi makulayı etkilemeye başladığında ortaya çıkar ve bu da görme kaybına neden olabilir [53].

Sağlıklı bir bireyin görüşü ile DR hastalığına sahip bir bireyin görüşü Şekil 3.5'te temsili olarak verilmiştir.



(a)

(b)

Şekil 3.5 (a) Sağlıklı Bir Bireyin Görüşü, (b) DR Hastalığına Sahip Bireyin Görüşü

#### 3.6.1. Diyabetik Retinopati Lezyonları


DR'nin şiddetine bağlı olarak retina bölgesinde çeşitli lezyonlar görülebilmektedir. Bu lezyonlar genel olarak şunlardır:

- Mikroanevrizma
- Hemoraji
- Vitröz Hemoraji
- Eksuda

- Pamuk/Yün Lekeleri
- IRMA (Retina İçi Mikrovasküler Anormallikler)
- Neovaskülarizasyon

### 3.6.1.1. Mikroanevrizma


Mikroanevrizmalar (MA), DR'nin en erken evresinde görünen deęişimi temsil eder. Genellikle gözün arka kısmında yuvarlak, kırmızı noktalar şeklinde görünürler. DR'nin ilerlemesi ile bu kırmızı noktaların sayısında da artış olur. Yaygın olarak küme halinde görülürler [54]. Mikroanevrizma lezyon örneęi Şekil 3.6'da gösterilmiştir.



Şekil 3.6 Mikroanevrizma Lezyonu Örneęi

### 3.6.1.2. Hemoraji

Kanama anlamına gelen hemorajiler, genellikle retinadaki MA'lara eşlik eder. Bir nokta, leke ve ayrıca alev gibi farklı şekiller alabilir [52]. Hemoraji lezyon örneęi Şekil 3.7'de gösterilmiştir.



Şekil 3.7 Hemoraji Lezyonu Örneği

### 3.6.1.3. Vitröz Hemoraji

Vitröz hemoraji, vitreus boşluğu içindeki büyük çaplı kanama anlamına gelmektedir. Kanamadan dolayı makula gizlendiğinde, görme kaybı görülme sıklığı keskin bir şekilde artmaktadır [52]. Şekil 3.8’de Vitröz Hemoraji lezyonu gösterilmiştir.



Şekil 3.8 Vitröz Hemoraji Lezyonu Örneği

#### **3.6.1.4. Sert Eksuda**


Sert eksudalar, anormal retina içi kılcal damarlardan sızan hücresel yağlar tarafından oluşturulan bir lezyon türüdür. Küçük lekelerden daha büyük lekeler kadar değişen keskin kenarlara sahip parlak renkte sarı-beyaz tortular olarak görülürler. Sert eksuda, beyaz veya sarı-beyaz renkte ve keskin bir görünüme sahiptir. Kan damarlarından sızan yağların foveada birleşmesi durumunda, görüş tehlikeye girebilir [54]. Sert Eksuda lezyonu Şekil 3.9'da gösterilmiştir.



Şekil 3.9 Sert Eksuda Lezyonu Örneği

#### 3.6.1.5. Pamuk/Yün Lekeleri


Yumuşak eksuda olarak da bilinen pamuk/yük lekeleri (cotton-wool spots) belirgin olmayan kenarlara sahip sinir lifi tabakasında grimsi veya beyaz renkte lekelerdir. Kenarları tüy gibi retina damarlarını örtebilen lezyonlardır. Retina sinir lif katmanında kılcal damarın tıkanıklığı sonucu gelişen lezyonlardır [43, 46]. Pamuk/yün lekeleri (yumuşak eksuda) lezyonu Şekil 3.10'da oklarla gösterilmiştir.



Şekil 3.10 Yumuşak Eksuda Lezyonu Örneği

### 3.6.1.6. IRMA

Retina içi mikrovasküler anormallikler, kılcal damarların, retina katmanları içinde oluşturulan yeni kıvrımlı damarlarla genişletilmiş görüldüğü bölgelerdir [56]. IRMA lezyonu Şekil 3.11’de gösterilmiştir.



Şekil 3.11 IRMA Lezyonu Örneği

### 3.6.1.7. Neovaskülarizasyon

Neovaskülarizasyon, anormal şekilde büyüyen yeni damarları temsil etmektedir. Bu yeni damarlar, geniş damarlardan oluşmaktadır. Başlangıçta retina yüzeyinde ince ot öbeği şekline benzer bir yapıda görünürler. Bu yeni oluşan damarlar çok kırılıgandır ve kolayca kanama yaparlar [54]. Lezyon örneği Şekil 3.12’de gösterilmiştir.



Şekil 3.12 Neovaskülarizasyon Lezyonu Örneği



### 3.6.2. Diyabetik Retinopati Evreleri

DR evreleri, dört aşamada ele alınmaktadır [57], [58].

#### 1. Hafif Düzeyde ve Proliferatif (Çoğalma) Olmayan Diyabetik Retinopati

Çoğalma olmayan DR'nin ilk ve en hafif evresidir. Retinanın kan damarlarında mikroanevrizmalar adı verilen küçük balon benzeri şişliklerin ortaya çıktığı evredir. Bu evrede hafif derecede kanamalar meydana gelir.

#### 2. Orta Düzeyde ve Proliferatif (Çoğalma) Olmayan Diyabetik Retinopati

Damarların şişmesi ve bozulmasının meydana gelebileceği ve ayrıca retina içindeki kan damarlarının kan taşıma kabiliyetini yitirebileceği evredir. Bu evrede damar tıkanıklığı ve damarlarda küçük çaplı anormallikler meydana gelir.

#### 3. Şiddetli Düzeyde ve Proliferatif (Çoğalma) Olmayan Diyabetik Retinopati

Bu aşamada daha fazla kan damarı tıkanarak retinadaki çeşitli bölgelere kan akışı durur. Bu şekilde retinada beslenemeyen alanlar artmaya başlar. Bu alanlardan beyne bazı sinyaller gönderilerek yeni damar oluşumunun başlaması istenir. Göz içi şiddetli kanamalar bu aşamada meydana gelir.


#### 4. Proliferatif Diyabetik Retinopati

DR'nin en ileri evresi olan bu aşamada, retinanın iç yüzeyi ve vitreus jeli boyunca büyüyen yeni kan damarı oluşumu meydana gelir. Bu damarlar çok kırılabilir olup, bu da sızıntı yapma ve kanamaya başlama olasılığını artırır. Bu da görme kaybına neden olur.

DR hastalığına ait bu dört aşama, Şekil 3.13'de gösterilmiştir.

Şekil 3.13'e göre 1 numarayla gösterilen fundus görüntüsü Hafif Düzeyde ve Proliferatif Olmayan Diyabetik Retinopatiyi, 2 numarayla gösterilen fundus görüntüsü Orta Düzeyde ve Proliferatif Olmayan Diyabetik Retinopatiyi, 3 numarayla gösterilen fundus görüntüsü Şiddetli Düzeyde ve Proliferatif Olmayan Diyabetik Retinopatiyi ve

4 numarayla gösterilen fundus görüntüsü ise Proliferatif Diyabetik Retinopatiyi temsil etmektedir [59].



Şekil 3.13 DR'nin aşamalarını temsil eden dört farklı fundus görüntüsü

### **3.7. DR Lezyonlarının ve Retinaya Ait Anatomik Yapıların Tespitinde Kullanılan Yöntemler**

DR hastalığını otomatik olarak tespit edebilmek ve retinal görüntüye ait fovea ve makula bölgesinin, OD'in ve kan damarlarının tespitini yapabilmek, onların konumunu saptayabilmek için genellikle üç aşama kullanılmaktadır. Bunlar; görüntü önileme, öznitelik çıkartımı ve sınıflandırmadır.

#### **3.7.1. Görüntü Önileme**

Görüntü önileme adımı, problemin çözümü için yapılacak ilk ve en önemli adımdır. Çünkü önileme, bir sonraki adımda yapılacak iş için görüntüye ait verilerin iyileştirilme sürecidir. Görüntü önileme adımları; piksel parlaklığı dönüşümleri,

geometrik dönüşümler, yerel ön işleme ve görüntü restorasyonu olmak üzere dört kategoriye ayrılmaktadır [60].

Piksel parlaklık dönüşümleri resmin parlaklık düzeltmeleri ve gri seviyeli dönüşümlerden oluşmaktadır. Geometrik dönüşümler, görüntü yakalama işlemi sırasında meydana gelen geometrik bozulmaların giderilmesi işlemidir. Geometrik bir dönüşümün iki temel adımı piksel koordinat dönüşümü ve parlaklık enterpolasyonudur. Görüntü restorasyonunun temel amacı ise bozulmayı bastırmaktır. Görüntü restorasyon yöntemleri, tüm görüntüde dekonvolüsyon kavramını uygulamaktadır. Yerel ön işleme yöntemleri ise yeni bir parlaklık değerine sahip bir sonuç görüntüsü oluşturmak için küçük piksel komşuluğu kullanmaktadır. Bunun için görüntü yumuşatma ve kenar tespiti kullanılır. Görüntü yumuşatma, görüntüdeki gürültüyü veya diğer küçük dalgalanmaları azaltmak için kullanılır. Gradient operatörleri ise konumların hızlı bir şekilde değiştiği kenarları belirler.

Çizelge 3.1'de DR lezyonlarının tespiti için geliştirilen sistemlerde ve bu tespit kapsamında OD, retinal kan damarları, fovea ve makula bölgesi gibi retinaya ait diğer anatomik yapıların tespiti aşamalarında uygulanan görüntü ön işleme teknikleri listelenmiştir.

Çizelge 3.1 Diyabetik Retinopati Tespiti Çalışmalarında Kullanılan Önişleme Teknikleri

<b>Yazar</b>	<b>Tespit Edilen</b>	<b>Önişleme Tekniği</b>
Fadzil v.d [61]	Retinal Kan Damarları	Ortalama Filtre, Kontrast Sınırlamalı Adaptif Histogram Eşitleme, Bottom-Hat Morfolojik Dönüşüm
Akram v.d. [41]	Mikroanevrizma Lezyonları	Matematiksel Morfolojik İşlemler, Kontrast Normalizasyonu, Filtre Bankası
Shirin v.d. [62]	Eksuda ve MA Lezyonları, OD, Retinal Kan Damarları	Kontrast Sınırlamalı Adaptif Histogram Eşitleme, Morfolojik İşlemler
Al-Rawi v.d. [26]	Retinal Kan Damarları	Eşleştirilmiş Filtre
Aravind v.d. [63]	Mikroanevrizma Lezyonları, Optik Disk, Retinal Kan Damarları	Yeşil Kanal Çıkartımı, Histogram Eşitleme, Kontrast İyileştirme, Morfolojik İşlemler
Ponnibala ve Vijayachitra [64]	Eksuda Lezyonları, Optik Disk	Yeşil Kanal Çıkartımı, Histogram Eşitleme, Kontrast İyileştirme, Morfolojik İşlemler
Fleming v.d. [47]	Mikroanevrizma Lezyonları	Medyan Filtreleme, Gauss Filtresi, Normalizasyon

Harangi v.d. [65]	Eksuda Lezyonları	Yeşil Kanal Çıkartımı, HIS Renk Uzayı, Kontrast Sınırlamalı Adaptif Histogram Eşitleme
Hatanaka v.d. [66]	MA Lezyonları	Işık Düzeltme, Histogram Genişletme, Yeşil Kanal Çıkartımı, Alçak Geçiren Filtre Tabanlı Hızlı Fourier Transformu
Hunter v.d. [67]	Fovea ve Makula	Kontrast İyileştirme, Eşikleme, Bölge Büyütme, Filtreleme
Orlando v.d.[46]	MA ve Hemoraji Lezyonları	Morfolojik İşlemler, Yeşil Kanal Çıkartımı, Filtreleme
Jaafar v.d. [68]	Eksuda Lezyonları	Top-Hat Dönüşümü, Medyan Filtreleme
Jimenez v.d. [69]	MA Lezyonları	Yeşil Kanal Çıkartımı, Yüksek Geçiren Filtre, Kontrast İyileştirme, Top-Hat Dönüşümü
Joshi ve Karule [70]	Retinal Kan Damarları	Kontrast Sınırlamalı Adaptif Histogram Eşitleme, Morfolojik İşlemler
Lazar ve Hajdu [71]	MA Lezyonları	Yeşil Kanal Çıkartımı, Adaptif Eşikleme
Lichode ve Kulkarni [72]	MA ve Eksuda Lezyonları, Retinal Kan Damarları	Yeşil Kanal Çıkartımı, Morfolojik İşlemler, Canny Kenar Belirleme Algoritması

Martins v.d. [73]	MA Lezyonları, Retinal Kan Damarları	Yeşil Kanal Çıkartımı, Gölge Düzeltme
Mizutani v.d. [74]	MA Lezyonları, Retinal Kan Damarları	Işık Düzeltme, Gama Düzeltmesi, Kontrast İyileştirme
Mookiah v.d. [75]	Normal ve DR Aşamaları	Wiener Filtre, Gri Seviyeli Gölge Düzeltme
Nagaveena v.d. [76]	Retinal Kan Damarları	Yeşil Kanal Çıkartımı, Adaptif Medyan Eşikleme
Niemeijer v.d. [45]	MA Lezyonları	Yeşil Kanal Çıkartımı, Gölge Düzeltme, Parlak Lezyon Silme
Osareh v.d. [77]	Eksuda Lezyonları	Normalizasyon, Yerel Kontrast İyileştirme, Bulanık C-Means Kümeleme
Prakash ve Sumanthi [78]	MA Lezyonları	Kontrast Sınırlamalı Adaptif Histogram Eşitleme, Gölge Düzeltme
Dai v.d. [48]	MA Lezyonları	Resim Yeniden Boyutlandırma, Histogram Eşitleme
Punnolil [79]	Eksuda, Hemoraji ve MA Lezyonları	Yeşil Kanal Çıkartımı, Normalizasyon, Morfolojik İşlemler

Quelleg v.d. [80]	MA Lezyonları	Optimal Dalgacık Dönüşümü
Ravishankar v.d. [4]	DR Lezyonları, OD, Retinal Kan Damarları	Yeşil Kanal Çıkartımı, Morfolojik İşlemler
Sopharak v.d. [81]	MA Lezyonları	Gölge Düzeltme, Medyan Filtre, Adaptif Histogram Eşitleme
Kar ve Maity [49]	OD, Retinal Kan Damarları, DR Lezyonları	Yeşil Kanal Çıkartımı, Kenar Geliştirme, Eşleştirilmiş Filtre, Morfolojik İşlemler
Sundhar ve Archana [82]	Eksuda ve MA Lezyonları, Retinal Kan Damarları	Yeşil Kanal Çıkartımı, Normalizasyon, Adaptif Histogram Eşitleme, Binarizasyon
Vimala ve Kajamohideen [83]	Eksuda Lezyonları, Makula	Yeşil Kanal Çıkartımı, Medyan Filtre, Adaptif Histogram Eşitleme, Morfolojik İşlemler
Wisaeng v.d. [84]	OD	Normalizasyon, Kontrast İyileştirme, Medyan Filtre, LUV Uzayı, Morfolojik İşlemler, Otsu Algoritması
Yadao v.d. [85]	Retinal Kan Damarları	Ortalama Filtre, Laplas Filtre, Morfolojik Açma İşlemi, Eşikleme, Gaussian Filtre, Kirsch Filtre
Ünver v.d. [86]	OD	Yeşil Kanal Çıkartımı, KSAHE, Dinamik. Eşikleme, İstatistik Tabanlı Kenar Belirleme Alg., Morfolojik İşlemler

### 3.7.2. Öznitelik Çıkartımı

Bir sistemin girişlerinin tüm bir bilgi olarak değil, bilgiyi oluşturan özelliklerden bir kısmının çıkarılması ve sistemin bu özellikler üzerine kurulması durumudur. Öznitelik çıkartımı bir boyut azaltma işlemidir. Karmaşık bir verinin boyutları düşürülerek çözümü daha basit bir problem haline indirgenir [87]. Görüntü ön işleme tekniklerinin ardından, resme ait özellikleri elde etmek üzere öznitelik çıkartımı yapılmaktadır. Görüntü işleme alanındaki öznitelik çıkartımı, dijital resimlere ve videolara uygulanarak onların sayısız özelliğini tespit etmeye yarar.

DR lezyonlarının sınıflandırılması amacıyla çıkartılan en temel öznitelikler piksellere ait alan, ortalama ve standart sapma bilgileridir. Bunun yanında DR tespiti sürecinde araştırmacıların kullandığı birçok öznitelik değeri de vardır. Bir dairenin yarıçapı, genişliği, alan, çevre, kompaktlık bilgisi, en- boy oranı, yuvarlaklığı, pikselin yoğunluğu bunlara örnek olarak gösterilebilir. Öznitelikler şekil özniteliği, yoğunluk özniteliği, renk özniteliği ve Fourier tanımlayıcı özniteliği olarak sınıflandırılabilir. Bu öznitelik değerlerine ek olarak ise, DR hastalığının şiddetini tespit etmek için kullanılabilen gri seviye eş oluşum matrisinden elde edilen entropi, kontrast, homojenlik, korelasyon, enerji gibi doku analizine dayalı öznitelikler de mevcuttur [1].

Çizelge 3.2’de DR lezyonlarının tespiti için geliştirilen sistemlerde ve bu tespit kapsamında OD, retinal kan damarları, fovea ve makula bölgesi gibi retinaya ait diğer anatomik yapıların tespiti aşamalarında uygulanan öznitelik değerleri listelenmiştir.



Çizelge 3.2 Diyabetik Retinopati Tespiti Çalışmalarında Kullanılan Öznitelik Değerleri

Yazar	Tespit Edilen	Öznitelik Değeri
Akram v.d. [41]	MA Lezyonları	Alan, eksantriklik, çevre, kompaktlık, en boy oranı, tüm yeşil kanal piksellerinin ortalama ve standart sapması, kontrastlı yeşil kanal piksellerinin ortalama ve standart sapması, aday lezyonun sınır pikselleri için ortalama gradyan büyüklüğü değeri, komşu piksellerin ortalama gradyan değeri, HSV, HSV standart sapması, entropi, enerji, homojenlik
Akram v.d. [88]	MA, Eksuda ve Hemoraji Lezyonları	Alan, eksantriklik, çevre, ortalama yoğunluk, en boy oranı, kompaktlık, ortalama HSV, ortalama gelişmiş yoğunluk, ortalama gradyan büyüklüğü, üçüncü moment, entropi, ortalama aralık filtresi, enerji
Alipour v.d. [62]	Eksuda ve MA Lezyonları, OD, Retinal Kan Damarları	Alan, yuvarlaklık, toplam MA sayısı, kan damarlarının alanı
Aravind v.d. [63]	MA Lezyonları, OD, Retinal Kan Damarları	Alan, entropi, korelasyon, enerji, contrast, homojenlik, standart sapma, ortalama

Ponnibala ve Vijayachitra [64]	Eksuda Lezyonları, OD	Eksuda alanı, eksuda çevresi, eksuda sayısı, istatistiksel özellikler (ortalama, standart sapma, enerji, kontrast korelasyonu, homojenlik, entropi, küme gölgesi, küme belirginliği, çarpıklık ve keskinlik)
Martins v.d. [73]	MA Lezyonları, Retinal Kan Damarları	Alan, çevre, yuvarlaklık, yoğunluk, ortalama yoğunluk
Mookiah v.d. [75]	Eksuda Lezyonları, Retinal Kan Damarları	Eksuda alanı, kan damarları alanı, entropi, düğüm nokta sayısı
Nagaveena v.d. [76]	Retinal Kan Damarları	Alan, ortalama, standart sapma, enerji
Orlando v.d. [46]	MA ve Hemoraji Lezyonları	Ortalama yoğunluk değeri, standart sapma, contrast, minimum yoğunluk değeri, toplam yoğunluk değeri, alan, çevre, en-boy oranı, yuvarlaklık, eksantriklik, kompaktlık, ana eksen uzunluğu, küçük eksen uzunluğu
Punnolil [79]	Eksuda, Hemoraji ve MA Lezyonları, OD, Fovea, Makula	Alan, doku öznelikleri (ortalama, standart sapma, entropi, homojenlik)
Selvathi v.d. [89]	Eksuda ve MA Lezyonları, Retinal Kan Damarları	Kan damarları alanı, eksuda alanı, MA alanı, kontrast, homojenlik, korelasyon, enerji
Sujithkumar ve Vipula [90]	MA Lezyonları	Alan, çevre, yuvarlaklık

Sundhar ve Archana [82]	Eksuda ve MA Lezyonları, Retinal Kan Damarları	Ana eksen uzunluęu, küçük eksen uzunluęu, çevre, yuvarlaklık, alan
Tariq v.d. [91]	Eksuda Lezyonları, OD, Makula	Alan, ortalama yoğunluk, kompaktlık, ortalama ton, ortalama doygunluk ve ortalama değęer

### 3.7.3. Sınıflandırma

Özellikle medikal görüntülerde analizi yapılan ilgi alanının doğru tespiti hayati bir önem arz etmektedir. Çünkü hastalığa yapılacak yanlış bir tespit, geri dönüşü mümkün olmayan sonuçlar doğurabilmektedir. Bu aşamada, sınıflandırıcı algoritmalarının öğrenme süreci işletilir. Sınıflandırma algoritmaları denetimli ve denetimsiz olmak üzere iki kategoride incelenmektedir. Denetimli sınıflandırıcıda, ayırıcı fonksiyonların türetildiği veri yapısının belirlenebilmesi için kullanıcıdan giriş parametreleri istenir. Öte yandan, denetimsiz sınıflandırıcılar verilerin doğal yapısını kendisinden elde etmek için küme analizine dayanmaktadır.

Medikal görüntülerin analizi için sıklıkla kullanılan sınıflandırma algoritmaları bu bölümün alt sekmelerinde açıklanmıştır.

#### 3.7.3.1. Destek Vektör Makineleri

Destek Vektör Makineleri (DVM), makine öğrenmesi yöntemleri arasında olan, sınıflandırma problemlerinde en sık kullanılan yöntemlerden birisidir. Cortes ve Vapnik tarafından 1995 yılında geliştirilen DVM sınıflandırmanın yanı sıra, regresyon ve kümeleme problemlerinde de kullanılabilen bir makine öğrenmesi metodudur [92]. Temel amaç, hedef değişkene ait olan sınıfları birbirlerinden en optimum şekilde ayıracak hiper düzlemi saptamaktır. Hiper düzlemi maksimum yapmak için kullanılan fonksiyon Eşitlik 3.1’de gösterilmiştir.

$$f(\vec{x}) = \text{sign}(\sum_{i=1}^n y_i a_i \cdot K(\vec{x}, \vec{x}_i) + b) \quad (3.1)$$


Eşitliğe göre  $y$  çıkış değişkenini temsil etmektedir.  $b$  önyargı ve  $a$  değeri ise her biri üzerinde Eşitlik 3.2’nin çözülmesinden elde edilmektedir.

$$\sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j \cdot y_i y_j \cdot K(\vec{x}_i, \vec{x}_j) \quad (3.2)$$

Eşitliğe göre  $a_i$  değeri pozitif ise  $x_j$  adlandırılmış destek vektörleridir.

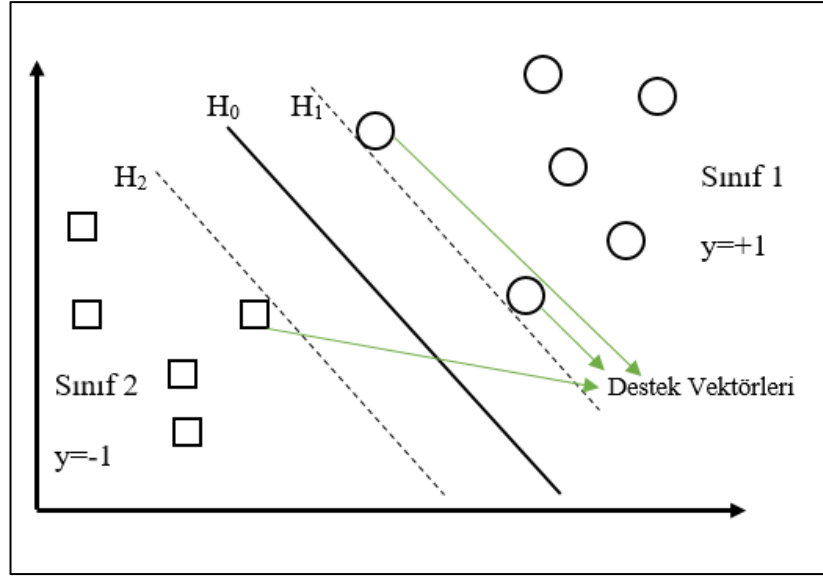
DVM, sınıflandırma işlemini doğrusal veya doğrusal olmayan bir fonksiyon yardımıyla gerçekleştirir. DVM yöntemi veriyi birbirinden ayırmak için uygun olan fonksiyonun tahmin edilmesi esasına göre çalışır.

Verilerin lineer olarak ayrılabilmesi durumunda;  $D$ ,  $n$  elemanlı bir veri kümesi ve elemanlarının  $(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)$  olduğu düşünülürse, Şekil 3.14'de  $D$  kümesinin grafiği iki sınıf halinde verdiği görülmektedir. Grafikten  $D$  kümesinin elemanlarının birbirinden farklı biçimlerde doğrusal olarak ayrılacağı görülmektedir.



Şekil 3.14 Lineer Olarak Ayrılabilen Verilerin Görünümü


Burada amaç, düzlemdeki verileri birbirinden ayıran doğrulardan hangisinin veri kümesi sınıflarının her ikisine de en uzak olduğunu bulmaktır. Şekil 3.15'de yer alan  $H_1$  ve  $H_2$  doğruları düşünüldüğünde, bu iki doğrunun ortasından geçen  $H_0$  doğrusunun bu iki sınıfı birbirinden en iyi ayıran doğru olduğu görülmektedir [93].



Şekil 3.15 Veriler Arasındaki Muhtemel En Büyük Boşluk

Sınıflandırma uygulamalarının birçoğunda veri setlerinin lineer olarak ayrılması mümkün olmamaktadır. Veri setinin bir kısmının ayırıcı doğrunun diğer tarafında kalmasından kaynaklı bu tarz problemler, bir hata değişkeni tanımlanarak çözülebilmektedir.

Bu türde olan veriler Şekil 3.16'da gösterilmiştir.




Şekil 3.16 Lineer olarak ayrılmaması durumunda iki sınıflı veriler ve ayırıcı hiper düzlemler

Lineer olmayan DVM’de ise, sınıflandırıcılar maksimum aralıklı hiper düzleme değişik yapıda çekirdek fonksiyonları uygulanarak elde edilmektedir. Ortaya çıkan sonuç, lineer DVM ile benzerlik gösterse de her bir iç çarpımı lineer olmayan çekirdek fonksiyonu ile değiştirilmiştir. Bir diğer deyişle, lineer olarak sınıflandırması yapılamayan girdiler, bir çekirdek fonksiyonu ile haritalanmak suretiyle lineer olarak sınıflandırılabilir.

Lineer olmayan DVM’lerin karar fonksiyonu Eşitlik 3.3’de gösterilmiştir.

$$f(x) = \text{sign}\left(\sum_{i=1}^N y_i a_i \cdot \phi(x)\phi(x_i) + b\right) \quad (3.3)$$

Lineer olmayan DVM’lerde sınıflandırma işlemi Şekil 3.17’de gösterilmiştir.



Şekil 3.17 Lineer olmayan DVM'lerde sınıflandırma işlemi

Lineer olmayan DVM'lerde en sık kullanılan çekirdek fonksiyonları Çizelge 3.3'de listelenmiştir.

Çizelge 3.3 Lineer olmayan DVM'lerde kullanılan çekirdek fonksiyonları

Çekirdek Fonksiyonlar	
Doğrusal	$K(x_i, x_j) = (x_i^T x_j)$
Polinomiyal	$K(x_i, x_j) = (1 + x_i^T x_j)^d$
Radyal Tabanlı	$K(x_i, x_j) = \exp\left(-\frac{\ x_i - x_j\ ^2}{2\gamma}\right)$
Sigmoid	$K(x_i, x_j) = \tanh(kx_i^T x_j - \delta)$

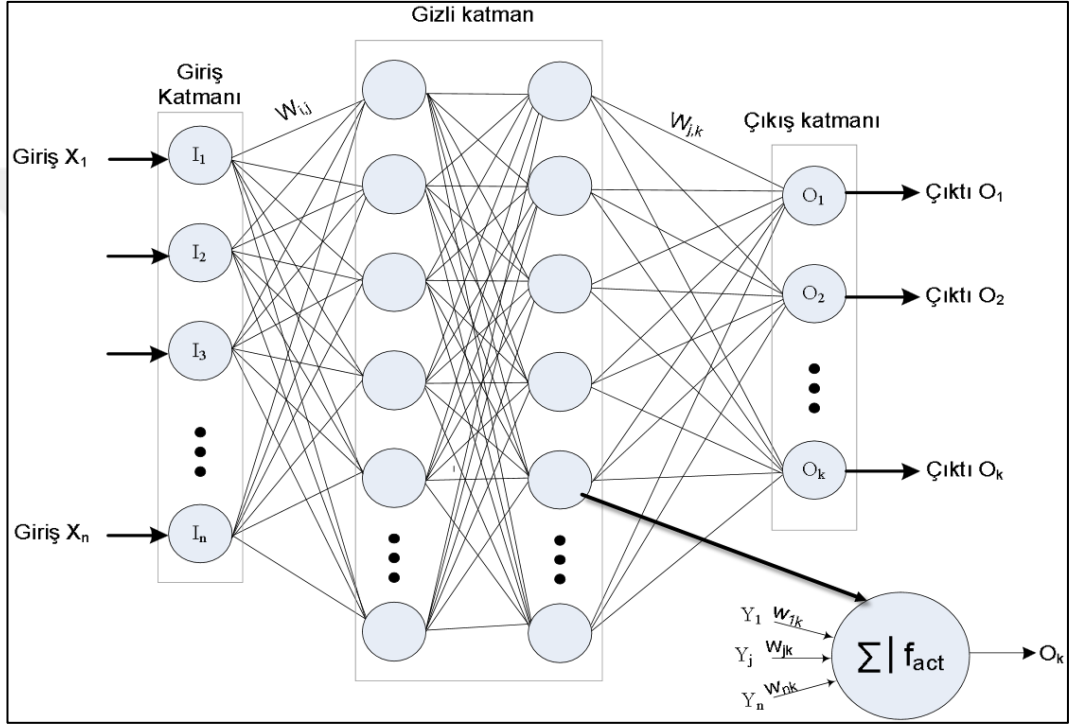
### 3.7.3.2. Yapay Sinir Ağları

Yapay sinir ağları (YSA), sistem tanımlama ve kontrolü, örüntü tanıma, medikal görüntü işleme, finansal uygulama, veri madenciliği ve daha birçok alanda yaygın bir



şekilde kullanılmaktadır. YSA'nın temel uygulamalarından birisi sınıflandırmadır. Bir sinir ağı düğüm adı verilen birçok nörondan oluşur. Bu nöronların iki işlevi vardır. Birincisi girdinin(verinin) diğer nöronlardan veya dış ortamdan toplanması ve ikincisi, toplanan girdilerden bir çıkış oluşturması.

Bir sinir ağı genel olarak giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmandan oluşmaktadır. Bir sinir ağının genel yapısı Şekil 3.18'de görülmektedir.



Şekil 3.18 Bir Sinir Ağının Genel Yapısı

Yapay nöronlar ile biyolojik nöronlar arasında bir benzerlik bulunmaktadır. Yapay nöronlarda düğümler arası bağlantılar biyolojik nöronlarda akson ve dendritleri temsil eder, aynı şekilde yapay nöronlarda kullanılan ağırlıklar biyolojik nöronlarda sinapsları, eşik ise vücuttaki bir aktiviteyi temsil eder. YSA'da ağırlık bağlantıları kullanılarak beyindeki nöronların birbirlerine karmaşık bağlantılar üzerinden bilgiler göndererek iletişim kurma özelliğini bir anlamda simüle etmektedir. Kullanılan ağırlıkların pozitif olması nöronun uyarımda olduğunu ifade etmektedir.

Her bir nöron, ağırlık katsayıları ile çarpılan girişlerin toplamını almaktadır. Buna toplam fonksiyonu denmektedir. Çıkış ise doğrusal olmayan bir çıktıya aktarılmadan bir aktivasyon fonksiyonuna aktarılmalıdır. En yaygın kullanılan aktivasyon fonksiyonu ayırt edilebilir özelliklerinden dolayı sigmoid fonksiyonudur. Sigmoid aktivasyon fonksiyonu girişe karşılık 0 ile 1 aralığında çıkış değeri üreten doğrusal olmayan bir fonksiyondur. Toplam fonksiyonu ve aktivasyon fonksiyonunun denklemleri sırasıyla Eşitlik 3.4 ve Eşitlik 3.5’de verilmiştir.


$$Toplam = \sum_{i=1}^n w_{ji}x_i + \theta_j \quad (3.4)$$

Bu eşitlikte  $w$  ağırlık katmanındaki bir düğümün ağırlık değerini,  $x$  ise giriş katmanındaki giriş değerini ifade etmektedir.

$$f(x) = \frac{1}{1+e^{-x}} \quad (3.5)$$

Bu eşitlikte fonksiyonun 0 ile 1 arasında sınırlanmış bir değer üreteceği açıktır.

Sigmoid aktivasyon fonksiyonunun grafiği Şekil 3.19’da gösterilmiştir.



Şekil 3.19 Sigmoid Aktivasyon Fonksiyonunun Grafiği

Çok Katmanlı Algılayıcı (ÇKA), ileri beslemeli yapay sinir ağı modeli içerisinde bir veya birden fazla gizli katmana sahip olan bir ağıdır. Burada sinyaller girişten çıkışa doğru sadece tek yönde iletilmektedir. Doğrusal olmayan yapıdadır.

### 3.7.3.3. Naive Bayes Sınıflandırıcısı

Naive Bayes, mevcut verilerin belirlenen sınıflara ait olma ihtimallerini öngören bir sınıflandırma algoritmasıdır. İstatistik bilimindeki Bayes teoremini temel almaktadır. Bu teorem, belirsizlik durumlarının modellenerek bu durumlarla alakalı kanıtlanmış doğrular ve gerçekçi gözlemler doğrultusunda sonuçlar oluşturulmasını sağlar. Algoritma, belirsizlik taşıyan konularda karar vermek konusunda son derece başarılıdır. Bundan dolayı genellikle belirsizlik durumlarını tahmin etmek ve sınıflandırmak için kullanılır. Hesaplama karmaşıklığının az olmasından ve büyük verilerle iyi çalışmasından dolayı bu sınıflandırıcı çok tercih edilmektedir. Bu algoritmanın dezavantajı ise değişkenler arası ilişkilerin modellenememesi ve tüm değişkenlerin birbirinden bağımsız olması varsayımıdır [94].

Bayes teoremine göre,  $A = \{A_1, A_2, A_3, \dots, A_n\}$  örnekler kümesi olsun. B ise ikili sınıf değişkeni olduğu varsayıldığında, A'nın hangi sınıfa ait olduğunu tahmin edebilmek için Eşitlik 3.6 kullanılır.

$$P(B|A) = P(B|A_1, A_2, A_3, \dots, A_n) = \frac{P(B).P(A_1, A_2, A_3, \dots, A_n|B)}{P(A_1, A_2, A_3, \dots, A_n)} \quad (3.6)$$

Bayes teoremine göre A sınıfının bir üyesi olan bilinmeyen bir sorgu dizisinin (B) olasılığını Eşitlik 2.1 vermektedir. Burada  $P(B|A)$  ifadesi, A olayı bilindiğinde, B olayının olasılığını temsil etmektedir.

$A_1, A_2, A_3, \dots, A_n$ 'in birbirinden bağımsız olduğu kabul edildiğinde basitleştirme (koşullu bağımsızlık varsayımı) yoluna gidilebilir. Böylece Naive Bayes sınıflandırıcı için Eşitlik 3.7 elde edilir.

$$P(B|A) = \frac{P(B)}{P(A_1, A_2, A_3, \dots, A_n)} \prod_{i=1}^n P(A_i|B) \quad (3.7)$$

#### 3.7.3.4. Karar Ağacı

Karar ağacı (KA), sınıflandırıcıları uygulamak için en popüler yaklaşımlardan birisi olarak kabul edilmektedir. Bir KA, bir ağaç yapısı formunda sınıflandırıcıdır ve örnekleri ağacın kökünden başlar ve yapraklara ulaşıncaya kadar sınıflara ayırma işlemi yapar. Bir ağaç yapısındaki düğümler öznitelikleri temsil ederken, kenarlar ise bu özniteliklerin olası değerlerini temsil etmektedir. Klasik sınıflandırma mantığında olduğu gibi öğrenme ve doğrulama olmak üzere iki aşamada değerlendirme yapmaktadır. Öğrenme kümesi ile oluşturduğu modeli, test kümesi ile kontrol eder.

Literatürde sıklıkla kullanılan KA algoritmaları aşağıda sıralanmıştır:

- ID3,
- CHAID (Chi-Squared Automatic Interaction Detector),
- CART (Classification and Regression Trees),
- C4.5,
- C5.0,
- QUEST (Quick, Unbiased, Efficient Statistical Tree)
- MARS (Multivariate Adaptive Regression Splines)
- SPRINT (Scalable Parallelizable Induction of Decision Trees)
- SLIQ (Supervised Learning in Quest)

Bir X özelliği karar ağacının bölümlendirilmesi için kullanıldığında, hedef nitelik olan T kümesi  $\{T_1, T_2, \dots, T_n\}$  şeklinde bölünür. T ağacı için bilgi gereksinimi, tüm  $T_i$  ağaçlarının bilgi gereksinimlerinin ağırlıklı ortalamalarının toplamı olup, T ağacının bir elemanının sınıfını belirleyebilmek için gerekli olan bilgi Eşitlik 3.8'de verildiği şekilde hesaplanabilmektedir.

$$H(X, T) = \sum_{i=1}^n \frac{|T_i|}{|T|} H(T_i) \quad (3.8)$$

X özelliğinden sağlanan bilgi kazancı ise Eşitlik 3.9'da gösterildiği gibi hesaplanabilmektedir.

$$Kazanç(X, T) = H(T) - H(X, T) \quad (3.9)$$

Eşitlik 3.9'a göre her defasında en büyük bilgi kazancı sağlayan X testi seçilir ve bu şekilde karar ağacı oluşturulmuş olur.

### 3.7.3.5. k-En Yakın Komşu Sınıflandırıcı

Verilerin ait olacağı sınıfı ve en yakın komşuyu k değerine göre belirleyen bir sınıflandırma yöntemidir. Nesnelere arası uzaklığa dayalı sınıflandırma yapan denetimli bir sınıflandırıcıdır. Medikal görüntü analizi, örüntü tanıma, istatistik, biyoinformatik gibi birçok alanda kullanımı vardır.

k-en yakın komşu sınıflandırıcısı, nesnelere arası uzaklık hesaplaması ile sınıflandırma yapar. Algoritmanın temelinde 'örnek uzayda birbirine yakın olan nesnelere aynı kategoriye atılır' varsayımı yer almaktadır. Algoritmanın amacı, nesnelere bu nesnelere ait özelliklerden yararlanarak, önceden belirlenen sınıflara veya gruplara en doğru şekilde atamaktır. Sınıflandırılmak istenen gözlem, öğrenme veri seti yardımıyla, en yakınında bulunan k tane gözlemden en fazla benzer olanlarla aynı veri setinde sınıflandırılması yapılır. Uzaklık hesaplaması için Öklid (Euclidean), Manhattan, Mahalanobis ve Chebyshev yöntemleri kullanılmakla birlikte, bu yöntemlerin formülleri de sırasıyla Eşitlik 3.10, Eşitlik 3.11, Eşitlik 3.12 ve Eşitlik 3.13'de verilmiştir.

$$d(x, y) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (3.10)$$

$$d(x, y) = |x_1 - x_2| + |y_1 - y_2| \quad (3.11)$$

$$d(x, y) = \sqrt{\sum_{i=1}^n \frac{(x_i - y_i)^2}{\sigma_i^2}} \quad (3.12)$$

$$d(x, y) = \max(|x_1 - x_2|, |y_1 - y_2|) \quad (3.13)$$

k-en yakın komşu sınıflandırıcısının dezavantajı ise, alakasız ve gereksiz özniteliklere karşı hassasiyeti ve büyük veri setleri için kullanıldığında, sınıflandırma işleminde test edilen veriyi tüm eğitim kümesiyle karşılaştıracağı için oldukça uzun hesaplama süresi çıkarır.

Çizelge 3.4’de DR lezyonlarının tespiti için geliştirilen sistemlerde ve bu tespit kapsamında OD, retinal kan damarları, fovea ve makula bölgesi gibi retinaya ait diğer anatomik yapıların tespiti aşamalarında uygulanan sınıflandırıcılar listelenmiştir.



Çizelge 3.4 DR Tespiti Çalışmalarında Kullanılan Sınıflandırıcılar

Yazar	Tespit Edilen	Sınıflandırıcı
Adal v.d. [95]	MA Lezyonları	DVM
Akram v.d. [88]	MA, Hemoraji ve Eksuda Lezyonları	Hibrit Sistem – Gaussian Mixture Model, DVM
Alipour v.d. [62]	Eksuda ve MA Lezyonları, OD, Retinal Kan Damarları	DVM
Aravind v.d. [63]	MA Lezyonları, OD, Retinal Kan Damarları	DVM
Chowriappa v.d.[96]	Makulopati Lezyonları	Naïve Bayes, SMO Optimizasyonu, C4.5
Dai v.d. [48]	MA Lezyonları	Metin Madenciliği, Derin Öğrenme Tabanlı Hücresel Sinir Ağı
Fleming v.d. [47]	MA Lezyonları	k-NN

Harangi v.d. [65]	Eksuda Lezyonları	Naïve Bayes
Hatanaka v.d.[66]	MA Lezyonları, Retinal Kan Damarları	Üç Katmanlı İleri beslemeli Sinir Ağı
Kar ve Maity [49]	OD, Retinal Kan Damarları, DR Lezyonları	Diferansiyel Evrim Algoritması
Lim v.d. [97]	MA, Hemoraji, Sert Eksuda Lezyonları	Hücrel Sinir Ağları
Martins v.d.[73]	MA Lezyonları, Retinal Kan Damarları	ÇKA Sinir Ağı
Mookiah v.d. [75]	Eksuda Lezyonları, Retinal Kan Damarları	Olasılıksal Sinir Ağı, Karar Ağacı, DVM
Mizutani v.d. [74]	MA Lezyonları, Retinal Kan Damarları	Üç Katmanlı İleri Beslemeli Sinir Ağı
Prakash ve Sumanthi [78]	MA Lezyonları	DVM
Orlando v.d. [46]	MA ve Hemoraji Lezyonları	CNN, Rastgele Orman



Punnolil [79]	Makula, Eksuda, Hemoraji ve MA Lezyonları, OD, Fovea	DVM
Ren v.d. [43]	MA Lezyonları	Ekstrem Öğrenme Makinesi
Selvathi v.d. [89]	Sert Eksuda ve MA Lezyonları, Retinal Kan Damarları	DVM
Sopharak v.d. [98]	Eksuda Lezyonları	Naïve Bayes, DVM, k-NN
Sundhar ve Archana [82]	Eksuda ve MA Lezyonları, Retinal Kan Damarları	Dört Katmanlı Geriye Yayılım Yapay Sinir Ağı
Tariq v.d. [91]	Eksuda Lezyonları, OD, Makula	Gaussian Mixture Model
Verma v.d. [99]	Hemoraji Lezyonları, Retinal Kan Damarları	Rastgele Orman
Vimala ve Kajamohideen [83]	Eksuda Lezyonları, Makula	DVM

### 3.8. Başarı Değerlendirmesi ve Analiz Yöntemleri

Sınıflandırma işlemlerinin hemen ardından, sınıflandırmanın ne kadar başarılı olduğunu ölçebilmek için bir başarı değerlendirme analizine ihtiyaç duyulmaktadır. Eğitim veri setinde eğitilen modelin, test veri setinde ne kadar doğru tahmin yaptığını ölçmek için karmaşıklık matrisi kullanılır. Bu matriste sütunlar örneklere ait gerçek bulguları, satırlar ise modelin sınıf tahminini ifade etmektedir.

İki sınıflı bir model için karmaşıklık matrisi, Çizelge 3.5’de gösterilmiştir.

Çizelge 3.5 İki Sınıflı Bir Model İçin Karmaşıklık Matrisi

	Gerçek Sınıf		
	Pozitif	Negatif	
Modelin Sınıf Tahmini	Pozitif	Doğru Pozitif Sayısı (True Positive - TP)	Yanlış Pozitif Sayısı (False Positive - FP)
	Negatif	Yanlış Negatif Sayısı (False Negative - FN)	Doğru Negatif Sayısı (True Negative - TN)

Karmaşıklık matrisinde yer alan bilgilere göre;

**Doğru Pozitif (TP):** Gerçek değeri pozitif olan verinin tahmin değerinin de pozitif olması durumudur.

**Yanlış Pozitif (FP):** Gerçek değeri negatif olan verinin tahmin değerinin yanlış sınıflandırma sonucu pozitif olması durumunu ifade eder.

**Yanlış Negatif (FN):** Gerçek değeri pozitif olan verinin tahmin değerinin yanlış sınıflandırma sonucu negatif olarak değerlendirildiği durumu ifade eder.

**Doğru Negatif (TN):** Gerçek değeri negatif olan verinin tahmin değerinin de negatif olduğu durumu ifade eder.

Çizelge 3.5’de belirtilen karmaşıklık matrisine göre modeli oluşturan toplam örnek sayısı Eşitlik 3.14’de verilen bağıntı ile belirlenmektedir:

$$N = TP + FP + FN + TN \quad (3.14)$$

Sınıflandırıcının test veri seti üzerinde hangi yüzde ile doğru tahmin yaptığının ölçütü doğruluk (accuracy)’tur. Karmaşıklık matrisi üzerinden sistemin doğruluk oranı Eşitlik 3.15’de verilen formülasyon ile hesaplanmaktadır.

$$\text{Doğruluk(Accuracy)} = \frac{TP+TN}{N} \times 100 \quad (3.15)$$

Doğruluk, sınıflandırıcının tahmin edebilme gücüdür ve değeri ne kadar büyük olursa o kadar güçlüdür.

Doğruluk, sınıflandırma sisteminin performansını değerlendirebilmek için tek başına yeterli bir kriter olamaz. Örneğin bir kanser hastalığının sınıflandırılmasında, gerçekte ‘kanser’ olan bir kişiye ‘sağlıklı’ teşhisi koymakla, gerçekte sağlıklı olan bir kişiye ‘kanser’ teşhisi koymak arasında aslında çok büyük bir fark vardır. Çünkü gerçekte kanser olan bir kişiye sağlıklı demek, geri dönüşü olmayan sonuçlar doğurabilmektedir. Bu sebeple, sınıflandırma işleminin performans sonuçları ROC eğrisi (Alıcı İşletim Karakteristiği) yardımıyla Duyarlılık ve Özgüllük arasındaki dengeyi değerlendirerek yapılmaktadır.

Sistemin negatif örneklerinin hangi oranda tahmin edildiğini ölçmek için özgüllük kullanılmaktadır. Sınıflandırıcının doğru negatif sayısının (TN), doğru negatif (TN) ve yanlış pozitif (FP) sayılarının toplamına oranıdır. Özgüllük, Eşitlik 3.16’da verilen formülasyon ile hesaplanmaktadır.

$$\text{Özgüllük(Specificity)} = \frac{TN}{TN+FP} \quad (3.16)$$

Sistemin pozitif örneklerinin hangi oranda tahmin edildiğini ölçmek için ise duyarlılık kullanılmaktadır. Sınıflandırıcının doğru pozitif sayısının (TP), doğru pozitif (TP) ve yanlış negatif (FN) sayılarının toplamına oranıdır. Duyarlılık, Eşitlik 3.17’de verilen formülasyon ile hesaplanmaktadır.

$$\text{Duyarlılık}(\text{Sensitivity}) = \frac{TP}{TP+FN} \quad (3.17)$$

İkiden fazla sınıftan oluşan sistemlerde ise özgüllük ve duyarlılığın yanında hassasiyet de hesaplanmaktadır.

Hassasiyet (Precision), sınıflandırıcının tahmin edilen pozitif değer o sınıfa ait tüm gözlemler içindeki oranını ölçmek amacıyla kullanılmaktadır. Eşitlik 3.18’de verilen formülasyon ile hesaplanmaktadır.

$$\text{Hassasiyet}(\text{Precision}) = \frac{TP}{TP+FP} \quad (3.18)$$

#### 4. ARAŞTIRMA BULGULARI VE TARTIŞMA

Fundus muayenesi veya retinal görüntü analizi sırasında göz hekimleri, olası hastalık lezyonlarını tanımlayabilmek ve bunlardan olası teşhisleri belirleyebilmek için öncelikle retina görüntüleri üzerindeki spesifik anatomik yapıları ararlar. Bu sebeple dijital fundus görüntülerinden DR lezyonlarının otomatik olarak teşhisini yapabilmek için de aynı mantıkla öncelikli olarak retina görüntüleri üzerindeki spesifik anatomik yapıların tespiti ve bölümlendirilmesi (segmentasyonu) yapılmalıdır [100].

Literatürde de retina üzerindeki spesifik anatomik yapıların tespitinin önemini vurgulayan birçok argüman mevcuttur. Bu şekilde, farklı anatomik yapıların tespit sonuçları, farklı retina hastalıklarının belirtilerini tespit etmek, hastalık seviyeleri hakkında bilgi sahibi olabilmek için birer referans noktası olarak kullanılmaktadır [101]–[106]. Örneğin OD'in tespiti, hipertansif/sklerotik retinopati için bazı önemli teşhis indekslerinin hesaplanması için bir önkoşuldur[105], [107]. Aynı şekilde lezyonların makula bölgesine yakınlığı, görme bozukluğu olasılığının yüksek olduğunu gösterir ve acil tıbbi yardım gerektirebilir [106]. Fovea ve makula bölgesinin tespiti de bu bağlamda önemlidir.

Öte yandan, anormal yapıların başarılı bir şekilde tespiti için, retina üzerindeki normal anatomik yapıları gizlemek çoğu zaman gereklidir [108]. Örneğin, OD sert veya yumuşak eksuda lezyonlarıyla kolayca karışabileceği için, tespiti olası lezyon setinden çıkarılması adına çok önemlidir [105]. Yine hemoraji gibi retinal kanamaların otomatik tespitinin yapılmasında fovea ve retinal kan damarları için de benzer bir görüş geçerlidir [109]. Çünkü fovea ve kan damarları da hemoraji gibi lezyonlarla kolayca karıştırılabilir.

##### 4.1. Optik Diskin Tespiti

OD tespitini etkin bir şekilde yapabilmek için öncelikle retina görüntüsü üzerinde yeşil kanal çıkartımı yapılmıştır. Yeşil kanal çıkartımının nedeni, yeşil kanalın, diğer

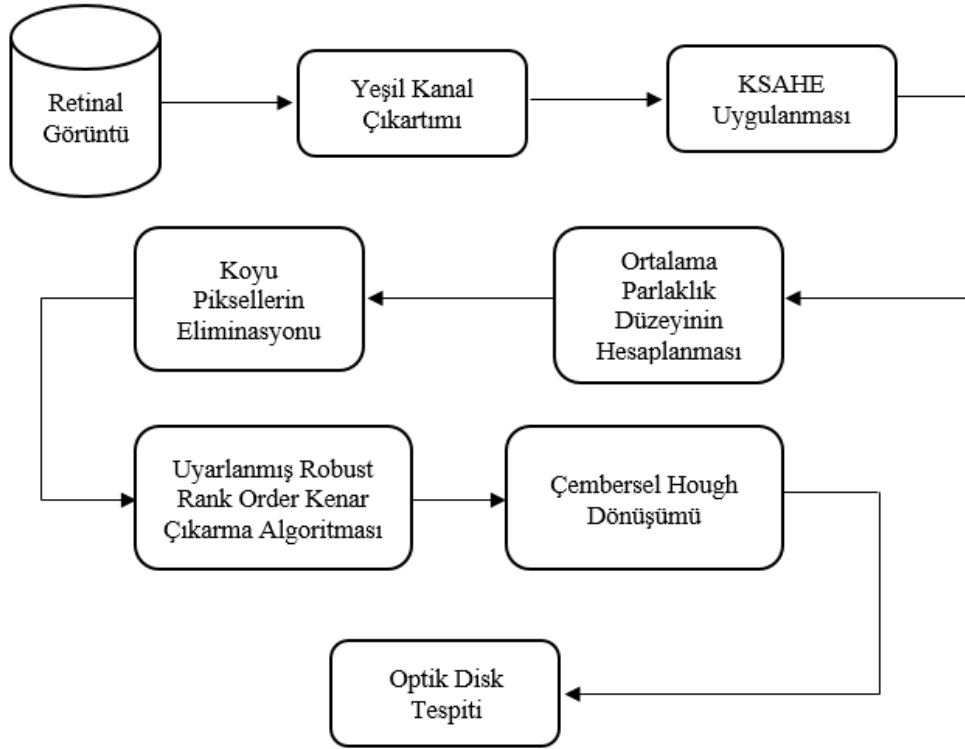
kanallara göre damarların daha koyu görünmesini ve arka plan ile anatomik yapıların arasındaki en iyi kontrast değerini içeren kanal olmasıdır [110].

Ardından Kontrast Sınırlamalı Adaptif Histogram Eşitlemesi(KSAHE) yöntemi ile resmin belirginliğinin artırılması sağlanmıştır. OD bölgesinin, retina resminin en parlak bölgesi olması kuralından yola çıkılarak [11], her bir resmin ortalama parlaklık düzeyi hesaplanarak, ortalama değerinin altında kalan pikseller resimden elimine edilmiştir. Burada standart bir eşik değeri belirlenmeyip, bunun her resim için dinamik olarak oluşturulmasının sebebi, her resmin ayrı parlaklık düzeyine sahip olmasıdır. Fundus kamerasının ayarlarından veya ortamın ışık derecesinden kaynaklı olarak bazı resimler parlak, bazı resimler ise daha karanlık çıkabilmektedir.

Daha sonra resme literatürdeki bu alanda hiç uygulanmamış olan, gürültülü resimlerde başarısı diğer geleneksel kenar belirleme algoritmalarından daha yüksek olduğu kanıtlanmış istatistiksel kenar belirleme yöntemlerinden Uyarlanmış Robust Rank-Order Test [111], [112] uygulanmıştır.

Son olarak ise kenarları tespit edilen resme, Çembersel Hough Dönüşümü (ÇHD) uygulanmış ve OD bölgesi tespit edilebilmiştir. OD'in çemberimsi bir yapıya sahip olması ve ortalama çözünürlüğe sahip her bir retina görüntüsü için OD çapının 80-100 piksel kadar olması [113] ÇHD uygulanmasını kolaylaştırmaktadır.

Şekil 4.1'de OD tespiti aşamaları görülmektedir.




Şekil 4.1 OD Tespiti Aşamaları

#### 4.1.1. Resim Önleme Adımları

Önleme adımı resmin belirginliğinin artırılması ve daha kolay bir OD tespiti için hayati bir öneme sahiptir.

##### 4.1.1.1. Yeşil Kanal Çıkartımı

Renkli bir retinal fundus görüntüsü, kırmızı, yeşil ve mavi (RGB) renk kanallarının birleşiminden oluşur. Bu kanallar arasında yeşil kanal, en yüksek kontrast değerlerini vererek, görüntünün önündeki OD ve kan damarlarını görüntünün arka planından ayırmada daha başarılı olur [114], [115]. Bu sebeple retinal görüntülerin ön işleme aşaması, yeşil kanal çıkartımı ile başlatılmıştır. Farklı retinal görüntülerin yeşil kanal çıkartımı sonuçları Şekil 4.2'de görülmektedir [116].



Şekil 4.2 Farklı Retinal Görüntüler ve Yeşil Kanal Çıkartımı Sonuçları

#### 4.1.1.2. Kontrast Sınırlamalı Adaptif Histogram Eşitleme


Görüntü kalitesinin iyileştirilmesinde sıkça kullanılan Kontrast Sınırlamalı Adaptif Histogram Eşitlemesinin (KSAHE) temeli Histogram Eşitlemeye dayanmaktadır. Histogram eşitleme yönteminde bütün görüntü histogramı ile yoğunluk dinamik aralığı genişletilerek resmin kalitesi iyileştirilebilmektedir. Histogram eşitlemede resmin yoğunluk dağılımı normalize edilerek düzgün yoğunluk dağılımına sahip bir sonuç görüntüsü elde edilir ve bu şekilde iyileştirme işlemi gerçekleştirilir.



Adaptif Histogram Eşitleme de değiştirilmiş bir histogram eşitleme işlemidir. Burada, resim ızgara şeklinde dikdörtgen alanlara bölünür ve her bir alana standart histogram eşitleme işlemi uygulanır. Resim alt alanlara ayrılıp her bir alana histogram eşitleme işlemi uygulandıktan sonra alt alanlar bi-lineer enterpolasyon yöntemiyle birleştirilerek iyileştirilmiş bütün bir resim elde edilir. Fakat adaptif histogram eşitleme işleminde gürültü problemi ortaya çıkmıştır. Bunun önüne geçebilmek için homojen bölgelerde kontrast iyileştirmenin sınırlandırılması gerekir, bu amaçla da kontrast sınırlı adaptif histogram eşitleme yöntemi geliştirilmiştir. KSAHE yönteminde pikseller, dört en yakın komşuları kullanılarak haritalanmaktadır. Bi-lineer enterpolasyon ile alt alanlar birleştirilirken, alt alanlar komşuluklarına göre gruplara ayrılırlar. KSAHE yöntemi, görüntünün yaklaşık olarak eşit boyutlarda ve birbiriyle çakışmayan birkaç alana bölünmesine dayanarak formüle edilmektedir.

KSAHE yöntemi, medikal görüntülerde genellikle iyi sonuçlar vermiştir [117]–[119].

Şekil 4.3’de DRIVE veri tabanından alınan sağlıklı bir fundus resminin ve DIARETDB0 veri tabanından alınan hastalıklı bir fundus resminin KSAHE yöntemi ile belirginliğinin artırılması görülmektedir.



Şekil 4.3 (a) DRIVE veri tabanından alınan orijinal sağlıklı retina görüntüsü (b) (a) Görüntüsüne KSAHE uygulanmış görüntü (c) DIARETDB0 veri tabanından alınan orijinal hastalıklı retina görüntüsü (d) (c) Görüntüsüne KSAHE uygulanmış görüntü

#### 4.1.2. Resmin Ortalama Parlaklık Düzeyinin Hesaplanması

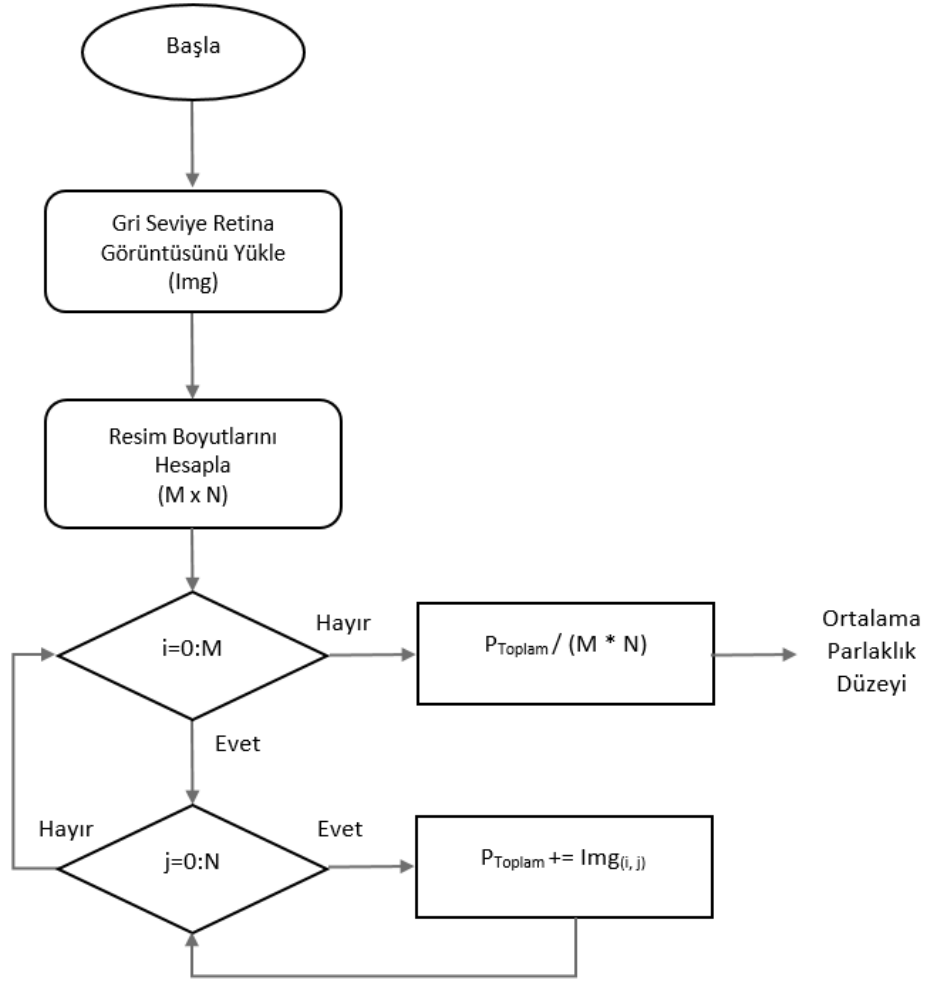
OD bölgesi retina resmi üzerindeki en parlak bölgedir ve retina resmi üzerinde OD'i koyu bölgeler üzerinde aramak zaman kaybıdır. Bu sebeple hesaplama zamanını düşürmek amacıyla resmin ortalama parlaklık düzeyi hesaplanmış, bu değer bir eşik değer olarak kabul edilmiş ve bu değerinin altında kalan, bir diğer anlamıyla daha koyu

pikseller resimden elimine edilmiştir. Her bir resmin parlaklık düzeyleri birbirinden farklı olduğu için de hesaplanan değer her resim için farklı olmuş ve her bir resimde elimine edilen piksel yoğunlukları da farklılık göstermiştir.

Ortalama parlaklık düzeyinin hesaplaması Eşitlik 4.1’de verilmiştir:

$$\text{Ortalama Parlaklık Düzeyi} = \frac{1}{M \times N} \sum_{i=0}^M \sum_{j=0}^N \text{Img}(i, j) \quad (4.1)$$

M ve N, sırasıyla retinal bir görüntünün satır ve sütun sayısını piksel cinsinden temsil etmektedir. Ortalama parlaklık değerini hesaplamak için, tüm piksellerin 0 ile 255 arasında olası bir değer aralığı olan gri tonlu renk değerleri eklenir ve görüntüdeki toplam piksel sayısına ( $M \times N$ ) bölünür. Bu hesaplama için bir blok diyagramı Şekil 4.4’te verilmiştir.




Şekil 4.4 Ortalama Parlaklık Düzeyinin Hesaplanması Blok Diyagramı

Belirlenen eşik değerin altında kalan piksellerin retina resminden elimine edilmesi Eşitlik 4.2’de verilmiştir:

$$Img(i, j) = \begin{cases} 255, & \text{Eğer } Img(i, j) < \text{Ortalama Parlaklık Düzeyi} \\ Img(i, j), & \text{Diğer Durumlarda} \end{cases} \quad (4.2)$$

Eşik değerin altında kalan piksellerin retina resminden elimine edilmesiyle ortaya çıkan görüntüler, Şekil 4.5’te verilmiştir.



Şekil 4.5 Belirlenen eşik değerin üzerinde kalan piksellerden oluşan görüntüler. **(a)** Sağlıklı retinal görüntü; **(b)** Hastalıklı Retinal Görüntü

#### 4.1.3. İstatistik Tabanlı Kenar Belirleme Algoritmasının Uygulanması

Uyarlanmış Robust Rank- Order (RRO) Test tabanlı bir kenar belirleyebilmek için öncelikle her bir piksel değeri için  $k \times k$  biçiminde bir maske boyutu belirlenmesi gerekmektedir. Her bir pikselin kenar olup olmadığı değerlendirileceği için, bu piksellerin maskenin orta kısmında yer alması gerekir. Bunun için  $k = \{3, 5, 7, 9, \dots, 2n - 1\}$  küme setinden, yani tek sayılardan seçilmelidir.  $k$  sayısı ne kadar artarsa hesaplama maliyeti de artarken, çok küçük bir değer alındığında da gürültülere karşı hassasiyeti bir o kadar artmaktadır. Uygulama esnasında en optimum değer olarak  $k = 5$  belirlenmiştir.

$k$  seçimi ile maske boyutunun belirlenmesi aşamasından sonra maskenin merkezinde bulunan piksel değerinin dışında kalan pikseller  $N = m + n$  olarak ifade edilir. Maske elemanlarının kümesi sürekli dağılım gösteren iki eş parçaya bölünür. Bu eş parçalar  $X = (X_1, X_2, X_3, \dots, X_M)$  ve  $Y = (Y_1, Y_2, Y_3, \dots, Y_M)$ 'dir. Kullanılacak modelde;

$$A_i = \begin{cases} X_i, & X_i \in X \\ Y_i, & Y_i \in Y \end{cases} \quad (4.3)$$

Sıfır hipotez ve karşı hipotez 4.4 ve 4.5 numaralı eşitliklerde belirtilmiştir:


$$H_0^{\uparrow}: X \geq Y \quad (4.4)$$

$$H_1^{\uparrow}: X < Y \quad (4.5)$$

‘Sıfır Hipotez’ terimini ortaya çıkaran ve kullanan kişi, istatistikçi ve genetikçi Fisher’dır ve ilk olarak 1937 yılında ortaya atılmıştır [120].

Önerilen çalışmada Wilcoxon Test’e alternatif olarak Rank-order tabanlı bir istatistiksel test kullanılmıştır. Şekil 4.6’da sekiz ayrı kenar senaryosu görülmektedir. Şekillerin beyaz pikselleri X bölgesini, mavi pikselleri ise maskedeki Y bölgesini temsil etmektedir. Uygulanacak olan yöntem her bir senaryo için ayrı ayrı uygulanacak ve bu senaryolardan biri kenar olarak algılanma kistasına uyarsa, değerlendirilen o piksel için ‘kenardır’ sonucuna varılacaktır.

Bu aşamadan sonra yöntemin aşamaları Şekil 4.6 üzerindeki (a) senaryosu üzerinden anlatılmış olup, (h) senaryosu dahil diğer tüm senaryolar için de aynı işlemler uygulanmaktadır.



Şekil 4.6 Beyaz piksellerin X bölgesini temsil ettiği ve mavi piksellerin maskedeki Y bölgesini temsil ettiği sekiz farklı kenar senaryosu.

Sıfır hipotez ve karşı hipotez testi için Eşitlik 4.3’de verilen  $A_i$  ifadesi şu şekilde elde edilebilir:

Her bir  $X_i, X_i \in X$  için,  $Y_i$  kümesinde gri seviye yoğunluk değerlerine göre daha düşük pikseller bulunup, her birinin hesaplanan  $X_i$  değeriyle farkları toplanır ve bu değer  $X_i$ ’nin değerini göstermektedir.  $U(Y, X_i)$  şeklinde gösterilir. Bu işlem adımı her bir  $X_i$  değeri için hesaplanır ve tüm  $U(Y, X_i)$  değerlerinin ortalaması  $U(Y, X)$  olarak ifade edilir. Bu işlemin matematiksel ifadesi Eşitlik 4.6’da gösterilmektedir.

$$U(Y, X) = \sum_{i=1}^m U(Y, X_i)/m \quad (4.6)$$

Benzer şekilde her bir  $Y_i, Y_i \in Y$  için,  $X$  kümesindeki gri seviye yoğunluk değerlerine göre daha düşük pikseller bulunup, her birinin hesaplanan  $Y_i$  değeriyle farkları toplanır ve bu değer  $Y_i$ ’nin değerini göstermektedir.  $U(X, Y_i)$  şeklinde gösterilir. Bu işlem adımı her bir  $Y_i$  değeri için hesaplanır ve tüm  $U(X, Y_i)$  değerlerinin ortalaması  $U(X, Y)$  olarak ifade edilir. Bu işlemin matematiksel ifadesi Eşitlik 4.7’de gösterilmektedir.

$$U(X, Y) = \sum_{i=1}^m U(X, Y_i)/n \quad (4.7)$$

Bir sonraki aşamada ise  $U(Y, X_i)$  ve  $U(X, Y_i)$  için  $V_X$  ve  $V_Y$  ile ifade edilen değişkenlik indeksi hesaplanmaktadır. Değişkenlik indeksi hesaplamaları Eşitlik 4.8 ve Eşitlik 4.9’da gösterilmiştir.

$$V_X = \sum_{i=1}^m [U(Y, X_i) - U(Y, X)]^2 \quad (4.8)$$

$$V_Y = \sum_{i=1}^m [U(X, Y_i) - U(X, Y)]^2 \quad (4.9)$$

Hesaplanan tüm veriler kullanılarak  $U_A$  olarak ifade edilen test istatistiği Eşitlik 4.10’da gösterildiği şekilde hesaplanmaktadır.


$$U_A = \left| \frac{m \cdot U(Y, X) - n \cdot U(X, Y)}{2\sqrt{V_X + V_Y + U(Y, X) \cdot U(X, Y)}} \right| \quad (4.10)$$

$$U_{selected} = \max(U_A i) \quad i \leq 0 \quad (4.11)$$

$U_A$  değeri Şekil 4.6’da tanımlı olan çerçeveler için sekiz kez hesaplanır. Elde edilen sekiz adet  $U_A$  değerinden en büyüğü bulunur. En büyük  $U_A$  değeri daha önceden belirlenen eşik değerden küçük çıkarsa  $H_0^{\wedge}$  hipotezi reddedilir, eğer en büyük  $U_A$  değeri eşik değerden büyük veya eşik değere eşitse hipotez kabul edilir ve değerlendirmesi yapılan piksel değerinin kenar olduğuna karar verilir. Deneysel çalışmalar neticesinde gürültülü resimlerde eşik değer olarak 3,5 değeri alındığında başarılı sonuçlar elde edildiği görülmüştür [111]. Bu sebeple bu çalışmada da eşik değer 3,5 olarak belirlenmiştir.

Uyarlanmış Robust Rank- Order Test Tabanlı Kenar Belirleme Algoritmasının uygulanmasının sonucu, Şekil 4.7’de gösterilmiştir.





(a)

(b)

Şekil 4.7 Uyarlanmış Robust Rank- Order Test Tabanlı Kenar Belirleme Algoritmasının uygulanması (a) Sağlıklı Retinal Görüntü; (b) Hastalıklı Retinal Görüntü


#### 4.1.4. Çembersel Hough Dönüşümü

Retina görüntülerinden OD merkezi ÇHD ile tespit edilmektedir. Hough dönüşümü birçok defa modifiye edilmiş ve en son ÇHD Duda ve arkadaşları tarafından sunulmuştur [121]. Hough dönüşümü temelde kenarların olası geometrik şekilleri oylaması mantığı ile çalışmaktadır [122]. Hough Dönüşüm, kartezyen uzayında bir noktanın, ilgilenilen nesnenin şekline göre tanımlanan parametre uzayına dönüşümü olarak tanımlanabilir. Dairesel formlar söz konusu olduğunda, Eşitlik 4.12’de sunulan daire denklemi dönüşüm için dikkate alınmaktadır:

$$r^2 = (x - a)^2 + (y - b)^2 \quad (4.12)$$

Burada r yarıçapı, a ve b ise sırasıyla daire merkezi ve apsisi temsil etmektedir [123].

Kenar algılama yöntemi sonrası retina görüntüsüne uygulanan ÇHD sonucu Şekil 4.8’de verilmiştir.



(a)



(b)

Şekil 4.8 Çembersel Hough Dönüşümü uygulanmış retina görüntüsü (a) Sağlıklı Retina Görüntüsü; (b) Hastalıklı Retina Görüntüsü

#### 4.1.5. Optik Diskin Tespiti Sonuçları

OD tespiti için önerilen bu yöntem DRIVE, DIARETDB0 ve DIARETDB1 veri tabanları üzerinde değerlendirilmiştir. Bu veri tabanlarına ait detaylı özellikler Çizelge 4.1’de verilmiştir.

Çizelge 4.1 OD Tespitinde Kullanılan Veri Tabanları ve Özellikleri

Veri Tabanı	Sağlıklı Görüntü	Hastalıklı Görüntü	Toplam
DRIVE	33	7	40
DIARETDB0	20	110	130
DIARETDB1	5	84	89

Geliştirilen yöntem için tüm deney ve gözlemler aşağıda özellikleri verilen bilgisayar ve programlar ile gerçekleştirilmiştir:

- İşletim Sistemi: Windows 10, 64-bit
- İşlemci: Intel(R) Core(TM) i5-2430 CPU @2.40 GHz
- Memory: 8.00 GB RAM
- Software Language: MATLAB R2016a

Önerilen algoritmada otomatik olarak tespit edilen OD merkezi performansı, tüm resimler için manuel olarak tespit edilen OD merkezi ile kıyaslanarak değerlendirilmiştir. Hoover ve Goldbaum’un 2003 yılında önerdikleri yaklaşıma göre [124], otomatik olarak tespit edilen OD merkezi, manuel olarak tespit edilen OD merkezi arasında 60 piksele kadar olan mesafe, kabul edilebilir bir uzunluktur. OD tespiti için önerilen yöntem, algoritmanın doğruluk yüzdesi ve ortalama mutlak mesafe bakımından ölçülmüş ve değerlendirilmiştir. Doğruluk, her bir veri tabanı için ayrı ayrı hesaplanmıştır. Ortalama mutlak mesafe ise otomatik olarak tespit edilen ve elle tespit edilen OD merkezleri arasındaki piksel cinsinden farkı ifade etmektedir. Doğruluk değeri ve ortalama mutlak mesafe aşağıdaki eşitliklerle hesaplanmaktadır:

$$\text{Doğruluk Değeri} = \frac{C_0}{N_0} \quad (4.13)$$

$$\text{Ortalama Mutlak Mesafe} = \frac{1}{N_0} \sum_{i=1}^{N_0} \frac{(|M_{ci}(x) - A_{ci}(x)|) + (|M_{ci}(y) - A_{ci}(y)|)}{2} \quad (4.14)$$

Burada  $N_0$  veri tabanının sahip olduğu toplam görüntü sayısını,  $C_0$  ise bu görüntülerden kaç tanesinin OD merkezinin doğru tespit edildiğini ifade eder. Ortalama Mutlak Mesafe, manuel olarak hesaplanan OD merkezleri ve otomatik olarak tespit edilen OD merkezleri arasındaki ortalama mesafedir.  $M_c(x, y)$  ve  $A_c(x, y)$  sırasıyla manuel ve otomatik olarak hesaplanan OD merkez noktalarıdır [18].

Önerilen yöntemin doğrulukları DRIVE, DIARETDB0 ve DIARETDB1 veri tabanları için sırasıyla %100, %96,92 ve %98,88 olarak elde edilmiş ve Çizelge 4.2’de detaylandırılmıştır. Ortalama mutlak mesafe değeri ise DRIVE veri tabanı için yaklaşık 10 piksel, DIARETDB0 için yaklaşık 10 piksel ve DIARETDB1 veri tabanı için ise yaklaşık 12 piksel olarak hesaplanmıştır. Bu değerler de yine Çizelge 4.2’de verilmiştir.

Çizelge 4.2 OD Tespiti İçin Önerilen Yöntemin Doğruluk ve Ortalama Mutlak Mesafe Bilgileri

Veri Tabanı	Görüntü Sayısı	Doğru Sınıflandırma	Doğruluk Değeri (%)	Ortalama Mutlak Mesafe
DRIVE	40	40	100	10,07
DIARETDB0	130	126	96,92	10,54
DIARETDB1	89	88	98,88	12,36
Ortalama	259	254	98,07	11,09

Önerilen yöntemin OD tespit sonuçları ve literatürdeki benzer çalışmaların sonuçlarının karşılaştırmalı analizi Çizelge 4.3’te verilmiştir.

Çizelge 4.3 OD Tespit Sonuçlarının Literatürdeki Benzer Çalışmaların Sonuçları ile Karşılaştırmalı Analizi

Yapılan Çalışma	Veri Tabanı	Görüntü Sayısı	Doğruluk Değeri (%)	Ortalama Mutlak Mesafe
Pereira v.d. [5]	DRIVE	40	100	-
	DIARETDB1	89	93,25	-
Ahmed & Amin [125]	DRIVE	40	97,5	-
	DIARETDB1	89	96,5	-
Youssif v.d. [126]	DRIVE	40	100	17
Rangayyan v.d. [127]	DRIVE	40	100	23,2
Dehghani v.d. [128]	DRIVE	40	100	15,9

Zhu v.d. [15]	DRIVE	40	90	18
Bharkad [18]	DRIVE	40	100	9,12
	DIARETDB0	130	96,92	11,83
	DIARETDB1	89	98,88	13,00
Mahfouz and Fahmy [101]	DRIVE	40	100	-
	DIARETDB0	130	98,5	-
	DIARETDB1	89	97,8	-
Sinha and Babu [129]	DRIVE	40	95	-
	DIARETDB0	130	96,9	-

	DIARETDB1	89	100	-
Önerilen Yöntem [86]	<b>DRIVE</b>	<b>40</b>	<b>100</b>	<b>10,07</b>
	<b>DIARETDB0</b>	<b>130</b>	<b>96,92</b>	<b>10,54</b>
	<b>DIARETDB1</b>	<b>89</b>	<b>98,88</b>	<b>12,36</b>

Bu çalışmada geliştirilen yöntem, literatürdeki dokuz çalışma ile karşılaştırılmış ve sonuçlar Çizelge 4.3'te gösterilmiştir.

DRIVE veri seti için, 3 çalışma haricindeki diğer tüm çalışmalarda OD'yi doğru olarak tespit etme oranının %100 olduğu görülmektedir. Ahmed ve Amin [125] yalnızca 1 resmi doğru tespit edememiş, Zhu ve arkadaşları [15] ise 4 resmin tespitinde başarısız olmuşlardır. DRIVE veri seti üzerindeki resimlerin tamamını tespit edemeyen diğer çalışma ise Sinha ve Babu'nun [129] çalışmalarıdır. Çalışmada 2 resim tespit edilememiştir. Önerilen çalışmada [86] ise DRIVE veri setinde bulunan tüm resimlerin OD bölgeleri doğru bir şekilde tespit edilebilmiştir.

DIARETDB0 veri seti için, Bharkad [18]'in yapmış olduğu çalışmada OD bölgesi %96.92 oranında tespit edilebilmiştir. Mahfouz ve Fahmy [101] aynı veri setinde %98,5 oranına ulaşmışlardır. Sinha ve Babu [129] ise %96,9'luk bir oranda OD tespiti yapabilmişlerdir. Önerilen yaklaşımda [86] ise 130 görüntüden 126 tanesinin OD bölgeleri doğru bir şekilde tespit edilebilmiştir.

DIARETDB1 veri seti için ise, Sinha ve Babu [129] tüm resimlerde OD lokalizasyonunu doğru bir şekilde yapmışlar, Sinha ve Babu'yu da önerilen yöntemle birlikte Bharkad'ın [18] yapmış olduğu çalışma %98,88'lik bir başarı oranıyla izlemiştir. Önerilen çalışmada yalnızca bir resim doğru tespit edilememiş, geri kalan 88 adet resim başarılı bir şekilde tespit edilebilmiştir. Ortalama mutlak mesafe, literatürde önerilen diğer çalışmalarda Bharkad'ın [18] yapmış olduğu çalışma haricinde sadece DRIVE veri seti için hesaplanmıştır. Önerilen çalışmada [86] hesaplanan ortalama mutlak mesafe değerleri, DRIVE, DIARETDB0 ve DIARETDB1 veri seti için sırasıyla 10,07, 10,54 ve 12,36 olarak hesaplanmıştır. Bu haliyle DIARETDB0 ve DIARETDB1 veri seti için literatürdeki tartışılan diğer çalışmalardan çok daha üstün olduğu görülmüştür. DRIVE veri seti için ise Bharkad'ın [18] önermiş olduğu yöntemde hesaplanan ortalama mutlak mesafe değerinin hemen ardından ikinci sırada yer almıştır.

Önerilen yöntemin, retinal görüntülerden OD tespitini tüm lezyon ve hastalıklara rağmen etkili ve başarılı bir şekilde yapabildiği görülmüştür.



OD tespitinin başarısız olduğu resimler incelendiğinde, OD bölgesinin diğer bölgelere göre belirgin bir şekilde parlak olmadığı ve önerilen yöntemin de OD bölgesinin resmin en parlak bölgesi olması hipotezinden yola çıkıldığı ve algoritmanın buna göre dizayn edilmesinden kaynaklandığı görülmüştür.

## 4.2. Retina Kan Damarlarının Tespiti

Retinal görüntüden kan damarlarının segmentasyonu için Bölüm 4.1.1’de belirtilen ön işleme adımlarından Yeşil Kanal Çıkartımı sonucu elde edilen görüntülere, 2 boyutlu Gabor Filtresi uygulanmış ve damarların daha belirgin hale gelmesi sağlanmıştır. Ardından retinal bölgenin dışında retina bölgesine ait olmayan koyu renkli bölgeleri resimden elimine etmek ve aktif retina bölgesinin seçimi için bir maske oluşturulmuştur. Daha sonra ise Bölüm 4.1.2’de verildiği şekilde her bir resim için hesaplanan ortalama parlaklık düzeyine göre resimler siyah-beyaz hale getirilmiş ve son olarak ise kesik pikselleri birleştirebilmek ve küçük bölgeleri görüntüden kaldırabilmek için morfolojik işlemler uygulanarak retinal kan damarları çıkartılmıştır.

### 4.2.1. 2 Boyutlu Gabor Filtresi

2 boyutlu Gabor Filtresi, kenar tespiti ve doku özellikleri çıkarmak amacıyla görüntü işleme ve bilgisayarlı görme alanlarında sıkça kullanılan lineer bir filtredir. Filtrenin genel denklemi Eşitlik 4.15’de gösterilmiştir. Kan damarlarının daha belirgin bir hale gelmesi için gabor dalgacığı, değişik açı ve dalga boyuna ayarlanabilmektedir.


$$g(x, y; \lambda, \theta, \psi, \sigma, \gamma) = \exp\left(\frac{-x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\lambda} + \psi\right) \quad 4.15$$

$$x' = x \cdot \cos(\theta) + y \cdot \sin(\theta) \quad 4.16$$

$$y' = -x \cdot \sin(\theta) + y \cdot \cos(\theta) \quad 4.17$$


Gabor filtresi birkaç parametreye bağlıdır. Bunlardan  $\theta$  parametresi filtrenin açısını göstermektedir.  $\lambda$ , sinüzoidal fonksiyonun dalga boyunu temsil eder. Diğer bir ifadeyle hedef örüntünün dalga boyunu vermektedir. Denklemdaki  $\psi$  ise faz kaymasını,  $\gamma$  gabor çekirdeğinin en-boy oranını vermektedir.  $\sigma$  ise aranan örüntünün ölçeğini temsil etmektedir [130],[131].

Şekil 4.9’da retinal görüntüden damar segmentasyonu aşamaları gösterilmiştir.



Şekil 4.9 Retinal Görüntüden Damar Tespiti Süreci (a) DRIVE'dan alınan sağlıklı retina görüntüsü (b) (a) Görüntüsünden elde edilen sonuç görüntü (c) DIARETDB0'dan alınan hastalıklı retina görüntüsü (d) (c) Görüntüsünden elde edilen sonuç görüntü

Yine sağlıklı ve hastalıklı retina görüntüsünden elde edilen maske görüntüleri ise Şekil 4.10'da gösterilmiştir.



Şekil 4.10 Retinal Görüntülerden Maske Oluşturma Süreci; **(a)** DRIVE'dan alınan sağlıklı retina görüntüsü **(b)** (a) Görüntüsünden elde edilen sonuç görüntü **(c)** DIARETDB0'dan alınan hastalıklı retina görüntüsü **(d)** (c) Görüntüsünden elde edilen sonuç görüntü

### 4.3. Makula ve Fovea Bölgesinin Tespiti

Retinal görüntülerin merkezine yakın bir bölgede olan makula, koyu renklidir ve içerisinde birçok kılcal damar bulunmaktadır. Fovea ise makula bölgesinin en koyu

kısımıdır [132]. DR sonucu oluşan mikroanevrizma ve hemoraji gibi lezyonlarla karışmaması için bu bölgenin tespit edilerek, DR lezyonlarının aranacağı resimden elimine edilmesi gerekmektedir.


Sinthanayothin ve arkadaşlarının yapmış olduğu çalışmaya göre foveanın, OD'in merkezinden uzaklığı yaklaşık olarak 2,5 OD çapı uzaklıktadır [132]. Benzer bir çalışmada da makula bölgesinin, OD'ten yaklaşık 2 OD çapı uzaklıkta konumlandığı belirtilmiştir [14].

Bu bağlamda, fovea bölgesinin tespiti için, OD merkezinden, OD çapının 2,5 katı kadar sağa veya sola bakılması gerekir. Görüntü sağ gözü içeriyorsa sola, sol gözü içeriyorsa OD merkezinden itibaren sağa doğru gidilmesi gerekir. Bunu otomatize edebilmek için ise görüntünün merkez koordinatları kullanılmıştır. OD merkez noktasından 2,5 kat sağa gidildiğindeki noktanın resmin merkezine uzaklığının, 2,5 kat sola gidildiğindeki noktanın resmin merkezine uzaklığından küçük olması durumunda retinanın görüntüsünün sol göze, tam tersi durumda da sağ göze ait olma prensibine göre hareket edilmiştir. Resmin arka planından farklı ışık seviyesindeki nesnelere ayırtmada kullanılan morfolojik işlemlerden Top-Hat Dönüşümü kullanılmıştır. İki noktanın birbirine uzaklığını ölçmek için ise Öklid uzaklığı denklemi kullanılmıştır ve Eşitlik 4.18'de gösterilmiştir.

$$d(x, y) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad 4.18$$

Burada  $x_1$  ve  $y_1$  resmin merkezinin x ve y koordinatlarını,  $x_2$  ve  $y_2$  ise OD merkezinin x ve y koordinatlarını temsil etmektedir.

Bu teknik bilgiler ışığında, retina fundus resmi içerisindeki aktif bölge üzerindeki en koyu alan, Şekil 4.11'de gösterilmiştir.



Şekil 4.11 Makula bölgesinin tespiti

#### 4.4. Mikroanevrizma Lezyonlarının Sınıflandırılması

Başarılı bir sınıflandırma, resmin iyi bir analizini gerektirir. MA lezyonları, DR'nin en erken görünen işaretidir. Bu sebeple, MA'ların erken teşhisi, DR'nin önlenmesi sürecindeki ilk adımdır. Gözün arka kısmında yuvarlak, kırmızı noktalar şeklinde görünen MA'ları sınıflandırmanın ilk aşaması, retina görüntüsünün, görüntü işleme algoritmaları yardımıyla, retinal kan damarları ve makula bölgesinden elimine edilmiş kısmını alarak, öznitelik çıkarımı için kullanılacak fonksiyona giriş parametresi olarak vermektir. Bunun sebebi, sınıflandırıcının yapacağı hatalı tespitlerin mümkün olduğunca önüne geçmektir. Çünkü bir retina görüntüsünde, kan damarları ve makula MA ve hemoraji lezyonlarıyla karışabileceği gibi, aynı şekilde sert ve yumuşak eksuda lezyonları da OD ile karışabilmektedir. Dolayısıyla eksuda tespiti yapılacağı zaman da retina görüntüsünden OD alanının elimine edilmesi gerekmektedir. Bu şekilde lezyonlu görüntüler daha iyi temsil edilerek sınıflandırma başarısını artırır.

Sınıflandırmanın ikinci aşamasında ise, giriş parametresi olarak verilen görüntülerden öznitelikler çıkartılarak bir öznitelik vektörü oluşturulmuştur. Öznitelik çıkartımı için literatürde en sık kullanılan özniteliklerden Şekil Öznitelikleri (Shape Features)

kullanılmıştır. Bu özniteliklerin çıkartılmasında Matlab'ın regionprops() fonksiyonundan yararlanılmıştır.

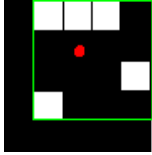

#### 4.4.1. Hesaplanan Şekil Öznitelikleri

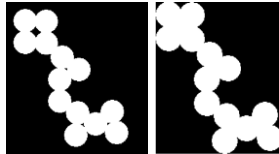
Bir resmin çeşitli boyut, şekil ve pozisyonu ile ilgili bilgiler veren öznitelikleridir. Resmin alanı, ağırlık merkezi, eni, boyu, dolu alanı, kapsamı, yuvarlaklığı gibi bilgileri verir.

regionprops() fonksiyonundan alınan skaler değerli şekil öznitelikleri ve açıklamaları Çizelge 4.4'te listelenmiştir [133].

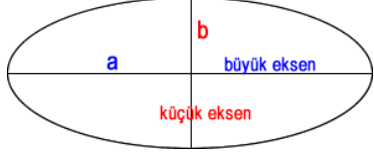
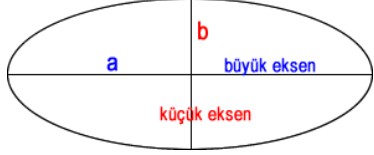

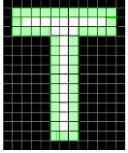


Çizelge 4.4 Mikroanevrizma Lezyonlarını Sınıflandırmak İçin Kullanılan Şekil Özellikleri ve Açıklamaları

Öznitelik	Açıklama	Formül/ Tanımlayıcı Şekil
Alan (Area)	İlgili bölgenin toplam piksel sayısı	$A = \sum_{i=0}^M \sum_{j=0}^N Img(i, j)$ <p>(Siyah-beyaz resimdeki toplam piksel sayısı)</p>
Sınırlayıcı Çerçeve (Bounding Box)	İlgili bölgeyi çevreleyen en küçük dikdörtgen	İki boyutlu durum için, ilk 2 öge sınırlayıcı kutunun sol üst köşesinin koordinatlarına karşılık gelirken, son iki giriş kutunun genişliği ve yüksekliğidir.
Ağırlık Merkezi (Centroid)	İlgili bölgedeki piksellerin ortalama konumu. Bölgenin kütle merkezidir.	
Dışbükey Alan (Convex Area)	Dışbükey Görüntü içerisindeki toplam piksel sayısı	

Dairesellik (Circularity)	Nesnelerin yuvarlaklığını belirleyen dairesellik. Nesnelerin ne kadar yuvarlağa benzediğini ölçen bir birimdir.	$C = 4\pi \frac{\text{Alan}}{\text{Çevre}^2}$
Dış Merkezlilik (Eccentricity)	Bir bölgenin çemberden ne kadar farklı olduğunu belirler. 0 ve 1 aralığında değer alır.	$E = \sqrt{\frac{a^2 - b^2}{a^2}}$ (a ve b, elips bir şeklin uzun ve kısa ekseninin yarıçapları)
Eşdeğer Çap (EquivDiameter)	Bölgeyle aynı alana sahip olan bir dairenin çapı	$ED = \sqrt{\frac{4x\text{Alan}}{\pi}}$
Euler Sayısı (EulerNumber)	Bölgedeki nesne sayısından bu nesnelerdeki boşluk sayısının farkı	
Kapsam (Extent)	Bölgedeki piksellerin toplam sınır çerçevesi (bounding box) piksellerine oranı	$Ex = \frac{\text{Alan}}{\text{Sınırlayıcı Çerçeve}}$
Dolu Alan (FilledArea)	Nesnenin içerisindeki tüm boşluklarla beraber piksel sayısı.	



Büyük Eksen Uzunluğu (MajorAxisLength)	En büyük eksenin, piksel cinsinden uzunluğu	 $Major = 2xa$
Küçük Eksen Uzunluğu (MinorAxisLength)	En küçük eksenin, piksel cinsinden uzunluğu	 $Minor = 2xb$
Yönelme (Orientation)	En büyük eksenle yatay noktaların yaptığı açı. Değer -90 ila 90 arasında değişen derece cinsindedir.	
Çevre (Perimeter)	Bölgenin sınırları etrafındaki mesafe (piksel sayısı)	
Sağlamlık (Solidity)	Toplam alanın, dışbükey alana oranı	$S = \frac{Alan}{Dışbükey Alan}$

#### 4.4.2. Mikroanevrizma Lezyonlarının Sınıflandırma Sonuçları

MA lezyonlarını sınıflandırmak için veri seti olarak DIARETDB0 ve DIARETDB1 kullanılmıştır. Bu iki veri setinin toplamından 219 adet görüntü içeren bir veri seti elde edilmiş ve bu veri seti üzerinde sınıflandırma algoritmaları çalıştırılmıştır.

Veri setlerine ait detaylı özellikler Çizelge 4.5’te verilmiştir.

Çizelge 4.5 Mikroanevrizma Tespiti İçin Kullanılan Veri Setleri ve Özellikleri

Veri Seti	Lezyonlu Görüntü	Lezyonsuz Görüntü	Toplam
<b>DIARETDB0</b>	110	20	130
<b>DIARETDB1</b>	84	5	89
<b>TOPLAM</b>	194	25	219

Birinci veri setinde 110 adet lezyonlu görüntü varken, ikinci veri setinde ise 84 adet lezyonlu görüntü bulunmaktadır. İki veri setinde toplamda 25 adet görüntüde herhangi bir MA lezyonuna rastlanmamıştır.

219 adet retinal görüntünün her birinden sınıflandırıcıların eğitilebilmesi için 15 tane şekil özniteliği çıkartılmıştır. Retinal görüntülerin her biri eğitim seti için ‘Lezyon Var’ ve ‘Lezyon Yok’ olarak etiketlenmiştir. ‘Lezyon Var’ için 1, ‘Lezyon Yok’ etiketi için ise 0 değeri kullanılmıştır.

MA lezyonlarının sınıflandırılması için Naive Bayes, k-NN, Karar Ağacı (C4.5), DVM ve ÇKA algoritmaları kullanılmıştır.

Test seçeneği olarak ise tüm sınıflandırıcılar için tüm veri kümesinin hem eğitim hem de test olarak kullanılabilirdiği 10 katmanlı çapraz doğrulama yöntemi kullanılmıştır. Bu yöntemle göre veri kümesi 10 parçaya bölünmüş ve her iterasyonda bu veri kümesinin %90’lık kısmı eğitim için, geriye kalan %10’luk kısmı ise test için

ayrılmıştır. Her iterasyonda farklı bir parça test işlemine tabi tutulmuştur. Bu sayede sınıflandırıcıların sonuçları ezberleme gibi yan etkilerinin önüne geçilmiştir.

Sınıflandırma sonucu oluşan karmaşıklık matrisleri, Çizelge 4.6, Çizelge 4.7, Çizelge 4.8, Çizelge 4.9 ve Çizelge 4.10 'da sunulmuştur.

Çizelge 4.6 Karar Ağacı Sınıflandırıcısı İçin Karmaşıklık Matrisi

	Gerçek Sınıf		
		Lezyon Var	Lezyon Yok
	Lezyon Var	173	5
Modelin Sınıf Tahmini	Lezyon Yok	21	20

Çizelge 4.6'ya göre, C4.5 algoritması, sınıflandırma sonucunda gerçekte 194 tane 'Lezyon Var' değerli verinin 173 tanesini doğru sınıflandırırken, 21 tanesini ise yanlış sınıflandırarak 'Lezyon Yok' olarak bulmuştur. Gerçekte 25 tane 'Lezyon Yok' değerli verinin 20 tanesini doğru sınıflandırırken, 5 tanesinde ise 'Lezyon Var' sonucuna ulaşmıştır.

Çizelge 4.7 Naive Bayes Sınıflandırıcısı İçin Karmaşıklık Matrisi

	Gerçek Sınıf		
		Lezyon Var	Lezyon Yok
	Lezyon Var	150	11
Modelin Sınıf Tahmini	Lezyon Yok	44	14

Çizelge 4.7'ye göre, Naive Bayes algoritması, sınıflandırma sonucunda gerçekte 194 tane 'Lezyon Var' değerli verinin 150 tanesini doğru sınıflandırırken, 44 tanesini ise yanlış sınıflandırarak 'Lezyon Yok' olarak bulmuştur. Gerçekte 25 tane 'Lezyon Yok'

değerli verinin 14 tanesini doğru sınıflandırırken, 11 tanesinde ise ‘Lezyon Var’ sonucuna ulaşmıştır.

Çizelge 4.8 k-NN Sınıflandırıcısı İçin Karmaşıklık Matrisi

		Gerçek Sınıf	
		Lezyon Var	Lezyon Yok
Modelin Sınıf Tahmini	Lezyon Var	168	7
	Lezyon Yok	26	18

Çizelge 4.8’e göre, k-NN algoritması, sınıflandırma sonucunda gerçekte 194 tane ‘Lezyon Var’ değerli verinin 168 tanesini doğru sınıflandırırken, 26 tanesini ise yanlış sınıflandırarak ‘Lezyon Yok’ olarak bulmuştur. Gerçekte 25 tane ‘Lezyon Yok’ değerli verinin 18 tanesini doğru sınıflandırırken, 7 tanesinde ise ‘Lezyon Var’ sonucuna ulaşmıştır.

Çizelge 4.9 DVM Sınıflandırıcısı İçin Karmaşıklık Matrisi

		Gerçek Sınıf	
		Lezyon Var	Lezyon Yok
Modelin Sınıf Tahmini	Lezyon Var	165	6
	Lezyon Yok	29	19

Çizelge 4.9’a göre, DVM algoritması, sınıflandırma sonucunda gerçekte 194 tane ‘Lezyon Var’ değerli verinin 165 tanesini doğru sınıflandırırken, 29 tanesini ise yanlış sınıflandırarak ‘Lezyon Yok’ olarak bulmuştur. Gerçekte 25 tane ‘Lezyon Yok’ değerli verinin 19 tanesini doğru sınıflandırırken, 6 tanesinde ise ‘Lezyon Var’ sonucuna ulaşmıştır.

Çizelge 4.10 ÇKA Sınıflandırıcısı İçin Karmaşıklık Matrisi

Modelin Sınıf Tahmini	Gerçek Sınıf		
		Lezyon Var	Lezyon Yok
	Lezyon Var	163	7
Lezyon Yok	31	18	

Çizelge 4.10'a göre, ÇKA algoritması, sınıflandırma sonucunda gerçekte 194 tane 'Lezyon Var' değerli verinin 163 tanesini doğru sınıflandırırken, 31 tanesini ise yanlış sınıflandırarak 'Lezyon Yok' olarak bulmuştur. Gerçekte 25 tane 'Lezyon Yok' değerli verinin 18 tanesini doğru sınıflandırırken, 7 tanesinde ise 'Lezyon Var' sonucuna ulaşmıştır.

Bu sonuçlara göre her bir sınıflandırıcının Doğruluk (Accuracy), Özgüllük (Specificity), Duyarlılık (Sensitivity) ve Hassasiyet (Precision) değerleri ayrı ayrı hesaplanıp, Çizelge 4.11'de sınıflandırma ölçüm performansları sunulmuştur.

Çizelge 4.11 Sınıflandırıcıların Performans Değerlendirmesi

	Doğruluk (Accuracy)	Özgüllük (Specificity)	Duyarlılık (Sensitivity)	Hassasiyet (Precision)
<b>C4.5</b>	%88,13	0,800	0,892	0,972
<b>Naive Bayes</b>	%74,88	0,560	0,773	0,931
<b>k-NN</b>	%84,93	0,720	0,866	0,960
<b>DVM</b>	%84,02	0,760	0,850	0,965
<b>ÇKA</b>	%82,65	0,720	0,840	0,959

Elde edilen sonuçların, literatürdeki benzer örneklerle karşılaştırması Çizelge 4.12'de verilmiştir.

Çizelge 4.12 Mikroanevrizma Lezyonlarının Sınıflandırma Performanslarının Karşılaştırması

Yazar	Veri Seti	Yöntem	Performans Ölçümleri	
			Duyarlılık %	Özgüllük %
Akram v.d. [41]	DIARETDB0, DIARETDB1	Hibrit Sınıflandırıcı	97,83	98,36
Streeter ve Cree [40]	Yerel Veri Seti	Top-Hat Dönüşümü, Eşleştirilmiş Filtre, LDA	56	-
Roychowdhury v.d. [42]	DIARETDB1, MESSIDOR	Gaussian Mixture Model, k-NN, SVM, AdaBoost Sınıflandırıcı	80	85
Ren v.d. [43]	E-Ophtha	Ekstrem Öğrenme Makinesi, Topluluk Öğrenme	96,1	82,1
Rocha v.d. [44]	RetiDB, MESSIDOR	SVM Sınıflandırıcısı	90	60
Niemeijer v.d. [45]	Yerel Veri Seti	k-NN	100	87

Orlando v.d. [46]	MESSIDOR	Hücreyel Sinir Ađı, Derin Öğrenme, Rasgele Orman	91,02	-
Fleming v.d. [47]	Yerel Veri Seti	k-NN	85,4	83,1
Dai v.d. [48]	DIARETDB1	Hücreyel Sinir Ađı	87,8	99,7
Kar ve Maity [49]	DIARETDB1, MESSIDOR, DRIVE, STARE, ROCh	Diferansiyel Evrim Algoritması	95,23	95,12
<b>Önerilen Yöntem</b>	<b>DIARETDB0, DIARETDB1</b>	<b>C4.5, Naive Bayes, k-NN, DVM, ÇKA</b>	<b>89,2</b>	<b>80</b>

Önerilen yöntemde en yüksek başarı oranı, %88,13 doğruluk oranı ile C4.5 karar ağacı algoritması ile sağlanmıştır. C4.5 algoritmasının sınıflandırma sonucunda duyarlılık değeri %89,2 olurken, özgüllük değeri ise %80 olarak hesaplanmıştır.

Önerilen yöntemde en düşük başarı oranı ise, %74,88 doğruluk oranı ile Naive Bayes algoritmasına aittir. Naive Bayes algoritmasının sınıflandırma sonucunda duyarlılık değeri %77,3 olurken, özgüllük değeri ise %56 olarak hesaplanmıştır. Naive Bayes algoritması, tüm öznitelikleri birbirinden bağımsız görerek öznitelikler arası ilişkileri modelleyememesi ve her bir öznitelik için bir tahmin oluşturması sebebiyle sınıflandırma konusunda diğer algoritmalara göre başarısız olmuştur.

Literatürde son yıllarda yapılan benzer MA tespiti sonuçlarına bakıldığı zaman, hibrit sınıflandırıcıların kullanıldığı çalışmalarda ve derin öğrenme tabanlı yaklaşımlarda sınıflandırma başarısının daha yükseldiği görülürken, başarıyı etkileyen bir diğer faktörün de öznitelik çıkartımının çeşitliliği olduğu görülmüştür.



## 5. SONUÇ VE ÖNERİLER

DR, 50 yaşından önce körlüğün önde gelen nedeni olan neredeyse hiç görme bozukluğu belirtisi olmayan ilerleyici bir diyabet hastalığıdır [134], [135]. DR'nin ilk tespit edilebilir işareti MA olarak adlandırılan, retina bölgesindeki küçük kan damarlarının sızıntısından kaynaklanan ve retina yüzeyinde küçük kırmızı dairesel noktalar olarak kendini gösteren lezyonların varlığıdır. Olası bir MA lezyonunun erken tespiti, gözün daha ağır hasarlar almadan gerekli tedavilerin başlamasına imkân tanımaktadır. Aksi durumda körlüğe kadar varabilen sonuçlar doğurabilmektedir.

DR lezyonlarının, retinal görüntülerden ayırt edilebilmesi için öncelikle retinaya ait diğer anatomik yapıların tespit edilmesi gerekir. Bu anatomik yapılar sırasıyla OD, retinal kan damarları, makula ve fovea bölgesidir.

Bu çalışmada ilk olarak, OD'in otomatik tespitinin yapılabilmesi için bir yöntem tanımlanmıştır. Bunun için, standart önışleme adımlarının hemen ardından her bir resim için ortalama parlaklık değeri hesaplanarak, bu değerin altında kalan pikseller, dinamik olarak belirlenen eşik değeri ile resimden elimine edilmiştir. Ardından yeni bir istatistikî kenar algılama yaklaşımı, retina görüntülerine uygulanmış ve başarılı sonuçlar alınmıştır. Kenar çıkartımı yapılan resimlere ÇHD uygulanarak OD'in tespiti yapılmıştır. Önerilen yöntemde 3 adet veri seti kullanılmış ve OD tespiti doğruluğu DRIVE, DIARETDB0 ve DIARETDB1 için sırasıyla %100, %96,92 ve %98,88 olarak elde edilmiştir. Ortalama mutlak mesafe ise yine sırasıyla 10,07, 10,54 ve 12,36 olarak hesaplanmıştır. Önerilen yöntemin, OD bölgesinin diğer bölgelere göre belirgin bir şekilde parlak olmadığı resimler için başarısız olduğu görülmüş, ileriki aşamada sezgisel yöntemlerin de çalışmaya hibrit bir şekilde ekleneceği farklı bir çalışma planlanmıştır.

İkinci olarak retinal kan damarları, literatürde sıkça kullanılan bir yöntem olan Gabor Filtresi yardımıyla ve morfolojik işlemler kullanılarak tespit edilebilmiştir. Yine makula ve fovea bölgesinin tespiti için de OD'in konumu ve literatürde bildirilen foveaya olan yaklaşık mesafe bilgisi kullanılmıştır. Bu sayede DR lezyonlarını

sınıflandırırken foveanın MA ve hemoraji gibi lezyonlarla karışması ihtimalinin mümkün olduğunca önüne geçilmiştir.

Son olarak ise, 15 adet şekil öznitelikleri kullanılarak DIARETDB0 ve DIARETDB1 veri setlerinden bir eğitim kümesi oluşturulmuş ve Karar Ağacı (C4.5), k-NN, Naive Bayes, DVM ve ÇKA sınıflandırıcıları ile MA lezyonları tespit edilmeye çalışılmıştır. %88,13 doğruluk oranı ile en yüksek başarıyı C4.5 algoritması vermiş, literatürdeki benzer çalışmalarla kıyaslandığı zaman ortalamanın üzerinde bir başarı gösterdiği görülmüştür. Bu haliyle sınıflandırma başarısı umut vericidir.

Gelecekte, çıkartımı yapılan 15 adet şekil özniteliklerinin yanında, yoğunluk özniteliği, renk özniteliği, fourier tanımlayıcı öznitelikler kullanılarak resimlerin farklı özellikleri de sınıflandırmaya dahil edilerek ve optimizasyon yöntemleri kullanarak öznitelik seçimi ile ve yeni sınıflandırıcı algoritmalar kullanarak daha etkin lezyon tespiti yapmak hedeflenmektedir.

## KAYNAKLAR

- [1] S. S. Rahim, “Automatic screening and classification of diabetic retinopathy eye fundus images”, Coventry University, 2016.
- [2] J. Cheng *et al.*, “Superpixel classification based optic disc and optic cup segmentation for glaucoma screening,” *IEEE Trans. Med. Imaging*, vol. 32, no. 6, pp. 1019–1032, 2013.
- [3] T. Walter, J.-C. Klein, P. Massin, and A. Erginay, “A contribution of image processing to the diagnosis of diabetic retinopathy-detection of exudates in color fundus images of the human retina,” *IEEE Trans. Med. Imaging*, vol. 21, no. 10, pp. 1236–1243, 2002.
- [4] S. Ravishankar, A. Jain, and A. Mittal, “Automated feature extraction for early detection of diabetic retinopathy in fundus images,” in *Computer Vision and Pattern Recognition, 2009. CVPR 2009. IEEE Conference on*, 2009, pp. 210–217.
- [5] C. Pereira, L. Gonçalves, and M. Ferreira, “Optic disc detection in color fundus images using ant colony optimization,” *Med. Biol. Eng. Comput.*, vol. 51, no. 3, pp. 295–303, 2013.
- [6] H.-K. Hsiao, C.-C. Liu, C.-Y. Yu, S.-W. Kuo, and S.-S. Yu, “A novel optic disc detection scheme on retinal images,” *Expert Syst. Appl.*, vol. 39, no. 12, pp. 10600–10606, 2012.
- [7] D. Welfer, J. Scharcanski, and D. R. Marinho, “A morphologic two-stage approach for automated optic disk detection in color eye fundus images,” *Pattern Recognit. Lett.*, vol. 34, no. 5, pp. 476–485, 2013.
- [8] B. Harangi and A. Hajdu, “Detection of the optic disc in fundus images by combining probability models,” *Comput. Biol. Med.*, vol. 65, pp. 10–24, 2015.
- [9] S. Abed, S. A. Al-Roomi, and M. Al-Shayegi, “Effective optic disc detection method based on swarm intelligence techniques and novel pre-processing steps,” *Appl. Soft Comput.*, vol. 49, pp. 146–163, 2016.

- [10] R. Kamble, M. Kokare, G. Deshmukh, F. A. Hussin, and F. Mériaudeau, “Localization of optic disc and fovea in retinal images using intensity based line scanning analysis,” *Comput. Biol. Med.*, vol. 87, pp. 382–396, 2017.
- [11] B. Zou, C. Chen, C. Zhu, X. Duan, and Z. Chen, “Classified optic disc localization algorithm based on verification model,” *Comput. Graph.*, vol. 70, pp. 281–287, 2018.
- [12] B. Al-Bander, W. Al-Nuaimy, B. M. Williams, and Y. Zheng, “Multiscale sequential convolutional neural networks for simultaneous detection of fovea and optic disc,” *Biomed. Signal Process. Control*, vol. 40, pp. 91–101, 2018.
- [13] J. Lowell *et al.*, “Optic nerve head segmentation,” *Med. Imaging, IEEE Trans.*, vol. 23, no. 2, pp. 256–264, 2004.
- [14] H. Li and O. Chutatape, “Automated feature extraction in color retinal images by a model based approach,” *IEEE Trans. Biomed. Eng.*, vol. 51, no. 2, pp. 246–254, 2004.
- [15] X. Zhu, R. M. Rangayyan, and A. L. Ells, “Detection of the optic nerve head in fundus images of the retina using the hough transform for circles,” *J. Digit. Imaging*, vol. 23, no. 3, pp. 332–341, 2010.
- [16] M. P. Sarathi, M. K. Dutta, A. Singh, and C. M. Travieso, “Blood vessel inpainting based technique for efficient localization and segmentation of optic disc in digital fundus images,” *Biomed. Signal Process. Control*, vol. 25, pp. 108–117, 2016.
- [17] B. Dai, X. Wu, and W. Bu, “Optic disc segmentation based on variational model with multiple energies,” *Pattern Recognit.*, vol. 64, pp. 226–235, 2017.
- [18] S. Bharkad, “Automatic segmentation of optic disk in retinal images,” *Biomed. Signal Process. Control*, vol. 31, pp. 483–498, 2017.
- [19] A. Li *et al.*, “Learning supervised descent directions for optic disc segmentation,” *Neurocomputing*, vol. 275, pp. 350–357, 2018.
- [20] M. M. Fraz *et al.*, “Blood vessel segmentation methodologies in retinal images - A survey,” *Comput. Methods Programs Biomed.*, 2012.

- [21] C. Kirbas and F. Quek, "A review of vessel extraction techniques and algorithms," *ACM Comput. Surv.*, 2004.
- [22] S. Chaudhuri, S. Chatterjee, N. Katz, M. Nelson, and M. Goldbaum, "Detection of blood vessels in retinal images using two-dimensional matched filters," *IEEE Trans. Med. Imaging*, 1989.
- [23] T. Chanwimaluang and G. Fan, "An efficient algorithm for extraction of anatomical structures in retinal images," in *Image Processing, 2003. ICIP 2003. Proceedings. 2003 International Conference on*, 2003.
- [24] A. D. Hoover, V. Kouznetsova, and M. Goldbaum, "Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response," *IEEE Trans. Med. Imaging*, vol. 19, no. 3, pp. 203–210, Mar. 2000.
- [25] M. G. Cinsdikici and D. Aydin, "Detection of blood vessels in ophthalmoscope images using MF/ant (matched filter/ant colony) algorithm," *Comput. Methods Programs Biomed.*, vol. 96, no. 2, pp. 85–95, Nov. 2009.
- [26] M. Al-Rawi, M. Qutaishat, and M. Arrar, "An improved matched filter for blood vessel detection of digital retinal images," *Comput. Biol. Med.*, vol. 37, no. 2, pp. 262–267, Feb. 2007.
- [27] J. P. Serra and Jean, *Image analysis and mathematical morphology*. Academic Press, 1982.
- [28] A. M. Mendonca and A. Campilho, "Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction," *IEEE Trans. Med. Imaging*, vol. 25, no. 9, pp. 1200–1213, Sep. 2006.
- [29] F. Zana and J.-C. Klein, "Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation," *IEEE Trans. Image Process.*, vol. 10, no. 7, pp. 1010–1019, Jul. 2001.
- [30] M. Niemeijer, J. Staal, B. van Ginneken, M. Loog, and M. D. Abramoff, "Comparative study of retinal vessel segmentation methods on a new publicly available database," 2004, vol. 5370, p. 648.

- [31] J. Staal, M. D. Abràmoff, M. Niemeijer, M. A. Viergever, and B. Van Ginneken, "Ridge-based vessel segmentation in color images of the retina," *IEEE Trans. Med. Imaging*, vol. 23, no. 4, pp. 501–509, 2004.
- [32] S. Garg, J. Sivaswamy, and S. Chandra, "Unsupervised curvature-based retinal vessel segmentation," in *2007 4th IEEE International Symposium on Biomedical Imaging: From Nano to Macro*, 2007, pp. 344–347.
- [33] C. Sinthanayothin, J. F. Boyce, H. L. Cook, and T. H. Williamson, "Automated localisation of the optic disc, fovea, and retinal blood vessels from digital colour fundus images," *Br. J. Ophthalmol.*, vol. 83, no. 8, pp. 902–910, 1999.
- [34] M. E. Martinez-Perez, A. D. Hughes, S. A. Thom, A. A. Bharath, and K. H. Parker, "Segmentation of blood vessels from red-free and fluorescein retinal images," *Med. Image Anal.*, vol. 11, no. 1, pp. 47–61, Feb. 2007.
- [35] Q. Li, B. Feng, L. Xie, P. Liang, H. Zhang, and T. Wang, "A Cross-Modality Learning Approach for Vessel Segmentation in Retinal Images," *IEEE Trans. Med. Imaging*, vol. 35, no. 1, pp. 109–118, Jan. 2016.
- [36] M. Krause, R. M. Alles, B. Burgeth, and J. Weickert, "Fast retinal vessel analysis," *J. Real-Time Image Process.*, vol. 11, no. 2, pp. 413–422, Feb. 2016.
- [37] B. D. Barkana, I. Saricicek, and B. Yildirim, "Performance analysis of descriptive statistical features in retinal vessel segmentation via fuzzy logic, ANN, SVM, and classifier fusion," *Knowledge-Based Syst.*, vol. 118, pp. 165–176, Feb. 2017.
- [38] M. Frucci, D. Riccio, G. Sanniti di Baja, and L. Serino, "Severe: Segmenting vessels in retina images," *Pattern Recognit. Lett.*, vol. 82, pp. 162–169, Oct. 2016.
- [39] R. GeethaRamani and L. Balasubramanian, "Retinal blood vessel segmentation employing image processing and data mining techniques for computerized retinal image analysis," *Biocybern. Biomed. Eng.*, vol. 36, no. 1, pp. 102–118, Jan. 2016.
- [40] L. Streeter and M. J. Cree, "Microaneurysm Detection in Colour Fundus Images," *Image Vis. Comput. New Zeal.*, 2003.

- [41] M. U. Akram, S. Khalid, and S. A. Khan, "Identification and classification of microaneurysms for early detection of diabetic retinopathy," *Pattern Recognit.*, vol. 46, no. 1, pp. 107–116, Jan. 2013.
- [42] S. Roychowdhury, D. D. Koozekanani, and K. K. Parhi, "DREAM: Diabetic Retinopathy Analysis Using Machine Learning," *IEEE J. Biomed. Heal. Informatics*, 2014.
- [43] F. Ren, P. Cao, W. Li, D. Zhao, and O. Zaiane, "Ensemble based adaptive over-sampling method for imbalanced data learning in computer aided detection of microaneurysm," *Comput. Med. Imaging Graph.*, 2017.
- [44] A. Rocha, T. Carvalho, H. F. Jelinek, S. Goldenstein, and J. Wainer, "Points of interest and visual dictionaries for automatic retinal lesion detection," *IEEE Trans. Biomed. Eng.*, 2012.
- [45] M. Niemeijer, B. Van Ginneken, J. Staal, M. S. A. Suttorp-Schulten, and M. D. Abràmoff, "Automatic detection of red lesions in digital color fundus photographs," *IEEE Trans. Med. Imaging*, 2005.
- [46] J. I. Orlando, E. Prokofyeva, M. del Fresno, and M. B. Blaschko, "An ensemble deep learning based approach for red lesion detection in fundus images," *Comput. Methods Programs Biomed.*, 2018.
- [47] A. D. Fleming, S. Philip, K. A. Goatman, J. A. Olson, and P. F. Sharp, "Automated microaneurysm detection using local contrast normalization and local vessel detection," *IEEE Trans. Med. Imaging*, 2006.
- [48] L. Dai *et al.*, "Clinical report guided retinal microaneurysm detection with multi-sieving deep learning," *IEEE Trans. Med. Imaging*, 2018.
- [49] S. S. Kar and S. P. Maity, "Automatic Detection of Retinal Lesions for Screening of Diabetic Retinopathy," *IEEE Trans. Biomed. Eng.*, 2018.
- [50] T. Kauppi *et al.*, "DIARETDB0: Evaluation database and methodology for diabetic retinopathy algorithms," *Mach. Vis. Pattern Recognit. Res. Group, Lappeenranta Univ. Technol. Finl.*, vol. 73, 2006.

- [51] R. Kälviäinen and H. Uusitalo, “DIARETDB1 diabetic retinopathy database and evaluation protocol,” in *Medical Image Understanding and Analysis*, 2007, vol. 2007, p. 61.
- [52] R. Donnelly and E. S. Horton, *Vascular complications of diabetes : current issues in pathogenesis and treatment*. Blackwell Pub, 2005.
- [53] R. J. Antcliff and J. Marshall, “The Pathogenesis of Edema in Diabetic Maculopathy,” *Semin. Ophthalmol.*, vol. 14, no. 4, pp. 223–232, Jan. 1999.
- [54] C. . Wilkinson *et al.*, “Proposed international clinical diabetic retinopathy and diabetic macular edema disease severity scales,” *Ophthalmology*, vol. 110, no. 9, pp. 1677–1682, Sep. 2003.
- [55] İ. Günalp, “GÖZ HASTALIKLARININ BELİRTİ ve BULGULARI,” 2016. [Online]. Available: <http://profdrilhangunalp.blogspot.com/2016/02/goz-hastaliklarinin-belirti-ve.html>. [Erişim: 05.04.2019].
- [56] C. S. Lee *et al.*, “Reevaluating the Definition of Intraretinal Microvascular Abnormalities and Neovascularization Elsewhere in Diabetic Retinopathy Using Optical Coherence Tomography and Fluorescein Angiography,” *Am. J. Ophthalmol.*, vol. 159, no. 1, p. 101–110.e1, Jan. 2015.
- [57] P. J. Watkins, “Abc of diabetes: The diabetic foot.,” *BMJ Br. Med. J.*, vol. 326, no. 7396, pp. 977–9, May 2003.
- [58] R. N. Frank, “Diabetic Retinopathy,” *Prog. Retin. Eye Res.*, vol. 14, pp. 361–392, 1995.
- [59] “Four different fundus images, representing a different stage of DR.” [Online]. Available: <http://sdhawan.com/eye-diseases-diabeteseeye.htm>. [Erişim: 10.04.2019].
- [60] M. Sonka, V. Hlavac, and R. Boyle, “Introduction,” in *Image Processing, Analysis and Machine Vision*, Boston, MA: Springer US, 1993, pp. 1–12.
- [61] M. H. Ahmad Fadzil, L. I. Izhar, P. A. Venkatachalam, and T. V. N. Karunakar, “Extraction and reconstruction of retinal vasculature,” *J. Med. Eng. Technol.*, vol. 31, no. 6, pp. 435–442, Jan. 2007.



- [62] S. Hajeb Mohammad Alipour, H. Rabbani, and M. R. Akhlaghi, "Diabetic Retinopathy Grading by Digital Curvelet Transform," *Comput. Math. Methods Med.*, vol. 2012, pp. 1–11, Sep. 2012.
- [63] C. Aravind, M. Ponnibala, and S. Vijayachitra, "Automatic Detection of Microaneurysms and Classification of Diabetic Retinopathy Images using SVM Technique," *IJCA Proc. Int. Conf. Innov. Intell. Instrumentation, Optim. Electr. Sci.*, vol. ICIIIIOES, no. 11, pp. 18–22, 2013.
- [64] M. PonniBala and S. Vijayachitra, "Computerised Retinal Image Analysis to Detect and Quantify Exudates Associated with Diabetic Retinopathy," *Int. J. Comput. Appl.*, 2012.
- [65] B. Harangi, B. Antal, and A. Hajdu, "Automatic exudate detection with improved naïve-Bayes classifier," in *Proceedings - IEEE Symposium on Computer-Based Medical Systems*, 2012.
- [66] Y. Hatanaka, T. Inoue, S. Okumura, C. Muramatsu, and H. Fujita, "Automated microaneurysm detection method based on double-ring filter and feature analysis in retinal fundus images," in *Proceedings - IEEE Symposium on Computer-Based Medical Systems*, 2012.
- [67] A. Hunter, J. A. Lowell, B. Ryder, A. Basu, and D. Steel, "Automated diagnosis of referable maculopathy in diabetic retinopathy screening.," *Conf. Proc. IEEE Eng. Med. Biol. Soc.*, 2011.
- [68] H. F. Jaafar, A. K. Nandi, and W. Al-Nuaimy, "Automated detection of exudates in retinal images using a splitand-merge algorithm," in *European Signal Processing Conference*, 2010.
- [69] S. Jiménez *et al.*, "Automatic detection of microaneurysms in colour fundus images," *Arch. la Soc. Española Oftalmol. (English Ed.)*, 2011.
- [70] S. Joshi and P. T. Karule, "Retinal Blood Vessel Segmentation," *Int. J. Eng. Innov. Technol.*, 2012.
- [71] I. Lázár and A. Hajdu, "Retinal Microaneurysm Detection Based on Intensity Profile Analysis," *Proc. 8th Int. Conf. Appl. Informatics*, vol. 1, pp. 157–165, 2010.

- [72] R. V. Lichode and S. Kulkarni, "Automatic Diagnosis of Diabetic Retinopathy by Hybrid Multilayer Feed Forward Neural Network," *Int. J. Sci. Eng. Technol. Res.*, vol. 2, no. 9, pp. 2278–7798, 2013.
- [73] C. I. O. Martins, R. M. S. Veras, G. L. B. Ramalho, F. N. S. Medeiros, and D. M. Ushizima, "Automatic Microaneurysm Detection and Characterization Through Digital Color Fundus Images," *Brazilian Symposium on Artificial Intelligence and Brazilian Symposium on Neural Networks*. 2010.
- [74] A. Mizutani, C. Muramatsu, Y. Hatanaka, S. Suemori, T. Hara, and H. Fujita, "Automated microaneurysm detection method based on double ring filter in retinal fundus images," in *Medical Imaging 2009: Computer-Aided Diagnosis*, 2009.
- [75] M. R. K. Mookiah *et al.*, "Evolutionary algorithm based classifier parameter tuning for automatic diabetic retinopathy grading: A hybrid feature extraction approach," *Knowledge-Based Syst.*, vol. 39, pp. 9–22, 2013.
- [76] D. Nagaveena, D. Devaraj, and S. C. Prasanna Kumar, "Vessels Segmentation In Diabetic Retinopathy By Adaptive Median Thresholding," *Int. J. Sci. Technoledge*, vol. 1, no. 1, pp. 17–22, 2013.
- [77] A. Osareh, M. Mirmehdi, B. Thomas, and R. Markham, "Automated identification of diabetic retinal exudates in digital colour images," *Br. J. Ophthalmol.*, 2003.
- [78] J. Prakash and K. Sumanthi, "Detection and classification of microaneurysms for diabetic retinopathy," *Int J Eng Res Appl*, vol. 4, pp. 31–36, 2013.
- [79] A. Punnolil, "A novel approach for diagnosis and severity grading of diabetic maculopathy," in *2013 international conference on advances in computing, communications and informatics (ICACCI)*, 2013, pp. 1230–1235.
- [80] G. Quellec, M. Lamard, P. M. Josselin, G. Cazuguel, B. Cochener, and C. Roux, "Optimal wavelet transform for the detection of microaneurysms in retina photographs," *IEEE Trans. Med. Imaging*, vol. 27, no. 9, pp. 1230–1241, 2008.

- [81] A. Sopharak, B. Uyyanonvara, and S. Barman, “Automated microaneurysm detection algorithms applied to diabetic retinopathy retinal images,” *Maejo Int. J. Sci. Technol.*, vol. 7, no. 2, p. 294, 2013.
- [82] C. Sundhar and D. Archana, “Automatic screening of fundus images for detection of diabetic retinopathy,” *Int J Commun Comput Technol*, vol. 2, no. 1, pp. 100–105, 2014.
- [83] G. S. A. G. Vimala and S. Kajamohideen, “Detection of diabetic maculopathy in human retinal images using morphological operations,” *Online J. Biol. Sci.*, vol. 14, no. 3, p. 175, 2014.
- [84] K. Wisaeng, N. Hiransakolwong, and E. Pothiruk, “Automatic Detection of Optic Disc in Digital Retinal Images,” *Int. J. Comput. Appl.*, 2014.
- [85] P. Yadao, N. Sayali, and M. Animesh, “Blood Vessel Segmentation in Retinal Fundus Images using Matched Filter,” *J. Harmon. Reaserch Eng.*, 2014.
- [86] H. M. Ünver, Y. Kökver, E. Duman, and O. A. Erdem, “Statistical edge detection and circular hough transform for Optic disk localization,” *Appl. Sci.*, vol. 9, no. 2, 2019.
- [87] Ş. E. Şeker, “Özellik Çıkarımı (Feature Extraction) – Bilgisayar Kavramları,” 2008.[Online].Available: <http://bilgisayarkavramlari.sadievrenseker.com/2008/12/01/ozellik-cikarimi-feature-extraction/>. [Erişim: 20.05.2019].
- [88] M. Usman Akram, S. Khalid, A. Tariq, S. A. Khan, and F. Azam, “Detection and classification of retinal lesions for grading of diabetic retinopathy,” *Comput. Biol. Med.*, 2014.
- [89] D. Selvathi, N. B. Prakash, and N. Balagopal, “Automated Detection of Diabetic Retinopathy for Early Diagnosis using Feature Extraction and Support Vector Machine,” *Int. J. Emerg. Technol. Adv. Eng.*, 2012.
- [90] S. SB and V. Singh, “Automatic Detection of Diabetic Retinopathy in Non-dilated RGB Retinal Fundus Images,” *Int. J. Comput. Appl.*, 2012.

- [91] A. Tariq, M. U. Akram, A. Shaukat, and S. A. Khan, "Automated detection and grading of diabetic maculopathy in digital retinal images," *J. Digit. Imaging*, 2013.
- [92] C. Cortes and V. Vapnik, "Support-vector networks," *Mach. Learn.*, 1995.
- [93] B. Liu, *Web Data Mining: Exploring Hyperlinks, Contents, and Usage Data Second Edition*. 2011.
- [94] J. Wang, *Encyclopedia of Data Warehousing and Mining, Second Edition*. Information Science Reference, 2010.
- [95] K. Adal, S. Ali, D. Sidibé, T. Karnowski, E. Chaum, and F. Mériaudeau, "Automated detection of microaneurysms using robust blob descriptors," in *Medical Imaging 2013: Computer-Aided Diagnosis*, 2013.
- [96] P. Chowriappa, S. Dua, U. Rajendra Acharya, and M. Muthu Rama Krishnan, "Ensemble selection for feature-based classification of diabetic maculopathy images," *Comput. Biol. Med.*, 2013.
- [97] G. Lim, M. L. Lee, W. Hsu, and T. Y. Wong, "Transformed representations for convolutional neural networks in diabetic retinopathy screening," in *AAAI Workshop - Technical Report*, 2014.
- [98] A. Sopharak *et al.*, "Machine learning approach to automatic exudate detection in retinal images from diabetic patients," *J. Mod. Opt.*, 2010.
- [99] K. Verma, P. Deep, and A. G. Ramakrishnan, "Detection and classification of diabetic retinopathy using retinal images," in *Proceedings - 2011 Annual IEEE India Conference: Engineering Sustainable Solutions, INDICON-2011*, 2011.
- [100] M. S. Haleem, L. Han, J. van Hemert, and B. Li, "Automatic extraction of retinal features from colour retinal images for glaucoma diagnosis: A review," *Comput. Med. Imaging Graph.*, vol. 37, no. 7–8, pp. 581–596, Oct. 2013.
- [101] A. E. Mahfouz and A. S. Fahmy, "Fast localization of the optic disc using projection of image features," *IEEE Trans. Image Process.*, vol. 19, no. 12, pp. 3285–3289, 2010.

- [102] H. Yu *et al.*, “Fast Localization and Segmentation of Optic Disk in Retinal Images Using Directional Matched Filtering and Level Sets,” *IEEE Trans. Inf. Technol. Biomed.*, vol. 16, no. 4, pp. 644–657, Jul. 2012.
- [103] M. E. Gegundez-Arias, D. Marin, J. M. Bravo, and A. Suero, “Locating the fovea center position in digital fundus images using thresholding and feature extraction techniques,” *Comput. Med. Imaging Graph.*, vol. 37, no. 5–6, pp. 386–393, Jul. 2013.
- [104] A. Giachetti, L. Ballerini, E. Trucco, and P. J. Wilson, “The use of radial symmetry to localize retinal landmarks,” *Comput. Med. Imaging Graph.*, vol. 37, no. 5–6, pp. 369–376, Jul. 2013.
- [105] M. Foracchia, E. Grisan, and A. Ruggeri, “Detection of Optic Disc in Retinal Images by Means of a Geometrical Model of Vessel Structure,” *IEEE Trans. Med. Imaging*, vol. 23, no. 10, pp. 1189–1195, Oct. 2004.
- [106] G. Mittal and J. Sivaswamy, “Optic disk and macula detection from retinal images using Generalized Motion Pattern,” in *2015 Fifth National Conference on Computer Vision, Pattern Recognition, Image Processing and Graphics (NCVPRIPG)*, 2015, pp. 1–4.
- [107] L. D. Hubbard *et al.*, “Methods for evaluation of retinal microvascular abnormalities associated with hypertension/sclerosis in the atherosclerosis risk in communities study,” *Ophthalmology*, vol. 106, no. 12, pp. 2269–2280, Dec. 1999.
- [108] M. Niemeijer, M. D. Abramoff, and B. van Ginneken, “Segmentation of the Optic Disc, Macula and Vascular Arch in Fundus Photographs,” *IEEE Trans. Med. Imaging*, vol. 26, no. 1, pp. 116–127, Jan. 2007.
- [109] J. P. Medhi and S. Dandapat, “An effective fovea detection and automatic assessment of diabetic maculopathy in color fundus images,” *Comput. Biol. Med.*, vol. 74, pp. 30–44, Jul. 2016.
- [110] U. Şevik, “Retinal Image Quality Assessment And Detection Of Diabetic Retinopathy Disease,” Karadeniz Technical University, 2014.

- [111] E. Duman and O. A. Erdem, "A statistical edge detection framework for noisy images," in *2018 26th Signal Processing and Communications Applications Conference (SIU)*, 2018.
- [112] D. H. Lim, "Robust edge detection in noisy images," *Comput. Stat. Data Anal.*, vol. 50, no. 3, pp. 803–812, 2006.
- [113] J. Kaur and D. H. P. Sinha, "Automated localisation of optic disc and macula from fundus images," *Int. J. Adv. Res. Comput. Sci. Softw. Eng.*, vol. 2, no. 4, 2012.
- [114] M. S. Miri and A. Mahloojifar, "Retinal image analysis using curvelet transform and multistructure elements morphology by reconstruction," *IEEE Trans. Biomed. Eng.*, vol. 58, no. 5, pp. 1183–1192, 2011.
- [115] R. Perfetti, E. Ricci, D. Casali, and G. Costantini, "Cellular neural networks with virtual template expansion for retinal vessel segmentation," *IEEE Trans. Circuits Syst. II Express Briefs*, vol. 54, no. 2, pp. 141–145, 2007.
- [116] M. B. Patwari, R. R. Manza, Y. M. Rajput, M. Saswade, and N. Deshpande, "Automatic detection of retinal venous beading and tortuosity by using image processing techniques," *Int. J. Comput. Appl.*, 2014.
- [117] K. Burçin and V. V NABIYEV, "Dijital mamografi görüntülerinin kontrast sınırlı adaptif histogram eşitleme ile iyileştirilmesi," 2010.
- [118] V. Göreke, E. Uzunhisarcıklı, and A. Güven, "Gri Seviyeli Eşoluşum Matrisleri Kullanılarak Sayısal Mamogram Görüntüsünden Doku Özniteliklerinin Çıkarılması ve Yapay Sinir Ağı ile Kitle Tespiti," *Tıp Teknol. Ulus. Kongresi-TıpTekno'14*, 2014.
- [119] A. M. Reza, "Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement," *J. VLSI signal Process. Syst. signal, image video Technol.*, vol. 38, no. 1, pp. 35–44, 2004.
- [120] R. A. Fisher, *The design of experiments*. Oliver And Boyd; Edinburgh; London, 1937.

- [121] R. O. Duda and P. E. Hart, "Use of the Hough transformation to detect lines and curves in pictures," *Commun. ACM*, vol. 15, no. 1, pp. 11–15, 1972.
- [122] E. Duman, Y. Kökver, H. M. Ünver, and O. A. Erdem, "Automatic landmark detection through circular hough transform in cephalometric X-rays," in *2017 10th International Conference on Electrical and Electronics Engineering, ELECO 2017*, 2018, vol. 2018–Janua.
- [123] N. Alioua, A. Amine, M. Rziza, and D. Aboutajdine, "Eye state analysis using iris detection based on Circular Hough Transform," in *Multimedia Computing and Systems (ICMCS), 2011 International Conference on*, 2011, pp. 1–5.
- [124] A. Hoover and M. Goldbaum, "Locating the optic nerve in a retinal image using the fuzzy convergence of the blood vessels," *IEEE Trans. Med. Imaging*, vol. 22, no. 8, pp. 951–958, 2003.
- [125] M. I. Ahmed and M. A. Amin, "High speed detection of optical disc in retinal fundus image," *Signal, Image Video Process.*, vol. 9, no. 1, pp. 77–85, 2015.
- [126] A. A.-H. A.-R. Youssif, A. Z. Ghalwash, and A. A. S. A.-R. Ghoneim, "Optic disc detection from normalized digital fundus images by means of a vessels' direction matched filter," *IEEE Trans. Med. Imaging*, vol. 27, no. 1, pp. 11–18, 2008.
- [127] R. M. Rangayyan, X. Zhu, F. J. Ayres, and A. L. Ells, "Detection of the optic nerve head in fundus images of the retina with Gabor filters and phase portrait analysis," *J. Digit. Imaging*, vol. 23, no. 4, pp. 438–453, 2010.
- [128] A. Dehghani, H. A. Moghaddam, and M.-S. Moin, "Optic disc localization in retinal images using histogram matching," *EURASIP J. Image Video Process.*, vol. 2012, no. 1, p. 19, 2012.
- [129] N. Sinha and R. V. Babu, "Optic disk localization using L 1 minimization," in *Image Processing (ICIP), 2012 19th IEEE International Conference on*, 2012, pp. 2829–2832.
- [130] N. Karunanayake and N. D. Kodikara, "An Improved Method for Automatic Retinal Blood Vessel Vascular Segmentation Using Gabor Filter," *Open J. Med. Imaging*, vol. 5, pp. 204–213, 2015.

- [131] Z. Yavuz and C. Kose, "Retinal blood vessel segmentation using gabor filter and top-hat transform," in *2011 IEEE 19th Signal Processing and Communications Applications Conference (SIU)*, 2011, pp. 546–549.
- [132] C. Sinthanayothin, J. F. Boyce, H. L. Cook, and T. H. Williamson, "Automated localisation of the optic disc, fovea, and retinal blood vessels from digital colour fundus images.," *Br. J. Ophthalmol.*, vol. 83, no. 8, pp. 902–10, Aug. 1999.
- [133] "Measure properties of image regions - MATLAB regionprops." [Online]. Available: <https://www.mathworks.com/help/images/ref/regionprops.html>. [Eriřim: 25.01.2019].
- [134] R. Klein, B. E. K. Klein, and S. E. Moss, "Visual Impairment in Diabetes," *Ophthalmology*, 1984.
- [135] A. K. Sjolie *et al.*, "Retinopathy and vision loss in insulin-dependent diabetes in Europe: The EURODIAB IDDM complications study," *Ophthalmology*, 1997.



## ÖZGEÇMİŞ

Adı Soyadı : Yunus KÖKVER

Yabancı Dil : İngilizce

Eğitim Durumu : (Kurum ve Yıl)

Lisans : Süleyman Demirel Üniversitesi, Teknik Eğitim Fakültesi, Elektronik ve Bilgisayar Eğitimi Bölümü, Bilgisayar ve Kontrol Öğretmenliği (2009)

Lisans : Erciyes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü (2015)

Yüksek Lisans : Kırıkkale Üniversitesi, Bilgisayar Mühendisliği ABD (2012)

Doktora : Kırıkkale Üniversitesi, Bilgisayar Mühendisliği ABD (2019)

Çalıştığı Kurum/Kurumlar ve Yıl/Yıllar:

(2017- Halen) : Ankara Üniversitesi Elmadağ MYO

(2010- 2017) : Kırıkkale Üniversitesi

(2009- 2010) : Omega İleri Teknolojileri Ltd. Şti.

Yayımları (SCI) : Ünver Halil Murat, Kökver Yunus, Duman Elvan, Erdem Osman Ayhan, “Statistical Edge Detection and Circular Hough Transform for Optic Disk Localization”, Applied Sciences, 9.2 (2019): 350

Yayımları (Diğer) : Kökver Yunus, Ünver Halil Murat, Duman Ebru Aydoğan, “Retina görüntülerinden kan damarlarının segmentasyonu”, Ortadoğu Tıp Dergisi, 9.4 (2017): 198-202.

Kökver Yunus, Barışçı Necaattin, Çiftçi Aydın, Ekmekçi Yakup, "Hipertansiyona Etki Eden Faktörlerin Veri Madenciliği Yöntemleriyle İncelenmesi." Engineering Sciences 9.2 (2014): 15-25.

Duman Elvan, Kökver Yunus, Ünver Halil Murat, Erdem Osman Ayhan, "Automatic landmark detection through circular hough transform in cephalometric X-rays", 2017 10th International Conference on Electrical and Electronics Engineering (ELECO). IEEE, 2017.

Kökver Yunus, Duman Elvan, Erdem Osman Ayhan, Ünver Halil Murat, "An Adaptive Gaussian Filter For Edge Preserving Image Smoothing", 2017 International Conference on Mathematics and Mathematics Education(ICMME-2017)