

**KARADENİZ TEKNİKÜNİVERSİTESİ  
FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**RETİNA GÖRÜNTÜLERİNİN KALİTE DEĞERLENDİRMESİ VE DİYABETİK  
RETİNOPATİ HASTALIĞININ TESPİTİ**

**DOKTORA TEZİ**

**Uğur ŞEVİK**

**HAZİRAN 2014  
TRABZON**

**KARADENİZ TEKNİKÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI**

**RETİNA GÖRÜNTÜLERİNİN KALİTE DEĞERLENDİRMESİ VE DİYABETİK  
RETİNOPATİ HASTALIĞININ TESPİTİ**

**Uğur ŞEVİK**

**Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünde  
“DOKTOR (BİLGİSAYAR MÜHENDİSLİĞİ)”  
Unvanı Verilmesi İçin Kabul Edilen Tezdir.**

**Tezin Enstitüye Verildiği Tarih : 20.05.2014**  
**Tezin Savunma Tarihi : 09.06.2014**

**Tez Danışmanı : Doç. Dr. Cemal KÖSE**

**Trabzon 2014**

Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Ana Bilim Dalında  
Uğur ŞEVİK Tarafından Hazırlanan

RETİNA GÖRÜNTÜLERİNİN KALİTE DEĞERLENDİRMESİ VE DİYABETİK  
RETİNOPATİ HASTALIĞININ TESPİTİ

başlıklı bu çalışma, Enstitü Yönetim Kurulunun 20 / 05 / 2014 gün ve 1554 sayılı  
kararıyla oluşturulan jüri tarafından yapılan sınavda

DOKTORA TEZİ  
olarak kabul edilmiştir.

Jüri Üyeleri

Başkan : Prof. Dr. Alp KUT  
Üye : Prof. Dr. Temel KAYIKÇIOĞLU  
Üye : Prof. Dr. Hidayet ERDÖL  
Üye : Doç. Dr. Cemal KÖSE  
Üye : Yrd. Doç. Dr. Tuğrul ÇAVDAR

  
.....  
.....  
.....  
.....  
.....  
.....

Prof. Dr. Sadettin KORKMAZ  
Enstitü Müdürü

## ÖNSÖZ

Teknolojinin gelişimi ile beraber, medikal cihaz teknolojilerindeki görüntüleme, analiz ve karar verme yetenekleri de oldukça ilerlemiştir. Özellikle medikal cihazlarla birlikte geliştirilen yazılımlar, uzmanların daha kolay ve doğru teşhis koyabilmelerine olanak sağlamaktadır. Bu tez çalışmasında, yeni bir görüntü kalite ve uygunluk testinin yanı sıra, diyabetik retinopati lezyonlarının tespiti için hızlı ve etkin yöntemler önerilerek yeni özniteliklerle sınıflandırılması yapılmıştır.

Çalışmalarında danışmanlığımı üstlenen, her türlü destek ve katkılarıyla çalışmamı yönlendiren çok değerli danışman hocam Sayın Doç. Dr. Cemal KÖSE'ye teşekkürlerimi sunarım.

Tez konusunun seçiminde bana fikir veren, değerli görüş ve önerileriyle çalışmalarında yol gösteren, kullandığım görüntüleri temin eden, gerekli tıbbi bilgileri anlatan ve her zaman yanımda desteğini gördüğüm sayın hocam, KTÜ Göz Hastalıkları ABD. Başkanı Prof. Dr. Hidayet ERDÖL'e en içten teşekkürlerimi sunarım.

Çalışma sürecinde değerli görüş ve katkılarını esirgemeyen sayın Prof. Dr. Temel KAYIKÇIOĞLU'na ve Yrd. Doç. Dr. Tuğrul ÇAVDAR'a teşekkür ederim.

Çalışmalarımın son aşamasında değerli bilgileri ve manevi desteğiyle her zaman yanımda olan değerli arkadaşım Yrd. Doç. Dr. Tolga BERBER'e teşekkürü bir borç bilirim.

Tez çalışması sürecinde bana her türlü maddi-manevi desteklerini ve tahammüllerini esirgemeyen bölümüm İstatistik ve Bilgisayar Bilimleri'ndeki tüm değerli hocalarıma ve Enformatik Bölümündeki değerli arkadaşlarıma şükranlarımı sunarım.

Doktora tez süresi boyunca Yurt İçi Doktora Bursu ile her türlü maddi desteği sağlayan TÜBİTAK'a ve 1216 nolu Bilimsel Araştırma Projesi ile çalışmamda kullandığım makine-teçhizatları sağlayan üniversitem, Karadeniz Teknik Üniversitesi'ne sonsuz minnettarlığımı sunarım.

Öğrenim hayatım boyunca buralara gelmemi sağlayan sevgili babama, anneme ve biricik ablama müteşekkir olduğumu belirtirim. Hayatıma anlam kazandıran, tez çalışması sürecinde her daim bana destek veren ve tahammül eden çok sevdiğim eşim Setenay ŞEVİK'e sonsuz teşekkürlerimi sunarım.

Uğur ŞEVİK  
Trabzon 2014

## TEZ BEYANNAMESİ

Doktora Tezi olarak sunduđum “Retina Görüntülerinin Kalite Deđerlendirmesi ve Diyabetik Retinopati Hastalığının Tespiti” başlıklı bu çalışmayı baştan sona kadar danışmanım Doç. Dr. Cemal KÖSE'nin sorumluluđunda tamamladıđımı, verileri/örnekleri kendim topladıđımı, deneyleri/analizleri ilgili laboratuvarlarda yaptıđımı/yaptırdıđımı, başka kaynaklardan aldıđım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiđimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandıđımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiđimi beyan ederim. 09/06/2014

Uđur ŐEVİK

## İÇİNDEKİLER

	<u>Sayfa No</u>
ÖNSÖZ .....	III
TEZ BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET .....	VIII
SUMMARY .....	IX
ŞEKİLLER DİZİNİ .....	X
TABLolar DİZİNİ.....	XIV
SEMBOLLER DİZİNİ .....	XVII
1. GENEL BİLGİLER.....	1
1.1. Giriş .....	1
1.2. Tezin Amacı ve Yapısı .....	3
1.3. Gözün Yapısı .....	7
1.3.1. Retina.....	9
1.3.2. Fotoreseptörler.....	11
1.3.2.1. Çubuk Hücreleri .....	11
1.3.2.2. Koni Hücreleri .....	11
1.3.3. Bipolar Hücreler .....	12
1.3.4. Ganglion Hücreleri .....	12
1.3.5. Destek Hücreleri .....	12
1.4. Diyabetik Retinopati.....	12
1.4.1. Non-proliferatif Diyabetik Retinopati .....	15
1.4.2. Proliferatif Diyabetik Retinopati .....	17
1.4.3. Diyabetik Retinopatinin Tedavisi.....	17
1.4.4. Diyabetik Retinopatinin İzlenmesi .....	20
1.5. Literatür Çalışması .....	24
1.5.1. Mikroanevrizma ve Hemoraji ile İlgili Literatür Değerlendirmesi .....	24
1.5.2. Sert ve Yumuşak Eksuda ile İlgili Literatür Değerlendirmesi .....	26
1.6. Retina Görüntü Veritabanları .....	28
2. YAPILAN ÇALIŞMALAR.....	33
2.1. Retina Görüntüsü Ön İşleme İşlemleri .....	33
2.1.1. Renk Kanalı Seçimi .....	33

2.1.2.	Görüntü İyileştirme .....	34
2.1.3.	Matematiksel Morfoloji İşlemleri.....	38
2.2.	Retinadaki Anatomik Yapıların Tespiti.....	40
2.2.1.	Kan Damarlarının Tespiti .....	41
2.2.2.	Optik Diskin (OD) Tespiti.....	45
2.2.3.	Fovea Bölgesinin Tespiti .....	48
2.3.	Retina Görüntülerinden Çıkarılan Öznelikler .....	50
2.3.1.	Bölgesel Öznelikler .....	51
2.3.2.	Dokusal Öznelikler.....	52
2.3.2.1.	Gri – Seviye Histogramın İstatistiksel Öznelikleri .....	53
2.3.2.2.	Haralick Doku Öznelikleri .....	54
2.3.3.	Zernike Momentleri.....	57
2.3.4.	Kenar Histogram Öznelikleri .....	58
2.4.	Makine Öğrenmesi ve Kullanılan Sınıflandırıcılar .....	59
2.4.1.	Doğrusal Ayrıştırma Analizi .....	60
2.4.2.	k-En Yakın Komşu Sınıflandırıcı .....	64
2.4.3.	Yapay Sinir Ağları.....	65
2.4.4.	Naive Bayes Sınıflandırıcısı .....	66
2.4.5.	Destek Vektör Makineleri .....	67
2.4.6.	Karar Ağaçları .....	69
2.4.7.	Rastgele Orman Sınıflandırıcı .....	70
2.4.8.	Adaboost Yaklaşımı .....	71
2.5.	Retina Görüntülerinin Kalite Değerlendirmesi .....	72
2.5.1.	Retina Görüntüsünün Bölgelere Ayrılması .....	77
2.5.2.	ISNT Bölgelerindeki Damarların Özneliklerinin Çıkarılması .....	79
2.5.3.	Tüm Retina Görüntüsünden Çıkarılan Öznelikler .....	80
2.5.4.	Uygun Retina Görüntüsünün Bulunması.....	81
2.6.	Diyabetik Retinopati Hastalığının Tespiti .....	83
2.6.1.	Retina Görüntüsünün Arka Plan Kestirimi.....	85
2.6.2.	Retinadaki Anatomik Yapıların Elimine Edilmesi.....	87
2.6.2.1.	Koyu Görüntüden Kan Damarlarının Eliminasyonu .....	87
2.6.2.2.	Parlak Görüntüden Optik Diskin Eliminasyonu.....	88
2.6.3.	Diyabetik Retinopati Lezyonlarından Öznelik Çıkarımı .....	90
2.6.3.1.	Şekilsel Öznelikler .....	91

2.6.4.	Lezyonlardan Çıkarılan Özniteliklerin Sınıflandırılması .....	94
2.6.4.1.	Çapraz Doğrulama.....	94
2.7.	Öznitelik Seçim Yaklaşımları.....	95
2.7.1.	İleriye Doğru Seçim .....	96
2.7.2.	Genetik Seçim .....	96
3.	BULGULAR VE İRDELEME.....	97
3.1.	Kullanılan Değerlendirme Ölçekleri .....	97
3.2.	Retinadaki Anatomik Yapıların Tespitindeki Sonuçlar .....	99
3.3.	Retina Görüntü Kalitesi Değerlendirme Sonuçları.....	102
3.4.	Uygun Retina Görüntülerinin Tespiti.....	113
3.5.	Diyabetik Retinopati Lezyonlarının Tespitindeki Sonuçlar .....	116
4.	SONUÇLAR.....	135
5.	ÖNERİLER .....	138
6.	KAYNAKÇA .....	140

ÖZGEÇMİŞ



Doktora Tezi

ÖZET

RETİNA GÖRÜNTÜLERİNİN KALİTE DEĞERLENDİRMESİ VE DİYABETİK  
RETİNOPATİ HASTALIĞININ TESPİTİ

Uğur ŞEVİK

Karadeniz Teknik Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalı  
Danışman: Doç. Dr. Cemal KÖSE  
2014, 153 Sayfa

Diyabetik Retinopati (DR), diyabet sonucu oluşan ve erken teşhis edilmediği takdirde körlüğe neden olan bir göz hastalığıdır. Dünyada körlüğe neden olan başlıca hastalıktır. Bu göz hastalığının görme kaybına yol açmaması için diyabet hastalarının düzenli olarak oftalmologlar tarafından renkli retina görüntüleri alınıp erken teşhis ve tedavi yöntemlerinin uygulanması gerekmektedir. Ancak günümüzde diyabet hastalığının oldukça artış göstermesi hasta yoğunluğunu da arttırmıştır. Tüm bu hastaların düzenli olarak takip edilebilmesi için yeterli sayıda uzman ve zamana ihtiyaç vardır. Bu nedenle çalışmamızda, oftalmologların teşhis işlerini kolaylaştırma ve zaman kaybının önlenmesi için göz hastalıklarının otomatik teşhisini amaçlayan yöntemler önerilmiştir. Bu tez çalışmasında öncelikle fundus kamera ile alınan görüntülerin yeterli kaliteye ve bilgiye sahip olup olmadıkları tespit edilmiştir. Uygun retina görüntüsü bulunduktan sonra retinanın temel anatomik yapıları olan kan damarları, optik disk ve fovea tespit edilmiştir. Bu anatomik yapılar retinadaki anormalliklerin tespitinde kullanılan yöntemler için önemli referans bölgelerdir. Daha sonra DRP sonucu oluşan sert eksuda, yumuşak eksuda, hemoraji ve mikroanevrizma gibi lezyonların öznelikleri çıkartılıp istatistiksel sınıflandırıcılar yardımıyla sınıflandırılmıştır.

**Anahtar Kelimeler:** Retina görüntü analizi, Görüntü kalite değerlendirmesi, Diyabetik Retinopati, Kan damarları, Optik disk, Makula, Fovea, Görüntü sınıflandırma, Görüntü işleme, Makine öğrenmesi.

PhD. Thesis

SUMMARY

RETINAL IMAGE QUALITY ASSESSMENT AND DETECTION OF DIABETIC  
RETINOPATHY DISEASE

Uğur ŞEVİK

Karadeniz Technical University  
The Graduate School of Natural and Applied Sciences  
Computer Engineering Graduate Program  
Supervisor: Assoc. Dr. Cemal KÖSE  
2014, 153 Pages

Diabetic retinopathy (DR) is an eye disease caused by diabetes, and results blindness if it is not diagnosed at early stages. DR is the major disease that causes blindness in the world. Patients with diabetes should be monitored using fundus imaging by an ophthalmologist for early diagnosis and treatment of DR. However, incidence of DR disease rises considerably depending on increased number of diabetes patients. Adequate amount of time and number of experts are needed to monitor DR patients. Unfortunately, these resources is unavailable at sufficient rates. Hence, we proposed automatic methods for diagnosing DR disease that will reduce diagnosis time of ophthalmologist by eliminating diagnosis of unnecessary images. In this thesis, a novel method for assessing adequacy of fundus image quality is proposed at first. After identification of suitable retinal images, fundamental anatomical structures of retina, which are blood vessels, optic disc and fovea, are detected. These anatomical structures are crucial for diagnosis of abnormalities in the retina. Finally, machine learning algorithms are used to identify hard and soft exudates, hemorrhages and microaneurysms.

**Key Words:** Retinal image analysis, Image quality assessment, Diabetic retinopathy, Blood vessels, Optic disc, Fovea, Image classification, Image processing, Machine learning.

## ŞEKİLLER DİZİNİ

### Sayfa No

- Şekil 1. Tezin genel akış şeması ..... 7
- Şekil 2. Gözün anatomik yapısı [6]..... 8
- Şekil 3. Retina anatomisi ve fotoreseptörler, (a) Retina anatomisi, (b) Retina katmanları, (c) Retina fotoreseptörleri [8]. ..... 10
- Şekil 4. Diyabetik Retinopati sonucu oluşan anormallikler. a) Mikroanevrizma, b) Hemoraji, c) Sert eksuda, d) Yumuşak eksuda, e) Optik diskin Neovaskularizasyona uğraması [10]. ..... 13
- Şekil 5. Neovaskularizasyon sonucu oluşan yeni damarlar [16]. ..... 17
- Şekil 6. DR’de lazer tedavisi ..... 18
- Şekil 7. Panretinal lazer fotokoagülasyonu işlemi ..... 19
- Şekil 8. Modern dijital fundus kameralar. a) Topcon firmasının TRC-NW300 Non-Mydriatic retina kamerası, b) Kowa Medicals firmasının nonmyd-WX3D retina kamerası ..... 21
- Şekil 9. (a.) Normal FFA görüntüsü. Damarlarda veya makulada herhangi bir sızıntıya ait parlak renkte beyazlık izlenmemektedir, (b.) DR’si olan bir hastanın FFA görüntüsü. Siyah ok ile gösterilen parlak renkteki beyazlık, damarlardan sızıntı olduğunu göstermektedir. .... 22
- Şekil 10. (a) Fundus kamera ile retina muayenesi, (b) Traksiyonel retina dekolmanı olan bir hastanın retinası. Retinanın normal rengini kaybettiği, beyaz zarların retina yüzeyini kaplayıp retinayı öne doğru çektiği izlenmektedir (siyah ok). ..... 22
- Şekil 11 a) Normal göz ultrasonografi görüntüsü. Beyaz ok göz sıvısını (vitreus), siyah ok retina tabakasını göstermektedir. b.) Sağ görüntüde traksiyonel retina dekolmanı olan bir hastanın göz ultrasonografisi görülmektedir. Retinanın normal yerinden öne, göz sıvısı içine doğru çekildiği izlenmektedir (siyah oklar). ..... 23
- Şekil 12. Soldaki görüntü (a), normal makulanın, sağdaki görüntü (b) kistoid makula ödemi olan makulanın OKT görüntüsünü göstermektedir. Normalde tüm retina tabakaları belli bir aralıklarla ve belli renklerde izlenmektedir. Ödemli bir makulanın ise kist şeklinde siyah boşluklarla dolu olduğu görülmektedir (kırmızı ok). ..... 23
- Şekil 13. Retina görüntüsünün RGB kanallarına ayrılması a) Orijinal görüntü, b) Kırmızı kanal, c) Yeşil kanal, d) Mavi kanal görüntüsü ..... 34

Şekil 14. (a) Tüm komşu bölgeler ile beraber bir IR bölgesi, b) (i,j) bölgesinin birinci çeyreğindeki p pikseli ve dört en yakın bölge merkezlerine göre ilişkisi.....	36
Şekil 15. (a) Tüm komşu bölgeleri ile beraber bir BR bölgesi. (b) (i,j) bölgesinin ikinci çeyreğindeki p pikseli ve iki en yakın bölge merkezlerine göre ilişkisi .....	36
Şekil 16. Üst-sol köşedeki bölge ve bu bölgenin komşuluk yapısı.....	37
Şekil 17. (a) Orijinal yeşil kanal retina görüntüsü, (b) a'nın tersinin alınması, (c) b'nin parlaklığının normalize edilmesi, (d) c'nin KSAHE dönüşümünün yapılması .....	38
Şekil 18. En sık kullanılan yapısal elemanlar .....	40
Şekil 19. Damar bölütlemesi için kullanılan yapısal eleman.....	43
Şekil 20. Yapısal eleman kullanılarak kapama ve açma işlemlerinin uygulanması .....	43
Şekil 21. 5 yarıçaplı disk yapısal elemanı kullanılarak aşınma ve genişleme işlemlerinin uygulanması .....	44
Şekil 22. Orijinal ve morfolojik işlemler sonucu elde edilen görüntüler.....	44
Şekil 23. Damar bölütlemesi.....	45
Şekil 24. OD bölgesinin tespit edilmesi, (a) Orijinal retina görüntüsü, (b) Dikey Sobel Kenar Filtreleme ile elde edilmiş görüntünün dikey histogramı .....	46
Şekil 25. OD aday bölgesinden OD'nin tespiti (a) OD aday bölgesinin tespiti, (b) OD aday bölgesinin parlaklığının düzeltimi, (c) Canny Kenar Algılama metodunun uygulanması, (d) Hough dönüşümü ile OD bölgesindeki olası OD adaylarının tespiti, (e) En büyük dairesellik değerine sahip aday OD olmaktadır .....	47
Şekil 26 a) Optik Diskin bulunması, b) Foveanın bulunduğu dairesel alan, c) Fovea bölgesi, d) Makula bölgeleri.....	49
Şekil 27. $d=1$ ve $\theta=(0^\circ, 45^\circ, 90^\circ, 135^\circ)$ için kullanılan pikseller.....	54
Şekil 28. GSBGM'nin elde edilmesi .....	55
Şekil 29. Zernike temel fonksiyonlarının birim disk üzerindeki etkileri.....	57
Şekil 30. Kenar algılama için kullanılan filtre katsayıları .....	59
Şekil 31. Ayrıştırma analizinin geometrik gösterimi .....	61
Şekil 32. YSA'nın genel yapısı.....	65
Şekil 33. DVM için ayırıcı düzlem ve destek vektörleri .....	68
Şekil 34. Rastgele Orman yönteminde veri seçimi .....	71

Şekil 35. Retina görüntülerinin kalite değerlendirmesi ve uygun görüntülerin tespiti için kullanılan akış diyagramı.....	75
Şekil 36. Retinanın ISNT bölgelerine ayrılması .....	77
Şekil 37. ISNT bölgelerinin maskeleri ve bu bölgedeki bölütlenen damarlar, a) Superior bölge maskesi, b) Superior bölgedeki damarlar, c) Inferior bölge maskesi, d) Inferior bölgedeki damarlar, e) Nasal bölge maskesi, f) Nasal bölgedeki damarlar, g) Temporal bölge maskesi, h) Temporal bölgedeki damarlar.....	78
Şekil 38. Uygun görüntünün ODBA sınırları ve anatomik yapıların otomatik tespiti, (a) ODBA sınırları, (b) Otomatik tespit sonucu bulunan OD ve Fovea bölgeleri .....	83
Şekil 39. Diyabetik Retinopati hastalığının tespiti için uygulanan yöntemlerin akış diyagramı .....	85
Şekil 40. Retina arka plan kestirimi, (a) Orijinal yeşil kanal retina görüntüsü, (b) 64x64 'lük medyan filtresi uygulanmış görüntü, (c) Koyu yapılar, (d) Parlak yapılar.....	86
Şekil 41. Görüntü iyileştirmede Gama düzeltilmesi .....	88
Şekil 42. Gama düzeltilmesi yapılan KAG .....	88
Şekil 43. Gama düzeltilmesi yapılan PAG.....	89
Şekil 44. PAG'dan OD'nin çıkartılması. a) Orijinal retina görüntüsü, b) OD'si tespit edilen retina görüntüsü, c) PAG, d) OD için hesaplanan maske, e) PAG'dan OD'nin çıkartılması, f) Parlak lezyonların orijinal görüntü üzerinde gösterilmesi .....	90
Şekil 45. DRIMDB ve DIARETDB1 veritabanlarında, OD tespitindeki başarılı ve başarısız sonuçlar.....	101
Şekil 46. Tüm özniteliklerin kullanıldığı deneylerin performans grafiği .....	107
Şekil 47. GA yaklaşımı ile öznitelik seçimi performans grafiği.....	110
Şekil 48. İDS yaklaşımı ile öznitelik seçimi performans grafiği. ....	112
Şekil 49. DRIMDB ve DIARETDB1 veritabanlarından tespit edilen başarılı ve başarısız örnekler. a) DRIMDB başarılı örnek, b)DRIMDB başarısız örnek, c) DIARETDB1 başarılı örnek, d) DIARETDB1 başarısız örnek.....	114
Şekil 50. Koyu DR lezyonları ve damar için tüm öznitelikler kullanıldığında elde edilen başarı.....	120
Şekil 51. GA yaklaşımı sonucu seçilen özniteliklerin sınıflandırma performansını gösteren grafik.....	122
Şekil 52. İDS yaklaşımı sonucu seçilen özniteliklerin sınıflandırma performansını gösteren grafik.....	124

Şekil 53. Adaboost'un oluşturduğu modeller .....	124
Şekil 54. KA'nın oluşturduğu en iyi model .....	125
Şekil 55. RO'nun oluşturduğu model .....	125
Şekil 56. Hemorajinin KA ile sınıflandırılması, (a) Orijinal görüntü (b) Elle etiketlenmiş görüntü, (c) KA ile sınıflandırılmış görüntü, (d) KA'nın bulamadığı lezyonlar ....	126
Şekil 57. Mikroanevrizmaların KA ile sınıflandırılması, (a) Orijinal görüntü, (b) KA ile sınıflandırılmış lezyonların ikili görüntüsü, (c) KA'nın bulduğu lezyonlar .....	127
Şekil 58. Parlak lezyonlar, (a) Yumuşak eksuda, (b) Sert eksuda .....	128
Şekil 59. Parlak lezyonların sınıflandırma performansları .....	129
Şekil 60. İDS yaklaşımı sonucu seçilen özneliklerin parlak lezyonları sınıflandırma performansını gösteren grafik .....	130
Şekil 61. GA yaklaşımı sonucu seçilen özneliklerin parlak lezyonları sınıflandırma performansını gösteren grafik .....	131
Şekil 62. Sert eksudanın bölütlenmesi, (a) Orijinal görüntü (b) Elle etiketlenmiş görüntü, (c) Arka plan yaklaşımı ile bölütlenmiş görüntü, (d) Yanlış pozitif (yeşil ile çevrilen) ve yanlış negatif (siyah ile çevrilen ) alanlar .....	132
Şekil 63. Yumuşak eksudanın bölütlenmesi (açık mavi ile çevrilen), (a) Orijinal görüntü, (b) Elle etiketlenmiş görüntü (yeşil ile etiketlenen), (c) Arka plan yaklaşımı ile bölütlenmiş görüntü, (d) Yanlış pozitif (yeşil ile çevrilen) ve yanlış negatif (siyah ile çevrilen ) alanlar .....	133

## TABLULAR DİZİNİ

	<b><u>Sayfa No</u></b>
Tablo 1. Diyabetik Retinopatinin safhaları ve oluşan anormallik [12]. .....	14
Tablo 2. Kullanıma açık retina görüntü veritabanları .....	32
Tablo 3. Gri-seviye histogramın istatistiksel öznitelikleri .....	53
Tablo 4. GSBGM'den hesaplanan Haralik-14 öznitelikleri .....	55
Tablo 5. Fleming ve arkadaşlarının retina görüntüsünü kalite bakımından sınıflandırması.....	76
Tablo 6. Retina görüntüsünün kalite bakımından sınıflandırılması .....	76
Tablo 7. 0o'deki Haralick dokusal özniteliklerinden bazıları. ....	80
Tablo 8. DR tespiti için kullanılan şekilsel öznitelikler .....	91
Tablo 9. 10-kere çapraz doğrulama yöntemi.....	94
Tablo 10. Hata Matrisi tablosu .....	97
Tablo 11. OD tespiti yaklaşımının performans sonuçları.....	100
Tablo 12. Fovea tespiti yaklaşımının performans sonuçları.....	100
Tablo 13. Literatürde OD tespitindeki başarı oranlarının karşılaştırılması.....	102
Tablo 14. DRIMDB veritabanından çıkartılan öznitelikler için performans tablosu (10 kere çalıştırılmıştır) .....	103
Tablo 15. Öznitelik seçimi yaklaşımlarının zaman performansları .....	105
Tablo 16. DAA+TBA sınıflandırma tablosu .....	106
Tablo 17. k-EYK sınıflandırma tablosu .....	106
Tablo 18. YSA sınıflandırma tablosu.....	106

Tablo 19. NB sınıflandırma tablosu .....	107
Tablo 20. DVM sınıflandırma tablosu .....	107
Tablo 21. Genetik algoritma yaklaşımı ile DAA'nın sınıflandırma tablosu .....	108
Tablo 22. Genetik algoritma yaklaşımı ile k-EYK'nın sınıflandırma tablosu .....	108
Tablo 23. Genetik algoritma yaklaşımı ile YSA'nın sınıflandırma tablosu.....	109
Tablo 24. Genetik algoritma yaklaşımı ile NB'nin sınıflandırma tablosu .....	109
Tablo 25. Genetik algoritma yaklaşımı ile DVM'nin sınıflandırma tablosu .....	109
Tablo 26. İDS yaklaşımı ile öznitelik seçiminde DAA'nın sınıflandırma tablosu .....	110
Tablo 27. İDS yaklaşımı ile öznitelik seçiminde k-EYK'nın sınıflandırma tablosu.....	111
Tablo 28. İDS yaklaşımı ile öznitelik seçiminde YSA'nın sınıflandırma tablosu .....	111
Tablo 29. İDS yaklaşımı ile öznitelik seçiminde NB'nin sınıflandırma tablosu.....	111
Tablo 30. İDS yaklaşımı ile öznitelik seçiminde DVM'nin sınıflandırma tablosu.....	112
Tablo 31. URG tespiti yaklaşımının performans sonuçları.....	113
Tablo 32. Koyu DR lezyonları ve damarlar için öznitelik seçimi yaklaşımlarının zaman karşılaştırmaları.....	118
Tablo 33. Tüm öznitelikler kullanıldığında koyu lezyonların ve damarların sınıflandırma performansları (H: Hemoraji, M: Mikroanevrizma, V: Damarlar) .....	119
Tablo 34. Koyu DR'ler için çıkartılan özniteliklerin kodlanması.....	120
Tablo 35. Genetik algoritma yaklaşımı ile seçilen özniteliklerin sınıflandırma performansları .....	121
Tablo 36. İleriye Doğru Seçim yaklaşımı ile seçilen özniteliklerin sınıflandırma performansları .....	123



Tablo 37. Tüm öznitelikler kullanıldığında parlak lezyonların sınıflandırma performansları (SE: Sert Eksuda, YE: Yumuşak Eksuda).....	129
Tablo 38. İDS yaklaşımı ile seçilen özniteliklerle parlak lezyonların sınıflandırma performansları (SE: Sert Eksuda, YE: Yumuşak Eksuda).....	130
Tablo 39. GA yaklaşımı ile seçilen özniteliklerle parlak lezyonların sınıflandırma performansları (SE: Sert Eksuda, YE: Yumuşak Eksuda).....	131
Tablo 40. Literatürdeki çalışmalar ile önerilen yöntemin karşılaştırma tablosu.....	134

## SEMBOLLER DİZİNİ

AA	:Ayrıştırma Analizi
CAD	:Bilgisayar Destekli Tanı
CHAID	:Chi-Squared Automatic Interaction Detector
CMIF	:Collection of Multispectral Images of the Fundus
ÇKA	:Çok Katmanlı Algılayıcı
DAA	:Doğrusal Ayrıştırma Analizi
DIARETDB1	:Diabetic Retinopathy Image Database 1
DR	:Diyabetik Retinopati
DRIMDB	:Diabetic Retinopathy Image Database
DRIVE	:Digital Retinal Images for Vessel Extraction
DRS	:Diyabetik Retinopati Çalışma Grubu
DVM	:Destek Vektör Makinesi
ETDRS	:Erken Tedavi Diyabetik Retinopati Çalışma Grubu
FFA	:Fundus Floresein Anjiyografi
FN	:Yanlış Negatif
FOV	:Görüş Alanı
FP	:Yanlış Pozitif
GA	:Genetik Algoritma
GSBGM	:Gri Seviye Birlikte Görülme Matrisinin
HD	:Hough Dönüşümü
ISNT	:Inferior, Superior, Nasal, Temporal
İDS	:İleriye Doğru Seçim
KA	:Karar Ağaçları
KAG	:Koyu Aday Görüntüler
k-EYK	:K-En Yakın Komşu
KHASE	:Kontrast Sınırlı Adaptif Histogram Eşitleme
KHT	:Kenar Histogram Tanımlayıcı
MESSIDOR	:Methods to Evaluate Segmentation and Indexing Techniques in the Field of Retinal Ophthalmology
NB	:Naive Bayes

NPDR	:Non-Proliferatif Diyabetik Retinopati
OD	:Optik Disk
ODBA	:Optik Diskin Beklenen Alanı
OKT	:Optik Koherens Tomografi
PAG	:Parlak Aday Görüntüler
PDR	:Proliferatif Diyabetik Retinopati
REVIEW	:Retinal Vessel Image Set for Estimation of Widths
RGB	:Kırmızı-Yeşil-Mavi (Red-Green-Blue)
RO	:Rastgele Orman
ROC	:Alıcı İşletim Karakteristiği
ROC	:Retinopathy Online Challenge
STARE	:Structured Analysis of The Retina
TBA	:Temel Bileşen Analizi
TN	:Doğru Negatif
TP	:Doğru Pozitif
URG	:Uygun Retina Görüntüsünün
YSA	:Yapay Sinir Ağları
ZM	:Zernike Momentleri

## **1. GENEL BİLGİLER**

### **1.1. Giriş**

Günümüzde, Tıbbi Görüntü Analizi, bilim adamları ve doktorların yoğun ilgi gösterdikleri araştırma alanlarından biridir. Bu alandaki çalışmaların amacı, ilginç patolojik ve anatomik görüntülerin istatistiksel ve matematiksel yöntemler kullanılarak teşhis, tedavi ve takip konusunda uzmanlara yardımcı olmaktır.

Son yıllardaki bilişim teknolojilerindeki gelişmelere paralel olarak tıbbi cihazların da gelişimi hızlanmıştır. Bunun sonucu olarak, doktorların teşhis ve tedavilerini bir öncekinden daha başarılı sonuçlar alabilmek için ayrıntılı bir şekilde insan bedeninin incelenmesi mümkün olmuştur. Böylece tekrarlanan tıbbi müdahaleler ve ölçülen değerler açısından doktorların karar destek mekanizması daha da güçlenmiş olur. Ancak, tüm bu gelişmelerin etkin olarak kullanılabilmesi için görüntü işleme, bilgisayarla görme, makine öğrenmesi, örüntü tanıma ve uzman sistemler gibi birçok disiplinin bulunduğu kapsamlı bir bilgi birikimi gerekmektedir.

Günümüzde, XRay, bilgisayarlı tomografi, ultrason, manyetik rezonans ve optik görüntüleme yöntemleri, uzmanların işini oldukça kolaylaştırmıştır. Ancak, bu görüntülerden anlamlı bilgiler çıkarmak, uzmanların teşhis ve tedavi için verecekleri kararlar açısından işi daha da kolaylaştıracaktır. Tıbbi görüntüleme yöntemleri, uzman hekimler ve bilim adamlarına insan vücudunun içerisini gözlemleyerek hastalıkların tanı ve teşhisinde vazgeçilmez bilgiler sunmaktadır. Görüntü alımındaki gelişmeler neticesinde, görüntülerin boyutları ve kalitesi artarak daha ince detayların yakalanması sağlanmıştır. Görüntü verisindeki bu yenilikler, eski görsel muayene teknikleri ile etkili ve doğru bir biçimde değerlendirilememektedir. Bu nedenle, tıbbi görüntü analizinde istatistiksel ve matematiksel hesaplama yöntemleri kullanılarak anlamlı bilgi çıkarımı önemli bir değere sahiptir.

Tıbbi görüntü analizi günümüzde bilim adamları ve doktorların yoğun ilgisini çeken ve hızla genişleyen bir araştırma alanı olmuştur. Tıbbi görüntüler üzerinde klinik açıdan bilgi çıkarmak için hesaplama algoritmaları tasarlanmaktadır. Tıbbi görüntülerin bilgisayar

ile analizi, ilginç patolojik ve anatomik yapıların görüntülenmesini ve yorumlanmasını sağlar. Tüm bu işlemler, hızlı tanı, işlem süresi ve sağlık maliyetlerinin düşürülmesinde, hastalık riskinin azaltılmasında ve uygun tedavi yöntemlerinin bulunmasında önemli yer teşkil etmektedir. Geçmiş yıllarda, gerçek zamanlı 3B ekokardiyografi gibi tıbbi görüntülemedeki büyük gelişmelere rağmen görüntülerin yorumlanması çoğunlukla uzmanlar tarafından yapılmaktaydı. [1,2]. Bununla birlikte uzman hekim, görüntülerdeki gürültü, yetersiz görüntü kalitesi ve göz yorgunluğu gibi nedenlerle tıbbi görüntüleri yorumlaması doğru teşhis açısından olumsuz etkilere neden olabilmekteydi.

Tıbbi görüntü analizi için geliştirilen bilgisayar tabanlı yöntemler, tıbbi görüntülerin yorumlanmasını arttırmak ve görüntülerden nicel ölçümler elde ederek tıp uzmanlarına yardımcı olma amacını taşımaktadır. Bilgisayar Destekli Tanı (Computer-Aided Diagnosis-CAD), tıp uzmanının tıbbi görüntülerin bilgisayarlı analiz sonuçlarını kullanarak tanı koymada “ikinci bir görüş” ya da karar destek sistemi olarak tanımlanabilir [1,2]. Bilgisayar yazılımları, uzmanın hastalığın yaygınlığını değerlendirmesine yardımcı olmak ve şüpheli anormalliklerin yerinin belirlenmesine de olanak sağlamaktadır. Tıbbi görüntülerin yorumlanmasının, normal insanların kontrolü (tarama) ve anormalliklerin nitelendirilmesi olarak iki temel amacı vardır [1]. Tarama görüntülerinin yorumlanması için uzmanlar görsel olarak genellikle büyük miktarlarda sağlıklı görüntüleri incelemektedirler. Bu işlem, tekrarlanan bir işlem olduğundan inceleme işleminin performansını azaltarak gözetim hatalarının artışına neden olabilmektedir. Bu nedenle, bir bilgisayar yardımıyla inceleme işlemi, tanısal performansı, patolojik görüntülerdeki anormalliklerin algılanmasını ve sağlıklı kişilerden ayrılmasını daha etkin bir biçimde sağlayabilmektedir. Bir lezyon tespit edildiğinde, lezyonun durumunu belirlemek ve önerilen eylemlerin belirlenmesi için o lezyondan öznelik çıkarımı yapmak gerekmektedir. Özneliklerin değişkenliği ve lezyonların karmaşık anatomisi nedeniyle insanların öznelik çıkarımı farklı yorumlama hatalarına yol açabilmektedir. Bilgisayar destekli tanı sistemleri, görüntülerden elde edilen lezyonların doğru ve tekrarlanabilir ölçümlerini sağlayarak tıp uzmanlarına yardımcı bir sistem olmaktadır.

CAD sistemleri, mamografi görüntülerinden meme kanserinin ve göğüs röntgeninden akciğer nodüllerinin tespiti gibi farklı görüntüleme yöntemleri kullanarak tıbbi görüntülerdeki birçok farklı türdeki anormalliklerin algılanmasında yaygın olarak

kullanılmaktadır. Fakat CAD sistemleri, retina görüntüleme gibi diğer görüntüleme yöntemlerinde yakın zamanda kullanılmaya başlanmıştır. Bu nedenle, son zamanlarda literatürde oldukça yoğun çalışmalar yapılmaktadır. Özellikle otomatik retina görüntü analiz sistemleri üzerinde çok sayıda çalışma vardır [3–5]

## 1.2. Tezin Amacı ve Yapısı

Çalışmanın amacı, oftalmologların fundus (retina) kameralarla elde ettikleri retina görüntülerinin değerlendirilebilir olup olmadığını, otomatik olarak kalite değerlendirmesi yaparak, elde edilen görüntünün kaliteli ve yeterli bilgi içermesi halinde, bu görüntü kullanılarak Diyabetik Retinopati (DR) hastalığının belirtilerinin teşhisi konusunda bir karar destek sistemi oluşturmaktır.

Retina görüntüleri yazılım destekli olarak, fundus kameralar yardımıyla belirli bir açıdaki görüş alanının (Field of View - FOV) fotoğrafı çekilerek elde edilmektedir. Ancak, elde edilen görüntülerin kalitesi, hastalıkları ve dokuları teşhis etmek için yeterli midir? Ya da eğer görüntü kaliteli ise DR lezyonlarını tespit edecek yeterli bilgi ve referansa sahip midir? Bu soruların cevabının otomatik olarak CAD sistemleri ile verilmesi oftalmologlar için büyük bir kolaylık sağlayacaktır. Otomatik bir görüntü kalite değerlendirme sistemi sayesinde yeterli bilgiye sahip olmayan kalitesiz görüntülerin gereksiz yere depolanması, oftalmoloğun bu görüntü üzerinde yanlış değerlendirme yapabilme olasılığı ve gereksiz zaman kaybının engellenmesi sağlanmış olur.

Çalışmadaki diğer bir hedef ise DR hastalığının erken safhalarında oluşan mikroanevrizma, hemoraji, sert eksuda ve yumuşak eksuda gibi lezyonların otomatik tespitini yapıp oftalmologlar için karar destek sistemi oluşturmaktır. DR, diyabete bağlı oluşan bir hastalık olduğundan dolayı tedavisi için erken teşhis mutlaka gereklidir. DR'nin ilk evrelerinde sert eksuda ve hemoraji lezyonları görülmektedir. Dolayısı ile bu lezyonların erken teşhis ile belirlenmesi, bu hastalığın tedavi süresinin kısalmasını ve hastalığı durdurabilmek için önemli adımlar atılmasını sağlayabilir. Bu amaçla çalışmada, otomatik olarak DR lezyonlarının, görüntü tanıma ve sınıflandırma yaklaşımları kullanılarak hızlı ve başarılı bir şekilde tespit edilmesi hedeflenmiştir.

Bu çalışmanın amaçlarını maddeler halinde özetleyecek olursak;

1. Kullanılacak retina görüntülerinin elde edilmesi ve açık erişimli bir retina görüntü veritabanının oluşturulması: Çalışmada analiz amacıyla kullanılacak görüntüler Karadeniz Teknik Üniversitesi, Tıp Fakültesi, Göz Hastalıkları Anabilim Dalı'na gelen hastalardan elde edilmiştir. Bu görüntüler hasta ile ilgili herhangi bir bilgi taşımadığından dolayı etik kullara aykırı herhangi bir durum oluşmamıştır. Elde edilen görüntülerdeki DR lezyonları, bu bölümün öğretim üyeleri gözetiminde elle etiketlenerek referans görüntüler oluşturulmuştur. Aynı şekilde, görüntü kalite sınıfları oluşturulmuştur.
2. Retinadaki referans yapılar olarak kullanılan optik disk, fovea ve kan damarlarının otomatik tespiti: Retinadaki bu anatomik yapıların tespiti lezyonların konumlandırılması ve bu yapılara benzer lezyonların ayrıştırılması için mutlaka gerekli bir aşamadır.
3. Retina görüntülerinin kalite değerlendirmesinin yapılması ve uygun retina görüntüsünün tespiti: DR lezyonlarının doğru analiz yapılabilmesi için yeterli kaliteye ve bilgiye sahip uygun görüntülerin belirlenmesi gerekmektedir. Kalite değerlendirmesi, hem yerel hem de global öznelikler çıkartılıp, sınıflandırıcılar tarafından üç sınıfa ayrıştırılarak yapılacaktır. Böylece, otomatik analiz sistemlerinin performans başarısının oldukça artacağı düşünülmektedir.
4. Retina görüntüsünde arka plan kestirimi yapılıp, aday lezyonların ve anatomik yapıların çıkartılması: Bu aşamada, arka plan kestirim yöntemi ve basit eşikleme yöntemi kullanarak retina üzerindeki hastalıklar ve anatomik yapıların sağlıklı arka plan dokusundan ayrıştırılması gerekmektedir. Böylece aday lezyonlar çıkartılmış olacaktır.
5. Tespiti yapılacak olan lezyonlardan öznelikler çıkarmak: Aday lezyonların bulunduğu görüntü elde edildikten sonra daha önceden oftalmologlar gözetiminde elle etiketlenmiş lezyonlardan öznelikler çıkartılacaktır. Çıkartılan öznelikler sınıflandırıcıların eğitimi için kullanılacaktır. Bu aşamada, DR lezyonlarını tespit

edecek en iyi sınıflandırıcıya ve modele karar verilecektir. Tespit edilen başarılı sınıflandırıcıyla, aday lezyonların bulunduğu görüntüler üzerinde sınıflandırma yapılacaktır.

6. Elde edilen sonuçların uluslararası indekslerde taranan dergilerde veya konferanslarda yayınlanması.

Görüntü analizi sistemleri genellikle düşük ve yüksek seviye işlemler içerir. Düşük seviye analizde, görüntü piksellerinin parlaklık değerleri sayısal bir matris haline dönüştürülür ve bu sayısal matris üzerindeki bölgeler bölütlenmeye çalışılır. Yüksek seviye analizde ise, görüntü üzerindeki bölgelerin öznitelikleri çıkartılarak, bu öznitelikler ile sınıflandırma algoritmalarının eğitilip bölgelerin sınıflara ayrılması sağlanmaktadır. Örneğin medikal görüntülerde görünen lezyonların veya dokuların oluşturduğu bölgeler, düşük ve yüksek seviyeli görüntü analiz yöntemleri kullanılarak tespit edilmektedir.

Bu çalışmada öncelikle, retina görüntülerindeki anatomik yapılarının tespit edilip, bu yapıların içerdikleri bilgi oranı ölçülerek görüntü kalitesi belirlenmiştir. Belirlenen kaliteli görüntüler arasında retina üzerindeki anatomik yapıların konumlarının ve görüntü üzerinde tüm retina yapılarının (kan damarlar, makula, optik disk, fovea vb.) mevcut olup olmadığı kontrol edilmiştir. Bu işlem sonunda oftalmologlar için uygun retina görüntüsüne karar verilmiştir. Uygun retina görüntüsü üzerinde, arka plan kestirim yaklaşımı kullanılarak arka plandaki retina dokusu silinmiştir. Geriye retina üzerindeki anatomik yapılar ve lezyonlar kalmıştır. Retina anatomik yapılarından optik disk, bu görüntü üzerinden maskeleyme yöntemi ile elimine edilmiştir. Geriye kalan anatomik yapılar ve lezyonlardan da şekilsel ve istatistiksel öznitelikler çıkartılarak sınıflandırma algoritmaları yardımıyla DR lezyonlarını sınıflandıran en iyi sınıflandırıcı tespit edilmiştir.

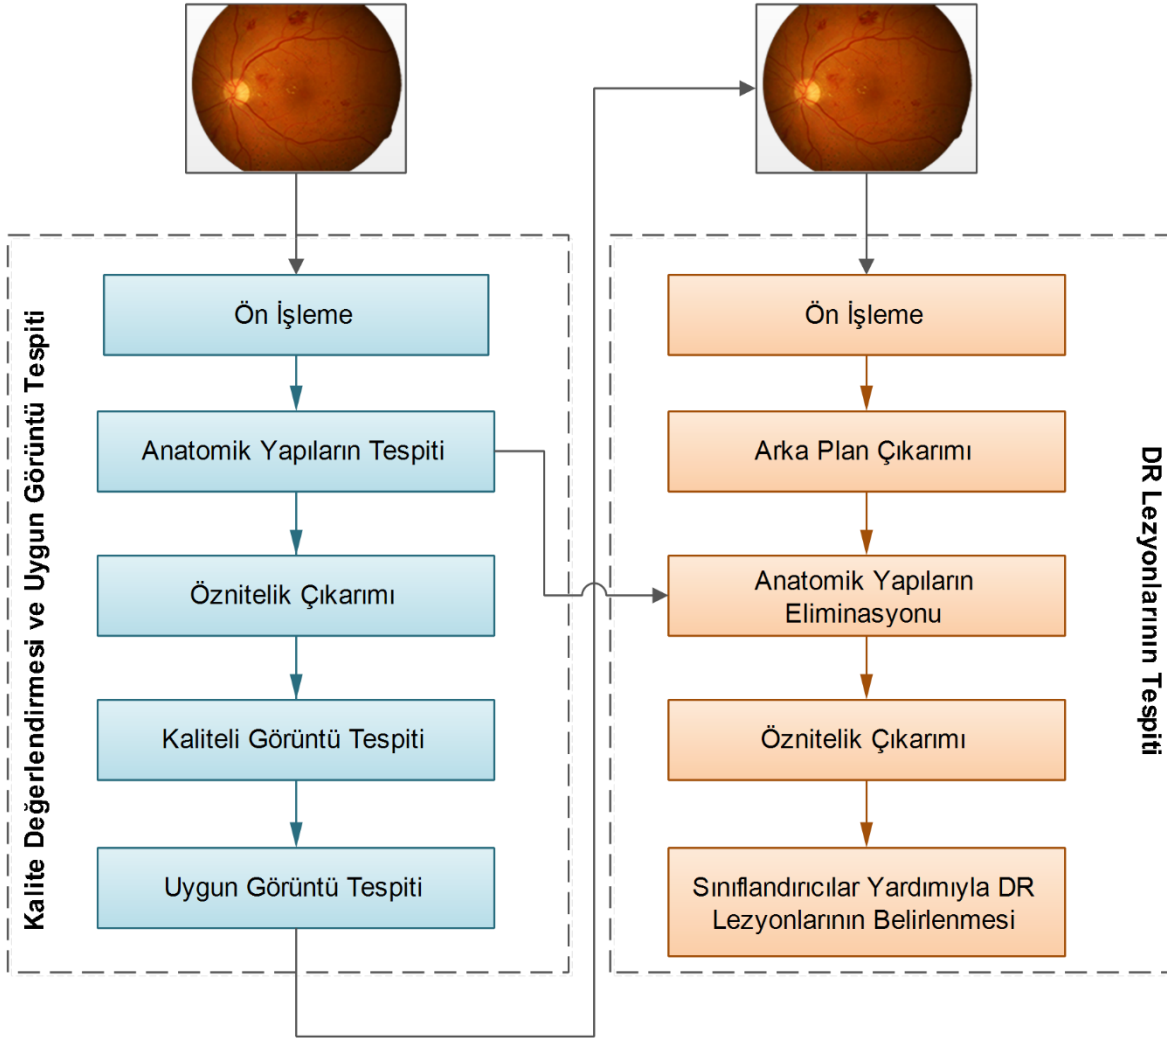
Tezin birinci bölümünde, göz ve retinanın anatomik yapısı, DR hastalığı sonucu meydana gelen anormallikler ile ilgili genel bilgiler verilmiştir. Ayrıca, literatürde kullanılan retina görüntü veritabanlarından ve tez ile ilgili literatürde yapılan çalışmalardan bahsedilmiştir.



İkinci bölümde, retina görüntü kalitesinin ölçümü için anatomik yapıların (damarlar, optik disk ve fovea) tespiti, öznitelik çıkarımı ve sınıflandırıcılar yardımıyla görüntü kalitesinin sınıflandırılması yapılmıştır. Bu çalışmada yeni önerilen bir yaklaşımla, kaliteli görüntüler arasından yeterli bilgi ve kaliteye sahip uygun retina görüntülerinin tespiti yapılmıştır. DR lezyonlarının tespitinde ise, öncelikle arka plan kestirimi yardımıyla retinanın sağlıklı dokusu elimine edilmiş, daha sonra geriye anatomik yapılar ve lezyonlar kalmıştır. Arka plan kestirimi sonrasında, parlak ve koyu yapıların ayrı ayrı olduğu iki yeni görüntü elde edilmiştir. Bu sayede basit ve hızlı biçimde DR lezyonları için ön bir sınıflandırma işlemi yapılmıştır. Daha önceden kalite değerlendirmesi için tespit edilen optik disk, eldeki parlak yapıların bulunduğu görüntüden çıkartılarak geriye parlak lezyonların kalması sağlanmıştır. Koyu yapıların bulunduğu görüntü ise direk olarak sınıflandırıcılara verilmiştir. DRIMDB veri tabanından elle seçilerek bölütlenen lezyonlardan istatistiksel ve şekilsel öznitelikler çıkartılarak literatürde en çok kullanılan Karar Ağaçları (KA), Rastgele Orman (RO), Adaboost, Naive Bayes (NB), k-En Yakın Komşu (k-EYK) ve Yapay Sinir Ağları (YSA) sınıflandırıcıları ile eğitilmiş olup sınıflandırma performansının en iyi olduğu sınıflandırıcı kullanılarak test görüntülerinden lezyonlar tespit edilmiştir.

Tezin üçüncü bölümünde, kalite değerlendirmesi, uygun retina görüntüsünün tespiti, DR lezyonlarının tespiti aşamasında önerilen yöntemlerin, literatürde kullanılan başarı metrikleri ile ölçülmesine yer verilmiştir.

Son olarak tezin dördüncü ve beşinci bölümlerinde bu çalışmanın sonuçlarından ve gelecekteki çalışmalardan bahsedilmiştir. Tezin genel akış diyagramı Şekil 1'de görülmektedir.




Şekil 1. Tezin genel akış şeması

### 1.3. Gözün Yapısı

Göz, yaklaşık 2.5 cm çapında küresel bir yapıya sahip olan, kafanın ön kısmında kaş kemeri, elmacık kemikleri ve burun kemeri arasında oluşan göz çukurunun içinde yer alan ve görme sisteminin reseptörü olan organdır. Ana hatlarıyla bir fotoğraf makinesine benzetilecek olursa, her ikisinde de gelen ışığı arka kısımdaki hassas bölgeye yansıtan bir merceğe sahip olmalarıdır. Bu hassas bölgeye fotoğraf makinesinde sensör ya da film denirken, gözde retina tabakası olarak adlandırılmaktadır.

Şekil 2’de de görüldüğü gibi gözün ön kısmındaki saydam tabakaya kornea denilirken, bunun dışındaki beyaz ve sert tabakadan oluşan kısma sklera tabakası denir. Korneanın arkasında bulunan ve ortasında göz bebeği denilen yapıya sahip renkli tabakaya iris denir. İrisi kontrol eden kaslar, korneadan giren ışığın şiddetine göre, göz bebeğinin genişliğini ayarlar. Bu fotoğraf makinelerindeki diyaframa benzetilebilir. Göz bebeğinden giren ışık, irisin arkasında yer alan göz merceğinden geçerek gözün arka kısmındaki retina tabakasına düşer. Göz merceği görmenin net olabilmesi için odaklama görevini kendi şişkinliğini azaltıp arttırarak kırma derecesi (diyoptri) ile gerçekleştirir.



Şekil 2. Gözün anatomik yapısı [6].

Kornea ile göz merceği arasındaki odacıkta (ön kamara) sürekli olarak üretilen saydam bir sıvı bulunur. Bu sıvının basıncı vücudumuz tarafından ayarlanır ve kornea ile irisin birleştiği köşedeki açıklıktan Schlemm kanalı ile kana karışmaktadır. Göz küresinin içi, jelâtin kıvamında saydam bir madde (corpus vitreum) ile doludur.


Gözün arka iç kısmına retina denilen 10 kattan oluşmuş bir tabaka bulunur. Retina tabakasını sklera ile retina arasında yer alan damar tabaka (choroid) besler. Gözün ön kısmındaki saydam tabakanın ve dışarıyla temas eden kısımların korunması için konjonktiva denilen ince bir zarla kaplanmıştır. Konjonktiva ile korneanın korunması ve kurummasının önlenmesi için gözyaşı adı verilen bir salgı üretilir. Göz çukuru içinde yer alan gözyaşı bezi sürekli olarak salgı üretir ve fazlası, göz çukurunun buruna yakın kısmında yer alan bir kanalla (lâkrimal kanal) burna akıtılır. Gözün ön kısmında yer alan göz kapakları belirli aralıklarla kapanarak gözü nemlendirme görevi ile birlikte, tehlike karşısında refleksiyle kapanarak gözü dış tehlikelerden korur. Gözün birbirinden belirli açıklıkta iki tane olması üç boyutlu görmeyi (stereoskopi) sağlar. Böylece cisimlerin uzaklığını belirlemek de mümkün olabilmektedir.

### 1.3.1. Retina


Retina, göz dibine oftalmoskopta bakıldığında görülebilir. Optik sinirin göz küresini elekli bir delik sisteminden geçerek çıktığı nokta papilla'dır. Aynı bölge optik disk, optik sinir başı olarak da adlandırılır. Optik sinir başı, retinanın merkezinde yer alır, burada fotoreseptör hücreler olmadığı için bu noktaya düşen ışık algılanamaz ve görme alanındaki izdüşümü "kör nokta" olarak anılır. Optik sinir başı boyutları kişiden kişiye değişiklik gösterse de yaklaşık 2,5 mm çapındadır. Şakağa doğru olan temporal kısmında makula yer alır, makula yaklaşık 5-6 mm çapındadır, merkezinde sarı nokta olarak da adlandırılan fovea yer alır. Foveada koniler yoğundur ve burası keskin görmemizi sağlar. İnsanlar ve primatlarda bir tane fovea vardır, ancak şahin gibi bazı kuşlarda iki tane fovea vardır, kedi ve köpeklerde ise fovea yerine bu işlevi üstlenen bant şeklinde anatomik bir alan bulunur. Makula dışında kalan bölge ise çevresel (periferik) retina olarak adlandırılır. Retina, iris köküne yaklaşık 5-6 mm geride *ora serrata* denilen alanda sonlanır [7].

Duyusal retina çok katlı bir yapıya sahiptir ve ışık enerjisini sinirsel uyarıya çevirir. Duyusal retina, sinir hücreleri ve destek hücrelerinden oluşmaktadır. Duyusal retinanın en iç katmanı sinir lifi katmanıdır, bu katman ganglion hücrelerinin akson denilen uzantıları tarafından oluşturulur. Akson ve dendritler tüm sinir hücrelerinde bulunan ve hücreler arası sinirsel iletişimi sağlamak için özelleşmiş olan ince uzantılardır. Ganglion hücrelerinden sonra, iç pleksiform katman yer alır. Bu katman ganglion hücrelerinin dendritleri ile daha


dıştaki hücrelerin aksonal uzantılarının birleştiği bir katmandır. Daha sonra bipolar hücrelerinin gövdelerinin yer aldığı iç çekirdek tabaka gelir. İç çekirdek tabakada yer alan bipolar ve diğer bazı hücrelerin uzantılarının daha dış kısımlarda yer alan fotoreseptör hücreleri ile buluştukları dış pleksiform tabaka yer alır. Daha sonra, fotoreseptör hücrelerinin gövdelerinin yer aldığı dış çekirdek tabaka ve fotoreseptör hücrelerinin dış segmentlerinin yer aldığı fotoreseptör tabakası gelir [7].



(a)



(b)



(c)

Şekil 3. Retina anatomisi ve fotoreseptörler, (a) Retina anatomisi, (b) Retina katmanları, (c) Retina fotoreseptörleri [8].

Duyusal retina, dört ana grup hücreden oluşur.

- Fotoreseptörler
- Bipolar hücreler
- Ganglion hücreleri
- Destek hücreleri

### **1.3.2. Fotoreseptörler**

Çubuk ve koni olmak üzere iki tip fotoreseptör vardır. Çubuk hücrelerinin sayısı 110-125 milyon, koni hücrelerinin sayısı ise 6,3-6,6 milyon arasındadır. Fotoreseptör hücreleri görünür ışığı dalga boyuna yani rengine uygun olarak elektrik enerjisine çevirir. Bu uyarılar da retinanın en iç tabakasında yer alan ganglion hücrelerinin uzantıları tarafından oluşturulan optik sinir ile beyindeki görme merkezlerine ulaştırılır [7].

#### **1.3.2.1. Çubuk Hücreleri**

Boyları yaklaşık 100 - 120 mikron arasında ve ince uzun yapıdadırlar. Çubuk hücreleri alaca karanlıkta görmemizi sağlarlar. Bu hücreler renklere karşı duyarlı değildir ve renkleri grinin tonları olarak görmemizi sağlarlar. Dış kısım ışık uyarımının alındığı bölgedir. Burada ışığa duyarlı bir pigment olan rodopsin bulunur. Bir çubuk hücresinin dış kısmında yaklaşık 600-1000 adet yatay yerleşimli disk vardır. Rodopsin bu disklerin zarları üzerinde yer alır. Birleştirici bir sap ile hücrenin iç kısmı ile iletişim sağlanır [7].

#### **1.3.2.2. Koni Hücreleri**

Boyut olarak 65-75 mikron arasında ve uzun ince yapıda olan koni hücreleri, yapı olarak çubuk hücrelerine benzer ve dış kısımları koni şeklindedir. Koni hücreleri sarı nokta (fovea) denilen alanda oldukça yoğundur. Koni hücreleri, gündüz ışığında ve renkli görmemizi sağlarlar. Görme merkezi ile görevli beyin korteksinin % 90'nı, bu sarı noktadan gelen uyarıları işlemekle görevlidir [7].

### **1.3.3. Bipolar Hücreler**

Bu hücreler, fotoreseptör hücrelerinden gelen uyarıları diğer hücrelere iletir. Bu hücrelerin bir alıcı kısmı bir de iletici kısmı vardır. Bu nedenle bipolar (iki kutuplu) olarak adlandırılır [7].

### **1.3.4. Ganglion Hücreleri**

Ganglion hücreleri, retinanın iç kısmında yer alırlar ve gözbebeğinden gözün içine bakıldığında aksonal uzantıları ile oluşturdukları ince çizgiler görülebilir. Retinanın büyük bir kısmında tek bir katman oluştururlar ancak optik sinire yaklaşıldığında bu katmanların sayısı artar. Ganglion hücreleri multipolar (çok kutupludur), dendritleri ise bipolar ve amakrin hücrelerinin aksonları ile komşuluk içerisindedir. Ganglion hücrelerinin uzun aksonları vardır. Bu aksonlar retina yüzeyine ulaşınca yaklaşık 90 derece açı yaparak optik sinirde toplanır ve gözün içini terk ederler. Ganglion hücreleri, fotoreseptör hücrelerce oluşturulan elektrik sinyallerini beyindeki görme merkezlerine taşırlar. Optik sinir işte bu ganglion hücrelerinin uzantılarının bir araya gelmesinden oluşmuştur. Yatay hücreler, çubuk ve koni hücrelerinin terminal şişkinliklerine yakın yerleşimlidirler. Multipolar hücrelerdir ve görsel uyarımın gerçekleşmesinde görev alırlar [7].

### **1.3.5. Destek Hücreleri**


Destek hücreleri olarak adlandırılan Müller hücreleri, neredeyse tüm retina kalınlığını kat eden, uzantıları olan, soluk boyanan ve ince uzun şekilde olan hücrelerdir. Müller hücreleri, retinada sinir hücreleri tarafından doldurulmayan boşlukları doldururlar ve iç - dış sınırlayıcı zarı oluştururlar [7].

## **1.4. Diyabetik Retinopati**

*Diabetes Mellitus* (şeker hastalığı), insülinin vücutta bulunmaması veya görev yapamaması nedeniyle kan şekerinin yüksekliği sonucu oluşan sistematik bir hastalıktır. Bütün vücudun damarlarını, özellikle küçük ve orta çaplı damarları etkiler. Ömür boyu süren



bir hastalık olduğundan, yıllar içinde çeşitli belirtiler ortaya çıkarır. Diyabetten en çok etkilenen organlar, milyonlarca kılcal damarın bulunduğu göz, böbrek ve beyindir [9].



Şekil 4. Diyabetik Retinopati sonucu oluşan anormallikler. a) Mikroanevrizma, b) Hemoraji, c) Sert eksuda, d) Yumuşak eksuda, e) Optik diskin Neovaskularizasyona uğraması [10].

Diyabet hastalığı gözün tüm bölümleri etkilemektedir. Diyabetik Retinopati (DR), gözün görmeyi sağlayan sinir tabakası olan retinadaki kılcal damarların etkilenmesiyle ortaya çıkan tablodur. Bu küçük kılcal damarlarda, kırmızı kan hücreleri ve pıhtılaşma hücrelerinde oluşan değişiklikler sonucu retina beslenemez ve oksijensiz kalır. Damar çeperlerinde bozulmalar ve damar geçirgenliğinde artış olur. Bu da damar dışında yani retina içinde kanamalara ve serum sızıntısına yol açmaktadır. Düşük oksijen seviyesi anormal yeni damarların oluşumuna da yol açabilir. Oluşan bu damarlar retinanın kendi damarları kadar sağlam olamazlar ve taşıdıkları kanı kolayca duvarlarından sızdırmaya başlarlar. Bu safhadan sonra Proliferatif Diyabetik Retinopati (PDR) dönemi başlar [11].



Tablo 1. Diyabetik Retinopatinin safhaları ve oluşan anormallik [12].

Sınıf	Alternatif Adlandırma	Özellikleri
Arka plan Diyabetik Retinopati	Hafif/Orta Nonproliferatif Diyabetik Retinopati	<ul style="list-style-type: none"> <li>▪ Hemorajiler</li> <li>▪ Ödemler</li> <li>▪ Mikroanevrizmalar</li> <li>▪ Sert Eksudalar</li> <li>▪ Yumuşak Eksudalar</li> <li>▪ Genişleyen Damarlar</li> </ul>
Ön -Proliferatif Diyabetik Retinopati	Şiddetli/ Çok Şiddetli Nonproliferatif Diyabetik Retinopati	<ul style="list-style-type: none"> <li>▪ Koyu Hemorajiler</li> <li>▪ Toplardamar Anormallikleri</li> <li>▪ Retina İçi Mikrovasküler Anormallikleri</li> <li>▪ Çoklu Yumuşak Eksudalar</li> </ul>
Proliferatif Diyabetik Retinopati	Proliferatif Diyabetik Retinopati (PDR)	<ul style="list-style-type: none"> <li>▪ Optik disk ve diğer bölgelerde yeni damarlanmalar oluşması</li> </ul>
İlerlemiş Diyabetik Göz Hastalıkları	Proliferatif Diyabetik Retinopati Komplikasyonları	<ul style="list-style-type: none"> <li>▪ Toplardamar Hemorajisi</li> <li>▪ Retina Dekolmanı</li> <li>▪ Neovasküler Glokom</li> </ul>

Gelişmiş ülkelerde 20-74 yaş grubunda görülen en önemli körlük nedeni DR'dir [13]. Hastalığın süresi, diyabetik retinopatinin gelişmesinde en önemli rolü teşkil eder. 5 yıl veya daha az süreli Tip 1 diyabeti olan hastalarda DR riski nadirdir. 5-10 yıl arasındaki hastalarda % 27, 10 yıldan daha uzun süreli diyabeti olanlarda ise % 71-90 DR'ye rastlanır. 20-30 yıl sonra ise yeni retinopati olanlar (insidans) % 95'lere çıkar ve hastaların % 30-50'sinde PDR'ye rastlanır. Tip 2 diyabetlilerde 11-13 yıl sonra risk altındaki nüfuzda retinopati olanlar (prevelansı) % 23, 16 ve daha uzun yıl sonra % 60 olarak bulunmuştur [13].

DR'nin çeşitli evreleri vardır. Başlangıçta küçük damarlarda değişiklikler meydana gelir. Bu değişikliklerin neticesinde retinada kanamalar başlar. Damarlar, sızdırmaması gereken maddeleri damar dışına sızdırır. Bu sızıntı retinada sıvı toplanmasına (ödem) yol açar.

Ayrıca küçük damarlarda tıkanıklıklar olur, tıkanan damarlar dokulara gerekli oksijeni ve besini götüremez. Sonuç olarak, yeni damarlar ortaya çıkar, ancak oluşan yeni damarlar anormal yapıda olduğundan kolayca kanar, şiddetli göz içi kanamalarına ve görme kaybına yol açarlar.

DR alanında çok merkezli üç araştırma yürütülmektedir: Diyabetik Retinopati Çalışma Grubu (DRS), Erken Tedavi Diyabetik Retinopati Çalışma Grubu (ETDRS) ve Diyabetik Retinopati Vitrektomi Çalışma Araştırma Grubu. ETDRS'ye göre DR, daha erken evre olan Non-proliferatif Diyabetik Retinopati (NPDR) ve daha ileri evre olan PDR olmak üzere iki sınıfa ayrılmıştır [2,14].

#### **1.4.1. Non-proliferatif Diyabetik Retinopati**

DR'nin erken dönemde görülen değişiklikleridir. Genellikle başlangıç retinopatisi olarak bilinen NPDR, DR'nin erken evresi olup gözdeki anormal değişikliklerin ilk göstergesidir [14]. Temelde anormal damar geçirgenliğinin etkisi sonucu retina dokusu çevresinde su, kan hücresi, protein, yağ ve diğer büyük moleküllerin sızıntısı sonucu oluşan durumlardır. Bu aşamada hastalar genellikle görme bozuklukları yaşamadığından dolayı bu hastalığın farkında olmamaktadır. Bu aşamadaki teşhis gelecekteki yan etkilerini önlemek için büyük bir öneme sahiptir ve aşağıdaki lezyonların sayısını ve konumunu saptama olanağını sağlar [2,15].


- Mikroanevrizmalar: DR'nin en erken klinik belirtilerini gösterir. Damar duvarlarının zayıflığı nedeniyle retina kılcal damarlarındaki küçük keseleşme sonucu oluşurlar. Retina yüzeyinde küçük yuvarlak koyu kırmızı noktalar halinde görünürler [2]. Mikroanevrizmalar, 12 µm ile 125 µm çapındadırlar; ancak 30 µm üstündekiler muayenede tespit edilebilir. 125 µm'den büyükleri hemoraji olarak kabul edilmelidir [2].

- **Retina İçi Hemorajiler:** Hemorajiler, retinada mikroanevrizmaların veya kılcal damarların yırtılması sonucu oluşan kan birikintileridir. Retinadaki kanama derinliğine bağlı olarak değişik şekillerde olabilirler. Hemorajiler retinada derinde bulunuyorsa, mikroanevrizmalardan farksız biçimde keskin kenarlı küçük kırmızı lekeler olarak da görülebilir. Retinanın yüzeyinde bulunuyorsa alev şeklinde kırmızı daha büyük bölgeler halinde olurlar. DR ilerledikçe hemorajilerin sayısında artış görülür [2].
- **Sert Eksuda:** Sert Eksudalar zayıflamış damarlardan sızan yağ ve protein oluşumları şeklindedir. Genellikle kılcal damarların sızıntı çevresinde tek nokta, kümelenmiş ya da büyük halkalar biçiminde kenarları keskin ve sarımsı-beyaz bölgeler halinde bulunurlar. Aynı zamanda hemorajiler gibi, hastalığın şiddeti ile sayıları artış gösterir [15].
- **Yumuşak Eksuda:** Bu eksuda türü, retinadaki arteriol (büyük atardamarları kılcal damarlara bağlayan küçük atardamar) damarların tıkanıklığı ve retinal iskemi (bir organ ya da bölümü besleyen atardamarda tıkanma yahut spazm nedeniyle, o organ ya da bölüme kan ulaşamaması) nedeniyle retina tabakası yüzeyindeki şişliklerdir. Genellikle, büyük damarların duvarlarında veya bir hemoraji bölgesi ile birlikte bitişik, bulanık kenarlı, beyazımsı kütleler olarak, retina üzerinde bulunurlar. Bu eksudalar, orta-ağır non-proliferatif diyabetik retinopati döneminde görülürler.

NPDR'nin bazı durumlarında, damar geçirgenliğine bağlı olarak retina kalınlaşması (ödem) ve geniş miktarlarda yağ katmanına neden olabilir. Eğer bu retina kalınlaşması veya yağ katmanları retinanın orta bölgesinde yani makula bölgesinde oluşmuşsa görme keskinliğini direk olarak etkileyebilir [14]. Bu duruma klinik açıdan belirgin makula ödemi denir. Makula ödemi, diyabetik hastaların yaklaşık %20'sinde ve NPDR'ye sahip hastalarda görme kaybının en sık nedenidir. Diyabetik makula ödemi olan hasta görme düzeyinde bulanıklık, koyulaşma, görme alanının ortasında bozulma veya sadece merkezi görme alanında bozulma şeklinde şikâyette bulunabilir. Makula ödemi oldukça hızlı ilerleyen ve birkaç yıl içerisinde kalıcı görme kaybına yol açabilen bir hastalıktır.

### 1.4.2. Proliferatif Diyabetik Retinopati

Bu ileri evrede, retinanın beslenebilmek için salgıladığı maddeler yeni damar oluşumunu tetiklemektedir. Bu olay proliferatif retinopati olarak adlandırılır. Yeni oluşan bu kan damarları anormal yapıda ve çok zayıftır. Tüm retina yüzeyi boyunca ve şeffaf vitre jeli içine doğru çok sayıda damar oluşumu gözlenir.




Şekil 5. Neovaskülarizasyon sonucu oluşan yeni damarlar [16].

Yeni oluşan bu damarlar kendi başlarına görmeyi etkilemezler. Ne var ki bunlar çok hassas ve zayıf olan duvarlarından kan sızdırmaya başladıklarında ciddi görme kaybına, hatta körlüğe neden olurlar.

### 1.4.3. Diyabetik Retinopatinin Tedavisi

DR'nin ilaçla tedavisi mümkün değildir. Göze yönelik sorunların tedavisiyle beraber, kan şekeri seviyesinin iyi bir şekilde kontrol altında tutulması gerekmektedir. Kan şekeri seviyesinin sıkı kontrolü diyabete bağlı komplikasyon gelişme riskini azaltır ve hastalığın ilerlemesini oldukça yavaşlatır.

Yüksek kan basıncı ve artmış kan yağlarının kontrolü de çok önemlidir. Bu risk faktörleri iyi bir şekilde kontrol altına alındığında, göze uygulanan tedavinin sonuçları daha iyi olmaktadır.




Şekil 6. DR'de lazer tedavisi

Diyabete bağlı retina tabakasındaki hasar için göze en sık uygulanan tedavi yöntemi lazerdir. Diyabetli kişiler oftalmologlara ne kadar erken başvururlarsa lazer ile elde edilen başarı oranı o kadar artmaktadır. Lazer tedavisi ile göz içerisinde kanama, glokom, görme merkezinde ödem (makula ödemi) oluşumu gibi yan etkilerinin gelişimi ve ilerlemesi engellenmeye çalışılmaktadır. Makula ödemi gidermek için yapılan lazerde tekrarlayan tedaviler gerekebilmektedir. Bu tedaviyle hastaların görmelerinin azalması durdurulmaya çalışılmaktadır.

Diyabetli kişilerin gözlerinde yeterli oksijen besini olmadığında yeni anormal damarlar oluşabilmektedir. Bunlar zayıf yapılarından dolayı gözün içerisine kanamakta ve glokom hastalığına da yol açarak körlüğe neden olabilmektedir. Lazer tedavisi, glokom ve göz içerisine olabilecek bir kanama riskini etkin bir şekilde azaltmaktadır. Bu olgularda, retina çevresine yoğun lazer tedavisi yapıldığından, tedaviden sonra görmede azalma olabilir. Ayrıca, görme alanı daralır, renkli görme ve karanlık uyumu kötüleşebilir. Ancak, genellikle eski düzeyine geri dönmektedir.

Proliferatif retinopati lazer ile tedavi edilebilir. Bu tedavi yöntemine panretinal lazer fotokoagülasyonu olarak adlandırılır. Bu işlem, anormal yapıdaki kan damarlarının büzülmesini ve kapanmasını sağlar. Bu işlem sırasında retinanın makula dışındaki

bölgelerinde 1000 ile 2000 adet noktasal yanık oluşturulur ve buralardaki anormal damarların büzüşmesi sağlanır. Çok sayıda lazer yanığı gerektiğinden bu tedavi genellikle iki ya da daha fazla seansta tamamlanır. Kenarlarda kalan görme alanınızda bir miktar görme kaybı olsa da, panretinal fotokoagülasyon sayesinde merkezi görmenin kalan kısmı kurtulabilir. Panretinal fotokoagülasyon sonrasında renkli görme ve gece görüşü bir miktar azalabilir.



Şekil 7. Panretinal lazer fotokoagülasyonu işlemi

Panretinal lazer fotokoagülasyonu, yeni oluşan kan damarları kanamaya başlamadan önce uygulanırsa daha iyi sonuç vermektedir. Bu nedenle düzenli göz muayeneleri çok önemlidir. Kanama başlamış olsa dahi, kanamanın miktarına bağlı olarak panretinal lazer uygulaması mümkün olabilmektedir.

Kanama yoğun olduğunda göze vitrektomi ameliyatı gerekebilir. Vitrektomi ameliyatında kanama gözün ortasındaki jöle kıvamındaki vitre maddesi ile birlikte temizlenmektedir.

Göz içerisinde kanama oluşursa ve belli bir süre içinde kendiliğinden açılmazsa vitrektomi ameliyatı ile kanama ve kanamaya yol açan yapılar gözden temizlenmektedir. Ameliyat sonrası elde edilecek görme düzeyi, diyabetin retina ve görme sinirinde oluşturduğu hasara bağlı olarak değişmektedir ve ancak ameliyattan sonra belirlenebilir [17].

Diyabetik retinopatinin en etkin tedavi kısmı erken teşhis yapıldığında gerçekleştirilmektedir. Dolayısıyla diyabet hastaları belli sürelerde göz kontrolüne gitmelidirler. Teknolojideki gelişmelere paralel olarak, retina analizi yazılımları DR'nin erken teşhis ve takibinde oldukça önemli bir yer tutmaktadır. Retina analizinin bilgisayarlar yardımıyla yapılması sayesinde, hem zaman kaybı önlenmesi sağlanır, hem de nicel verilerin elde edilip hekimlere bir karar destek sistemi oluşturulabilir.


#### **1.4.4.Diyabetik Retinopatinin İzlenmesi**

Diyabet hastalığı önlenememesine rağmen, DR gibi bazı yan etkileri kontrol altına alınabilir. DR tedavisinde erken teşhis ile güncel tedavi yöntemleri kullanılarak ciddi görme bozuklukları %90 oranında önlenebilmektedir. Erken teşhis ile DR tanısı koyabilmek için diyabet hastalarının yılda en az bir kere retina taramasından geçmesi gerekmektedir. Retina taramasında her iki gözün retinası için aşağıdakiler amaçlanır;

- Gözle görülür NPDR lezyonları (hemoraji, microanevrizma, sert eksuda ve yumuşak eksuda vb.) var mıdır?
- Bu lezyonların sayısına ve yerlerine göre DR'nin derecelendirmesi,
- Hemoraji ve makula ödemi gibi çeşitli yan etkilerinin olup olmadığının incelenmesi,
- NPDR'den PDR'ye hastalığın ilerlemesinin takibi,
- Gerektiğinde tedavi yöntemlerine karar vermek.

Diyabet tiplerinin belirlenmesinde ve tedavinin planlanmasında Fundus Floresein Anjiyografi (FFA) çok önemli yer tutar. Hastanın kolundan damar içine boya (kontrast) maddesi verilir. Hasta oturur pozisyondayken belli aralıklarla retinanın fotoğrafları çekilir. Bu tetkik yöntemi ile diyabetik hastalarda, damarlarda kaçak, tıkanıklık ve beslenme bozukluğunu saptamak daha rahat olmaktadır.


DR tanısında en çok kullanılan tarama yöntemi, fundus kameralarla alınan göz arkasındaki retina görüntüleridir. Bazı firmaların fundus kameraları Şekil 8'de görülmektedir.




Şekil 8. Modern dijital fundus kameralar. a) Topcon firmasının TRC-NW300 Non-Mydriatic retina kamerası, b) Kowa Medicals firmasının nonmyd-WX3D retina kamerası

Çok ilerlemiş diyabetik retinopati olgularında tekrarlayan vitreus içi, retina önü kanamaları veya retina üzerini kaplayan zarların sürekli retinayı büzştürmesi ve çekmesi sonucu oluşan *traksiyonel retina dekolmanı* (çekme sonucunda retinanın olması gereken yerden öne ayrılması ve öne doğru gelmesi) nedeni ile retina cerrahisi yapılması gerekebilmektedir. Bu gibi durumlarda yapılan cerrahiye pars plana vitrektomi denir. Pars plana vitrektomi ile gözün içindeki jel kıvamındaki sıvı (vitreus) uzaklaştırılarak, retina zarlardan temizlenip tekrar eski yerine yatışması sağlanmaktadır [18].






Şekil 9. (a.) Normal *FFA* görüntüsü. Damarlarda veya makulada herhangi bir sızıntıya ait parlak renkte beyazlık izlenmemektedir, (b.) DR'si olan bir hastanın *FFA* görüntüsü. Siyah ok ile gösterilen parlak renkteki beyazlık, damarlardan sızıntı olduğunu göstermektedir.




Şekil 10. (a) Fundus kamera ile retina muayenesi, (b) Traksiyonel retina dekolmanı olan bir hastanın retinası. Retinanın normal rengini kaybettiği, beyaz zarların retina yüzeyini kaplayıp retinayı öne doğru çektiği izlenmektedir (siyah ok).

Bazı durumlarda retina, normal fundus muayenesi ile net seçilemeyebilir. Bu gibi durumlarda, göz ultrasonografisi çekilmektedir.



Şekil 11. a) Normal göz ultrasonografi görüntüsü. Beyaz ok göz sıvısını (vitreus), siyah ok retina tabakasını göstermektedir. b.) Sağ görüntüde traksiyonel retina dekolmanı olan bir hastanın göz ultrasonografisi görülmektedir. Retinanın normal yerinden öne, göz sıvısı içine doğru çekildiği izlenmektedir (siyah oklar).

DR'si olan hastalarda kullanılabilecek diğer bir tanı yöntemi de Optik Koherens Tomografidir (OKT). OKT diyabetik makula ödemi gibi patolojilerde hastalığın evresi, tedavi endikasyonu ve tedavi sonrası takiplerde yol gösterici olmaktadır [18].



Şekil 12. Soldaki görüntü (a), *normal makulanın*, sağdaki görüntü (b) *kistoid makula ödemi* olan makulanın OKT görüntüsünü göstermektedir. Normalde tüm retina tabakaları belli bir aralıklarla ve belli renklerde izlenmektedir. Ödemli bir makulanın ise kist şeklinde siyah boşluklarla dolu olduğu görülmektedir (kırmızı ok).

OKT, retina görüntülerindeki lezyonların otomatik değerlendirilmesi için güvenilir bir sistemdir. DR'nin kitle taraması için etkin bir yardımcı araç olarak kullanılmaktadır.

Otomatik retina görüntü değerlendirme sistemi, tanı süresini, oftalmologların iş yükünü ve maliyetleri düşürerek daha çok sayıda retina görüntüsünün incelenmesine olanak sağlayacaktır. Ayrıca, otomatik retina görüntü analizi, retina görüntülerindeki ayrıntıları daha da belirginleştirir ve DR'nin tanısına yardımcı olmak için objektif ölçümler sunarak rutin göz muayenelerinde yararlı bir klinik yardımcı olabilir [18].

## 1.5. Literatür Çalışması

Dijital görüntülemeindeki gelişmeler ve bilgisayar sistemleri yardımıyla hesaplama gücünün artması son yıllarda DR'nin otomatik tespiti konusunda uzmanların ilgisini oldukça çekmektedir [2]. DR'nin otomatik tespiti ve tanısı için son 10 – 15 yılda kullanılan birçok algoritma, [2,3,10,19,20] çalışmalarında irdelenmiş ve karşılaştırmaları yapılmıştır [2]. Bu başlık altında DR lezyonları ile ilgili literatürde yapılan bazı çalışmalardan bahsedilecektir [2]. Literatürdeki çalışmalar DR lezyonlarının durumuna göre iki kısımda incelenmiştir. Birinci kısımda, koyu lezyonlar olan mikroanevrizma ve hemorajilerin tespiti ile ilgili çalışmalar, ikinci kısımda ise parlak lezyonlardan sert eksudalar ve yumuşak eksudaların tespiti ile ilgili çalışmalar değerlendirilmiştir [2].

### 1.5.1. Mikroanevrizma ve Hemoraji ile İlgili Literatür Değerlendirmesi

Diyabetik Retinopati için ilk otomatik tespit yöntemlerinden biri Baudoin ve diğerlerinin yayınladığı göz anjiyosu görüntülerinden mikroanevrizmaların tespiti olmuştur [21,22]. Farklı yönlerdeki küçük yuvarlak şekilli mikroanevrizmalar, doğrusal yapısal eleman kullanılarak morfolojik top-hat dönüşümü yardımıyla damarlardan ve hemorajilerden ayrıştırılmıştır. Ancak, top-hat dönüşümü mikroanevrizmalara çok duyarlı olmasına rağmen çok sayıda yanlış tespit de yapmaktadır. Spencer ve diğerleri [23] bu özellikten faydalanıp top-hat dönüşümü kullanarak aday mikroanevrizmalar ortaya koymuşlardır. Gerçek mikroanevrizmalar ise [24] çalışmasında sonra-işleme (post-processing) dayalı yöntemlerle ayıklanarak sınıflandırılmıştır. Aday mikroanevrizma bölütlemesi, top-hat dönüşümü ve eşleştirilmiş filtreleme yöntemlerinin bölge büyütme yöntemi ile birlikte kullanılarak gerçekleştirilmiş ve duyarlılığın artırılması için ön-işlem (pre-processing) olarak gölge düzeltme ve dinamik aralıklı normalizasyon adımları uygulanmıştır. Aday mikroanevrizmaların tespiti ve bölütlenmesinden sonra, şekil ve parlaklık yoğunluğunda çıkartılan öznelikleri kullanarak kural tabanlı sınıflandırıcılar ile gerçek mikroanevrizmalar ayrıştırılmıştır.

Walter ve Klein [25], yeşil kanal retina görüntüsünde Gauss filtresi kullanarak görüntünün karşıtlığını arttırmış ve gürültüsünü azaltarak renkli retina görüntülerinde mikroanevrizma tespiti yapmışlardır. Mikroanevrizmayı arka plandaki gürültüden ayırmak

için eğitilmiş görüntülerde tuz-biber gürültüsünün ölçümünden çıkartılan bir eşik değeri (threshold) kullanılmıştır.

Streeter ve Cree [26], renkli retina görüntüsünde Spencer ve diğerlerinin [23] çalışmasına uyarlanarak mikroanevrizma tespiti yapmışlardır. Çalışmada, arka plan kestirimi için medyan filtresi yardımıyla gölge-düzeltilme işlemi uygulanmıştır. Kan damarlarının ortadan kaldırılabilmesi için top-hat dönüşümü yapmışlardır. Geriye kalan aday lezyonlardan 8 adet renk ve morfolojik öznitelik çıkartıp, bu öznitelikleri ileri-geri öznitelik seçiminden sonra doğrusal ayrıştırma analizi, destek vektör makineleri ve lojistik regresyon yöntemleri kullanarak sınıflandırma yapılmıştır.

Fleming ve diğerleri [27], yeşil kanal üzerinde arka plan yaklaşımı ve standart sapma kullanarak normalizasyon ve gölge-düzeltilme işlemi yapmışlardır. Çalışmada, Spencer ve diğerlerinin [23] önermiş olduğu yöntem yardımıyla aday mikroanevrizmalar çıkartılmıştır. Nesnelerin sınır çevreleri etrafında tanımlanan bir enerji fonksiyonu kullanarak bölge büyütme yöntemi uygulanmıştır. Lokal karşıtlık normalizasyonu ve lokal damar eliminasyonu için havza bölge büyütme (watershed region growing) tekniği uygulanmıştır. Son olarak, istatistiksel ve moment tabanlı öznitelikler çıkartılarak, k-en yakın komşu yaklaşımı ile sınıflandırma yapılmıştır.

Ege ve diğerleri [28], medyan filtresi kullanarak yeşil kanal arka plan kestirimi yapmışlardır. Arka plan parlaklık ortalamasının altında bir seviyede eşik değeri kullanarak, koyu nesnelerin çıkarımı gerçekleştirilmiştir. Her nesnenin gerçek şeklinin, bölge büyütme ve öznitelikler kullanarak, kestirimi yapılmıştır. Daha sonra, Bayes, Mahalanobis mesafesi ve k-en yakın komşu sınıflandırıcıları ile hemorajiler mikroanevrizmalardan ayrılmıştır.

Sinthanayothin ve diğerleri [29], koyu lezyonların kenarlarının daha keskin olması için yeşil kanala lokal kontrast iyileştirmesi ve “Moat Operator” uygulamıştır. Retina görüntüsünün arka plan ve hemoraji olarak ayırabilmek için özyineli (recursive) bölge büyütme bölütleme algoritması uygulanmıştır. Kan damarlarının tespiti için sinir ağı yaklaşımı kullanılmıştır. Usher ve diğerleri [30], Sinthanayothin ve diğerlerinin [29] yaklaşımını geliştirerek sinir ağı temelli bir sınıflandırma yöntemi uygulamışlardır. Aday lezyonlar çıkartıldıktan sonra hemoraji lezyonları sınıflandırılmıştır.

Zhang ve Chutatape [31], her bir RGB kanalına bağımsız olarak histogram spesifikasyon metodu uygulayarak renk normalizasyonu yapmışlardır. Hemorajiler, destek vektör makineleri kullanılarak lokalize edilmiş ve boyut indirgemesi için Temel Bileşen Analizi (TBA) ve Çekirdek Temel Bileşen Analizi (Çekirdek-TBA) uygulanmıştır. Son olarak, hemoraji sınırlarının doğru şekilde bölütlenmesi için Level Set yöntemi kullanmışlardır.

Niemeijer ve diğerleri [32] başlangıçta, Spencer ve diğerlerinin [23] önermiş olduğu aday tespit yaklaşımını kullanmışlardır. Yazarlar, renkli retina görüntülerinden koyu lezyonların tespitinde, gözetimli piksel sınıflandırmaya dayalı yeni bir aday tespit şeması yöntemi önermişlerdir. Farklı ölçeklerde, Gauss Türev Filtrelerinin tepkilerine göre yeşil kanaldaki tüm pikseller için farklı öznitelikler çıkartılmış ve k-en yakın komşu sınıflandırıcısı ile görüntünün olasılık haritası çıkartılmıştır. Aday koyu lezyonlardan elde edilen eğitim kümesi bilgileri yardımıyla bu olasılık haritasına eşikleme yöntemi uygulanmıştır. Kan damarlarının yol açtığı yanlış pozitif (false positive) alanların elimine edilmesi için bağlı bileşen analizi (connected component analysis) uygulanmış ve koyu lezyonlardan daha büyük alana sahip aday bölgeler silinmiştir. Sonuç olarak, hemoraji ve mikroanevrizma tespit edilmiştir. [32]

### **1.5.2. Sert ve Yumuşak Eksuda ile İlgili Literatür Değerlendirmesi**

Literatürde parlak lezyonlar olarak adlandırılan sert ve yumuşak eksudalar ile ilgili birçok çalışma mevcuttur [2]. Parlak lezyonlar parlaklık değeri ve yanlış pozitif alanlar açısından koyu lezyonlara göre gri seviye eşikleme yöntemiyle daha kolay bölütlenebilirler. Ward ve diğerleri [33], global bir eşikleme yöntemi kullanarak arka plan ile sert eksudayı birbirinden ayırt etmiştir. Philips ve diğerleri [34], kullanıcının manuel olarak seçtiği global ve lokal eşik değerleri ile sert eksudalar bölütlenmiştir. Eşikleme işleminden önce medyan filtresi kullanarak gölge-düzeltilme işlemi yapılmıştır. İstenmeyen parlaklık etkilerini azaltmak için Liu ve diğerleri [35] lokal dinamik eşikleme algoritması olan Otsu Algoritması'nı [36] 64x64 piksellik alt görüntülere uygulayarak bölütlemeyi gerçekleştirmişlerdir.

Eksudaların tespitinde matematiksel morfoloji veya bölge büyütme yöntemleri gibi diğer görüntü işleme teknikleri de kullanılmıştır. Matematiksel morfolojiden yaralanan Walter ve diğerleri [25] eksudaların gri seviye değişimleriyle bölütleme yapmıştır. Yazarlar, matematiksel morfoloji uygulaması olan kapama işlemi yaparak kan damarlarını elimine etmişlerdir. Sabit bir eşik değerinden daha büyük bir standart sapma değeri olan bölgeler aday lezyon olarak seçilmiş ve genişleme yöntemi kullanarak sert eksudalar lokalize edilmiştir.

Sinthanayothin ve diğerleri [29], eksuda bölgelerinin homojenliğini temel alıp özyineli bölge büyütme bölütleme algoritması (recursive region growing segmentation algorithm) kullanarak sert eksudaları tespit etmiştir. Bu yöntemi, Usher ve diğerleri [30] sinir ağları kullanarak sert eksuda ve gürültüleri sınıflandırmışlardır.

Li ve Chutatape [37], bölge büyütme ve kenar algılama yöntemlerinin kombinasyonundan yararlanarak retina görüntüsünden sert eksudaları tespit etmişlerdir. Yazarlar, gölge değişiminin etkisini kaldırabilmek için retina görüntüsünü 64 alt görüntüye bölmüşler ve her alt görüntüye kural tabanlı bölge büyütme uygulamışlardır.

Sert eksudaların otomatik sınıflandırılması için literatürde birçok farklı gözetimli ve gözetimsiz sınıflandırma yöntemleri kullanılmıştır [2]. Gardner ve diğerleri [38], minimum medyan yumuşatma kullanarak görüntü ön işlemeden sonra, görüntüyü 30x30 ve 20x20 piksellik alt parçalara bölerek sinir ağları yardımıyla sert eksudaları sınıflandırmıştır.

Goh ve diğerleri [39], her bir pikselin renk özniteliklerini temel alıp minimum uzaklık sınıflandırıcı kullanarak eksudaları tespit etmişlerdir.

Ege ve diğerleri [28], hemorajilerin tespitine benzer şekilde farklı bir istatistiksel sınıflandırıcı ile sert eksudaları otomatik bölütlemişlerdir. Eşikleme yöntemiyle aday lezyonlar tespit edilmiş ardından bölge büyütme yöntemi uygulanmış ve öznitelik çıkarımı yapıldıktan sonra k-en yakın komşu, Bayes ve Mahalonobis sınıflandırıcıları kullanılarak sert eksudalar sınıflandırılmıştır.

Osareh [40], eşikleme ve bulanık c-ortalama kümeleme yöntemleri kullanarak aday eksuda alanlarını tespit etmiş, histogram spesifikasyonu ve lokal kontrast iyileştirmesi yapmıştır. Aday bölgelerden çıkartılan öznelikler destek vektör makineleri kullanılarak eksuda ve eksuda olmayan diye iki sınıfa ayrıştırılmıştır.

Sanchez ve diğerleri [5], renk bilgilerinden faydalanarak retina görüntülerine Fisher doğrusal ayrıştırma analizi uygulamıştır. Yazarlar, görüntü normalizasyonunun ardından, her görüntüden dinamik bir öğrenme kümesi çıkartıp daha sonra geri kalan pikselleri Fisher doğrusal ayrıştırma analizi kullanarak sınıflandırmışlardır. Sonra-işleme adımında, gradyan bilgisinden faydalanarak yumuşak eksuda (pamuk görünümlü eksuda) ile sert eksudalar birbirinden ayrıştırılmıştır.

Niemeijer ve diğerleri [41], k-en yakın komşu sınıflandırıcısından faydalanarak görüntüdeki tüm pikseller için parlak lezyona ait olma olasılığını hesaplamışlardır. Bu yöntem ile, Gauss türevi tabanlı 14 filtrenin tepkisine göre her bir piksel sınıflandırılmıştır. Piksel olasılık haritasından elde edilen eşik değeriyle parlak lezyon adayları kümesi oluşturulmuştur. İkinci bir k-en yakın komşu sınıflandırıcısı kullanılarak gerçek parlak lezyonlar tespit edilmiştir.

## **1.6. Retina Görüntü Veritabanları**

Literatürde, retina analizi için kullanılan algoritmaları test edip sonuçlarını karşılaştırabilecek birçok açık veritabanı mevcuttur. Bu veritabanları, retina üzerindeki kan damarları, optik disk vb. gibi anatomik yapıların, DR, Makulapati ve YBMD lezyonlarının uzman kişiler tarafından etiketlenmesiyle, görüntülere uygulanan algoritmaların başarı oranlarının ölçülmesi ve karşılaştırılması için kullanılmaktadır. En çok kullanılan veritabanları aşağıdaki gibi sıralanabilir.

STARE (Structured Analysis of the Retina) veritabanı, retinadaki kan damarlarının tespiti ve optik diskin lokalizasyonu için literatürde en çok kullanılan referans görüntü veritabanlarından biridir [42]. Bu veritabanında 400'e yakın ham görüntü mevcuttur. Uzmanlar tarafından her görüntünün teşhisi yapılmış ve birer teşhis kodu verilmiştir. Bu veritabanındaki 40 görüntü kan damarları, 10 görüntü ana damarlar ve 80 görüntü ise optik

sinir tespiti için etiketlenmiştir. Kan damarlarının tespitinin başarı ölçümü ROC (Receiver Operating Characteristic ) Eğrisi Analizi yardımıyla yapılmıştır. Bu analizde, duyarlılık ölçütüyle doğru sınıflandırılan kan damarları piksellerinin oranını, özgüllük ölçütüyle de normal piksellerin doğru sınıflandırılma oranı hesaplanmıştır[43]. Optik diskin lokalizasyonun değerlendirilmesinde ise, optik diskin elle etiklendiği görüntüden en az 60 pikselinin doğru tespit edilmesi halinde başarılı bir bölütleme olarak kabul edilmektedir [44].

Kan damarlarının tespitinde kullanılan bir başka referans veritabanı ise 40 adet elle etiketlenmiş retina görüntüsünden oluşan DRIVE (Digital Retinal Images for Vessel Extraction) veritabanıdır [45,46]. Retina görüntüleri Canon CR5 midriatik olmayan 3CCD kamera ile 45° görüş alanıyla elde edilmiştir. Görüntü boyutları 768 x 584 piksel olup 20 görüntü test ve 20 görüntü de eğitim kümesi olarak kullanılmıştır. Bu veritabanının elle etiketleme görevi üç tıp uzmanı tarafından yapılmış ve damar bölütleme algoritmaları ile birlikte yayınlanmıştır [46]. Bölütleme performansı STARE veritabanındaki gibi eğri altındaki alan (AUC) hesaplanarak duyarlılık ve özgüllüğün karşılaştırılması ile hesaplanmıştır.

MESSIDOR (Methods to evaluate segmentation and indexing techniques in the field of retinal ophthalmology), DR hastalığının bilgisayar destekli görüntü analizini kolaylaştırmak için oluşturulan bir görüntü veritabanıdır [47]. Bu veritabanı, 45° görüş alanıyla 3CCD video kamerası olan Topcon TRC NW6 midriatik olmayan retinograf ile üç oftalmoloji bölümü tarafından 1200 göz dibi renkli görüntü elde ederek oluşturulmuştur. Elde edilen renkli görüntülerin her bir kanalı 8 bittir ve boyutları 1440 x 960, 2240 x 1488 ve 2304 x 1536 pikseldir. Bu görüntülerden 800'ü hastalara ilaç verilerek göz bebeğinin büyütülmesi yöntemiyle, diğer 400'ü ise normal olarak elde edilmiştir. Görüntülerin değerlendirilmesi, tıp uzmanları tarafından her bir görüntü için retinopati derecelendirmesi ve makular ödemin riski olmak üzere iki çeşit teşhis koyularak yapılmıştır [47]. Retinopati derecelendirmesi,  $\mu A$  mikroanevrizmaların ve H hemorajilerin sayısı, NV neovaskülarizasyonun varlığı (1: var, 0: yok) olmak üzere;

- 0 : (Normal): ( $\mu A = 0$ ) AND (H = 0)
- 1 : ( $0 < \mu A \leq 5$ ) AND (H = 0)
- 2 : ( $(5 < \mu A < 15)$  OR ( $0 < H < 5$ )) AND (NV = 0)



- 3 : ( $\mu A \geq 15$ ) OR ( $H \geq 5$ ) OR ( $NV = 1$ )

dört sınıfa ayrılmıştır. Makular ödemin riskinin derecelendirmesinde sert eksudalar kullanılmıştır.

- 0 : (Risk Yok) Sert eksuda bulunmamaktadır,
- 1 : Makula ile sert eksudalar arasındaki en kısa mesafe bir gözbebeği çapından büyük ise,
- 2 : Makula ile sert eksudalar arasındaki en kısa mesafe bir gözbebeği çapı kadar veya daha küçük ise.

CMIF (Collection of multispectral images of the fundus) veritabanı, multispektral açık bir retina görüntü veritabanıdır [48,49]. Spektral retina görüntüleri 17 çeşit dalga boyunda (nm cinsinden) ve bir filtre tekerleği kullanılarak, Zeiss RCM250 fundus kamera ile 40° görüş açısıyla elde edilmişlerdir. Bu veritabanındaki görüntüler Kafkasya, Afrika ve Akdeniz gibi değişik etnikteki kişilerden toplanıp, karşılaştırma için tam olarak hazır olmamakla beraber, içerdiği değişik retinal patolojiler sayesinde yeni bir bakış açısı sağlamaktadır.

ROC (Retinopathy online challenge), web üzerinden retina görüntülerinden oluşan veri setinin indirilip daha sonra uygulanan algoritmaların sonuçlarının eklenip değerlendirilmesi yapılan çevrimiçi bir değerlendirme sistemidir [50,51]. Değerlendirme sistemi tamamen otomatiktir ve kullananlar tarafından eklenen sonuçlar sürekli güncellenmektedir. ROC veritabanı sitesi, 100 tane retina görüntüsünün yanı sıra, mikroanevrizmalar için çevrimiçi değerlendirme sitemine de sahiptir. Kullanılan algoritmanın performansı, duyarlılıkla (doğru sınıflandırılan lezyonların oranı) görüntüdeki yanlış pozitiflerin sayısının ortalaması karşılaştırılarak ölçülmüştür [51].

REVIEW (Retinal Vessel Image Set for Estimation of Widths), kan damarlarının genişliklerinin ölçüldüğü algoritmaların performanslarının değerlendirilmesi için kullanılan yeni bir retina görüntü veritabanıdır [52,53]. Bu veritabanı, 4 görüntü 60° görüş alanıyla Canon 60UV kamera ile, 8 görüntü 50° görüş alanıyla Zeiss fundus kamera ile damarsal hastalıklarını, 2 görüntü 50° görüş alanıyla Zeiss FF 450 fundus kamera ile merkezi ışık

refleksini ve 2 görüntü de 60° görüş alanıyla Canon 60UV fundus kamera ile kick-point görüntüsü olmak üzere dört kümeden oluşmuştur. REVIEW veritabanı, yüksek hassasiyetli betimleme üzerine yoğunlaştığından, tüm damar ağı değil, sadece bazı kesimleri etiketlenmiştir. Performans değerlendirmesi, damar genişliklerinin kestirimini yapan algoritma ile uzmanlar tarafından etiketlenen aynı damarın yansız olarak standart sapma farkları ölçülerek yapılmıştır.

DIARETDB1 (Diabetic retinopathy image database 1) veritabanında 89 renkli fundus görüntününün 84'ü en az hafif non-proliferatif DR belirtileri taşıırken, 5 görüntü herhangi bir DR belirtisi taşımamaktadır [10,54]. Retina görüntüleri, 50° görüş alanıyla ZEISS FF 450Plus fundus kamera ile elde edilmiştir. Görüntüler PNG formatında olup, bağımsız olarak dört tıp uzmanı tarafından oluşturulan betimlemeler XML dosyasında tutulmaktadır. Veritabanındaki görüntülerin değerlendirilmesi ROC analizi ile yapılmıştır [10].

BRISTOLDB veritabanı, Bristol Göz Hastanesinden elde edilen ve sert eksudalar için otomatik tanıma sisteminin geliştirilmesinde kullanılan, ortak kullanıma açık olmayan bir göz fundus görüntü veritabanıdır [40]. Veritabanında 142 göz fundus görüntüsünden 17'si normal ve 90'ı da sert eksuda lezyonları içermektedir. Görüntüler, 45° görüş alanıyla midriatik olmayan Canon CR6-45NM fundus kamera ile elde edilmiştir. Bu veritabanında sert eksudalar uzman oftalmologlar yardımıyla elle etiketlenmiş ve referans görüntüler elde edilmiştir [40].

Görüldüğü üzere literatürde retinadaki anatomik yapılar ve lezyonlarla ilgili birçok çalışma mevcut olup, bu çalışmalara ek olarak kullanılan görüntülerin veritabanları da oluşturulmuştur.

Bu tez çalışmasında, Karadeniz Teknik Üniversitesi, Göz Hastalıkları Anabilim Dalı'nda Canon UV60 fundus kamera ile 60 derecelik alanda hem optik sinir başını, hem de makulayı içerecek şekilde pupillaların genişletilmesiyle (1% tropikamid ve 10% fenilefrin damla ile) 570x760 piksel çözünürlükte 24bit jpg görüntü formatı ile elde edilen ve DRIMDB (Diabetic Retinopathy Image DataBase) adını verdiğimiz retina görüntü veritabanı kullanılmıştır. Bu veritabanının en önemli özelliği retina görüntülerinin kalitesini

ölçmek için kullanılabilir literatürdeki ilk ve tek olmasıdır. Veritabanındaki 216 görüntü, 125'i *iyi*, 69'u *kötü* ve 22'si *retina dışı* görüntü olarak 3 sınıfa ayrılmıştır. DRP hastalığının tespiti için önerilen yöntemler, DRIMDB veritabanındaki *iyi* sınıfında olan görüntüler kullanılarak uygulanmıştır.

Literatürdeki retina görüntü veritabanları ve içerdikleri bilgiler Tablo 2'de özetlenmiştir.

Tablo 2. Kullanıma açık retina görüntü veritabanları

Veritabanı	Damar	OS	MA	SE	DL	Uzm. S	G.S
STARE	✓						81
DRIVE	✓					1	40
ARIA	✓	✓					212
DIARETDB1			✓	✓	✓	4	89
MESSIDOR			✓	✓		1	1200
ROC			✓			4	100
HEI-MED		✓	✓	✓	✓	1	169
DRIMDB		✓	✓	✓	✓	1	216

Not: Damar: Manuel damar bölütlemesi, OS: Optik sinir tespiti, MA: Mikroanevrizma bölütlemesi, SE: Sert Eksuda bölütlemesi, DL: Diğer Lezyonlar, Uzm. S: Elle etiketleyen uzman sayısı, G.S. Görüntü Sayısı


## **2. YAPILAN ÇALIŞMALAR**

### **2.1. Retina Görüntüsü Ön İşleme İşlemleri**

#### **2.1.1. Renk Kanalı Seçimi**

Retina görüntüsü üzerinde bölütleme ve örüntü tanıma algoritmaları çalıştırılmadan önce, görüntünün parlaklık dağılımının düzeltilmesi ve gürültünün giderilmesi için bazı ön işlemler yapılmalıdır. RGB uzayında bulunan retina görüntüsünde en çok bilgi yeşil kanalda bulunmaktadır. Retinadaki melanin ve hemoglobin pigmentleri ışığın dalga boyuna göre değişik yansımaya ve emilim özelliği göstermektedirler. Işığın mavi spektrumu her iki pigment tarafından kuvvetli biçimde emilmesinden dolayı yansıyan ışıkta mavi renk oldukça azdır. Mavi ışık benzer olarak retinadaki pigment epitelyum katmanında da emilmektedir. Kırmızı ışık, mavi ışık kadar olmasa da melanin ve hemoglobin pigmentlerinde emilirken, koroidal katmanı ve skleradan yansımaya yapar. Ancak yansımaya yapan kırmızı ışık retina ile ilgili fazla bilgi içermemektedir. Yeşil ışık ise melanin ve hemoglobin katmanlarında, mavi ve kırmızı ışıktan daha az emilir. Yeşil ışığın diğerlerinden en büyük farkı ise koroidal katmana girmeden önce pigment epitelyum katmanından yansımastır. Bu nedenle, RGB uzayındaki yeşil kanal, diğer kanallara göre damarların daha koyu görünmesi ve arka plan ile anatomik yapıların arasındaki en iyi kontrast değerini içeren kanaldır.

Şekil 13'de görüldüğü gibi mavi kanalda kontrast değeri oldukça düşük, kırmızı kanalda ise renk doygunluğu çok fazladır.



Şekil 13. Retina görüntüsünün RGB kanallarına ayrılması a) Orijinal görüntü, b) Kırmızı kanal, c) Yeşil kanal, d) Mavi kanal görüntüsü

### 2.1.2. Görüntü İyileştirme


Görüntü histogramı, görüntü içerisindeki piksellerin 0-255 arasındaki gri seviye değerlerin frekanslarından elde edilmektedir. Karşıtlık ve keskinlik değeri uygun olan bir görüntüde bu frekans dağılımı 0-255 arasında denk olarak yayılmış olması beklenir. Histogram eşitleme yöntemi, görüntünün yoğunluk dağılımını genişleterek düzgün bir dağılıma dönüştürmeye çalışır. Histogram eşitleme yöntemi, homojen parlaklık dağılımına sahip olmayan görüntünün tümüne yapılırsa, görüntüde yerel olarak istenilen sonuçlar elde edilemeyebilir. Özellikle retina görüntülerinde, retina tabakasının disk biçimindeki yapısından dolayı elde edilen görüntülerin, ışık etkisinden dolayı kenarlara doğru daha koyu ve orta kısımları daha parlak olduğundan tüm görüntünün yoğunluk dağılımının kullanılarak histogram eşitleme yönteminin uygulanması etkin bir sonuç vermemektedir.

Retinanın küresel yapısından dolayı görüntüye yerel ve adaptif değerlerle histogram eşitleme yönteminin uygulanması daha iyi sonuçlar vereceği düşünülmüştür. Bu nedenle, Kontrast Sınırlı Adaptif Histogram Eşitleme (KSAHE) yöntemi yardımıyla yerel histogram eşitleme yöntemi uygulanmıştır [55]. Bu yöntemde öncelikle görüntü ızgara şeklinde alt bölgelere bölünür. Bu alt bölgeler, köşe bölgeleri (CR – Corner Regions), sınır bölgeleri (BR – Border Regions) ve iç bölgeler (IR – Inner Region) olmak üzere üç gruba ayrılırlar [55]. Her bölgenin histogramı hesaplandıktan sonra belirlenen bir kırpma sınır (clip limit) değerine göre üst kısım sınırlandırılıp bu sınırı aşmayacak şekilde tekrar histogram dağılımı hesaplanır. Hesaplanan kontrast-sınırlı histogramların gri seviye eşleştirmesi için kümülatif dağılım fonksiyonları belirlenir [55].

KSAHE yönteminde pikseller, en yakın dört bölgenin eşleşmesi ile oluşan sonucun doğrusal birleşimleri ile eşlenmektedir. IR grubundaki bölgeler için bu yaklaşımın formülasyonu basittir. Ancak, CR ve BR gruplarındaki bölgeler için yapılan hesaplamalar bazı özel durumları göz önünde bulundurmayı gerektirir. KSAHE yönteminde her bölge dört parçadan oluşmaktadır. IR bölgesi için her dört parça, kendilerine en yakın dört komşu bölge ile eşleşme temeline dayanarak eşlenir. Örneğin, Şekil 14(a)'da verilen birinci parçadaki (i,j) bölgesindeki piksel, merkeze göre dikey ve yatay mesafelerdeki (i,j), (i,j-1), (i-1,j) ve (i-1,j-1) bölgeleri ile eşlenir. Şekil 14(b)'de bu mesafeler görülmektedir. Eğer (i,j) bölgesindeki pikseller için eşleme fonksiyonu  $f_{i,j}(\cdot)$  ise, dörtlü parçanın ilk parçasındaki (i,j) bölgesinde yeni p pikselinin mesafesi;

$$p_{yeni} = \frac{s}{r+s} \left( \frac{y}{x+y} f_{i-1,j-1}(p_{eski}) + \frac{x}{x+y} f_{i,j-1}(p_{eski}) \right) + \frac{r}{r+s} \left( \frac{y}{x+y} f_{i-1,j}(p_{eski}) + \frac{x}{x+y} f_{i,j}(p_{eski}) \right) \quad (1)$$

olarak hesaplanmaktadır.




Şekil 14. (a) Tüm komşu bölgeler ile beraber bir IR bölgesi, b) (i,j) bölgesinin birinci çeyreğindeki p pikseli ve dört en yakın bölge merkezlerine göre ilişkisi

BR grubundaki bölgeler için komşuluk yapısı farklıdır. Bu durum Şekil 15’de gösterilmiştir. (i,j) bölgesindeki birinci ve üçüncü çeyreklerdeki pikseller için komşuluk yapısı IR grubundaki bölgeler ile aynı olmasına rağmen ikinci ve dördüncü çeyrekteki pikseller farklıdır. Örneğin ikinci çeyrekteki yapıda p pikseli için yeni gri seviye değeri;

$$p_{yeni} = \frac{s}{r+s} f_{i,j-1}(p_{eski}) + \frac{r}{r+s} f_{i,j}(p_{eski}) \quad (2)$$


olarak hesaplanmaktadır [55].



Şekil 15. (a) Tüm komşu bölgeleri ile beraber bir BR bölgesi. (b) (i,j) bölgesinin ikinci çeyreğindeki p pikseli ve iki en yakın bölge merkezlerine göre ilişkisi.

CR grubundaki bölgelerde farklı çeyrekler farklı özelliklere sahiptir. Şekil 16’da da görüldüğü gibi dördüncü çeyreğin komşuluk yapısı IR bölgesine, ikinci ve üçüncü çeyrek

BR bölgesine benzemektedir. Birinci çeyrek ise tektir ve diğer bölgelerle bağlantısı yoktur. Bu çeyrekteki pikseller için yeni gri seviye değeri değişmemektedir.  $p_{yeni} = f_{i,j}(p_{eski})$




Şekil 16. Üst-sol köşedeki bölge ve bu bölgenin komşuluk yapısı.

Sonuç olarak, her bölgenin histogramı hesaplanır ve istenilen kırpma faktörüne göre yeniden oluşturulur. Her bölgenin gri seviye eşleşmesi, bu bölgelerin yeniden hesaplanmış histogramlarının uygulanmasıyla gerçekleştirilir. Sonuç görüntüsü ise, merkez noktalarında işlem yapılan pikselin dört, iki veya tek en yakın komşuları olan bölgelerin KSAHE dönüşümü yapılarak her pikselin eşleşmesi ile oluşturulur [55]. Şekil 17'de KSAHE yönteminin, yeşil kanal retina görüntüsüne uygulanması görülmektedir.

Damarlar retina görüntüsünde, kandan dolayı koyu parlaklığa sahip yapıdadırlar (Şekil 17(a)). Bu nedenle, damarların daha net görülebilmesi amacıyla yeşil kanaldaki retina görüntüsünün tersi alınmıştır (Şekil 17(b)). Elde edilen ters görüntü, görüntünün minimum ve maksimum parlaklık değerleri arasında normalize edilerek parlaklık değerleri belirli bir aralığa çekilmiştir (Şekil 17(c)). Sonuç olarak, normalize edilen görüntüye KSAHE yöntemi uygulanıp Şekil 17(d)'deki görüntü elde edilmiştir.





Şekil 17. (a) Orijinal yeşil kanal retina görüntüsü, (b) a'nın tersinin alınması, (c) b'nin parlaklığının normalize edilmesi, (d) c'nin KSAHE dönüşümünün yapılması

### 2.1.3. Matematiksel Morfoloji İşlemleri

Matematiksel Morfoloji Yöntemleri bu tez çalışmasında kan damarlarının ve optik diskin daha belirgin hale getirilmesi için kullanılmıştır. Özellikle, damar bölütlenmesinde hızlı ve etkin bir yöntemdir.

İkili (binary) seviyedeki görüntülerde, görüntü içerisindeki yapıların inceltmesini veya yok edilmesini sağlayan morfolojik işleme aşınma (erosion) işlemi denilmektedir.  $A$  ve  $B$ ,  $Z^2$ 'de birer küme olmak üzere,  $A$ 'nın  $B$  ile aşınma işlemi  $A \ominus B$  ile gösterilir;

$$A \ominus B = \{z | (B)_z \subseteq A\} \quad (3)$$

Eş değer olarak;

$$A \ominus B = \{z | (B)_z \cap A^c = \emptyset\} \quad (4)$$

yazılabilir [56]. Aşınma işlemi ile görüntü içerisindeki yapılar küçülür, boşluklar genişler ve birbirine bağlı yapılar ayrılma eğilimi gösterir [56–58].

İkili seviyedeki görüntülerde görüntü içerisindeki yapıların kalınlaştırılmasını veya büyütülmesini sağlayan morfolojik işleme genişleme (dilation) işlemi denmektedir. A ve B,  $Z^2$ 'de birer küme olmak üzere, A'nın B ile genişleme işlemi  $A \oplus B$  ile gösterilir;

$$A \oplus B = \{z | (\hat{B})_z \cap A = \emptyset\} \quad (5)$$

Eş değer olarak;

$$A \oplus B = \{z | [(\hat{B})_z \cap A] \subseteq A\} \quad (6)$$

yazılabilir [56]. Sayısal bir görüntüyü genişletmek demek, görüntüyü belirli bir yapısal elemanla kesiştiği kısımlar kadar genişletmek demektir. Çalışma prensibi olarak, genişleme yapılan görüntünün her bir pikseli, yapısal elemanın merkez noktasına konumlandırılması ile genişletilir. Görüntüdeki yapıların ne kadar genişleceğine yapısal eleman karar verir. Genleşme işlemi uygulanmış görüntülerde yapılar arasındaki boşluklar doldurulmuş ve görüntünün köşe noktasının yumuşadığı gözlenmektedir [56–58].

İkili görüntü üzerinde aşınma işlemi yapıldıktan sonra genişleme işlemi yapılması sonucu açma işlemi gerçekleştirilmiş olur. Açma işlemi sonucunda, görüntü içerisindeki bazı yapılar ve boşluklar yapısal elemanın büyüklüğüne göre yok edilmektedir. Görüntü üzerinde kalan yapılar önceki şekillerinden biraz daha küçük hale gelir. Asıl amaç, birbirine komşu iki yapının, görüntü üzerinde fazla bir değişime uğramadan birbirinden ayrıştırılmasıdır [56–58]. Açma işlemi, A kümesi ile yapısal eleman olan B arasında  $A \circ B$  şeklinde gösterilir.

$$A \circ B = (A \ominus B) \oplus B \quad (7)$$

Kapama işlemi ise ikili görüntü üzerinde genleşme işleminin ardından aşınma işlemi yapılarak gerçekleştirilir. Kapama işlemi sonunda, görüntü içerisindeki ana hatlar daha dolgunlaşmış olur. Böylece yakın iki yapı orijinal görüntüde fazla değişiklik yapılmadan birbirine bağlanmış olur.

Kapama işlemi, açma işlemine benzer olarak  $A$  kümesi ile yapısal eleman olan  $B$  arasında  $A \bullet B$  şeklinde gösterilir.

$$A \bullet B = (A \oplus B) \ominus B \quad (8)$$

Yapısal eleman, farklı geometrik şekillerden oluşan istenilen boyutlarda seçilebilen küçük boyutlarda ikili bir resimdir. Şekil 18’de en sık kullanılan kare, dikdörtgen ve disk şekilleri görülmektedir.

0	1	0	0	1	0	1	1	1
1	1	1	1	0	1	1	1	1
0	1	0	0	1	0	1	1	1

Şekil 18. En sık kullanılan yapısal elemanlar

## 2.2. Retinadaki Anatomik Yapıların Tespiti

Bir retina izleme sistemi için retinadaki optik disk, kan damarları ve damarsal ark (ana arter damar) gibi anatomik yapıların tespiti önemli bir işlem adımıdır. Bu yapıların bulunduğu konumlar referans alınarak retinadaki lezyonların yerleri, buldukları yerler açısından önemleri ve hastalık seviyesi hakkında bilgi verilebilir. Retina görüntülerinin homojen olmaması ve anormalliklerin varlığı nedeniyle anatomik yapıların otomatik bölütlenmesi oldukça zordur. Bununla birlikte, özellikle DR lezyonlarının takibi için geliştirilen sistemlerde kullanılan algoritmaların, büyük verileri kısa sürede hesaplaması gerekmektedir.

Retinadaki anatomik yapıların tespitinin yapılmasının bir diğer önemli yanı bu yapıların parlaklık ve şekilsel olarak lezyonlara benzeyebilir olmasıdır. Piksellerin parlaklık

değerleri kullanılarak bölütleme yapılan bazı yöntemlerde, sert eksuda ve yumuşak eksudaların optik diskle, hemoraji ve mikroanevrizmaların da damarlarla aynı parlaklık özellikleri taşıdığı görülür. Bu nedenle, DR lezyonlarının tespiti için bu anatomik yapıların tespit edilip yanlış pozitif alanlar oluşturmaması için bölütleme sonucundan çıkartılmaları gerekmektedir.

### **2.2.1. Kan Damarlarının Tespiti**

Retinadaki damarların tespiti, hem koyu DR lezyonlarının tespitinde hem de retina görüntü kalitesinin ölçülmesi için önemli bir aşamayı teşkil eder. Buna ek olarak, farklı açılardan çekilen aynı hastaya ait retina görüntülerinin birleştirilmesinde de referans olarak kan damarları kullanılmaktadır [59,60]. Retina damarları, arterler ve venlerden oluşan bir ağaç yapısına sahiptir ve retina tabakasını beslemekle görevlidir. Retina üzerindeki ana arterler optik diskte birleşir ve görme sinirleri ile beraber buradan beyne ulaşırlar. Kan damarları retina arka plan dokusundan farklı olarak koyu bir parlaklık değerine sahiptir. Ayrıca optik diskle olan kesişimi de optik diskin tespitinde kullanılan bir özelliktir.

Literatürde birçok damar tespiti yapan otomatik yöntemlerle ilgili çalışmalar vardır. Damar tespitinde kullanılan en önemli yöntemler, uyumlu süzgeç, alan ölçüm analizi ve bölge büyütme yaklaşımı, matematiksel morfoloji ve eğri kestirim yöntemleri, yerel eşikleme yaklaşımı ve piksel sınıflandırma yaklaşımları olarak sıralanabilir [46,61–64].

Chaudhuri ve diğerleri [61] iki boyutlu bir uyumlu süzgeç kullanarak damarları tespit etmeye çalışmışlardır. Retinada çeşitli yönlerde bulunan damar bölümlerinin tespiti, döndürülmüş uyumlu süzgeç çekirdekleri ile görüntünün arasında katlama işlemi yapılarak maksimum tepki veren kısımlar ile elde edilmiştir. Bu işlemde 15°'lik açılar için 12 katlama işlemi yapılmıştır. Daha sonra sonuç görüntüsü eşiklenerek ikili görüntüde damar bölütlenmesi gerçekleştirilmiştir.

Martinez-Perez ve diğerleri [62] alan ölçüm analizi ve bölge büyütme yöntemlerini kullanarak damar bölütlemesi yapmışlardır. Kan damarlarını tanımlamak için, görüntü parlaklığının gradyan büyüklüğü ve sırt dayanıklılığı öznitelikleri kullanılmıştır. Sırt

dayanıklılığı, görüntünün parlaklık değerlerinin ikinci dereceden türev matrisinin (Hessian) mutlak en büyük özdeğeri hesaplanarak belirlenmiştir.

Zana ve diğerleri tarafından sunulan çalışmada [63] matematiksel morfoloji yöntemleri kullanarak damar bölütlemesi ve mikroanevrizma tespiti yapılmıştır. Morfolojik işlemler, görüntü içerisindeki özel nesnelere belirgin hale getirilmesinde hızlı ve gürültüden etkilenmeyen işlemlerdir. Bu tez çalışmasında da, bu nedenlerden dolayı damar bölütlemesinde morfolojik operatörler kullanılmıştır.

Jiang ve Majon [64] doğrulama tabanlı çoklu eşiklemeye dayalı bir adaptif yerel eşikleme yöntemi önermiştir. Retinanın küresel yapısından dolayı arka planının değişken bir parlaklığa sahip olması nedeniyle retina görüntüsüne genel bir eşikleme yöntemi uygulanamadığından Jiang ve Majon yerel eşik değeri algılama yöntemi geliştirmişlerdir. Böylece yerel bölgelerdeki damar parçaları ile ikili görüntü olarak damar ağacını oluşturmuştur.

Niemeijer ve arkadaşları [65] piksel sınıflandırmaya dayalı basit bir damar bölütleme yöntemi geliştirmişlerdir. Görüntüdeki her piksel için bir öznitelik vektörü oluşturulmuş ve sınıflandırıcılara eğitim verisi olarak verilmiştir. Öznitelik çıkarımı sadece yeşil kanal retina görüntüsünden elde edilmiştir. Uygulanan süzgecin verdiği sonuç ve piksellerin komşuluk değerleri olmak üzere iki tip öznitelik çıkartılmıştır. Süzgeç sonucu elde edilen öznitelikler en iyi sonucu vermiştir. Sınıflandırıcı olarak, k-En Yakın Komşuluk, Lineer Sınıflandırıcı ve Karesele (quadratic) Sınıflandırıcı kullanılmış ve k-En Yakın Komşu sınıflandırıcısı ile en iyi sonuç alınmıştır [66].

Bu tez çalışmasında, damar bölütlemesi için hızlı ve gürültüleri azaltan morfolojik operatörler kullanılmıştır. Bölütleme işlemine geçilmeden önce ön işlemler yapılmış ve damarlar görüntü üzerinde daha da belirginleştirilmiştir. Damar bölütlemesi için bu çalışmada kullanılan veri tabanından 125 görüntü seçilmiştir [45,54].

Damarların bulunduğu anatomik dokulardan damarları ayırt etme işlemi birçok tıbbi görüntüleme uygulamalarında büyük öneme sahip bir işlemdir. Zana ve Klein, retina görüntülerindeki görünür damar ve arterlerin bölütlenmesi için matematiksel morfoloji

yöntemini esas alan bir algoritma geliřtirmişlerdir [63]. Bu algoritma, damar bölütlemesi için herhangi bir eğitim yükü getirmediğinden kullanışlı ve kolaydır.

Tersi alınmış gri seviye retina görüntüsünün normalizasyonu ve KSAHE yöntemi uygulandıktan sonra anatomik yapıların daha belirgin olabilmeleri için görüntü üzerinde bazı morfolojik işlemler yapılmıştır. Damar yapısının bölütlenebilmesi için diğerk yapıların elimine edilmesi gerekmektedir. Bu nedenle morfolojik işlemler iki gruba ayrılmıştır. Bu gruptaki işlemler sonucu çıkan görüntülerin farkı alınarak optik disk, arka plan ve parlak lezyonlar elimine edilip damarların bölütlenmesi planlanmıştır. Öncelikle ilk grubun yapısal elemanı olarak;

0	1	0
1	1	1
0	1	0


Şekil 19. Damar bölütlemesi için kullanılan yapısal eleman

seçilmiştir. Bu yapısal eleman ile kapama işlemi gerçekleştirilmiş ve damarlardaki ana hatlar daha da belirginleşmiştir. Yine aynı yapısal eleman kullanılarak açma işlemi gerçekleştirilmiş ve görüntü içerisindeki küçük yapılar ile büyük yapılar arasındaki boşluklar temizlenmiştir. Böylece birinci grup morfolojik işlemler sonucu Şekil 20'deki sonuçlar elde edilmiştir.



Şekil 20. Yapısal eleman kullanılarak kapama ve açma işlemlerinin uygulanması

İkinci grup morfolojik işlemler için, 5 yarıçapında *disk* yapısal elemanı seçilmiştir. En son açma işlemi yapılan görüntüye, ilk olarak aşınma işlemi yapılarak kalınlaşan damarlar inceltilip diğer yapılarla beraber küçültülmüştür. Daha sonra genişleme işlemi gerçekleştirilmiş ve yapılar kalınlaştırılmıştır. Bu işlemlerin sonucu Şekil 21’de görülmektedir.




Şekil 21. 5 yarıçaplı disk yapısal elemanı kullanılarak aşınma ve genişleme işlemlerinin uygulanması

Şekil 22’de, iki grup şeklinde uygulanan morfolojik işlemlerin sonucunda elde edilen görüntülerin farkı ile optik disk ve parlak lezyonların elimine edildiği görülmektedir.



Şekil 22. Orijinal ve morfolojik işlemler sonucu elde edilen görüntüler

Morfolojik işlemler sonucu elde edilen görüntüye üçgensel eşikleme yöntemiyle otomatik olarak % 9'luk bir değerle eşikleme işlemi uygulanmış ve 130 pikselden küçük yapılar silinmiştir. Şekil 23'de nihai damar bölütlenmesi görülmektedir.



Şekil 23. Damar bölütlenmesi


### 2.2.2. Optik Diskin (OD) Tespiti

Retina görüntülerinde Optik Diskin (OD) tespiti, retinadaki anatomik yapıların ve lezyonların bulunmasında kullanılan çoğu sınıflandırma ve bölütleme algoritması için bir ön çalışma gerekliliği olmuştur. Örneğin, kan damarlarının tespitinde kullanılan izleme algoritması için OD iyi bir başlangıç noktası olmaktadır. Gözdeki görme merkezi olarak bilinen makula bölgesinin tespitinde de OD önemli bir referans noktasıdır. OD ile makula arasında yaklaşık olarak, OD çapının 2,5 katı kadar mesafe bulunmaktadır. OD'nin tespitinin bir diğer önemli gerekliliği, DR lezyonları olan sert ve yumuşak eksudaların parlaklık olarak



OD'ye benzemesidir. Bu nedenle, lezyon tespitinin performansını ölçerken “yanlış pozitif” alanlardan kaçınmak için OD tespitinin yapılması gerekmektedir.

Optik disk, yüksek parlaklık değerlerine sahip olduğundan, sağlıklı bir retina görüntüsünde kolayca ayırt edilebilmektedir. Ancak, retinada DR lezyonu olan ve optik disk ile benzer parlaklık değerlerine sahip sert eksudalar mevcutsa, eşikleme gibi basit bölütleme yöntemleri işe yaramayabilir. Bu nedenle bu çalışmada, daha efektif sonuç alabilmek için kan damarlarının OD ile olan ilişkisinden yararlanılmıştır. Kan damarlarının OD'de birleşmesi, retina görüntüsünde optik diskin bulunduğu bölgede dikey yönde bir damar yoğunluğunun oluşmasını sağlamaktadır.



Şekil 24. OD bölgesinin tespit edilmesi, (a) Orijinal retina görüntüsü, (b) Dikey Sobel Kenar Filtreleme ile elde edilmiş görüntünün dikey histogramı

Bu çalışmada, Sobel Dikey Kenar Algılama Algoritması uygulanarak, elde edilen görüntünün dikey olarak piksel değerlerinin toplam histogramı hesaplanmıştır. OD'nin çevresindeki damarların oluşturduğu dikey kenarlar bu histogram üzerinde Şekil 24(b)'de görüldüğü üzere maksimum değerleri oluşturmaktadır [56].



Şekil 25. OD aday bölgesinden OD'nin tespiti (a) OD aday bölgesinin tespiti, (b) OD aday bölgesinin parlaklığının düzeltimi, (c) Canny Kenar Algılama metodunun uygulanması, (d) Hough dönüşümü ile OD bölgesindeki olası OD adaylarının tespiti, (e) En büyük dairesellik değerine sahip aday OD olmaktadır

Şekil 25'de görüldüğü üzere dikey koordinatlar üzerindeki piksellerin parlaklık değerleri toplamı ile oluşturulan histogramdan faydalanarak retina görüntüsünde 2 OD çapında (yaklaşık 200 piksel boyutunda) yeni bir görüntü elde edilmiştir. Yeşil kanal görüntüsü olan ve OD'nin bulunduğu bu yeni görüntü, öncelikle parlaklık değerleri 0-255 arasına normalize edilmiş ve daha sonra Şekil 25 (c)'de görüldüğü gibi Canny kenar algılama algoritması uygulanmıştır [67].

Canny kenar algılama algoritması dört adımda gerçekleştirilir. Öncelikle bir Gauss filtresi yardımıyla görüntüye yumuşatma işlemi uygulanır. İkinci adımda kısmi türevleri için sonlu-fark yaklaşımları kullanılarak eğimin büyüklüğü ve yönü bulunur. Eğimin büyüklüğü  $G = \sqrt{G_x^2 + G_y^2}$ , yönü ise  $\theta = \arctan\left(\frac{G_x}{G_y}\right)$  şeklinde hesaplanır. Üçüncü adımda,

görüntünün maksimum olmayan noktaları bastırılır. Son adımda ise adaptif bir eşikleme metodu uygulanarak gürültülü kenar noktalarının azaltılması sağlanır [67].


OD'yi tespit için, kenarları çıkartılmış ikili görüntü üzerinde geometrik şekillerin tespitinde başarılı bir yöntem olan Hough Dönüşüm (HD) yöntemi uygulanmıştır. Dairesel HD yöntemi,  $0-2\pi$  aralığında ve  $(a,b)$  noktasının bilinen bir  $r$  yarıçaplı çember üzerinde yer alıp almadığının tespiti için iki boyutlu bir akümülatör matrisi kullanarak görüntü üzerindeki daireesel nesnelere bulabilmektedir. Eğer,  $r$  yarıçapı bilinmiyor ise, akümülatör matrisi  $(a,b,r)$  olarak üç boyutlu hale dönüştürülebilir [68]. Çalışmada uygulanan daireesel HD yöntemi, 50 ile 70 piksel yarıçapındaki daireesel şekilleri arayarak OD'nin tespitini gerçekleştirmiştir. Dairesel şekillerin bulunmasında denklem (9) kullanılmaktadır

$$r^2 = (x - a)^2 + (y - b)^2 \quad (9)$$

Burada  $a$  ve  $b$  noktaları dairenin merkez koordinatlarını,  $r$  ise yarıçapını vermektedir [69]. Görüntü üzerinde bulunan daireelerin her birinin daireye benzerliklerinin ölçüsünü veren birer etkinlik değerleri vardır. OD'nin daireesel yapısından dolayı etkinlik değeri en yüksek daire, OD'nin oluşturduğu dairedir.

### 2.2.3. Fovea Bölgesinin Tespiti

Makula bölgesi, uygun retina görüntüsünün merkezine yakın bir bölgede olup renkli retina görüntüsünde milyonlarca kılcal damarın oluşturduğu koyu renkli bir bölgedir. Fovea ise makula bölgesinin tam ortasında olup makulanın en koyu renkli kısmıdır. Bu bölge görme merkezinden sorumlu olduğu için, eksuda veya hemoraji gibi lezyonların bu bölgede olması, görme kayıplarına yol açan Makulapati Hastalığına neden olabilmektedir. Fovea ve makulanın tespiti, DR sonucu oluşan mikroanevrizma ve hemoraji gibi koyu renkli lezyonların tespitindeki yanlış pozitiflerden kurtulmak için önemlidir. Ayrıca fovea, DR lezyonları ve diğer patolojilerin retina üzerindeki yerlerinin tanımlanması açısından referans bölge olarak da kullanılmaktadır.



Şekil 26 a) Optik Diskin bulunması, b) Foveanın bulunduğu dairesel alan, c) Fovea bölgesi, d) Makula bölgeleri

Foveanın tespitinde, tüm retina görüntüsü üzerine uygulanan eşikleme yöntemi, diğer koyu parlaklık değerlerine sahip lezyonlar ve damarlar nedeniyle DR hastalığı olan retina görüntüsünde başarılı sonuç vermez. Bu nedenle, optik diskin makula ile olan sabit mesafe ve açı değerleri kullanılarak daha başarılı fovea tespitleri yapılabilir. Şekil 26(b)'de görüldüğü üzere, foveanın merkezi optik diskin merkezinden, optik diskin çapının 2,5 katı mesafede bulunmaktadır [70]. Bu bilgi kullanılarak, optik diskin tespitinden sonra foveanın da tespiti kolayca ve başarılı bir şekilde yapılabilir.

Optik disk tespit edildikten sonra, OD'nin merkez noktasından 2 ve 3 OD çapı uzaklığında Şekil 26(b)'de görüldüğü üzere, iki adet daire çizilir ve fovea bu daireler arasında kalmaktadır. Fovea, optik diskin her zaman temporal (şakak) bölgesinde yer aldığından sağ gözde optik diskin sağında, sol gözde de optik diskin solunda yer almaktadır. Tüm bu konumsal bilgiler ışığında, Şekil 26(c)'de foveanın aranacağı lokal bölge, optik diskin merkez koordinatından 1 OD çapı yukarı ve aşağısı olmak üzere 2 OD çapında dikey bir kısıtlama bölgesi elde edilmektedir. Şekil 26(c)'de elde edilen bölge üzerinde morfolojik kapama işlemi yapılarak foveanın koyu kısmı biraz daha belirginleştirilmiştir. Sınırlandırılmış bu bölgede en küçük piksel değeri foveanın merkezini vermektedir.

Makula bölgesi Şekil 26(d)'de de görüldüğü gibi merkezden dışa doğru foveola, fovea, parafovea ve perifovea olmak üzere dört kısımdan oluşmaktadır. Foveanın merkez noktası bulunduktan sonra 0,35mm foveola, 1,5mm fovea, 2,5mm parafovea ve 5,5mm perifovea olmak üzere makula bölgesi dört bölgeye ayrılabilir. Böylece, hem uygun retina görüntüsünde bulunması gereken fovea bölgesi hem de makula bölgesinde meydana gelen Makulapati Hastalığı kolaylıkla tespit edilebilmektedir [71].

### 2.3. Retina Görüntülerinden Çıkartılan Öznitelikler

Örüntü tanıma çalışmalarında en önemli aşamayı oluşturan öznitelik çıkarımı, sistemin başarısını direk olarak etkileyen etkenlerden biridir. Öznitelikler, ayrıştırılacak sınıfların karakteristik özelliklerini barındıracak şekilde ve aralarında ilişki olmadan elde edilmelidir. Öznitelik çıkarımının amacı, en az boyuttaki öznitelikle, sınıfa ait bilginin mümkün olduğunca fazlasını ortaya koyabilmektir. Diğer bir ifadeyle,  $n$ -boyutlu bir  $X$  örnek

uzayında, daha küçük  $m$ -boyutlu  $Y$  öznitelik uzayına,  $X$  uzayının içerdiği bilginin mümkün olan en çoğunu transfer edebilen bir  $T$  dönüşümünü sağlayabilmektir [72].

$$X[n \times n] \xrightarrow{T} Y[m \times m] \quad n > m \quad (10)$$

Öznitelik çıkarımı sonucunda, sınıfın karakteristiğini yansıtmayan veya aralarında yüksek ilişki olan öznitelikler olabilir. Bu durumu aşmak için de öznitelik seçimi yöntemlerinden faydalanılır. Bu çalışmada, öznitelik seçimi için *İleriye Doğru Seçim (İDS)* ve *Genetik Algoritma (GA)* yaklaşımları kullanılmıştır.

### 2.3.1. Bölgesel Öznitelikler

Görüntülerden çıkartılan bölgesel öznitelikler, genelde parlaklık ve doku özelliklerini yansıtmayan, nesnelerin şekilsel ve alansal özelliklerini ortaya koyan özniteliklerdir. Çalışmada damar bölütlemesinden sonra çıkartılan bölgesel öznitelikler;

- Alan Özelliği: Bölgedeki piksellerinin sayıları toplamı olarak hesaplanmaktadır.

$$F_A = \sum_{i=1}^N \sum_{j=1}^M B[i, j], \quad \text{ikili görüntü için } F_A = \sum_{x \in A} 1 \quad (11)$$

- Büyük Eksen Uzunluğu: Bölgenin içerisindeki en büyük damarı kapsayan elipsin, en büyük eksen uzunluğu öznitelik olarak kullanılmıştır. Bunun amacı, kaliteli retina görüntülerinde bölütlenen damarların bu öznitelik için kalitesizlere göre daha büyük değerlere sahip olması beklenmektedir.
- Küçük Eksen Uzunluğu: Bölgedeki en küçük damarı kapsayan elipsin, en küçük eksen uzunluğu ele alınmıştır. Bu öznitelikte de küçük damarların ne kadar bölütlendiği hakkında bilgi vermektedir.
- Dış Merkezlilik: İkili görüntüdeki şeklin etrafına oturtulmuş elipsin, bir çembere ne ölçüde benzediğini gösteren orandır. Bu öznitelik retinanın dört parçaya bölündükten sonra Inferior, Superior, Nasal ve Temporal (ISNT) bölgelerindeki elipsin odakları

ile büyük eksen uzunluğu arasındaki mesafe oranını temsil etmektedir. Bu oran eğer 0'a yakınsa elips daire biçimine daha yakın olmakta, 1'e yakın ise elips doğruya daha yakın bir şekil almaktadır. Bu öznelik sayesinde, kaliteli görüntülerdeki bölütlenen damarların şekilleri hakkında bir bilgiye erişilebilir.

- Dışbükey Alan: Bir şeklin ne ölçüde konveks ne ölçüde konkav olduğunu tanımlayan ölçüdür. ISNT bölgelerindeki dışbükey özelliğini gösteren yapıların alanları öznelik olarak alınmıştır.
- Yönelme: ISNT bölgelerindeki elipsin x eksenini ile elipsin büyük eksenini arasındaki yaptığı açı da bir öznelik olarak kullanılmıştır. Bu öznelikte yine damarların konumları ile ilgili bilgi içermektedir.
- Kapsam: ISNT bölgelerindeki damarların alanının, tüm damarları içerisine alan dikdörtgenin alanına oranını vermektedir.
- Çevre: Damarların oluşturduğu çevre bilgisini veren özneliktir. İkili görüntülerde nesnenin kenar piksellerinin sayısı, çevre uzunluğunu vermektedir.  $B$ , nesnenin kenar piksellerinin kümesi olmak üzere  $F_C$ , çevre uzunluğu;

$$F_C = \sum_{x \in B} 1 \quad (12)$$

şeklinde hesaplanmaktadır.

### 2.3.2. Dokusal Öznelikler

Tıbbi görüntü analizlerinde en çok kullanılan öznelikler görüntünün dokusal öznelikleridir. Tıbbi görüntülerin çoğunda amaç, görüntü üzerindeki lezyon veya yapıların bölütlenmesi, kümelenmesi ya da sınıflandırılması olduğu için denetimli öğrenim algoritmalarında çoğunlukla dokusal öznelikler kullanılmaktadır. Benzer şekilde, retina görüntülerinde gerek arka plan, gerekse anatomik yapıların tespitinde dokusal öznelikler kullanılmıştır [2,31,32,40,73–76].

### 2.3.2.1. Gri – Seviye Histogramın İstatistiksel Öznitelikleri

Gri seviye görüntülerin histogramı, görüntü üzerindeki objelerin parlaklıkları ile ilgili birçok öznitelik taşımaktadır. Örneğin, bir objenin ortalama parlaklık değeri, standart sapması, pürüzsüzlüğü, keskinliği ve tekdüzeliği gibi değerler ayırt edici öznitelikler olarak kullanılabilir. Buna benzer olarak, görüntü üzerindeki bir nesnenin pikselleri arasındaki parlaklık ilişkisi dokusal öznitelikler olarak kullanılabilir [77].

Tablo 3. Gri-seviye histogramın istatistiksel öznitelikleri

Öznitelik	Formül	Açıklama
Ortalama (Mean)	$\mu = \frac{\sum_{ij} x_{ij}}{N}$	Piksellerin parlaklık değerlerinin ortalaması ile hesaplanır.
Standart Sapma (Standart Deviation)	$\sigma = \sqrt{\frac{\sum_{ij} (x_{ij} - \mu)^2}{N}}$	İlgilenilen bölgelerin parlaklık değerlerinin standart sapmasıdır.
Yumuşaklık (Smoothness)	$R = 1 - \frac{1}{(1 + \sigma^2)}$	Bölgenin yumuşaklık özniteliğini verir.
Çarpıklık (Skewness)	$S = \frac{\sum_{ij} (x_{ij} - \mu)^3}{N\sigma^3}$	Piksellerin parlaklık değerlerinin ortalama etrafındaki simetrikliğin ölçüsünü verir.
Tekdüzelik (Uniformity)	$U = \sum_{i=0}^{L-1} p(i)^2$	Histogramın tekdüzelik bilgisini verir.
Basıklık (Kurtosis)	$K = \frac{\sum_{ij} (x_{ij} - \mu)^4}{(N - 1)\sigma^4}$	Histogram dağılımının düzgünlüğünü belirlemek için kullanılan ölçüttür.
Parlaklık Olasılıkları (Average Histogram)	$AH_g = \frac{1}{L} \sum_{i=0}^{L-1} N(i)$	Parlaklık değerlerinin olasılıkları olarak adlandırılabilir.
Modifiye Standart Sapma (Modified Standard Deviation)	$\sigma_m = \sqrt{\sum_{i,j} (x_{ij} - \mu)^2 P(x_{ij})}$	Karşıtlığın ortalamasını verir.

$x_{ij}$ ,  $(i,j)$  konumundaki pikselin parlaklık değeri olmak üzere,  $N$  görüntüdeki piksellerin sayısı,  $L$  gri seviye sayısı,  $p(i)$  histogramdaki  $i$ . seviyedeki parlaklığın olasılığını




ve  $P(x_{ij})$  ise  $x_{ij}$ 'nin parlaklık seviyesinin olasılığını göstermek üzere, gri-seviye histogramın istatistiksel öznitelikleri Tablo 3'deki gibidir.

### 2.3.2.2. Haralick Doku Öznitelikleri

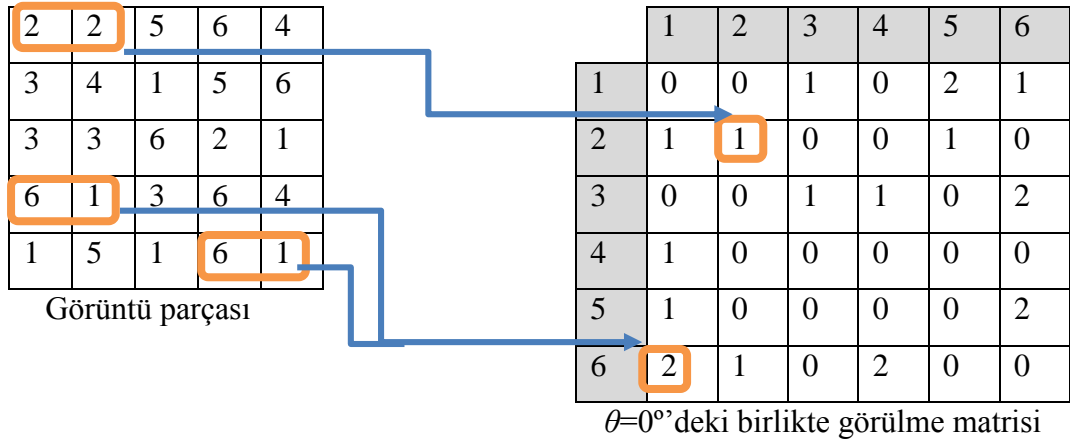
Haralick doku öznitelikleri, Haralick ve arkadaşları tarafından önerilmiş [77] ve doku alanında yapılan birçok çalışmada kullanılmıştır. Bu öznitelikler, dokuyu uzamsal parlaklık bağımlılıkları ile açıklamayı hedeflemiştir. Özgün çalışmada; doku, parlaklık değerlerinin  $d$  uzaklığında ve  $\theta$  açısında birlikte görülmelerini temsil eden Gri Seviye Birlikte Görülme Matrisinin (GSBGM, Gray Level Co-occurrence Matrix, GLCM) bazı istatistiksel özelliklerinin hesaplanmasıyla tanımlanmıştır. GSBGM, tüm satır ve sütunların gri seviye parlaklık değerini gösteren kare bir matristir. Dolayısıyla, GSBGM'nin boyutları görüntüdeki gri seviye parlaklık değerlerinin sayısına bağlıdır. GSBGM değerleri (13) formülü aracılığı ile hesaplanır.

$$C_{\Delta x, \Delta y}(i, j) = \sum_{p=1}^m \sum_{q=1}^n \begin{cases} 1, & I(p, q) = i \text{ ve } I(p + \Delta x, q + \Delta y) = j \\ 0, & \text{diğer durumlarda} \end{cases} \quad (13)$$

Burada,  $I(x, y)$  görüntü fonksiyonunu;  $m$  ve  $n$  sırasıyla görüntü genişliğini ve yüksekliğini;  $\Delta x$  ve  $\Delta y$ ,  $d$  ve  $\theta$  aracılığıyla hesaplanan uzaklık parametrelerini göstermektedir. Şekil 27'de  $d=1$  ve  $\theta=(0^\circ, 45^\circ, 90^\circ, 135^\circ)$  değerleri için kullanılan ilişkili pikseller görülmektedir.



Şekil 27.  $d=1$  ve  $\theta=(0^\circ, 45^\circ, 90^\circ, 135^\circ)$  için kullanılan pikseller



Şekil 28. GSBGM'nin elde edilmesi

GSBGM hesaplandıktan sonra, matrisin her elemanı, normalleştirilmiş birlikte görülme matrisini ( $p(i, j)$ ) elde edebilmek için (14) formülü aracılığı ile normalleştirilir.

$$p(i, j) = \frac{C(i, j)}{\sum_{k=1}^L \sum_{l=1}^L C(k, l)} \quad (14)$$

Burada,  $L$  görüntüdeki gri seviye parlaklık değer sayısını;  $p_{ij}$  olarak ta ifade edilen  $p(i, j)$  de normalleştirilmiş birlikte görülme matrisinin  $(i, j)$ . elemanını göstermektedir. Tablo 4'de GSBGM'den hesaplanan özneliklerin bir listesi mevcuttur [75].

Tablo 4. GSBGM'den hesaplanan Haralik-14 öznelikleri

Öznelik	Matematiksel Tanım
Açısal İkinci Moment ( $f_1$ ) (Enerji)	$\sum_i \sum_j \{p_{ij}\}^2$
Karşıtlık ( $f_2$ )	$\sum_{n=0}^{N_g} n^2 \left\{ \sum_{i=1}^{N_g} \sum_{j=1}^{N_g} p_{ij} \right\}_{ i-j =n}$
Korelasyon ( $f_3$ )	$\frac{\sum_i \sum_j (ij)p_{ij} + \mu_x \mu_y}{\sigma_x \sigma_y}$ burada $\mu_x$ ve $\sigma_x$ GSBGM'nin satır bazlı ortalama ve standart sapması; $\mu_y$ ve $\sigma_y$ GSBGM'nin sütun bazlı ortalama ve standart sapmasıdır.
Kareler Toplamı (Varyans) ( $f_4$ )	$\sum_i \sum_j (i - \mu)^2 p_{ij}$


Tablo 4'ün devamı

Öznitelik	Matematiksel Tanım
Ters Fark Momenti ( $f_5$ ) (Homojenlik)	$\sum_i \sum_j \frac{1}{1 + (i - j)^2} p_{ij}$
Toplam Ortalama ( $f_6$ )	$\sum_{i=2}^{2N_g} i \left\{ \sum_{\substack{j=1 \\ j+k=i}}^{N_g} \sum_{k=1}^{N_g} p_{jk} \right\}$
Toplam Standart Sapma ( $f_7$ )	$\sum_{i=2}^{N_g} (i - f_8) \left\{ \sum_{\substack{j=1 \\ j+k=i}}^{N_g} \sum_{k=1}^{N_g} p_{jk} \right\}$
Toplam Entropi ( $f_8$ )	$- \sum_{i=2}^{N_g} \left\{ \sum_{\substack{j=1 \\ j+k=i}}^{N_g} \sum_{k=1}^{N_g} p_{jk} \right\} \log \left\{ \sum_{\substack{j=1 \\ j+k=i}}^{N_g} \sum_{k=1}^{N_g} p_{jk} \right\}$
Entropi ( $f_9$ )	$- \sum_i \sum_j p_{ij} \log(p_{ij})$
Fark Varyansı ( $f_{10}$ )	$\left\{ \sum_{\substack{i=1 \\  i-j =n}}^{N_g} \sum_{j=1}^{N_g} p_{ij} \right\}$
Fark Entropisi ( $f_{11}$ )	$- \sum_{i=0}^{N_g-1} \left\{ \sum_{\substack{j=1 \\  j-k =i}}^{N_g} \sum_{k=1}^{N_g} p_{jk} \right\} \log \left\{ \sum_{\substack{j=1 \\  j-k =i}}^{N_g} \sum_{k=1}^{N_g} p_{jk} \right\}$
Korelasyonun Bilgi Ölçekleri ( $f_{12}$ , $f_{13}$ )	$f_{12} = \frac{f_9 - HXY1}{\max\{HX, HY\}}$ $f_{13} = 1 - e^{\sqrt{-2(HXY2-f_9)}}$ <p>burada HX ve HY sırasıyla <math>p_x</math> ve <math>p_y</math>'nin entropileridir, ve</p> $HXY1 = - \sum_i \sum_j p_{ij} \log(p_{x,i} p_{y,j})$ $HXY2 = - \sum_i \sum_j p_{x,i} p_{y,j} \log(p_{x,i} p_{y,j})$
En Büyük Korelasyon Katsayısı ( $f_{14}$ )	<p>burada;</p> $f_{14} = \sqrt{Q' \text{nin ikinci büyük özdeğeri}}$ $Q(i, j) = \sum_k \frac{p_{ik} p_{jk}}{p_{x,i} p_{y,j}}$

### 2.3.3. Zernike Momentleri

Görüntü momentleri etkin birer şekil tanımlayıcı olarak tıbbi görüntü analizlerinde ve nesne tanımda öznitelik olarak kullanılmaktadır. Momentler, görüntüdeki boyut değişimleri, ötelemeler ve dönmelere karşı bağımsız öznitelikler oluşturur [78]. Yani, görüntü üzerindeki parlaklık değişimleri ya da aynı görüntünün farklı görüş açısıyla ele alınması, momentlerin oluşturduğu özniteliklerde çok fazla değişim gerçekleştirmemektedir. Moment öznitelikleri, uygulanan görüntü üzerindeki piksel değerlerinin belirli bir bölge üzerindeki ağırlıklı ortalamasından görüntüye ait bilgiler vermektedir [75,76,78].

Zernike Momentleri (ZM), görüntü tanımda etkin öznitelikler olarak kullanılmaktadır [79,80]. Bir görüntünün ZM'leri, ortogonal polinom ailesinden gelen karmaşık Zernike polinomlarının görüntü üzerine izdüşümü gibi gösterilebilir. Şekil 29'da 5. momente kadar olan izdüşümleri görülmektedir.



Şekil 29. Zernike temel fonksiyonlarının birim disk üzerindeki etkileri

Görüntüler üzerindeki ZM'ler üç adımda hesaplanmaktadır. Sırasıyla, ortogonal polinom, Zernike radyal polinomu ve görüntünün bu fonksiyonlar üzerindeki izdüşümleri hesaplanarak ZM'ler elde edilir [81].

Zernike ortogonal polinomları;

$$V_{nm}(\rho, \theta) = R_{nm}(\rho)e^{jm\theta} \quad (15)$$

şeklinde tanımlanır. Burada  $n$  polinom derecesini,  $m$  ise  $|m| < n$  ve  $n - |m|$  çift sayı olacak şekilde yineleme sayısını göstermektedir. Buradaki  $R_{nm}$  radyal polinomu;

$$R_{nm}(\rho) = \sum_{s=0}^{\frac{n-|m|}{2}} (-1)^s \frac{(n-s)!}{s! \left(\frac{n+|m|}{2} - s\right)! \left(\frac{n-|m|}{2} - s\right)!} \rho^{n-2s} \quad (16)$$

olarak hesaplanır. Sonuç olarak,  $f(i, j)$  görüntüsünün ZM'leri;

$$Z_{nm} = \frac{n+1}{\pi} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} f(i, j) V^*(\rho_{ij}, \theta_{ij}) \Delta x_i \Delta y_j \quad (17)$$

şeklinde hesaplanır.  $x_i$  ve  $y_i$  değerleri  $[-1, 1]$  aralığına çekilmiş görüntünün koordinatlarını göstermektedir.  $\rho_{ij} = \sqrt{x_i^2 + y_j^2}$ ,  $\theta_{ij} = \tan^{-1} \frac{y_j}{x_i}$  ve  $\Delta x_i = \Delta y_j = 2/N\sqrt{2}$  şeklindedir [80,81].

### 2.3.4. Kenar Histogram Öznitelikleri

İnsan gözü, görüntü algılamada kenar özniteliklerine çok duyarlıdır. Böyle önemli bir özniteliği tanımlamanın bir yolu da histogram kullanımıdır. Görüntü uzayında bir kenar histogramı, parlaklık değerlerinin değişimini ve yönünü göstermektedir. Bir renk histogramı veya homojen doku özniteliklerinin tekrarlanmadığı benzersiz bir öznitelik olarak kullanılabilir. MPEG-7 standardı için önerilen Kenar Histogram Tanımlayıcı (KHT), görüntüde sadece yerel kenar dağılımlarını temsil etmektedir [82]. İlk olarak, görüntü  $4 \times 4$ 'lük alt görüntülere bölünmektedir. Şekil 30'da gösterilen 5 standart kenar yönünün histogramı, her bir alt görüntü için hesaplanır. Böylece KHT, dört yönlü filtre ve bir izotropik filtre ile oluşturulmuş olur. Kenar histogramını hesaplamak için, her alt görüntünün  $2 \times 2$ 'lik örtüşmeyen bloklarındaki kenar filtre tepkileri hesaplanır ve filtre tepkisi en büyük olduğunda her bir blok bir kenara atanmaktadır. Bu nedenle her 16 alt görüntü için 5 kenar histogramı hesaplandığından kenar histogram öznitelik eleman sayısı 80'dir [75,83].

1	-1	1	1	$\sqrt{2}$	0	0	$\sqrt{2}$	2	-2
1	-1	-1	-1	0	$-\sqrt{2}$	$-\sqrt{2}$	0	-2	2
Dikey Kenar Filtresi		Yatay Kenar Filtresi		45° Kenar Filtresi		135° Kenar Filtresi		İzotropik Filtre	

Şekil 30. Kenar algılama için kullanılan filtre katsayıları

## 2.4. Makine Öğrenmesi ve Kullanılan Sınıflandırıcılar

Son yıllardaki çalışmalar, bilgisayarların insanoğlu gibi öğrenebilen, çıkarım yapabilen ve kararlar verebilecek yazılımlar üzerine yoğunlaşmıştır. Bilgisayarların karar verebilme yeteneği, sistemin etkin değerlerle eğitimine bağlıdır. Günümüzde depolama ve iletişim maliyetlerinin azalması ile çok büyük veri kümelerini saklamak ve paylaşmak oldukça kolaylaşmıştır. Gelişen teknoloji ile hesaplama hızındaki gelişmelere paralel olarak öğrenme algoritmalarını çok büyük veriler üzerinde uygulamak mümkün hale gelmiştir [84].

Makine öğrenmesi, insan beyni model alınarak bilgisayarlara “öğrenme” yeteneği sağlayacak algoritma ve yaklaşımların geliştirilmesini ele alan yapay zekânın bir alt dalıdır. Makine öğrenmesinin temel amacı, insanlardaki geri beslemeli öğrenmenin bilgisayarlarda da gerçekleştirebilmesidir. Makine öğrenmesi, veri setinin hazırlanması, öğrenme algoritmalarının uygulanması ve öğrenme performansının değerlendirilmesi olarak üç aşamadan oluşur. Bu konunun gelişimi ile çeşitli öğrenme sistemleri ortaya konmuştur. Bunlar, Gözetimsiz Öğrenme, Gözetimli Öğrenme, Yarı-Gözetimli Öğrenme, Ödüllü Öğrenme, Uyum Sağlama ile Öğrenme ve Öğrenme ile Öğrenme şeklinde sıralanabilir [85].

Literatürdeki çalışmalarda en çok gözetimsiz ve gözetimli öğrenme metodunu kullanan algoritmalar kullanılmaktadır. Gözetimsiz öğrenme (Unsupervised Learning) sistemleri, çıktı verilerini kullanmadan sadece girdi verileri üzerinden öğrenme işlemini gerçekleştirirken, Gözetimli öğrenme (Supervised Learning) sistemleri ise eğitim verileri (etiketlenmemiş veri) ile çıktı verileri (etiketlenmiş veri) arasında eşleme yaparak öğrenme yapar [85].

Makine öğrenmesi ve sınıflandırma, yüz tanıma, medikal görüntü analizi, finansal tahminler, bilgisayar oyunları, robot hareketleri, arama motorları ve doğal dil işleme gibi uygulamalarda kullanılmaktadır.

Bu tez çalışmasında, literatürde en çok bilinen gözetimli sistemlerden, Doğrusal Ayırıştırma Analizi (DAA), k-En Yakın Komşu (k-EYK) Yöntemi, Yapay Sinir Ağları (YSA), Naive Bayes (NB) ve Destek Vektör Makineleri (DVM), Karar Ağaçları (KA), Rastgele Orman (RO) sınıflandırıcıları ve Adaboost yaklaşımı kullanılmıştır.


#### 2.4.1. Doğrusal Ayırıştırma Analizi

Örüntü tanımadaki Ayırıştırma Analizi (AA), ayırıştırma fonksiyonları yardımı ile örüntü üzerindeki bir nesnenin ayırma işlemine en fazla etki eden özniteliklerin tespitinde ve nesnenin hangi sınıfa dâhil olacağına karar vermede kullanılmaktadır. AA,  $n$  adet özniteliğe sahip bir nesnenin, bu öznitelikleri kullanarak en uygun sınıfa atanması ya da diğer nesnelere ayırma için en uygun ayırıştırma fonksiyonunun bulunmasını sağlayan çok değişkenli istatistik yöntemlerden biridir. AA, yöntemleri genel olarak parametrik ve parametrik olmayan şeklinde ayrılabilir [86]. Parametrik yaklaşımda, temel veri dağılımı konusunda kesin varsayımlar yapılır. Parametrik olmayan yaklaşım ise özel bir dağılıma ihtiyaç duymamaktadır. AA yönteminin Doğrusal Ayırıştırma Analizi (DAA), Karesele Ayırıştırma Analizi ve Lojistik Regresyon gibi çeşitleri vardır [87].

DDA'yı geometriksel olarak göstermek istenirse, Şekil 31'deki  $I$  doğrusu,  $K_1$  ve  $K_2$  sınıfına ait iki boyutlu özellik uzayını ayıran  $J$  doğrusuna dik bir doğru olsun.  $K_1$  ve  $K_2$  sınıflarına ait nesnelere temsil eden noktaların izdüşümleri  $I$  doğrusu üzerine düşürülür.  $K_1$  ve  $K_2$  sınıflarının  $I$  doğrusu üzerindeki ortalama vektörlerinin izdüşümü arasındaki varyans maksimize edilmiş olur.  $I$  eksenini, nesnelere ait  $n$  adet özniteliği,  $I$  doğrusu üzerindeki izdüşümlerinin doğrusal bir dönüşümü yardımıyla  $n$  adet özniteliği ayıran bir eksen haline gelmiştir. Bu doğruya ayırıştırma fonksiyonu denir [87,88].

$I$  ve  $J$  doğrularının kesiştiği  $w$  noktası, tek boyutlu bu ayırma uzayını,  $S_1$  ve  $S_2$  olarak iki bölgeye ayırır.  $S_1$  bölgesine izdüşümü düşen bir nesne  $K_1$  sınıfına,  $S_2$  bölgesine düşen nesne ise  $K_2$  sınıfına ait olur [87].

Ayrırma eksenini  $I$ ,  $K_1$  ve  $K_2$  sınıflarının çok değişkenli normal dağılıma ve ortak varyans-kovaryans'a sahip olmaları varsayımı üzerine oluşturulmuştur. Bu varsayımlar altında  $J$  doğrusu iki sınıfı birbirinden ayıran en iyi doğru olacaktır [87,88].



Şekil 31. Ayrıştırma analizinin geometrik gösterimi

DAA'nın temel amacı, gruplar arası kareler toplamının, gruplar içi kareler toplamına oranını maksimum yapacak  $n$  adet nesneyi ayıracak doğrusal fonksiyonu bulmaktır.  $n$  adet nesnenin  $g$  adet sınıfa ayrıldığını varsayarak,  $k$ . sınıfta  $N_k$  adet nesne ve toplam nesne sayısı da  $N$  olsun. Her nesne için  $n$  adet öznelik  $X_1, X_2, \dots, X_n$  şeklinde verildiğinde, grup ortalama vektörü [87,88];

$$\mu_k = \frac{1}{N_k} \sum_{i=1}^{N_k} X_{ik} ; k = 1, 2, \dots, g \quad (18)$$

genel ortalama vektörü;

$$\mu = \frac{1}{N} \sum_{k=1}^g \sum_{i=1}^{N_k} X_{ik} \quad (19)$$

ile gösterilir. Çok değişkenli varyans analizinden (MANOVA), toplam çarpımlar ve kareler toplamı [87];



$$T = \sum_{k=1}^g \sum_{i=1}^{N_k} (X_{ik} - \mu)(X_{ik} - \mu)^T \quad (20)$$

şeklinde olup, gruplar arası çarpımlar ve kareler toplamı;

$$B = \sum_{k=1}^g \sum_{i=1}^{N_k} (\mu_k - \mu)(\mu_k - \mu)^T \quad (21)$$

grup içi çarpımlar ve kareler toplam ise;

$$W = \sum_{k=1}^g W_k = \sum_{k=1}^g \sum_{i=1}^{N_k} (X_{ik} - \mu_k)(\mu_k - \mu)^T \quad (22)$$

şeklindedir. T, B ve W arasında ise;

$$T = B + W \quad (23)$$

şeklinde bir ilişki vardır [87]. Bu değerler serbestlik dereceleri ile bölünürse, toplam varyans, gruplar arası varyans ve gruplar içi varyans;

$$S_X = \left( \frac{1}{N-1} \right) T \quad (24)$$

$$S_B = \left( \frac{1}{g-1} \right) B \quad (25)$$

$$S_W = \left( \frac{1}{N-g} \right) W \quad (26)$$

şeklinde olur.

Ayrıştırma analizinin temel varsayımı göz önüne alınırsa;

$$\lambda = \frac{u^T B u}{u^T W u} \quad (27)$$

Burada  $u$ ;

$$u = \begin{bmatrix} u_1 \\ u_2 \\ \vdots \\ u_n \end{bmatrix}_{n \times 1} \quad (28)$$

$n \times 1$  boyutlu katsayılar vektörüdür. Lagrange yöntemine göre,  $\lambda$ 'nın sütun vektörü olan  $u^T$ 'ye göre kısmi türevi alınarak sifıra eşitlenir [87,88].

$$\frac{\partial \lambda}{\partial u} = \frac{2[(Bu)(u^T W u) - (u^T B u)(W u)]}{u^T W u} = 0 \quad (29)$$

Burada,  $u^T W u = 1$  kısıtlaması kullanılarak;

$$B u - \lambda W u = 0 \quad (30)$$

eşitlik halini alır.

Bu eşitlik,  $W$  matrisinin tersi  $W^{-1}$  matrisi ile soldan çarpılırsa;

$$(W^{-1} B - \lambda I) u = 0 \quad (31)$$

eşitlik elde edilir. Özdeğer  $\lambda$ 'nın köklerini bulan her  $\lambda$  için;

$$(W^{-1} B - \lambda I) = 0 \quad (32)$$

denkleminin çözümünü arayan  $u$  vektörünü verir.  $\lambda$ 'nın  $i$ . kökü için bulunan vektör  $u_i$  ile gösterilirse  $i$ . ayrıştırma fonksiyonu;

$$f_i = u_i^T X_i \quad (33)$$

şeklinde ifade edilir. Buna göre, n adet ayırıcı öznelik için k. gruptaki, m. nesne için ayrıştırma fonksiyonu;

$$f_{km} = u_1X_{1km} + u_2X_{2km} + \dots + u_nX_{nkm} \quad (34)$$

şeklini alır [87]. Burada;

$X_i$ : i. nesnelere ait öznelikler ( $i = 1, 2, \dots, n$ ), k. gruptaki ( $k = 1, 2, \dots, g$ ), m. nesne ( $m = 1, 2, \dots, N_k$ ) için değeri,

$u_i$ : ayrıştırma fonksiyonunun i. katsayısı,

$g$ : sınıf sayısıdır [87,88].

#### 2.4.2.k-En Yakın Komşu Sınıflandırıcı

k-EYK algoritması gözetimli ve örnek tabanlı bir sınıflandırıcıdır. Sınıfları belirli olan örnek kümeye ait gözlemlere yeni bir gözlem eklendiğinde bu gözlemin hangi sınıfa ait olacağını belirlenmesini sağlar. Bu algoritmanın sınıflandırma işlemi, gözlemler arası uzaklık hesaplanarak yapılır. Sınıflandırma, en son eklenen gözlemin sistemdeki mevcut gözlemlere uzaklıklarının hesaplanması ve en az uzaklığa sahip k adet gözlemin seçilmesi ile yapılır. Uzaklık hesaplaması için *Öklid (Euclidean)*, *Manhattan*, *Mahalanobis* ve *Chebyshev* yöntemleri kullanılmaktadır [84,89].

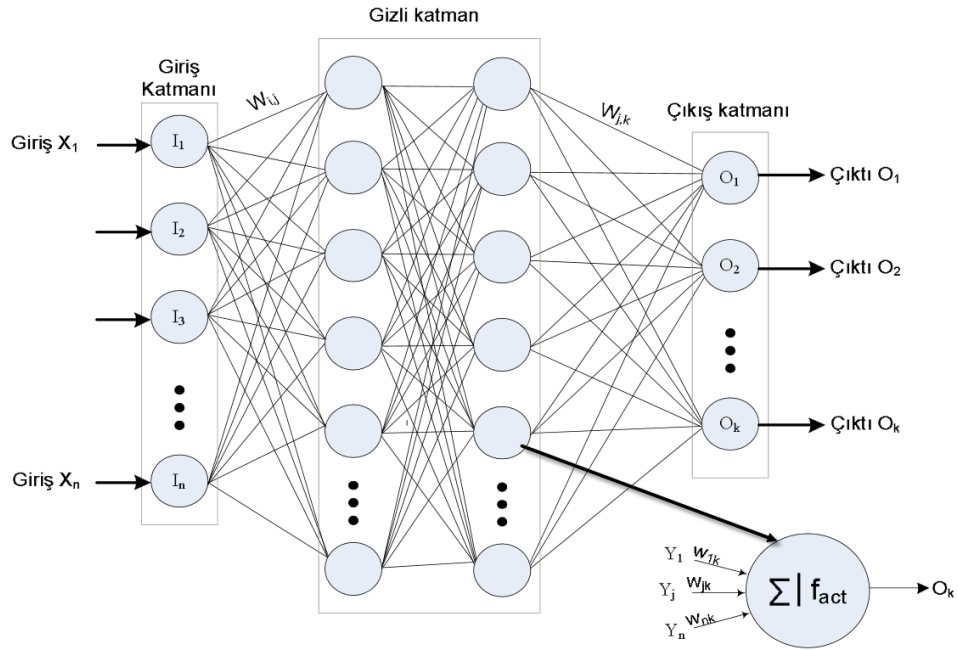
k-EYK yaklaşımı, örnek tabanlı bir sistem olduğundan parametre olarak sadece örnekler tutulur. Tüm örneklerin d boyutlu bir uzaydaki elemanlar olduğu varsayılır. Sınıfı bilinmeyen yeni bir örnek sisteme geldiğinde, örneğin kendi komşularından k tanesinin çoğunluğunun bulunduğu sınıfa ataması yapılır. k-EYK'nın ayrıca bir eğitim aşaması yoktur. Bir başka ifadeyle, eğitim aşaması sadece örneklerin ve ait oldukları sınıf bilgilerinin tutulmasından ibarettir. Komşuların belirlenmesinde, örneklerin hepsi çok boyutlu uzaydaki vektörler olarak gösterilir. Genel olarak, uzaklık hesabında Öklid mesafesi kullanılmaktadır [85,90].

k-EYK algoritması, örneklerin dağılımına bağlı olmadan çalıştığı için sınıflandırıcı olarak daha yüksek bir genelleme imkanı sağlar [91]. Ayrıca k-EYK algoritmasında eğitim verisinin kaybolmaması avantaj olarak görülebilir. Ancak, büyük veri setleri için sınıflandırmada test edilen veriyi tüm eğitim kümesiyle karşılaştırdığından oldukça uzun olan hesaplama süresi bir dezavantaj olarak söylenebilir [90]

### 2.4.3. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), insan beyninin basit biyolojik sinir (nöron) sistemini model olarak, öğrenme yoluyla yeni bilgiler üreten ve önceki örnekleri kullanarak bilgiler arasında ilişkileri ortaya koyan, karar verebilme yeteneği olan sistemlerdir.

YSA'nın temeli, biyolojik sinirlerdeki nöronlar gibi yapay nöronlardan oluşur. Yapay nöronlar sinir ağının temel birim elemanıdır. Ağ içerisindeki nöronlar birden fazla girdi alabilirler ancak tek bir çıktı verirler. Nöronların çıktıları YSA'nın çıktısı olabileceği gibi başka bir nöronun girdisi de olabilir. YSA genel olarak Şekil 32'de de görüldüğü üzere, giriş katmanı, gizli katman ve çıkış katmanı şeklinde üç katmandan oluşmaktadır [92].



Şekil 32. YSA'nın genel yapısı

YSA'da nöronların oluşturduğu gizli katman sayısının az olması karmaşık problemlerin çözümünde yetersiz kalırken, çok fazla gizli katman ise YSA'nın yanlış kararlar almasına yol açabilir. Uygun katman ve nöron sayısı belirleme süreci, problemde probleme değişiklik gösterdiğinden YSA'nın kurulumu oldukça karmaşık ve zor olabilmektedir [93].

YSA'nın öğrenme ve katman sayılarına göre birçok çeşidi vardır [92]. Bu çalışmada giriş ve çıkış katmanları arasında birden fazla katmanın kullanıldığı Çok Katmanlı Algılayıcı (ÇKA) sistemi kullanılmıştır. ÇKA girdi ve çıktı düğümleri ile direkt bağlantılı olmayan gizli düğümler bulundurabilmektedir [92–94].

#### 2.4.4. Naive Bayes Sınıflandırıcısı

NB sınıflandırıcısı, Bayes teoremini temel alarak hedef değişkenle bağımsız değişkenler arasındaki ilişkiyi analiz eden tahminci ve tanımlayıcı bir sınıflandırma algoritmasıdır. Bayes karar kuralı, verilmiş kararlar arasındaki farkları ve bu kararların olasılıklarını hesaplayan olasılıksal bir yaklaşımdır [91].

NB sınıflandırıcı, olasılık modeline bağlı olarak gözetimli öğrenmede etkin bir şekilde kullanılmaktadır. Bayes modellerinin parametre tahmini için *maksimum olabilirlik* yöntemi kullanılmaktadır [95]. Bayes teoremi, hesaplanan olasılıkların doğruluk oranının tespiti için kullanılabilir.

A ve B rastgele olaylar olduğu varsayılarak;

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (35)$$

$P(A)$  : A olayının bağımsız olasılığı

$P(B)$  : B olayının bağımsız olasılığı

$P(B | A)$  : A olayının olduğu bilindiğinde B olayının olma olasılığı (Likelihood, Şartlı Olasılık)

$P(A | B)$  : B olayının olduğu bilindiğinde A olayının olma olasılığı (Posterior, Sonsal Olasılık)

NB, kuralına dayanarak  $P(A|B)$  olasılığını maksimum yapan durumlar hesaplanabilir [96].

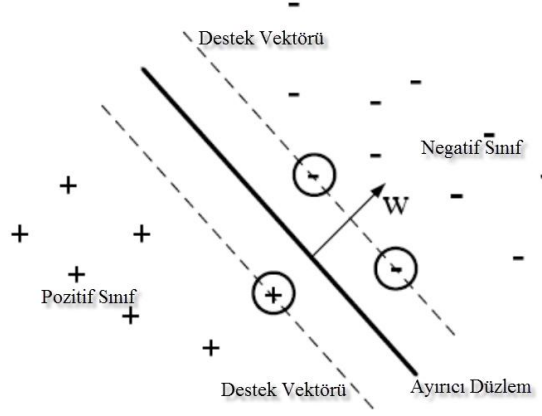
$E$ , A olayının bütün durumlarını kapsayan evrensel kümesi olmak üzere;

$$\begin{aligned}
 A_{MAX} &= \operatorname{argmax}_{A \in E} P(A|B) \\
 &= \operatorname{argmax}_{A \in E} \frac{P(B|A)P(A)}{P(B)} \\
 &\cong \operatorname{argmax}_{A \in E} P(B|A)P(A)
 \end{aligned} \tag{36}$$

Burada  $P(B)$  toplam olasılık olduğundan 1 değeri aldığı varsayılarak göz ardı edilebilir. NB, en yüksek olasılık hangi sınıf için hesaplandıysa karar sınıfı olarak o sınıfı seçer.

#### 2.4.5. Destek Vektör Makineleri

DVM, gözetimli öğrenme yöntemi ile ikili sınıflandırma ve regresyon kestirimi için kullanılan başarılı bir sınıflandırıcıdır [97,98]. Sınıflandırma işlemi, eldeki veri kümesini iki veya daha çok bölüme ayıran d-boyutlu alt-düzlem (hyperplane) oluşturularak gerçekleştirilir. Temelde ikili sınıflandırıcı olan DVM ile çoklu sınıflandırma problemi ise veri kümesinin farklı biçimlerde (bire karşı hepsi gibi) ikiye bölünmesiyle çözülür. Örüntü tanıma problemlerinde alt-düzlem, eğitim kümesindeki pozitif ve negatif örnekleri ayırmak için kullanılmaktadır [97]. Verilerin dağılımlarına göre birden fazla ayırıcı düzlem olduğunda, kendisine en yakın pozitif ve negatif verinin uzaklıkları en büyük olan ayırıcı düzlem seçilir. Ayırıcı düzleme en yakın pozitif ve negatif veriler *destek vektörleri* olarak adlandırılır ve karar sınırını belirler [99,100].



Şekil 33. DVM için ayırıcı düzlem ve destek vektörleri

Şekil 33’de veri kümesindeki vektörleri ifade eden değişken  $x$ , bağıl konum değeri  $b$  ve ayırıcı düzlemin normal vektörü  $w$  olmak üzere ayırıcı düzlem,  $w \cdot x + b = 0$  doğrusu ile ifade edilebilir [99].  $n$  adet örnek içeren ve eğitim kümesinde sınıflarına göre etiketlenmiş veriler kullanılarak en iyi ayırıcı düzlem,  $x_i$  d-boyutlu eğitim vektörü,  $y_i$  bu vektörün sınıfı ve  $b$  de bağıl konum değeri olmak üzere;

$$y_i(w \cdot x_i + b) - 1 \geq 0, \quad i = 1, 2, \dots, n, \quad x_i \in R^d, y_i \in \{-1, 1\} \quad (37)$$

şeklinde ifade edilebilir.

Burada, en yakın eğitim örneği ile arasındaki uzaklık değeri  $2/\|w\|$  olan en büyük düzlem, ayırıcı düzlem olarak belirlenir. Ayırıcı düzlemi belirlenmiş bir DVM için, gelen yeni bir verinin sınıflandırılması ( $y_i$ 'nin bulunması) ise [99,101];

$$y_i = \text{sgn}(w \cdot x_i + b) \quad (38)$$

şeklinde gerçekleştirilir.

Doğrusal DVM’de en iyi ayırıcı düzlemi bulmak için en yakın eğitim örneğine olan uzaklığına bakılır. Doğrusal olarak sınıflandırılmayan veriler için ise, verilerin doğrusal olarak sınıflandırılabilmesi ve iç çarpımın tanımlı olduğu başka bir uzaya dönüşüm için çeşitli çekirdek fonksiyonları tanımlanmaktadır. Doğrusal çekirdek fonksiyonu denklem (39)’daki gibi ifade edilmektedir [99].

$$K(x_i, x_i) = (x_i \cdot x_i) \quad (39)$$

#### 2.4.6. Karar Ağaçları

Karar ağaçları (KA), bir dizi kurala göre sınıf oluşturan, bir kök, düğüm kümesi ve kenarlardan oluşan hiyerarşik ve çevrimsel olmayan grafiklerdir. Bir ağaç yapısındaki düğümler öznitelikleri temsil ederken, kenarlar ise bu özniteliklerin olası değerlerini temsil etmektedir. Bir nesne, karar ağaçlarında yukarıdan aşağıya bir yol izleyerek ve önceden çıkartılan öznitelik değerleri göz önüne alınarak sınıflandırılırlar [102]. KA, diğer sınıflandırma yaklaşımlarında olduğu gibi öğrenme ve doğrulama olmak üzere iki aşamada değerlendirme yapar. Eğitim veri kümesi ile oluşturulan karar modelleri test veri kümesi ile sınanır. KA sınıflandırma yönteminin ayrıştırma performansındaki başarısı veri kümesinin homojen olmamasına bağlıdır [85,103].

KA algoritmalarının temel işlevi seçim ağacındaki her düğümde en uygun değişkenin seçilmesini sağlamaktır. Literatürde kullanılan başlıca KA algoritmaları;

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

şeklinde sıralanabilir. Bu çalışmada kullanılan CHAID algoritması, düzeltilmiş anlamlılık (Bonferroni) sınavasını kullanan bir karar ağacı yöntemidir. CHAID algoritması 1980 yılında G.V. Kass tarafından geliştirilmiştir [104]. Bu algoritma, gruplar arasında istatistiksel olarak anlamlı bir fark olduğunda ayrıştırma işlemine başlamaktadır [105,106]. CHAID algoritmasında uygulanan adımlar, kayıp değerlerin bulunması, ağacın büyütülmesi,



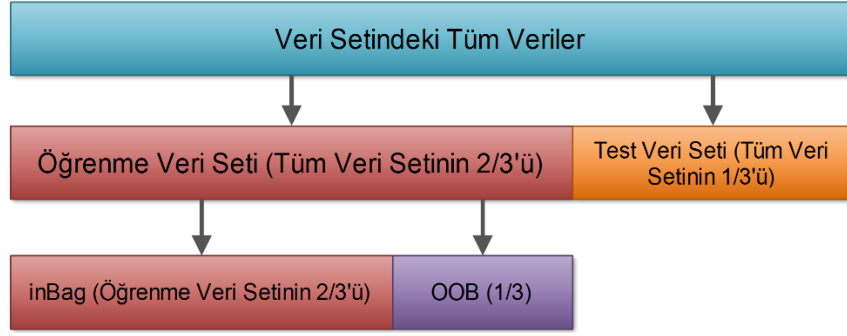
durdurma kurallarının ve modelin performans ölçümlerinin tespiti şeklinde sıralanabilir [103].

KA yaklaşımında ağaçlanmayı sağlayan farklı bölme kriterleri mevcuttur. Bu çalışmada, bilgi kazancı (information gain) yöntemi kullanılmıştır. Bilgi kazancı metodunda ayırma ölçütü, entropi hesabıyla yapılmaktadır [107].

#### **2.4.7. Rastgele Orman Sınıflandırıcı**

Rastgele Orman (RO) sınıflandırıcısının temelinde KA vardır. Tekil olarak oluşturulan KA birleştirilerek bir karar ormanı oluşturmakta ve ağaçların yapmış olduğu tahminler bir araya getirilerek nihai bir tahmin yapılmaktadır. RO yönteminde dallanma kriterlerinin kullanılmasında Gini indeksi yöntemi kullanılmaktadır. Gini indeksi, sınıf özniteliklerinin zayıflık derecesini ölçme temeline dayanmaktadır. Diğer sınıflandırıcılarda olduğu gibi RO yaklaşımında da kullanıcı tarafından belirlenen parametreler mevcuttur. Bu parametre değerleri ağaç yapısının oluşturulması için her bir düğümde kullanılacak örneklerin sayısı ve oluşturulacak ağaç sayısıdır. Sınıflandırma işlemi sırasında karar ormanı, kullanıcı tarafından belirlenen  $k$  adet ağaçtan oluşturulur. Yeni bir sınıflandırma işleminde veri seti bu  $k$  adet karar ağacından geçirilir ve RO sınıflandırıcısı ile  $k$  adet ağaçtan elde edilen  $k$  adet oy arasından en fazla oya sahip olan sınıf seçilir [108,109]. Bu çalışmada, RO için  $k=10$  adet ağaç oluşturulmuştur.

RO yönteminde, üretilen modeli test etmek için ayrı bir veri seti yoksa ya da orijinal veri setinden test veri seti ayrılmamışsa, sınıfın dağılımı dikkate alınmak suretiyle orijinal veri setinin  $2/3$ 'ü eğitim verisi,  $1/3$ 'ü ise test verisi olarak ayrılır. Eğer test verisi mevcut ise, eğitim verilerinin  $2/3$ 'ü (inBag) yine eğitim için geri kalan  $1/3$ 'ü (Out-of-Bag (OOB)) ise test için kullanılır [108].



Şekil 34. Rastgele Orman yönteminde veri seçimi

#### 2.4.8. Adaboost Yaklaşımı

Adaboost, herhangi bir öğrenme algoritmasının performansını arttıran genel bir yaklaşım olup, öğrenme algoritması tarafından üretilen zayıf sınıflandırıcılardan daha iyi bir performans sağlamayı amaçlamaktadır. Adaboost algoritması Freund ve Schapire tarafından 1997’de önerilmiş ve önceki artırım (boosting) yaklaşımlarına göre üstünlük sağlamıştır [110,111].

Adaboost algoritması her bir eğitim verisi için eşit bir  $d$  dağılımı ile başlar. Her iterasyonda sınıflandırma performansına bağlı olarak en iyi sınıflandırıcıyı bulur ve ağırlıklar güncellenerek bir olasılık dağılım fonksiyonu elde edilir. Belirli sayıda iterasyon sonucunda her iterasyonda seçilen en iyi sınıflandırıcılar bir araya getirilerek güçlü bir sınıflandırıcı oluşturulur.

Adaboost algoritmasının çoklu sınıflandırma problemlerinin çözümü için geliştirilen Adaboost.M1 versiyonunun sınıflandırma yöntemi aşağıdaki gibidir [112].

$M$  örnekten oluşan eğitim seti  $S = \langle (x_1, y_1), \dots, (x_m, y_m) \rangle$ ,  $x_i \in X$  ve  $y_i \in Y = \{1, \dots, k\}$  sınıf etiketlerini göstermek üzere, ağırlık değerlerine başlangıç değerleri olarak  $w_i^1 = D(i) = \frac{1}{m}$ , ( $i = 1, \dots, m$ ) verilir. Her  $t = 1, 2, \dots, T$  için; ( $T$  iterasyon sayısı olmak üzere)

1.  $p^t$  bir olasılık dağılımını göstermek üzere ağırlıklar normalize edilir;

$$p^t = \frac{w^t}{\sum_{i=1}^m w_i^t}$$

2. S eğitim kümesi üzerinde  $p^t$  dağılımını sağlayan bir zayıf sınıflandırıcı  $h_t = X \rightarrow Y$  şeklinde bir hipotez hesaplar. Zayıf sınıflandırıcının amacı eğitim hatasını minimuma indiren bir hipotez bulmaktır.

3.  $h_t: \varepsilon_t = \sum_{i=1}^m p_i^t h_t(x_i) \neq y_i$  olarak ifade edilen eğitim hatası hesaplanır. Bu hata zayıf sınıflandırıcı tarafından sağlanan  $p^t$  dağılımına göre hesaplanır. Eğer hata  $\varepsilon_t > 1/2$  ise,  $T = t - 1$  olacak şekilde ayarlanır ve döngüden çıkılır.

4.  $\beta_t = \varepsilon_t / (1 - \varepsilon_t)$  değeri hesaplanır.

5. Ağırlıklar  $w_i^{t+1} = w_i^t \beta_t^{1-h_t(x_i) \neq y_i}$  ile hesaplanan yeni değerlerine güncellenir.

Bu işlem  $T$  iterasyon boyunca devam eder ve  $h_1, \dots, h_t$  zayıf sınıflandırıcıları birleştirerek kuvvetli sınıflandırıcı bulunmuş olur [110,112].

$$h_f = \operatorname{argmax}_{y \in Y} \sum_{t=1}^T \left( \log \frac{1}{\beta_t} \right) h_t(x_i) = y_i \quad (40)$$

## 2.5. Retina Görüntülerinin Kalite Değerlendirmesi

Literatürdeki görüntü kalite değerlendirmesinin asıl amacı, sıradan görüntülerin sıkıştırma algoritmaları ile boyutları küçültüldükten sonra orijinal halleriyle kıyaslanıp ne kadar bir kalite kaybının yaşandığını belirlemek için kullanılmaktadır. Yani bir başka deyişle sıkıştırma algoritmalarının performansını ölçmek için kullanılır. Kalite değerlendirmesinde sıkça kullanılan ölçütler, orijinal görüntü ile kodlanmış görüntü arasındaki ortalama kareler hatasının değişimi veya sinyal/gürültü oranıdır. Bunların yanı sıra yapısal içerik, normalleşmiş çapraz korelasyon, ortalama fark, en büyük fark ve normalleşmiş mutlak hata gibi ölçütlerde kullanılmaktadır.

Tıbbi görüntüleme alanında ise yüksek çözünürlükteki görüntülerin depolanma probleminden dolayı sıkıştırılmaları gerekmektedir. Bu nedenle orijinal görüntülerle sıkıştırılan görüntüler arasında bir kalite ölçütü belirlenmektedir. Ancak tıbbi görüntüler elde edildikten sonra, bu görüntülerin kullanılıp kullanılmayacağına karar vermek de bir kalite değerlendirme sürecine gerek duymaktadır. Elde edilen görüntülerin kalitelerini herhangi bir referans görüntü olmadan, görüntünün içeriğindeki bilgi yeterliliği ölçülerek kalite değerlendirmesi yapılabilir.

Görüntü kalite değerlendirmesi, medikal görüntülerin analizi yapılmadan önce uygulanacak yöntemlerin ve algoritmaların etkin sonuç verebilmeleri için görüntü ön işlemeden önce yapılması gereken önemli bir aşamadır. Özellikle retina görüntülerinin analizi yapılmadan önce fundus kameralar ya da diğer görüntü toplama cihazlarından elde edilen görüntüler mutlaka ön bir kalite değerlendirmesine tabii tutulmalıdır. Örneğin, retina üzerinde milyonlarca kılcak damar, sinir yapıları ve mikro seviyelerde lezyonlar vardır. Elbette görüntü ön işleme yöntemleri ile parlaklık dağılımı ve gürültü azalımı işlemleri yapılmalıdır. Fakat elde edilen görüntünün, çok karanlık, çok aydınlık, göz kapağının kapanması, bulanıklık, kirli lens, yanlış odaklanma, objektif karşısında hastanın olmayışı ve objektif kapağının kapalı olması gibi istenmeyen durumlarda, otomatik tespit sistemlerinin analizi doğru sonuçlar vermeyecektir.

Otomatik teşhis ve tanı koyma sistemlerinde retina görüntülerinin ön işlemeye alınmadan önce mutlaka bir kalite değerlendirme işlemi yapılması önerilmektedir. Çünkü, sistem otomatik çalışmakta ve her kararı kendisi vermektedir. Sisteme retina görüntüsü dışında herhangi bir görüntü verildiğinde sistem bu görüntüyü işlememeli ya da yeterli bilgi içeriği olmayan retina görüntülerini algılayıp, sisteme analiz için almamalıdır. Kalite değerlendirme sistemi sayesinde analiz sürecinin sebep olduğu zaman kaybı engellenir ve sistemin doğru kararlar vermesi sağlanmış olur. Literatürde retina görüntü kalitesinin değerlendirilmesi ile ilgili fazla çalışma bulunmamaktadır. Bu konuyla ilgili bazı çalışmalardan aşağıda bahsedilmiştir.

Bölütlemeyle ilgili yaklaşımlar, retinanın anatomik yapılarının tespiti üzerine olduğu için düşük kaliteli görüntülerde bu yapıların tespiti yapılamamaktadır. Fleming [113], retinadaki makula bölgesinde damarların tespitini yaparak kaliteyi belirlemeye çalışmıştır.

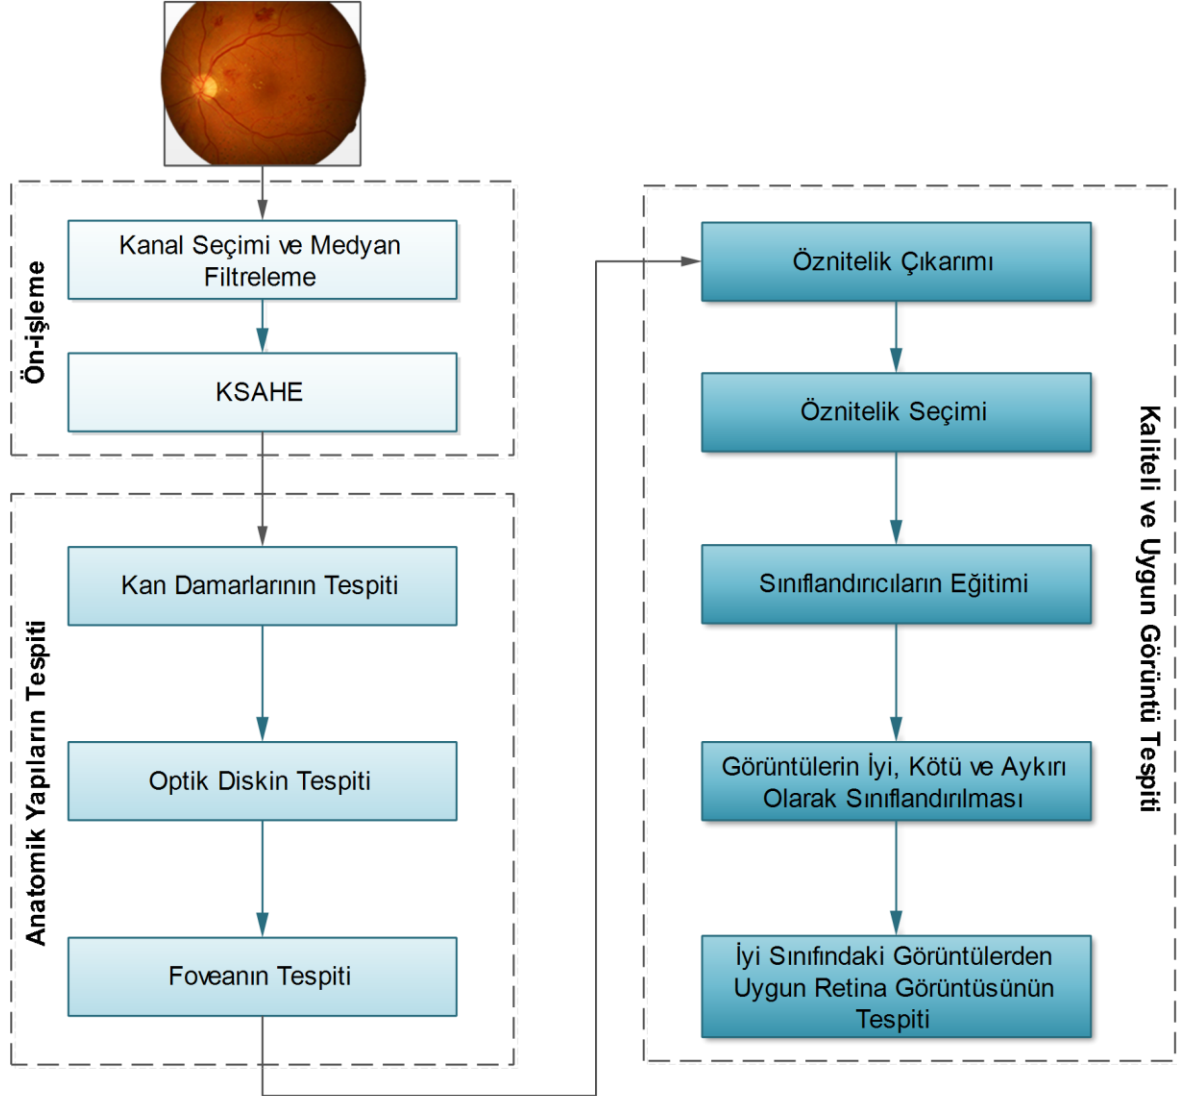
Buna ek olarak optik disk başının da keskin ve algılanabilir olması gerektiğini tespit etmiştir. Giancardo [114], retina görüntüsünde farklı bölgeler için damar yoğunluklarını kullanarak değerlendirme yapmıştır. Sınıflandırmada damar yoğunlukları ve her renk kanalı için 5 elemanlı histogram kullanarak özellik çıkarımı yapmıştır.

Histograma bağlı yaklaşımlarda ise düşük kaliteli görüntülerin istatistiksel değerlerini kullanarak karar verme mekanizması oluşturulmuştur. Lalonde [115], gri seviye görüntünün yerel histogram bilgilerini ve görüntünün gradyan büyüklüğünün histogramını değerlendirmeye almıştır. Lalonde çalışmasında, yüksek kaliteli referans görüntülerin histogramlarını hesaplamış ve test görüntüsü ile karşılaştırıp kalite oranını buna göre belirlemiştir. Lee [116], kaliteli retina görüntüleri ile değerlendireceği görüntünün parlaklık histogramlarını katlama (convolving) yöntemi kullanarak aralarında bir kalite indeksi oluşturmuştur. Neimeijer [117], Yapısal Görüntü Kümelemesi (Image Structure Clustering - ISC) yöntemi ile anatomik yapıların bulunduğu görüntüleri kümeleyerek ve görüntünün parlaklık dağılımlarını kullanarak görüntü kalitesini karakterize etmiştir. Giriş görüntüsünden piksellerin dönüşümü yardımı ile bir filtre bankası oluşturmuş ve kaliteyi beş sınıfa ayırmıştır [115].

Sonuç olarak, literatürde kullanılan mevcut algoritmalar, retinadaki anatomik yapıların (damar, optik disk, makula vb.) uzunluk, kenar ve parlaklık değerlerini referans görüntülerle karşılaştırarak veya danışmansız öğrenme (unsupervised) yöntemini kullanan sınıflandırıcılar yardımıyla değerlendirme yapmaktadır [115–117]. Bu tez çalışmasında ise, öncelikle morfolojik yöntemler yardımıyla damar bölütlenmesi yapıp ikili görüntü (binary image) halinde damarların tespiti yapılmıştır. Daha sonra retina görüntüsü, Inferior, Superior, Nasal ve Temporal (ISNT) olmak üzere dört parçaya ayrılmaktadır. ISNT bölgelerinde ikili görüntüdeki damar yapılarının çevre, alan, en büyük eksen vb. gibi lokal bölgesel öznitelikler çıkartılmıştır. Ayrıca tüm görüntüden de istatistiksel ve dokusal öznitelikler çıkartılarak bir öznitelik kümesi oluşturulmuştur.

Bu tez çalışmasında kullanılan görüntüler, Karadeniz Teknik Üniversitesi, Göz Hastalıkları Anabilim Dalı'nda *Canon UV60 Fundus Kamera* ile 60 derecelik alanda hem optik sinir başını ve hem de makulayı içerecek şekilde pupillaların dilatasyonundan (1% tropikamid ve 10% fenilefrin damla ile) sonra 570x760 piksel çözünürlükte *jpg* görüntü

formatı ile elde edilmiştir. Retina görüntülerindeki kalite değerlendirmesi için yapılan işlemler Şekil 35'deki akış diyagramında verilmiştir.



Şekil 35. Retina görüntülerinin kalite değerlendirmesi ve uygun görüntülerin tespiti için kullanılan akış diyagramı

Retina görüntünün kalitesini, içerdiği damar, optik disk ve fovea gibi anatomik yapıların algılanabilir ve yeterli bilgiye sahip olması belirler. Dolayısıyla, öncelikli iş olarak bu yapıların görüntü üzerinde ne kadar algılanabilir olduğunu ölçmek gerekmektedir.

Fleming ve arkadaşları [113], görüntü berraklığı için Tablo 5'de görüldüğü üzere 4 sınıftan oluşan bir derecelendirme şeması oluşturmuşlardır.

Tablo 5. Fleming ve arkadaşlarının retina görüntüsünü kalite bakımından sınıflandırması

Derecesi	Kategorisi	Tanımlama
1	Mükemmel	Hem foveadaki kılcal damarlar net, hem de makula bölgesinde en az 1 optik disk çapı kadar alan ve sinir lifinin net olarak görünebilir olması.
2	İyi	Kılcal damarlar net ancak makula bölgesinde 1 optik disk çapından daha az net alan mevcut olması ve sinir lifi katmanının net olmaması.
3	Kabul edilebilir	Küçük damarlar makulanın 1 optik disk alanında net seçilemiyor ancak damarların 3. dallanma yerleri seçilebiliyor olması.
4	Yetersiz	Damarlardaki 3. dallanmaların bile seçilemiyor olması.

Ancak bu sınıflandırmada retina görüntüsü olmayan (objektif karşısında hastanın olmayışı gibi) görüntülerin yer aldığı bir *aykırı* sınıfı bulunmamaktadır. Bu tez çalışmasında, retina görüntüleri kalite bakımından *iyi*, *kötü* ve *aykırı* olmak üzere 3 sınıfa ayrılmıştır.

Tablo 6. Retina görüntüsünün kalite bakımından sınıflandırılması

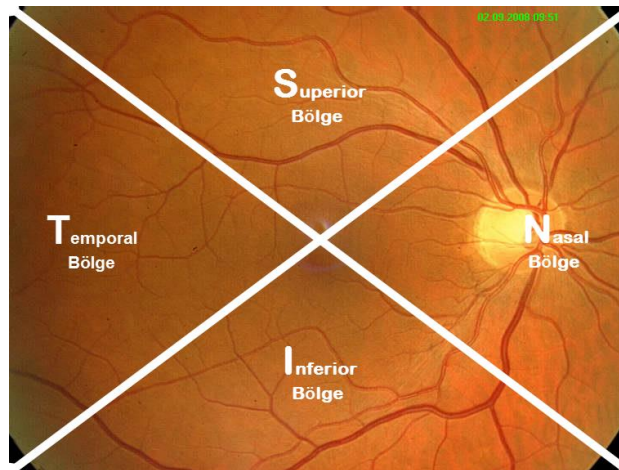
Kategorisi	Tanımlama
İyi	Foveadaki kılcal damarlar, optik disk, ana arter damarlar ve bu damarların 3. dallanmaya kadar tespit edilebilmesi, kontrast oranının yüksek ve berraklığın iyi olması
Kötü	Foveadaki kılcal damarların, ana arter damarların, optik diskin ve makulanın net olarak görülememesi, kontrast oranının çok düşük ve görüntünün bulanık olması.
Aykırı	Elde edilen görüntünün retina görüntüsü olmaması.

Kalite değerlendirmesindeki amaç, retinadaki anatomik yapıların görünürlüğünü test ederek görüntüyü kalite bakımından derecelendirmektir. Ancak, Tablo 5’de Fleming’in çalışmasına bakıldığında kaliteyi etkileyen en önemli faktör küçük damarlar olmuştur.

### 2.5.1. Retina Görüntüsünün Bölgelere Ayrılması


ISNT bölgeleri retina görüntüsündeki optik diskin diyagonal olarak dört parçaya bölünmesi ile elde edilir. Inferior ile superior alanın nasal ile temporal alana oranı ISNT oranını verir. ISNT oranı genelde optik diskte meydana gelen göz içindeki sıvı basıncının görme yeteneği için gerekli olan göz sinirine zarar verecek düzeyde yükselmesi sonucu oluşan *glokom* hastalığının tespitinde kullanılmaktadır. Optik diskteki büyük değerli ISNT oranı gözde glokom olma ihtimalini gösterirken küçük değerler ise gözün normal bir optik diski olduğunu göstermektedir [118].

Bu çalışmada, retina görüntülerinin kalitesini ölçebilmek için tüm retina görüntüsü, diyagonal olarak ISNT bölgelerine ayrılmıştır. Bunun amacı, yerel olarak elde edilen öznelikler kullanılarak, tüm görüntünün kalitesinin ölçülmesidir. Eğer kalite ölçmek için kullanılan öznelikler sadece tüm görüntüden çıkartılırsa, görüntüdeki yerel kalite bozuklukları göz ardı edilmiş olur. Bir başka deyişle, kaliteli bölgelerin öznelik değerleri, kalitesi bozuk bölgelerin öznelik değerlerini bastırabilmektedir. Dolayısıyla, ISNT bölgeleri, retina görüntüsünün yerel özneliklerinin çıkartılıp, tüm görüntünün kalitesinin etkin bir şekilde tespitini sağlamada katkıda bulunacaktır. Retinadaki damarların bölütlenmesi sonucunda Şekil 37’de görüldüğü gibi damarlar superior denilen üst bölge ve inferior denilen alt bölgede yoğun biçimde bulunmaktadır.



Şekil 36. Retinanın ISNT bölgelerine ayrılması





Şekil 37. ISNT bölgelerinin maskeleri ve bu bölgedeki bölütlenen damarlar, a) Superior bölge maskesi, b) Superior bölgedeki damarlar, c) Inferior bölge maskesi, d) Inferior bölgedeki damarlar, e) Nasal bölge maskesi, f) Nasal bölgedeki damarlar, g) Temporal bölge maskesi, h) Temporal bölgedeki damarlar

Retina görüntüsü, Şekil 23'deki damar bölütleme işlemi yapıldıktan sonra Şekil 37'deki gibi ISNT maskeleri ile bölgelere ayrıştırılıp, özellik çıkarımları yapılmaktadır.

### 2.5.2. ISNT Bölgelerindeki Damarların Özniteliklerinin Çıkartılması

ISNT bölgelerine ayrılan ikili retina görüntüsünde damar yapılarına bakıldığında parlaklık veya renk ile ilgili herhangi bir bilgi bulunmamaktadır. Buradaki amaç, bölütlenen damarların bu bölgelerdeki yoğunlukları, şekilleri, geometrik yapıları gibi öznitelikleri çıkartılıp sınıflandırıcılar için bir eğitim kümesi oluşturmaktır. Bu amaçla her bir ISNT bölgesindeki damarlardan Bölüm 2.3.1'de bahsedilen 8 özniteliğe ek olarak, *sağlamlık (solidity)* ve *euler sayısı* öznitelikleri eklenerek, her bölgede toplam 10 şekilsel öznitelik çıkartılıp genel toplamda 40 adet bölgesel damar özniteliği çıkartılmıştır. Bunlara ek olarak, IS bölgesindeki damar alanları ile NT bölgesindeki damar alanları arasındaki oran ve I bölgesi ile S bölgesi arasındaki oran da öznitelik olarak kullanılarak, bölgesel öznitelikler 42'ye çıkartılmıştır [118]. Burada I/S oranı kalite değerlendirmesi bakımından ilk defa bu çalışmada önerilen bir özniteliktir. Optik diskin, kaliteli ve uygun görüntünün merkez koordinatları üzerinde olduğu düşünülürse I ve S bölgesindeki damarlar simetrik bir yapı görünümünü vermektedir. Bu da görüntünün I/S oranı 1 değerine yaklaştıkça istenilen kalitede bir görüntü olduğu fikrini verir. Bölüm 2.3.1'deki bölgesel özniteliklere ek olarak aşağıdaki özniteliklerde kullanılmıştır.

- S ile I Oranı: Bu oran yeni önerilen bir öznitelik olup superior bölge ile inferior bölgenin içerisinde yer alan damarların simetrik bir yapıya benzediği için bu değer 1'e yakın bir değer alması, görüntü kalitesinin istenilen düzeylerde olduğunu göstermektedir.
- IS ile NT Oranı: Bu oran inferior bölge ile superior bölgenin toplamının, nasal ile temporal bölgelerin toplamına oranı ile bulunmuştur. [118]'de glokom için hesaplanan bir orandır. Bu çalışmada bu oran tüm görüntü üzerinden hesaplanmıştır.
- Sağlamlık (Solidity): Bir R bölgesinin alanının, dışbükey alanına oranı vermektedir.

- Euler Sayısı (Euler Number): Bir R bölgesindeki nesnelerin sayısından, bu nesnelereki boşlukların sayısının farkı alınarak hesaplanır.

### 2.5.3. Tüm Retina Görüntüsünden Çıkarılan Öznitelikler

ISNT alanlarındaki bölgesel özniteliklerden sonra görüntü üzerinde dokusal öznitelikler de kullanılmıştır. Dokusal öznitelikler olarak bu çalışmada, Gri-Seviye Histogramın istatistiksel öznitelikleri ve Haralick doku öznitelikleri ele alınmıştır. Yeşil kanal retina görüntüsünün Gri-Seviye Histogramı hesaplandıktan sonra histogramla ilgili, *Ortalama, Standart Sapma, Yumuşaklık, Çarpıklık, Tekdüzelik, Basıklık, Parlaklık Olasılıkları, Modifiye Standart Sapma* öznitelikleri Tablo 3'deki denklemler kullanılarak hesaplanmıştır. Aynı şekilde Haralick Doku özniteliklerinden, *Açısal İkinci Moment, Karşıtlık, Korelasyon, Kareler Toplamı (Varyans), Ters Fark Momenti, Toplam Ortalama, Toplam Standart Sapma, Toplam Entropi, Entropi, Fark Varyansı, Fark Entropisi, Korelasyonun Bilgi Ölçekleri, En Büyük Korelasyon Katsayısı* öznitelikleri Tablo 4'teki denklemler yardımıyla hesaplanmıştır. Hesaplanan dokusal özniteliklerden bazıları Tablo 7'de gösterilmiştir.

Tablo 7. 0<sup>o</sup>'deki Haralick dokusal özniteliklerinden bazıları.

Görüntü Adı	Etiket	Karşıtlık	Korelasyon	Enerji	Entropi	Homojenlik	Ters Fark Momenti	En Büyük Korelas.
655311_005_001.jpg	İyi	1.630.465	1.271.494	177.340.194	0.953611	0.000472	-4.332.929	0.279583
727280_001_005.jpg	İyi	1.088.252	1.580.938	165.056.469	0.970913	0.000492	-4.354.040	0.342077
727280_001_014.jpg	İyi	1.067.596	1.450.177	237.995.368	0.946705	0.000429	-4.139.836	0.277332
730667_012_001.jpg	İyi	0.769371	1.071.257	202.880.318	0.949419	0.000542	-4.429.438	0.303677
730667_012_004.jpg	İyi	1.041.968	1.103.313	161.393.010	0.952430	0.000736	-4.651.566	0.336255
000000_001_001.jpg	Kötü	0.000000	0.000000	85.736.972	0.927363	0.154346	-10.481.417	0.964977
472939_001_026.jpg	Kötü	0.000000	0.000000	61.010.295	0.985348	0.079863	-8.133.206	0.735913
472939_001_029.jpg	Kötü	0.000000	0.000000	55.768.691	0.996339	0.059707	-6.408.772	0.613068
472939_001_043.jpg	Kötü	0.000000	0.000000	68.469.912	0.989113	0.035566	-6.493.460	0.597142
781672_012_003.jpg	Kötü	0.000000	0.000000	74.150.265	0.989897	0.002694	-5.939.284	0.647336
0000012_002_003.jpg	Aykırı	0.000000	0.322646	133.114.668	0.986670	0.060756	-6.792.516	0.657353
0000012_002_004.jpg	Aykırı	4.622.263	0.950339	166.423.519	0.977988	0.021377	-6.360.555	0.655071
125601_001_003.jpg	Aykırı	0.301659	1.903.870	211.639.646	0.968510	0.000327	-4.012.196	0.304383
245432_001_003.jpg	Aykırı	0.632460	0.787191	292.436.687	0.950108	0.000333	-3.885.759	0.259359
5710_001_021.jpg	Aykırı	0.087844	2.031.949	128.601.412	0.963499	0.000846	-4.807.087	0.389495

Zernike Momentleri, görüntüdeki boyut değişimleri, ötelemeler ve dönmelere karşı bağımsız öznitelikler oluşturmaktadır. Bu çalışmada 2.3.3'te teorisi verilen Zernike momentlerinin ilk 15 momentini öznitelik olarak kullanılmıştır.

KHT, görüntüde sadece yerel kenar dağılımlarını ele aldığından, retinadaki damar yapısının oluşturduğu kenar bilgisi sınıflandırma için önemli öznitelikler oluşturabilir. Bu amaçla, damar bölütlemesi yapılmış ikili görüntüye 16 alt görüntü için 5 kenar histogramı hesaplanıp toplamda 80 adet KHT özniteliği çıkartılmıştır [82,83]. Öznitelik uzayının yarısına yakın kısmını KHT oluşturmaktadır. Ancak, öznitelik seçimi sonrasında bu 80 öznitelikten en etkin olanları seçilmiştir.

Kaliteli retina görüntülerindeki parlaklık dağılımları genelde bir birine benzer bir dağılım içerisindedir. Bu nedenle, retina görüntü kalitesinin değerlendirilmesi için ilk defa önerilen, görüntünün dominant renk değeri öznitelikleri çıkartılmıştır. Bu amaçla, retina görüntüsünden, *maksimum dominant renk değeri*, *dominant kırmızı renk*, *dominant yeşil renk*, *dominant mavi renk*, *ortalama dominant renk* olmak üzere 5 adet öznitelik çıkartılmıştır.

Retina görüntü kalitesinin değerlendirilmesi için toplamda 177 adet öznitelik çıkartılmıştır.

#### **2.5.4. Uygun Retina Görüntüsünün Bulunması**

Bu tez çalışmasında, retina görüntülerinin kalite değerlendirmesi yapıldıktan sonra, iyi görüntüler arasından oftalmologların yeterli bilgiye ulaşabilecekleri uygun retina görüntüsü otomatik olarak tespit edilmektedir. Uygun görüntüde, OD, fovea, superior ve inferior ana damarlar gibi anatomik yapılar görüntü üzerinde bulunması gerekmektedir. Tüm bu anatomik yapıların retina görüntüsü üzerinde bulunabilmesi için, OD ve fovea Şekil 38(a)'da görüldüğü gibi yatay merkez koordinata yakın olmalıdır. Bu anatomik yapıların referans noktalar olarak konumlarının bulunması, lezyonların ve diğer hastalıkların lokalizasyon bilgilerinin tanımlanabilmesi açısından da önemlidir.

Uygun retinadaki anatomik yapıların görülebilmesi için OD'nin, OD beklenen alanının (ODBA) sınırları içerisinde bulunması gerekmektedir. OD merkez koordinatları ve çapı hesaplandıktan sonra ODBA sınırları, görüntünün yatay merkez çizgisinden 1 OD çapı kadar yukarı ve aşağısı olmak üzere üst ve alt sınır olarak belirlenmiştir. Şekil 38'de, ODBA sınırları;

$$\text{Üst}_{ODBA} = y_c - r(OD) \quad (41)$$


$$\text{Alt}_{ODBA} = y_c + r(OD) \quad (42)$$

şeklinde hesaplanmaktadır. Burada  $y_c$ , retina görüntüsünün yatay merkez çizgisi,  $r(OD)$  OD'nin çapı,  $\text{Üst}_{ODBA}$  ve  $\text{Alt}_{ODBA}$  OD'nin aşmaması gereken üst ve alt sınırlardır. Kaliteli bir retina görüntüsüne uygun denilebilmesi için OD ve foveanın ODBA sınırları içerisinde bulunması gerekmektedir. Böylece superior ve inferior ana damarların da görülebilir olması sağlanacaktır.

ODBA içerisinde, OD'nin merkez noktasının, retinanın yatay merkez çizgisine uzaklığı hesaplanarak, bu çalışmada yeni önerilen, uygunluk değeri (S) adında bir derecelendirme yüzdesi hesaplanmıştır.

$$S = 100x \left( 1 - \frac{|y_c - y_{OD}|}{r(OD)} \right) \quad (43)$$

$y_{OD}$ , OD'nin merkezi noktasıdır. OD'nin merkez noktası retinanın yatay merkez çizgisine ne kadar yakın olursa, uygun retina görüntüsü olma yüzdesi (S), o kadar yüksek olmaktadır.



Şekil 38. Uygun görüntünün ODBA sınırları ve anatomik yapıların otomatik tespiti, (a) ODBA sınırları, (b) Otomatik tespit sonucu bulunan OD ve Fovea bölgeleri

## 2.6. Diyabetik Retinopati Hastalığının Tespiti

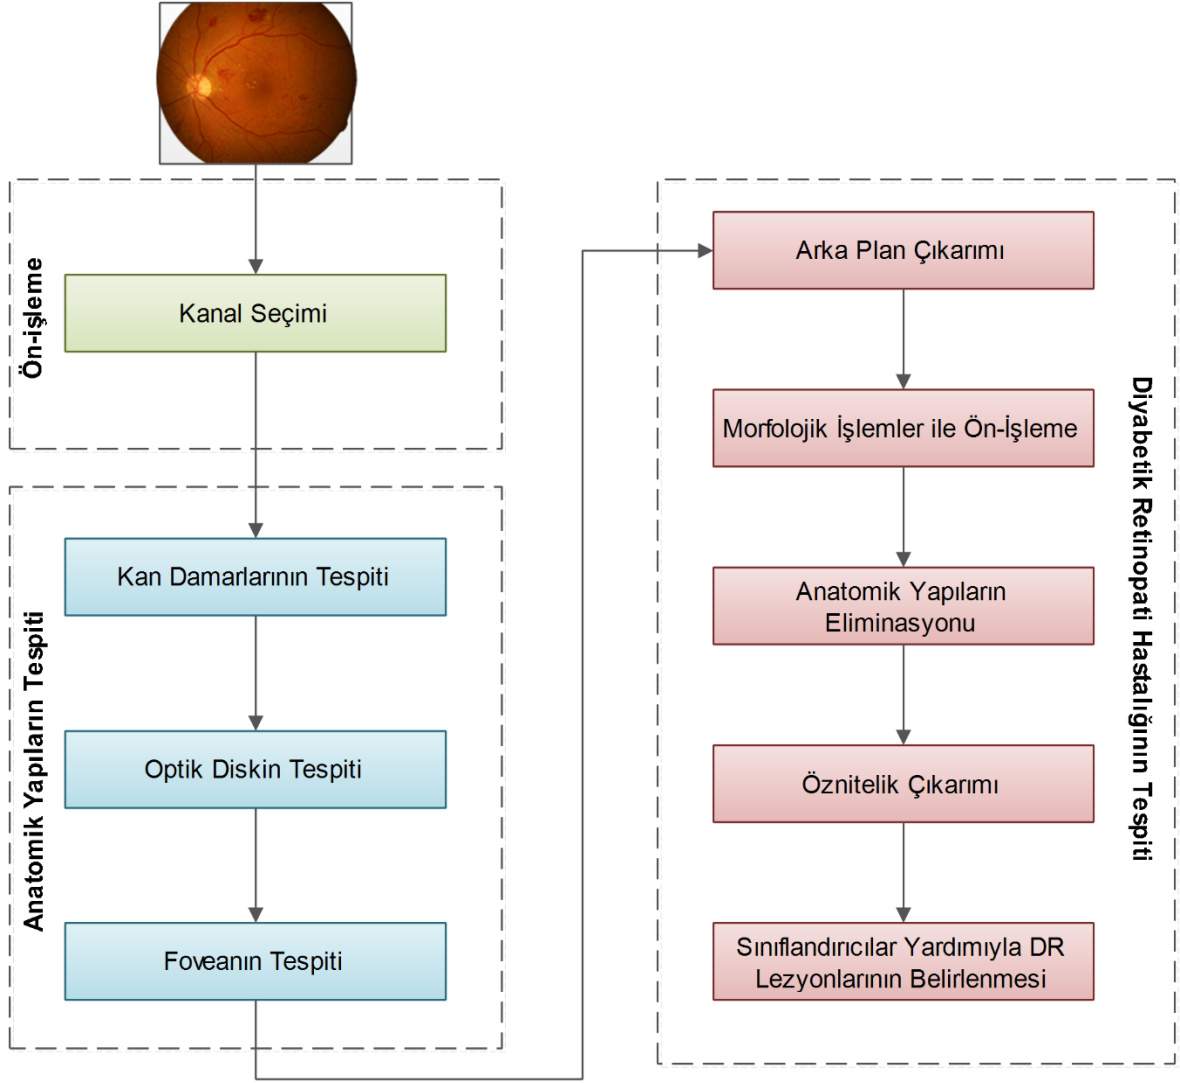
Görüntü analiz yöntemleri genellikle iki veya üç aşamadan oluşmaktadır. İki aşamalı işlemlerde ilk aşamada ön işleme ve sonraki aşamada ise bölütleme işlemi yapılmaktadır. Üç aşamalı işlemlerde ise, ilk iki aşamadan sonra üçüncü aşama öznitelik çıkarımı, sınıflandırıcıların bu özniteliklere göre eğitilmesi ve sınıflandırma işleminin gerçekleştirilmesidir. Bu çalışmada ise, tüm aşamaları direk olarak etkileyecek ve tıbbi görüntülerde otomatik tespit sistemleri için gerekli gördüğümüz kaliteli görüntü tespiti ilk aşama olarak ele alınmıştır. Uygun retina görüntüsünün tespitinden sonra uygulanacak olan

otomatik tespit sistemleri ile daha etkin ve doğru sonuçlar alınabilmesi amaçlanmıştır. Diğer aşamalarda ise görüntünün ön-işlemeden geçirilmesi, arka plan kestiriminin yapılması, daha önceden tespit edilen damar, optik disk ve fovea yapılarının çıkarımı, elle bölütlenmiş lezyonlar kullanılarak sınıflandırıcıların eğitimi ve son olarak lezyonların sınıflandırılması gerçekleştirilmiştir.

Kaliteli ve uygun görüntü seçiminden sonra görüntü analizi süreci, görüntü ön işleme adımıyla devam etmektedir. Ön işleme adımında amaçlanan, başta retinadaki anatomik yapılar olmak üzere diğer lezyonların başarılı biçimde tespittir. Görüntü bölütleme veya sınıflandırma algoritmalarının başarısı görüntü üzerindeki değerlere bağlı olduğundan, ön işleme safhasında uygulanan yöntemler, direk olarak sonucu etkilemektedir. Bu nedenle, ön işleme yöntemleri her görüntü analizi probleminde en önemli aşamalardan bir tanesidir.

Arka plan kestiriminden sonra geriye aday DR lezyonları, optik disk ve damarlar gibi anatomik yapılar kalır. Daha önceden bölütlenen damarlar ve optik diskin bu aday dokular içerisinde çıkarılması ile geriye sadece aday DR lezyonları kalmaktadır.

DR hastalığının tespiti için önerilen yöntemde, ön işlemeden sonra arka plan kestirim yöntemleri kullanılarak sağlıklı retina dokusu homojen hale getirilmiştir. Arka planı düzleştirilen görüntüden de anatomik yapılar elimine edilerek geriye kalan lezyonların istatistiksel ve morfolojik öznitelikleri çıkartılıp sınıflandırma algoritmaları yardımı ile lezyonların tespit edilmesi amaçlanmıştır.



Şekil 39. Diyabetik Retinopati hastalığının tespiti için uygulanan yöntemlerin akış diyagramı

### 2.6.1. Retina Görüntüsünün Arka Plan Kestirimi


Bu tez çalışmasında, kan damarları, optik disk ve fovea haricindeki sağlıklı dokuya retina arka plan dokusu denilmiştir. Daha önceki çalışmalarımızda, ters bölütleme yaklaşımı çerçevesinde, bölge büyütme ve istatistiksel bölütleme yöntemleri kullanılarak retinanın arka plan dokusu başarılı bir şekilde bölütlenmiştir [119,120]. Bu tez çalışmasında ise, arka plan kestirimi yardımıyla retina dokusunun görüntü üzerinden silinmesi amaçlanmıştır. Bu amaçla, arka plan yaklaşımı için  $N \times N$  çekirdekli medyan filtresi kullanılmıştır.

$$G_p = G_y - G_{ap} \quad (44)$$



$$G_K = G_{ap} - G_y \quad (45)$$

$G_{ap}$ ,  $64 \times 64$  çekirdekli medyan filtresi uygulanmış görüntü ve  $G_y$  ise retina görüntülerinde en çok bilgi içeren yeşil kanal görüntüsüdür.  $G_y$  görüntüsünden  $G_{ap}$  görüntüsü çıkarıldığında retina üzerindeki koyu yapılar silinerek, optik disk ve parlak lezyonları içeren  $G_p$  görüntüsü elde edilir.  $G_{ap}$  görüntüsünden  $G_y$  görüntüsü çıkarıldığında ise parlak yapılar silinir, kan damarları ve koyu lezyonları içeren  $G_K$  görüntüsü elde edilir.



Şekil 40. Retina arka plan kestirimi, (a) Orijinal yeşil kanal retina görüntüsü, (b)  $64 \times 64$  'lük medyan filtresi uygulanmış görüntü, (c) Koyu yapılar, (d) Parlak yapılar

Şekil 40(c)'deki görüntüye Koyu Adayların Görüntüsü (KAG), Şekil 40(d)'deki görüntüye de Parlak Adayların Görüntüsü (PAG) şeklinde adlandırılmıştır.


## 2.6.2. Retinadaki Anatomik Yapıların Elimine Edilmesi

Retina üzerindeki optik disk, kan damarları ve makulanın eliminasyonu, lezyon tespitinde yanlış pozitif alanlar bulunmasını engellemek için önemli bir aşamadır. Retina görüntüsü incelendiğinde, OD'nin renk ve yapısal olarak, sert ve yumuşak eksudalar ile aynı özelliğe sahip olduğu görülmektedir. Benzer şekilde, bazı kan damarları, kanama sonucu oluşan hemoraji gibi lezyonlarla aynı özelliklere sahip olabilmektedir. Bu durumu ortadan kaldırmak için, lezyon tespitinden önce retinadaki anatomik yapıların tespit edilip, bölütleme sonucu ortaya çıkan aday lezyon bölgelerden çıkartılması gerekmektedir.

### 2.6.2.1. Koyu Görüntüden Kan Damarlarının Eliminasyonu


Retinadaki kan damar ağlarının bölütlenmesi ile ilgili literatürde birçok çalışma vardır. Bu çalışmaların çoğu yaklaşımlarını, erişime açık retina görüntü veritabanlarındaki görüntüler üzerinde uygulayarak performanslarını ölçmüşlerdir. Ancak bu çalışmaların çoğunun, DR ve neovaskülarizasyon gibi hastalık belirtileri bulunan anormal görüntülerde bölütleme performansları oldukça düşük kalmaktadır. Literatürdeki damar bölütleme yöntemleri, morfolojik yöntemler [63,121], uyumlu süzgeç (matched filter) [61,122], çizgisel ve parça nesnelere öznitelik vektörü çıkartılarak k-EYK ile sınıflandırma [46], çizgi operatörü ile çıkartılan özniteliklerin DVM ile sınıflandırılması [123] ve gri seviye ile moment değişmezi tabanlı özniteliklerin sinir ağları ile sınıflandırılması [124] şeklinde sıralanabilir [125]. Bu konu ile ilgili ayrıntılı yöntemler, Kirbas ve Quek [126], Fraz ve diğerleri [4] ve Honale ve Kapse'nin [125] çalışmalarında yer almaktadır.

Bu tez çalışmasında, kalite değerlendirme aşamasında kullanılan damar bölütleme yaklaşımı, Zana ve diğerlerinin [63] çalışmalarında uyguladıkları morfolojik yöntemler ile benzerdir. Ancak bu yöntem anormal retina görüntüleri için damar bölütlemesinde lezyonların oluşturduğu yanlış pozitif alanlardan dolayı çok başarılı olamamaktadır. Ancak görüntü kalitesi ölçmede yeterli olmuştur. Literatürdeki çalışmalara bakıldığında, damarlardan öznitelik çıkartılıp sınıflandırıcılar yardımıyla tespit işleminin daha etkin ve başarılı sonuçlar verdiği görülmektedir [4,126]. Bu nedenle, KAG'daki kan damarları, direk olarak elimine edilmeyerek hemoraji ve mikroanevrizma lezyonları ile beraber öznitelikleri çıkartılıp, sınıflandırmaya tabii tutulmuşlardır.



Şekil 41. Görüntü iyileştirmede Gama düzeltmesi

Elde edilen KAG ve PAG'ın daha ayrıntılı görünebilmesi için Gama Düzeltmesi yaklaşımı uygulanmıştır. Gama düzeltmesi,  $s = cr^\gamma$  formülü ile gerçekleştirilir.  $c$  ve  $\gamma$  pozitif katsayılar ve  $c$  genelde 1 olarak alınmaktadır.  $\gamma$  değeri 1'den küçük ise  $s$  görüntüsü  $r$  görüntüsüne göre daha parlak olurken 1'den büyük gama değerlerinde ise daha koyu bir  $s$  görüntüsü elde edilir. Gama düzeltmesi, bir görüntüdeki ilgilenilen belirli bir yoğunluktaki bölgeleri ön plana çıkarabilmek için kullanılmaktadır.



Şekil 42. Gama düzeltmesi yapılan KAG

### 2.6.2.2. Parlak Görüntüden Optik Diskin Eliminasyonu

Bölüm 2.2.2'de önerilen yeni bir OD tespiti yaklaşımı ile retina üzerinde dairesel yapıya sahip OD'nin  $M(x,y)$  merkez noktası ile  $r$  yarıçap uzunluğu bilgisi elde edilmektedir. Arka plan kestirimi sonucu elde edilen PAG'dan OD çıkartılarak geriye sadece aday sert ve yumuşak eksudalar kalmaktadır.

OD'nin oluşturduğu alan,  $X$  ve  $Y$  görüntü boyutları,  $M_x$  ve  $M_y$  merkez noktaları olmak üzere;


$$OD_{Mask} = \sqrt{(X - M_x)^2 + (Y - M_y)^2} \leq r \quad (46)$$

ile bir maske görüntüsü oluşturulmuştur.  $OD_{Mask}$  görüntüsü, ikili PAG görüntüsünden çıkartılarak;


$$SPAG = PAG - OD_{Mask} \quad (47)$$

sınıflandırılacak PAG elde edilmiştir. Şekil 43'de PAG'ı iyileştirmek için gama  $\gamma=0.5$  düzeltmesi yapılmıştır.

Buna ek olarak, arka plan kestirimi yaparken kullanılan yüksek boyutlu medyan filtresi PAG'ın kenarlarında istenmeyen yanlış pozitif alanlar oluşturmaktadır. Bu olumsuz etki de maskeleme metodu ile aşılmıştır.



Şekil 43. Gama düzeltmesi yapılan PAG



Şekil 44. PAG'dan OD'nin çıkartılması. a) Orijinal retina görüntüsü, b) OD'si tespit edilen retina görüntüsü, c) PAG, d) OD için hesaplanan maske, e) PAG'dan OD'nin çıkartılması, f) Parlak lezyonların orijinal görüntü üzerinde gösterilmesi

### 2.6.3. Diyabetik Retinopati Lezyonlarından Öznitelik Çıkarımı

Retina görüntülerinin arka plan kestirimi ve bölütlenmesi gerçekleştirildikten sonra aday DR lezyonları elde edilmiştir. Arka plan kestirim yaklaşımı, Şekil 40'da görüldüğü gibi koyu ve parlak yapılar için ayrı ayrı yapıldığından, iki görüntü üzerinde ayrı analiz işlemleri

yapılacaktır. Koyu yapıların olduğu görüntüde DR hastalığı sonucu oluşan hemoraji, mikroanevrizma ve damar ağı bulunurken parlak yapıların bulunduğu görüntüde ise, sert, yumuşak eksuda ve optik disk bulunmaktadır. PAG içerisindeki yapılar parlaklık ve dokusal olarak aynı özelliklere sahip olduğundan, bu görüntülerden bu tür özniteliklerin çıkartılması çok ayırt edici olmayacaktır. Aynı durum KAG içinde geçerlidir. Böylece, her iki görüntüde kendi aralarında sadece bölgesel ve şekilsel öznitelikler kullanarak sınıflandırma yapılmıştır. Ancak sert ve yumuşak eksudalar için parlaklık değerlerinin dağılımlarından öznitelikler çıkartılmıştır. İki ayrı görüntü kullanarak, öznitelik çıkarım işlemine geçmeden önce öznitelik seçim işlemi yapılmış ve sınıflandırıcıların hesaplama yükü azaltılmıştır.

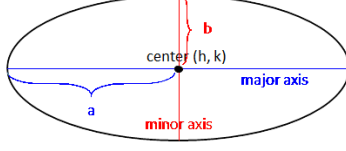
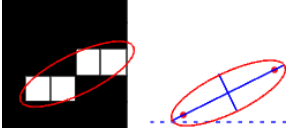


### 2.6.3.1. Şekilsel Öznitelikler

Retina görüntüsü üzerinde arka plan kestirimi uygulandıktan sonra, parlak ve koyu yapıların ayrı ayrı bulunduğu PAG ve KAG görüntüleri elde edilmiştir. Böylece koyu ve parlak lezyonlar, parlaklık bakımından ayrıştırılmıştır. Dolayısıyla sınıflandırma işlemi koyu ve parlak lezyonların kendi aralarında yapılacaktır. Parlaklık değerlerinin kullanımına gerek duyulmadığından, bu sınıflandırmada kullanılacak olan en etkin öznitelik grubu şekilsel öznitelikler olacaktır. Bu çalışmada çıkartılan şekilsel öznitelikler Tablo 8’de verilmektedir.

Tablo 8. DR tespiti için kullanılan şekilsel öznitelikler

Öznitelik	N	Formül	Açıklama
Alan (Area):	1	$A = \sum_{(r,c) \in R} 1$	R bölgesindeki piksellerin sayısı
Ağırlık Merkezi (Centroid):	2	$\bar{r} = \frac{1}{A} \sum_{(r,c) \in R} r$ $\bar{c} = \frac{1}{A} \sum_{(r,c) \in R} c$	R bölgesindeki piksellerin ortalama konumları
Sınırlayıcı Çerçeve (Bounding Box):	4	R bölgesini yatay ve dikey olarak tümünü kapsayacak şekilde çevreleyen en küçük dikdörtgendir. x ve y başlangıç noktası h ve w ise yükseklik ve genişlik değerleridir.	
Büyük Eksen Boyutu (Major Axis Length):	1		En büyük eksenin uzunluğu (2a)

Tablo 8'in devamı

Öznitelik	N	Formül	Açıklama
Küçük Eksen Uzunluğu (Minor Axis Legth):	1		En küçük eksenin uzunluğu (2xb)
Dış Merkezilik (Eccentricity):	1	$e = \sqrt{\frac{a^2 - b^2}{a^2}}$	Bir bölgenin çemberden ne kadar farklı olduğunu belirler
Yönelme (Orientation):	1		En büyük eksenle yatay noktaların yaptığı açı.
Dışbükey Alan (Convex Area):	1		Nesnenin dışbükey sınırları içerisindeki alanı
Dolu Alan (Filled Area):	1		Nesnenin içerisindeki tüm boşluklarla beraber alanı
Euler Sayısı (Euler Number):	1	R bölgesindeki nesnelerin sayısından, bu nesnelereki boşlukların sayısının farkı	
Eşdeğer Çap (EquivDiameter):	1	$ED = \sqrt{\frac{4A}{\pi}}$	R bölgesiyle aynı alana sahip dairelerin çapını belirtir.
Sağlamlık (Solidity):	1	$S = \frac{\text{Alan}}{\text{Dışbükey Alan}}$	R bölgesinin alanının, dışbükey alana oranı
Kapsam (Extent):	1	$Ext = \frac{\text{Alan}}{\text{Sınır.Çer. Alanı}}$	R bölgesinin alanının sınır çerçevesi alanına oranı

Tablo 8'in devamı

Öznitelik	N	Formül	Açıklama
Çevre (Perimeter):	1	$Per = \sum_{x \in B} 1$	Nesnenin B sınırındaki piksellerin sayısı
Yuvarlaklık (Roundness):	1	$Rn = 4\pi \frac{Alan}{Çevre^2}$	Nesnenin çembere yakınlığını ölçen birim
Öznitelik 1 (Centdist):	1	Görüntü üzerindeki nesnenin ağırlık merkezinin sınır çerçevesine uzaklığı. (Manhattan)	
Öznitelik 2 (WHRatio):	1	$WHRatio = \frac{BEU}{KEU} \times Alan$	Bu değer küçüldükçe damara yakın değerler çıkar.
Öznitelik 3 (BBAreaRatio):	1	$BBAreaRatio = \frac{BBA}{I_A}$	Nesnenin Sınır çerçevesinin alanı ile tüm görüntünün alanı arasındaki oran
Öznitelik 4 (ShapeAreaRatio):	1	$ShapeAreaRatio = \frac{Alan}{I_A}$	Nesnenin alanı ile tüm görüntünün alanı arasındaki oran
Öznitelik 5 (MeanLigth):	1	$\mu = \frac{\sum_{ij} x_{ij}}{N}$	Parlak lezyonlarda oluşan nesnelerin ortalama parlaklık değerleri
Öznitelik 6 (StdDevLigth):	1	$\sigma = \sqrt{\frac{\sum_{ij} (x_{ij} - \mu)^2}{N}}$	Parlak lezyonlarda oluşan nesnelerin parlaklık değerlerinin standart sapması
Öznitelik 7 (MedLigth):	1	$Medyan = \frac{a(N + 1)/2}{1}$	Parlak lezyonlarda oluşan nesnelerin parlaklık değerlerinin medyanı



### 2.6.4. Lezyonlardan Çıkarılan Özniteliklerin Sınıflandırılması

DR lezyonlarının sınıflandırılması için öncelikle bir eğitim kümesinin oluşturulması gerekmektedir. Bu nedenle, DRIMDB veritabanından uzman oftalmologlar gözetiminde, elle DR lezyonları ve damar yapıları etiketlenmiştir. Etiketli görüntülerden sınıflandırıcıların eğitimi için 19 adet şekilsel 3 adet dokusal öznitelik çıkartılmıştır. Bu 3 adet dokusal öznitelik, parlak lezyonlardan parlaklık değerleri yardımıyla lezyonların ortalama, standart sapma ve medyan değerleri hesaplanarak çıkartılmıştır.

DR lezyonlarının sınıflandırılması için, k-En Yakın Komşu (k-EYK), Naive Bayes (NB), Yapay Sinir Ağları (YSA), Karar Ağaçları (KA), Rastgele Orman (RO) ve Adaboost yaklaşımları kullanılmıştır. Bu sınıflandırıcılarla ilgili ayrıntılı bilgiler çalışmanın 2.4 bölümünde, kullanılan parametreler ve sonuçlar ise 3.5 bölümünde verilmiştir.

#### 2.6.4.1. Çapraz Doğrulama

DR lezyonlarında kullanılan sınıflandırıcıların eğitim aşamasında veri seti 10-kere Çapraz Doğrulama (10-fold Cross Validation) yöntemiyle eğitime alınmıştır. Bu sayede sınıflandırıcılar, ezberleme gibi yan etkilerinden kurtulmuştur.

Tablo 9. 10-kere çapraz doğrulama yöntemi

	Eğitim Veri Seti										Test Performansı	
1.İter.	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	$P_1$
2.İter.	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	$P_2$
3.İter.	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	$P_3$
4.İter.	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	$P_4$
5.İter.	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	$P_5$
6.İter.	Eğitim	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	$P_6$
7.İter.	Eğitim	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	$P_7$
8.İter.	Eğitim	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	$P_8$
9.İter.	Eğitim	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	$P_9$
10.İter	Test	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	Eğitim	$P_{10}$
Toplam Hata:											$\bar{E} = \frac{1}{10} \sum_{i=1}^{10} E_i$	

Tablo 9’da da görüldüğü üzere, 10-kere çapraz doğrulama yöntemi, veri kümesini 10 eşit parçaya bölüp her bir iterasyonda veri kümesinin 9/10’luk kısmını eğitim için geri kalan 1/9’luk kısmı da test için kullanır [127]. Her iterasyonda farklı bir parça test için ayrılarak tüm veri kümesinin eğitim ve test için kullanımı sağlanır [128]. Her iterasyon sonucu;

$$E = \frac{1}{K} \sum_{i=1}^K E_i \quad (48)$$

formülü ile test örneklerinin hatalarının ortalamaları alınarak 10 iterasyon sonucu toplam hata hesaplanır. Bu yöntemin en önemli avantajları, bazı örneklerin eğitim aşamasında yapmış oldukları pozitif ve negatif etkiler azaltılıp, her örneğin 9 kere eğitim ve 1 kere test aşamasından geçmesi sağlanmaktadır [128].

## 2.7.Öznitelik Seçim Yaklaşımları

Öznitelik seçme işlemine, çıkartılan özniteliklerin sınıflandırıcılara verilmeden önce yapılan bir ön işleme adımı denilebilir. Örüntüden çıkartılan özniteliklerin tümü, sınıf kararında ayırt edici bir rol oynamayabilir veya negatif bir etkiye yol açabilir. Bu nedenle bazı özniteliklerin eğitim safhasına geçmeden ayıklanması gerekmektedir. Bu ayıklama işlemi sonrasında öznitelik kümesinden, daha iyi bir öznitelik alt kümesi elde edilmesi amaçlanmaktadır [129,130]. Böylece, sınıflandırma modelinin anlaşılabilirliği artar, eğitim süresi düşer ve eğitim aşamasındaki tekrarlamalar azalır [131,132]. Ayrıca, özniteliklerin boyutunun indirgenmesi literatürdeki “boyutun laneti” etkisini de azaltmış olur [90,133,134].

Literatürde yaygın olarak kullanılan bazı öznitelik seçimi yaklaşımlarını; Bireysel En İyi Öznitelik Seçimi, İleriye Doğru Seçim, Geriye Doğru Seçim, Artı 1- Çıkar Seçim, Ardışık İleriye Doğru Kayan Seçim, Ardışık Geriye Doğru Kayan Seçim ve Genetik Seçim şeklinde sıralayabiliriz [135–138]. Bu çalışmada hızlı ve etkin sonuçlar verdiği için İleriye Doğru Seçim (Forward Selection) ve Genetik Algoritma yaklaşımları uygulanmıştır.

### 2.7.1. İleriye Doğru Seçim

İleriye Doğru Seçim (Forward Selection) yaklaşımında, öznitelik seçimine herhangi bir öznitelik seçilerek başlanır ve diğer tüm öznitelikler sırası ile denenir. Bu işlemi gerçekleştirirken performans testi için bir sınıflandırıcıdan yararlanır. Bir araya getirilen her bir öznitelik için bir sınıflandırma başarısı elde edilmekte ve en yüksek başarıya ulaşan öznitelik grubu yeni en iyi öznitelik alt kümesi olarak belirlenmektedir [135,139].

### 2.7.2. Genetik Seçim

Genetik Algoritma (GA), biyolojik evrimleşme sürecini model alan stokastik bir arama yöntemidir [140]. GA, potansiyel çözümlerin olduğu nüfus arasından en uygun olanların yaşaması ve bunlardan türeyen yeni kuşakların daha iyi çözümler üretmesi prensibine göre çalışır [72]. Bu stokastiksel metot, optimizasyon ve arama problemleri için uygun çözümler üretmek için kullanılmaktadır.

Öznitelik seçimi için genetik algoritmadaki “mutasyon”, özniteliklerin başlayıp bitmesi, “geçiş” ise kullanılan özniteliklerin değiştirilmesi anlamına gelir. Seçim işlemi özel bir seçim şeması ile yapılır. GA, ilk kez Siedlecki ve Sklansky [137] çalışmasında öznitelik seçim yöntemi olarak kullanılmıştır. Bu seçim yönteminde kromozomların uzunluğu öznitelik sayısına eşittir. Kromozomlar  $\{0,1\}$  ile kodlanır. İndis değerleri “1” olan öznitelikler seçilirken “0” olanlar seçilmeyenlerdir [72]. GA, seçim yönteminde, nüfus boyutu, kuşak sayısı ve çaprazlama – mutasyon olasılık değerleri deneysel olarak belirlenmektedir. Ölçüt fonksiyonu olarak, genellikle doğru sınıflandırma olasılığı kullanılır [72,138].

### 3. BULGULAR VE İRDELEME

#### 3.1. Kullanılan Değerlendirme Ölçekleri

Genellikle sınıflandırma yöntemi kullanılan çalışmalarda, ikili sınıflandırma sistemi adı verilen iki ayrı örneğin değerlendirilmesi yapılmaktadır. Sınıflandırıcıların performanslarını ölçmek için Tablo 10'daki Hata Matrisi (Confusion Matrix) tablosu kullanılır.

Tablo 10. Hata Matrisi tablosu

		Tahmin Edilen Sınıf	
		Pozitif	Negatif
Gerçek Olan Sınıf	Pozitif	Doğru Pozitif (True Positive - TP)	Yanlış Negatif (False Negative - FN)
	Negatif	Yanlış Pozitif (False Positive - FP)	Doğru Negatif (True Negative - TN)

Hata matrisindeki Doğru Pozitif (TP) ifadesi sınıflandırıcının pozitif olan örneklerden kaçını doğru olarak, Yanlış Pozitif (FP) ifadesi sınıflandırıcıların kaç adet negatif örneğin yanlış sınıflandırma sonucu pozitif olarak sınıflandırdığını belirtir. Aynı şekilde Yanlış Negatif (FN) ifadesi sınıflandırıcının kaç adet pozitif örneği yanlış sınıflandırma sonucu negatif örnek olarak sınıflandırdığını ve Doğru Negatif (TN) ifadesinin sınıflandırıcının negatif örneklerden kaçını doğru olarak yani negatif olarak sınıflandırdığını belirtir.

Hata matrisi üzerinden sistemin hangi yüzde ile doğru tahmin yaptığının ölçütü olan *doğruluk* (accuracy) oranı (49)'daki gibi hesaplanır.

$$\text{Doğruluk} = \frac{\text{Doğru Pozitif} + \text{Doğru Negatif}}{\text{Tüm Tahminlerin Sayısı}} \times 100 = \frac{TP + TN}{TP + FP + TN + FN} \times 100 \quad (49)$$

Genel olarak sınıflandırma sisteminin performans sonuçları *Alıcı İşletim Karakteristiği* (Receiver Operating Characteric - ROC) eğrisi yardımıyla *özgüllük* (specificity) ve *duyarlılık* (sensitivity) arasındaki dengeyi değerlendirerek yapılmaktadır. Özgüllük (50)'de görüldüğü üzere sistemin negatif örnekleri hangi doğruluk yüzdesi ile sınıflandırdığını gösterir.

$$\text{Özgüllük (Specificity)} = \frac{\text{Doğru Negatif}}{\text{Doğru Negatif} + \text{Yanlış Pozitif}} \times 100 = \frac{TN}{TN+FP} \times 100 \quad (50)$$

Duyarlılık ise sistemin pozitif örnekleri hangi doğruluk yüzdesi ile sınıflandırıldığını gösterir.

$$\text{Duyarlılık (Sensitivity)} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \times 100 = \frac{TP}{TP+FN} \times 100 \quad (51)$$

Ancak bu tez çalışmasında, çoklu sınıf sınıflandırıcılarının performans değerleri gereklidir. Bu amaçla, literatürde çoklu sınıf için tercih edilen *hassasiyet* (precision) ve *duyarlılık* (recall) ölçütleri kullanılmıştır. Hassasiyet ölçütü sınıflandırma sonuçları arasındaki doğru tahmin edilen örneklerin oranını, duyarlılık ölçütü ise gerçek örnekler arasındaki doğru sınıflandırılan örneklerin oranını vermektedir [141]. Bu iki performans ölçütü bazı sınıflandırma sonuçlarında farklı karakteristikler gösterebilir. Bu nedenle bu tez çalışmasında, hassasiyet ve duyarlılığın harmonik ortalaması olan  $F_1$  ölçütü kullanılmıştır [141].

$$\text{Hassasiyet (Precision)} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Pozitif}} \times 100 = \frac{TP}{TP+FP} \times 100 \quad (52)$$

$$\text{Duyarlılık (Recall)} = \frac{\text{Doğru Pozitif}}{\text{Doğru Pozitif} + \text{Yanlış Negatif}} \times 100 = \frac{TP}{TP+FN} \times 100 \quad (53)$$

$$F_1 = 2 \times \frac{\text{Hassasiyet} \times \text{Duyarlılık}}{\text{Hassasiyet} + \text{Duyarlılık}} \quad (54)$$

Bu çalışmada kullanılan bir diğer performans ölçümü ise yapılan çalışmanın seri ve paralel işlemcilerde ne kadar bir farkla icra edildiğidir. Bu amaçla, seri ve paralel olarak yazılmış kodların performans ölçümlerinde kullanılan *Hızlanma (Speed-up)* değeri ve *Verimlilik* değerleri aşağıdaki gibi hesaplanmıştır.

$$Hızlanma = \frac{T_s}{T_p(p)} \quad (55)$$

$$Verimlilik = \frac{Hızlanma}{p} \quad (56)$$

Burada  $T_s$ , seri çalışan algoritmanın gerçekleşme süresi,  $p$ , işlemci sayısı ve  $T_p$ ,  $p$  işlemci sayısı ile paralel çalışan algoritmanın gerçekleşme süresi olarak tanımlanmıştır.

### 3.2. Retinadaki Anatomik Yapıların Tespitindeki Sonuçlar

Otomatik retina görüntüsü analizi üzerine yapılan çalışmaların çoğunda optik disk, kan damarları ve makulanın tespiti için birçok yöntemin önerildiği görülmektedir [63,69,70,119,142,143]. Lezyon tespiti amaçlı çalışmalarda, retinadaki anatomik yapılar genellikle referans noktası olarak kullanılması amacıyla tespit edilmektedir. Ayrıca uzman hekimler lezyonların yerlerini optik disk ve makula gibi yapıları referans göstererek tanımlama yapmaktadır. Bu nedenle bu anatomik yapıların başarılı bir biçimde tespiti önemlidir.

Kan damarlarının başarılı şekilde tespiti oldukça zordur. Literatürdeki birçok çalışmada uygulanan damar tespit yaklaşımları genellikle sağlıklı retina görüntüleri üzerinde uygulanmıştır [4,65,144,145]. Özellikle DR veya neovaskülarizasyon gibi hastalıkların oluşturmuş olduğu yanlış pozitif alanlar retinadaki damar ağının başarılı bir biçimde tespiti, oldukça zorlaştırmaktadır. Bu nedenle retina damar ağının tespiti kapsamlı bir çalışma gerektirir. Bu çalışmada kullanılan morfolojik yöntemlerle elde edilen damar ağı, kalite değerlendirmesi işleminde öznelilik çıkartmak için kullanıldığından yeterli bir yaklaşım olmuştur.

Koyu DR lezyonlarının tespiti için kan damarlarının, KAG'dan elimine edilmesi gerekmektedir. Bu amaçla, kan damarları eğitim görüntüleri üzerinde etiketlenmiş ve şekilsel öznelilikler çıkartılarak KAG'dan sınıflandırıcılar yardımıyla ayırt edilmiştir.

Böylece KAG üzerinde hemoraji, mikroanevrizma ve kan damarları olmak üzere üç sınıf oluşturulmuştur.

OD, PAG üzerinde bulunan eksuda lezyonları ile parlaklık ve doku bakımından aynı özelliklere sahiptir. Bu nedenle, PAG üzerinden OD'nin elimine edilmesi gerekmektedir. Bu tez çalışmasında önerilen OD tespit yaklaşımı hem DRIMDB'de hem de diğer açık erişimli veritabanlarındaki görüntüler üzerinde test edilmiş ve ortalama % 98,34 oranında başarı elde edilmiştir. Bu yöntem kullanılarak OD elimine edildikten sonra, parlak yapıların olduğu PAG üzerinden sadece eksuda lezyonları üzerinde sınıflandırmaya yapılmıştır.

OD, uygun retina görüntüsünde olması gereken bir retinal yapıdır. Bu nedenle, bu çalışmada OD'nin bir başka kullanım amacı da retina görüntüsünün uygunluğunu tespit etmektir. Ancak uygun görüntüye karar verebilmek için, OD ile birlikte fovea'nda tespit edilmesi gerekmektedir. Tablo 11 ve Tablo 12'de uygun retina için tespit edilen OD ve Fovea bölgelerinin başarı performansları ayrı ayrı verilmiştir.


Tablo 11. OD tespiti yaklaşımının performans sonuçları

Veritabanları	Görüntü Sayısı	Doğru Tespit	Başarı
		Edilen OD Sayısı	Performansı
DRIMDB	125	123	% 98,40
DRIVE	40	40	% 100,00
DIARETDB1	89	86	% 96,63

Tablo 12. Fovea tespiti yaklaşımının performans sonuçları

Veritabanları	Görüntü Sayısı	Doğru Tespit	Başarı
		Edilen Fovea Sayısı	Performansı
DRIMDB	125	115	% 92,00
DRIVE	40	40	% 100,00
DIARETDB1	89	83	% 93,25

Tablolarda da görüldüğü üzere OD tespiti Fovea'nın tespitinden biraz daha başarılıdır. Bunun nedeni, bazı görüntülerde DR sonucu oluşan hemoraji lezyonları yanlış pozitif alanlar oluşturduğundan, Fovea yanlış olarak tespit edilmiştir. OD'nin başarısını ise, yine bazı lezyonların Sobel kenar algılama yöntemi uygulandıktan sonra oluşturmuş olduğu dikey kenarların, yatay histogram üzerinde maksimum noktalar oluşturması etkilemiştir.



Şekil 45.DRIMDB ve DIARETDB1 veritabanlarında, OD tespitindeki başarılı ve başarısız sonuçlar

Şekil 45'de görüldüğü üzere DRIMDB veritabanındaki başarısız tespitinin nedeni, retina üzerindeki DR sonucu oluşan lezyonlar ve yeni damarlanmaların oluşturduğu yoğun dikey kenarlardır. Bu veritabanındaki başarılı OD tespitinin nedeni ise, damar yapısının OD'nin dikey hizasında olması sonucu dikey kenarların yoğunluğundan faydalanılması ile OD'nin dikey bölgesi doğru olarak tespit edilmesinden kaynaklanmaktadır. DIARETDB1'deki başarısız tespitinin nedeni ise damar yapılarından ve lezyonların negatif kenar etkisindedir. Bu veritabanındaki başarılı sonucun alınması ise damarların oluşturduğu kenar yoğunluğundandır.



Tablo 13. Literatürde OD tespitindeki başarı oranlarının karşılaştırılması

OD Tespiti Metodu	Veri Seti	Başarı Oranı (%)	Açıklama
Sinthanayothin [70]	112	99,1	Kontrastı iyi olan lezyonlarda başarısız
Lalonde [115]	40	100	OD en parlak yapı kabul edilmiş
Walter [25]	30	96,7	Kontrastı iyi olan lezyonlarda başarısız
Hoover [44]	81	89	Damar bölütlemesine bağlı
Osareh [40]	75	100	OD en parlak yapı kabul edilmiş
Li [37]	79	98,7	OD en parlak yapı kabul edilmiş
Niemeijer [41]	1000	99,9	Damar bölütlemesine bağlı
Fleming [27]	1056	98,4	Damar bölütlemesine bağlı
Gutierrez [2]	179	96,3	Damar ön bilgisi ve OD'nin lokal özneliklerini kullanmış
Önerilen Yöntem	125 (DRIMDB)	<b>98,4</b>	
Önerilen Yöntem	40 (DRIVE)	<b>100</b>	Damarların oluşturduğu dikey kenar ve OD'nin dairesel yapısı kullanılmıştır.
Önerilen Yöntem	89 (DIARETDB1)	<b>96,63</b>	

### 3.3. Retina Görüntü Kalitesi Değerlendirme Sonuçları

Retina görüntü kalitesi, otomatik retina analiz sistemleri için çok önemli bir aşamadır. Bu tip sistemlerde mutlaka görüntü kalitesinin değerlendirildikten sonra analiz işlemlerine geçmek gerekir. Aksi takdirde, yetersiz karşıtlık, bulanıklık, yanlış odaklanma, yanlış kadraj veya sisteme retina yerine başka bir görüntünün gelmesi otomatik analiz sisteminin gereksiz yere analizine veya yanlış sonuçlar üretmesine neden olabilir. Bu nedenle, bu tez çalışmasında öncelikle retina görüntü kalitesinin değerlendirilmesine yer verilmiştir [76]. Kalite değerlendirme işlemi iki aşamadan oluşmaktadır. Öncelikle görüntü karşıtlık, bulanıklık ve retina görüntü özneliklerine uygunluğu değerlendirilmiştir. Burada literatürdeki çalışmalardan farklı olarak *iyi*, *kötü* ve *aykırı (retina dışı)* olmak üzere üç kalite sınıfı tanımlanmıştır. İkinci aşamada ise literatüre yeni bir katkıda bulunularak *iyi* kalite sınıfındaki görüntülerin kadraj olarak uygun olup olmadıkları tespit edilmiştir [76]. Buradaki amaç, retinadaki tüm anatomik yapıların (ana arter kan damarları, optik disk ve makula) görüntü üzerinde bulunup bulunmadığını tespit etmektir. Böylece günümüzdeki veri depolama problemleri de göz önünde bulundurulduğunda, klinikteki görüntü

veritabanlarında gereksiz görüntüler tutulmayacaktır. Bu da kliniğin elindeki verilerin çok daha kaliteli olmasını sağlayacaktır.

Retinanın küresel yapısından dolayı elde edilen görüntüler, genellikle ortası daha parlak ve kenarlara doğru koyulaşan bir parlaklık dağılımına sahiptirler. Dolayısı ile kalite değerlendirmesini sadece global veya sadece yerel olarak incelemek doğru sonuçlar vermeyebilir. Bu nedenle, bu tez çalışmasında hem global hem de yerel olmak üzere toplam 177 adet öznelik çıkartılmıştır.

Öznelik çıkarımı, DRIMDB veritabanından MATLAB yazılımı yardımıyla kodlanarak iki ayrı bilgisayarda test edilmiştir (PC1 ve PC2). PC1, Intel Core i7 3770 dört çekirdekli işlemciye ve 16 GB belleğe sahip olup, PC2 ise Intel Core i7 3930K altı çekirdekli işlemciye ve 16 GB belleğe sahiptir. Öznelik çıkarımı hem seri hem de paralel kodlama yöntemi ile ön bellek etkisini elimine etmek için 10 kez çalıştırılmıştır. Ayrıca paralel hesaplama ile öznelik çıkarımının hızlanma (speed-up) ve verim (efficiency) değerleri de hesaplanmıştır.

Tablo 14. DRIMDB veritabanından çıkartılan öznelikler için performans tablosu (10 kere çalıştırılmıştır)

	<b>PC1</b>	<b>PC2</b>
Seri kodlama	385.83 s	304.32 s
Paralel kodlama	145.60 s	56.51 s
Hızlanma (Speed-up)	265.00 %	538.49 %
Verim (Efficiency)	33.12 %	44.87 %

Tez çalışmamızda, görüntü kalite değerlendirmesi için çıkartılan özneliklerin sınıflandırma performansları açık kaynak kodlu RapidMiner v.5.3 veritabanı madenciliği yazılımıyla gerçekleştirilmiştir [146]. Literatürde en bilinen beş sınıflandırıcıdan, Doğrusal Ayırıştırma Analizi (DAA), k-En Yakın Komşuluk (k-EYK), Yapay Sinir Ağları (YSA), Naive Bayes (NB) ve Destek Vektör Makineleri (DVM) kullanılarak öznelik öğrenimi ve sınıflandırılması yapılmıştır [98,147–151].

DAA, birbiri ile ilgili öznitelikler kullanıldığında teklik (singularity) sorunu sebebiyle hatalı sonuçlar ürettiğinden öznitelikler öncelikle Temel Bileşenler Analizi (TBA) ile birbirinden ayrık yeni bir öznitelik kümesine indirgenmiştir [148]. Aksi takdirde, benzer öznitelikler aynı sonuçları verebilir ve sonuçlarda karmaşıklığa neden olabilir. Yapılan deneyler sonucunda TBA yöntemiyle öznitelik sayısı 77'ye indirgenmiştir. k-EYK sınıflandırıcısı için kullanılan k değeri yapılan optimizasyon deneyleri ile  $k = 1$ 'den  $k = 15$ 'e kadar bütün olasılıklar 10-katlı çapraz doğrulama yöntemi kullanılarak optimum komşuluk değeri belirlenmiştir. Sonuç olarak, k-EYK'nın en başarılı sonuçlar  $k = 1$  olarak tek komşuluk değeri yaptığı sınıflandırmada elde edilmiştir. YSA için yaptığımız deneylerde, katman boyutu girdi vektörünün boyutu ve sınıf sayısı aracılığı ile hesaplanan bir gizli katman kullanılmıştır. NB deneylerimiz de ise sıfır olasılıkların yüksek etkilerinden kurtulmak için Laplace düzeltmesi yöntemi kullanılmıştır. Laplace düzeltmesi yöntemi ile her bir sınıfa 1 adet fazladan örnek atanarak, olasılıkların sıfır çıkması engellenmiş olur. DVM sınıflandırıcısı ise çalışmada kullanılan tek ikili sınıflandırıcı olup "bire karşı-hepsi" yaklaşımı ile sınıflandırma yapılmıştır. DVM sınıflandırıcısının düzenleme katsayısı olan  $C$  parametresi -1 ile 1 arasında yapılan deneyler sonucunda en uygun  $C = -1$  olarak belirlenmiştir. Burada kullanılacak küçük değerli  $C$  katsayısı kısıtlamaları kolayca göz ardı ederken, büyük değerli  $C$ , sınırlamaları göz ardı etmeyi zorlaştırmaktadır.

Sınıflandırma performansının başarısını etkileyen birçok parametre vardır. Bunlardan bazıları sınıflandırıcının türü, eğitim için kullanılan öznitelikler, sınıflandırıcı parametreleri ve sınıf sayısı şeklinde sıralanabilir. Fakat en önemlisi sınıflandırıcının eğitileceği özniteliklerin türleri ve sayılarıdır. Sınıflandırma işleminde amaç, en az öznitelikle en başarılı sınıflandırma işlemi gerçekleştirilmesidir. Özellikle, öznitelik kümesinde sınıfı tanımlayamayan hatta yanlış sonuçlara yol açabilecek gereksiz öznitelikler olabilir. Bu nedenle gereksiz özniteliklerin elimine edilmesi gerekir. Öznitelik kümesinden sınıflandırma işlemi için en etkin öznitelikleri belirleme işlemine *Öznitelik Seçimi* denir. Ayrıca, öznitelik kümesindeki fazla öznitelikler sınıflandırıcılar tarafından kullanılırken hesaplama yükünü de beraberinde getirecektir. Bu nedenle öznitelik uzayının daha etkin bir boyuta dönüştürülmesi için *Öznitelik Boyut Azaltımı* yapılması gerekir. Kalite değerlendirmesi için çıkartılan 177 öznitelikli sınıflandırma için her hangi bir olumsuz yan etkisi olmaması için *İleri Doğru Seçim Metodu* ve *Genetik Algoritma* yaklaşımı kullanılarak öznitelik kümesinden etkin özniteliklerin seçimi yapılmıştır. Öznitelik seçimi PC1 üzerinde

gerçekleştirilmiş olup, kullanılan yaklaşımlarla ilgili hesaplama zamanları Tablo 15’de görülmektedir [76].

Tablo 15. Öznitelik seçimi yaklaşımlarının zaman performansları

Sınıflandırıcı	Tüm Öznitelikler için test süresi (sn)	Genetik Algoritma		İleri Doğru Seçim	
		Öznitelik Vektör Boyutu	Test Süresi (sn)	Öznitelik Vektör Boyutu	Test Süresi (sn)
DAA	<1	85	<1	8	<1
k-EYK (k=1)	<1	177	<1	6	<1
SA	<1	98	<1	4	<1
NB	<1	84	<1	4	<1
DVM	<2	95	<1	10	<1

Literatürdeki birçok sınıflandırmayla ilgili çalışmalar, iki farklı sınıftaki örneklerin ikili sınıflandırma sistemi ile değerlendirilmesi şeklindedir. Bu değerlendirme sonucunda en çok kullanılan ölçütler, ROC eğrisi, özgüllük ve duyarlılık oranlarıdır. Ancak çalışmada, örnek sayıları ile çoklu sınıflandırma işlemi yapılmak istenmektedir. Bu nedenle çalışmada, çoklu sınıflandırma işleminin değerlendirilmesinde kullanılan hassasiyet (precision) ve duyarlılık (recall) ölçütleri kullanılmıştır. Ancak bu iki ölçüt bazı deneylerde farklı karakteristik özellikler gösterebilmektedir. Bu nedenle, hassasiyet ve duyarlılık oranlarının harmonik ortalaması alınarak  $F_1$  ölçütü adı verilen bir değerlendirme metriği kullanılmıştır [141]. Sonuç olarak, yüksek tahmin gücünün yanı sıra, yüksek sınıflandırma doğruluğu elde edilen deneysel çalışmalar da yapılmıştır.

Çalışmada çıkartılan öznitelikler üç şekilde sınıflandırıcılara verilerek sınıflandırma performansları ölçülmüştür. Öncelikle 177 özniteliğin tümü sınıflandırıcılara verilmiştir. Şekil 46’da sonuçlara bakıldığında, DVM sınıflandırıcısı diğer sınıflandırıcılardan biraz daha fazla performans göstererek, *iyi* sınıftaki örnekleri % 99,60, *aykırı* sınıftaki örnekleri % 84,21  $F_1$  ölçütü ile sınıflandırmıştır. DAA sınıflandırıcı ise diğer yöntemlere göre *kötü* sınıftaki örnekleri % 97,78  $F_1$  ölçütü daha başarılı şekilde sınıflandırmıştır. Bu durumda her iki sınıflandırıcı, farklı sınıflar için farklı sonuçlar ürettiğinden, % 93,44

ortalama başarı oranı göz önüne alındığında DVM en başarılı sınıflandırıcı olarak seçilebilir. Tablo 16'dan Tablo 20'ye kadar tüm öznelikler kullanılarak yapılan sınıflandırma sonuçları görülmektedir.

Tablo 16. DAA+TBA sınıflandırma tablosu

DAA+TBA (TBA ile 77 öznelik seçildi, eğitim süresi: <1, test süresi:<1)				
	İyi	Kötü	Aykırı	Hassasiyet
İyi	125	2	5	<b>% 94,70</b>
Kötü	0	65	4	<b>% 94,20</b>
Aykırı	0	2	13	<b>% 86,67</b>
<b>Duyarlılık</b>	<b>% 100</b>	<b>% 94</b>	<b>% 59</b>	

Tablo 17. k-EYK sınıflandırma tablosu

k-EYK (k=1'den k=15'e kadar kaba kuvvet yöntemiyle optimizasyon yapıldı ve k=1 optimum değer olarak seçildi, eğitim süresi: <1sn, test süresi:<1sn)				
	İyi	Kötü	Aykırı	Hassasiyet
İyi	110	27	10	<b>% 74,83</b>
Kötü	15	41	3	<b>% 69,49</b>
Aykırı	0	1	9	<b>% 90,00</b>
<b>Duyarlılık</b>	<b>% 88</b>	<b>% 59</b>	<b>% 41</b>	

Tablo 18. YSA sınıflandırma tablosu


YSA (Bir gizli katmanda 91 sinir seçildi, eğitim süresi: 20sn, test süresi:<1sn)				
	İyi	Kötü	Aykırı	Hassasiyet
İyi	125	1	1	<b>% 98,43</b>
Kötü	0	64	3	<b>% 95,52</b>
Aykırı	0	4	18	<b>% 81,82</b>
<b>Duyarlılık</b>	<b>% 100</b>	<b>% 93</b>	<b>% 82</b>	

Tablo 19. NB sınıflandırma tablosu

NB (eğitim süresi: <1sn, test süresi:<1sn)				
	İyi	Kötü	Aykırı	Hassasiyet
İyi	125	0	2	<b>% 98,43</b>
Kötü	0	62	1	<b>% 98,41</b>
Aykırı	0	7	19	<b>% 73,08</b>
<b>Duyarlılık</b>	<b>% 100</b>	<b>% 90</b>	<b>% 86</b>	

Tablo 20. DVM sınıflandırma tablosu

DVM (eğitim süresi: 60sn, test süresi: 2sn)				
	İyi	Kötü	Aykırı	Hassasiyet
İyi	125	0	1	<b>% 99,21</b>
Kötü	0	69	5	<b>% 93,24</b>
Aykırı	0	0	16	<b>% 100,00</b>
<b>Duyarlılık</b>	<b>% 100</b>	<b>% 100</b>	<b>% 73</b>	



Şekil 46. Tüm özniteliklerin kullanıldığı deneylerin performans grafiği

Çalışmadaki ikinci ve üçüncü performans ölçüm deneyleri, genetik algoritma ve ileriye doğru seçim metodu kullanılarak öznelik boyutunun azaltılıp, performansa yansıyan olumlu etkilerini araştırmak için yapılmıştır. Özellikle NB gibi olasılık tabanlı sınıflandırıcılar DAA yaklaşımından daha başarılı performans göstermiştir. Benzer şekilde, k-EYK yaklaşımının da İleriye Doğru Seçim (İDS) yaklaşımı kullanılarak başarısının arttığı gözlenmiştir. Ancak, deneyler sonunda DVM ve YSA sınıflandırıcılarının öznelik seçimi sonrasında *aykırı* sınıfını ayırmada, performansının oldukça düştüğü görülmektedir. Bu performans düşüşüne sebep olan ana neden, *aykırı* sınıfındaki örneklerin sayılarının diğer sınıflara oranla daha az olmasından kaynaklandığı düşünülmektedir. Öznelik boyutunun indirgenmesi, *aykırı* sınıfı için önemli olan özneliklerin kaybolmasına yol açmış olabilir.

Tablo 21. Genetik algoritma yaklaşımı ile DAA'nın sınıflandırma tablosu

DAA (GA ile 85 öznelik seçildi, seçim + eğitim süresi: 28sn, test süresi:<1sn)

	İyi	Kötü	Aykırı	Hassasiyet
İyi	125	3	4	<b>% 94,70</b>
Kötü	0	63	2	<b>% 96,92</b>
Aykırı	0	3	16	<b>% 84,21</b>
Duyarlılık	<b>% 100</b>	<b>% 91</b>	<b>% 73</b>	

Tablo 22. Genetik algoritma yaklaşımı ile k-EYK'nın sınıflandırma tablosu

k-EYK (k=1'den k=15'e kadar kaba kuvvet yöntemiyle optimizasyon yapıldı ve k=1 optimum değer olarak seçildi, GA ile 177 öznelik seçildi, seçim + eğitim süresi: 9sn, test süresi:<1sn)

	İyi	Kötü	Aykırı	Hassasiyet
İyi	106	24	9	<b>% 76,26</b>
Kötü	18	44	2	<b>% 68,75</b>
Aykırı	1	1	11	<b>% 84,62</b>
Duyarlılık	<b>% 85</b>	<b>% 64</b>	<b>% 50</b>	

Tablo 23. Genetik algoritma yaklaşımı ile YSA'nın sınıflandırma tablosu

YSA (Gizli katman sayısı 1, GA ile 98 öznitelik seçildi, seçim + eğitim süresi: 5 sa 43 dk 44 sn, test süresi:<1sn)

	İyi	Kötü	Aykırı	Hassasiyet
İyi	123	0	2	<b>% 98,40</b>
Kötü	1	67	4	<b>% 93,06</b>
Aykırı	1	2	16	<b>% 84,21</b>
Duyarlılık	<b>% 98</b>	<b>% 97</b>	<b>% 73</b>	

Tablo 24. Genetik algoritma yaklaşımı ile NB'nin sınıflandırma tablosu

NB (GA ile 84 öznitelik seçildi, seçim + eğitim süresi: 8sn, test süresi:<1sn)


	İyi	Kötü	Aykırı	Hassasiyet
İyi	125		2	<b>% 98,43</b>
Kötü	0	63	1	<b>% 98,44</b>
Aykırı	0	6	19	<b>% 76,00</b>
Duyarlılık	<b>% 100</b>	<b>% 91</b>	<b>% 86</b>	

Tablo 25. Genetik algoritma yaklaşımı ile DVM'nin sınıflandırma tablosu

DVM (GA ile 95 öznitelik seçildi, seçim + eğitim süresi: 1 dk 16 sn, test süresi:<1)

	İyi	Kötü	Aykırı	Hassasiyet
İyi	125	2	3	<b>% 96,15</b>
Kötü	0	65	8	<b>% 89,04</b>
Aykırı	0	2	11	<b>% 84,62</b>
Duyarlılık	<b>% 100</b>	<b>% 94</b>	<b>% 50</b>	





Şekil 47. GA yaklaşımı ile öznitelik seçimi performans grafiği

Tablo 26. İDS yaklaşımı ile öznitelik seçiminde DAA'nın sınıflandırma tablosu

DAA (İDS ile 8 öznitelik seçildi, seçim + eğitim süresi: 24sn, test süresi:<1sn)

	İyi	Kötü	Aykırı	Hassasiyet
İyi	125	1	2	<b>% 97,66</b>
Kötü	0	67	3	<b>% 95,71</b>
Aykırı	0	1	17	<b>% 94,44</b>
<b>Duyarlılık</b>	<b>% 100</b>	<b>% 97</b>	<b>% 77</b>	

Tablo 27. İDS yaklaşımı ile öznitelik seçiminde k-EYK'nın sınıflandırma tablosu

k-EYK (k=1'den k=15'e kadar kaba kuvvet yöntemiyle optimizasyon yapıldı ve k=1 optimum değer olarak seçildi, İDS ile 6 öznitelik seçildi, seçim + eğitim süresi: 17sn, test süresi:<1sn)

	İyi	Kötü	Aykırı	Hassasiyet
İyi	123	1	2	<b>% 97,62</b>
Kötü	1	64	4	<b>% 92,75</b>
Aykırı	1	3	17	<b>% 80,95</b>
<b>Duyarlılık</b>	<b>% 98</b>	<b>% 94</b>	<b>% 74</b>	

Tablo 28. İDS yaklaşımı ile öznitelik seçiminde YSA'nın sınıflandırma tablosu

YSA (İDS ile 4 öznitelik seçildi, seçim + eğitim süresi: 18dk 52 sn, test süresi:<1sn)

	İyi	Kötü	Aykırı	Hassasiyet
İyi	123	0	2	<b>% 98,40</b>
Kötü	1	67	4	<b>% 93,06</b>
Aykırı	1	2	16	<b>% 84,21</b>
<b>Duyarlılık</b>	<b>% 98</b>	<b>% 97</b>	<b>% 73</b>	

Tablo 29. İDS yaklaşımı ile öznitelik seçiminde NB'nin sınıflandırma tablosu


NB (İDS ile 4 öznitelik seçildi, seçim + eğitim süresi: 9sn, test süresi:<1sn)

	İyi	Kötü	Aykırı	Hassasiyet
İyi	124	0	0	<b>% 100,00</b>
Kötü	0	66	3	<b>% 95,65</b>
Aykırı	1	3	19	<b>% 82,61</b>
<b>Duyarlılık</b>	<b>% 99</b>	<b>% 96</b>	<b>% 86</b>	

Tablo 30. İDS yaklaşımı ile öznitelik seçiminde DVM'nin sınıflandırma tablosu

DVM (İDS ile 10 öznitelik seçildi, seçim + eğitim süresi: 1 dk 32 sn, test süresi:&lt;1sn)

	İyi	Kötü	Aykırı	Hassasiyet
İyi	125	0	2	<b>% 98,40</b>
Kötü	0	67	5	<b>% 93,06</b>
Aykırı	0	2	15	<b>% 88,24</b>
Duyarlılık	<b>% 100</b>	<b>% 97</b>	<b>% 68</b>	



Şekil 48. İDS yaklaşımı ile öznitelik seçimi performans grafiği.

Buna ek olarak öznitelik seçimi, DAA'nın ortalama başarı oranına bakıldığında diğerlerine göre başarı oranını arttırmıştır. Şekil 48'de görüldüğü üzere İDS yaklaşımı ile öznitelik seçimi sonrasında DAA sınıflandırıcı % 98,81 ile *iyi*, %96,40 ile *kötü* ve %85,00 ile *aykırı* sınıflandırma başarısını yakalamıştır.

Sonuç olarak, Tablo 21 ile Tablo 25 arasındaki tablolarda GA yaklaşımının, Tablo 26 ile Tablo 30 arasındaki tablolarda ise İDS yaklaşımının öznitelik seçimi sonrasında

sınıflandırıcıların performansları ayrıntılı biçimde verilmiştir. Tüm yaklaşımlar incelendiğinde DVM yaklaşımı, herhangi bir öznitelik seçimi olmadan tüm öznitelikler kullanılarak Tablo 20’de de görüldüğü üzere *iyi* sınıfındaki tüm görüntüleri *iyi*, *kötü* sınıfındaki tüm görüntüleri *kötü*, *aykırı* sınıfındaki 1 görüntüyü *iyi*, 5 görüntüyü *kötü* ve 16 görüntüyü de *aykırı* olarak sınıflandırarak en iyi başarı performansını göstermiştir.

### 3.4. Uygun Retina Görüntülerinin Tespiti


Uygun Retina Görüntüsünün (URG) tespiti, kalite değerlendirmesi yapılan görüntülerin *iyi* sınıfında bulunan görüntüler arasında yapılmıştır. Burada, görüntünün kalitesinin iyi olması yeterli değildir. Görüntülerin aynı zamanda bilgi ve içerik bakımından da yeterli olması gerekmektedir. Bu amaçla, retina üzerindeki anatomik yapıların hepsinin aynı kadrajda olup olmadığının kararını veren bir *uygunluk değeri* önerilmiştir. Uygunluk değeri Şekil 38’deki OD’nin üst ve alt sınırlara olan mesafesine göre hesaplanmaktadır. OD’nin merkezi görüntünün merkezine yaklaştıkça uygunluk değeri artmaktadır.

URG tespiti için geliştirilen yeni yaklaşım, çalışmadaki özgün veri setinden oluşan DRIMDB veritabanının yanı sıra, literatürde açık erişimli veritabanlarından DRIVE ve DIARETDB1’deki görüntülerde de test edilmiştir. Literatürde açık erişimli olup ve kalite ölçmek için veritabanı bulunmadığından, DRIVE ve DIARETDB1 veritabanlarındaki görüntülerin kaliteli olduğu varsayılarak URG için yeterli olup olmadıkları ölçülmüştür.

Tablo 31. URG tespiti yaklaşımının performans sonuçları

Veritabanları	Görüntü Sayısı	Toplam Doğru Sınıflandırılan URG Sayısı	Doğru Tespit Edilen URG Oranı
DRIMDB	125	122	% 97,60
DRIVE	40	40	% 100,00
DIARETDB1	89	86	% 96,63

Tablo 31’de de görüldüğü gibi, URG tespiti yaklaşımı ile sırasıyla % 97,60, % 100 ve % 96.63 oranında başarı performansı elde edilmiştir.



Şekil 49. DRIMDB ve DIARETDB1 veritabanlarından tespit edilen başarılı ve başarısız örnekler. a) DRIMDB başarılı örnek, b)DRIMDB başarısız örnek, c) DIARETDB1 başarılı örnek, d) DIARETDB1 başarısız örnek.

Şekil 49’da kırmızı puntolu olan bölgeler tespit edilen OD ve Fovea bölgeleridir. URG için bu anatomik yapılar alt ve üst sınırlar arasında bulunmak zorundadır. Şekil 49(a)’da, DRIMDB görüntüsü kalite açısından *iyi* sınıfında olmasına rağmen, OD kadraj dışında kaldığından URG için geliştirilen yaklaşım bu görüntü için olumsuz sonuç vermiştir. Benzer şekilde, DIARETDB1 veritabanındaki görüntüler için bir kalite bilgisi olmadığından Şekil 49(d)’de parlaklık ve karışıklık yetersizliğinden dolayı foveanın yeri yanlış tespit edilmiştir.

Oftalmoloji kliniklerinde çekilen birçok retina görüntüsü yeterli kalite ve bilgi içermemektedir. Bu durum, otomatik retina analiz sistemlerinin doğru sonuç üretememesi, gereksiz görüntülerin saklanması ve zaman kaybı gibi olumsuz nedenlere yol açmaktadır. Bu çalışmada, bu tür olumsuzlukların önüne geçebilecek ön bir kontrol mekanizması önerilmiştir. Bu yaklaşım kullanılarak, fundus kameraların görüntü çekim aşamasında ya da

otomatik analiz sistemlerine veya oftalmologların teşhis aşamasından önce kalitesiz ve uygun olmayan görüntüler elimine edilebilir.

Literatürde retina görüntü kalitesi ile ilgili çalışmalar genellikle damar yoğunlukları veya parlaklık değişimlerinin ölçümü ile ilgilidir [113–117,152]. Bu çalışmalardan bazıları, retina olmayan görüntüler hariç tutularak sadece kalite üzerine değerlendirme yapmıştır. Ancak retina olmayan görüntüler, otomatik analiz sistemlerinde yanlış pozitif değerler üretebilmektedir. Örneğin, Fleming ve diğerleri [113] ile Paulus ve diğerleri [152], retina görüntüsü olmayan görüntüler için herhangi bir *aykırı* sınıfı oluşturmamışlardır [152]. Paulus ve diğerleri [152], Haralick ve diğerlerinin [77] önermiş olduğu doku özneliklerini kullanarak %92,7'lik eğri altı alan (AUC) başarı oranı yakalamışlardır. Wen ve diğerleri [153], retinadaki damar bilgilerini kullanarak bir görüntü kalite değerlendirme yaklaşımı önermişlerdir. Ancak retina görüntüsünün çanak şeklindeki yapısından dolayı kontrast ve parlaklık dağılımını göz ardı etmiştir. Fleming ve diğerleri [113], retina görüntü kalitesi için karmaşık bir sınıflandırma tablosu oluşturmuştur. Sınıflandırma tablosunda bir tane *kötü* sınıfı varken, *iyi* sınıfı dörde ayırmış ve *aykırı* sınıfına yer vermemiştir. Bununla beraber, retina görüntüsü olmayan görüntülerin tespitini yapan çalışmalarda vardır. Örneğin, Giancardo ve diğerleri [114], *aykırı* sınıfı için uygulamış olduğu yaklaşımın başarı oranı % 80'dir. Bunun nedeni olarak, çalışmanın sadece damar bilgisi kullanılarak yapılması ve retina olmayan görüntülerde damar benzeri nesnelere değerlendirmeye alınmasından kaynaklanmaktadır. Buna ek olarak, yeterli teşhis bilgisi olmayan retina görüntülerini de *aykırı* sınıfında değerlendirmişlerdir. Lalonde ve diğerleri [115], lokal piksel parlaklık dağılımlarından faydalanarak bir aykırı tespit sistemi geliştirmişlerdir. Ancak bu yaklaşım retina benzeri parlaklık dağılımlarına sahip *aykırı* görüntülerde doğru sonuçlar vermeyebilir.

Bu tez çalışmasında, retina kalite değerlendirmesi ve URG tespiti olmak üzere iki aşamalı bir sistem önerilmiştir. Retina kalite değerlendirmesinde aykırı sınıfı mevcut olup sınıflandırma basit ve açıktır. Uygunluk aşamasındaki yaklaşım ise literatüre yeni önerilen bir sistemdir.

Literatürde, medikal görüntü analizi sistemleri için farklı görüntü özneliklerinin başarı oranları verilmiştir [154]. Bu tez çalışmasında, literatürdeki mevcut özneliklerin yanı sıra yeni özneliklerde önerilmiştir [71,113,114]. Kalite değerlendirmesinde kullanılan

ISNT bölgelerinin I/S ve (I+S)/(N+T) oranları, URG tespitinde *uygunluk değeri* gibi yeni öznitelikler önerilmiştir. Buna ek olarak, benzer çalışmalarda olmayan, retina görüntüsünün hem lokal hem de global özelliklerini ortaya koyan öznitelikler seçilerek başarı oranı artırılmıştır. Mevcut öznitelikler, problemin cinsine göre değerlendirmeli ve gereksiz yere kullanılıp öznitelik boyutu büyütülmemelidir [155–157]. Bu çalışmada da uygulandığı üzere, gerektiğinde öznitelik seçimi veya boyut indirilmesi yapılmalıdır.

### 3.5. Diyabetik Retinopati Lezyonlarının Tespitindeki Sonuçlar

DR lezyonlarının tespiti ile ilgili literatürde birçok çalışma mevcuttur [3,25,28–31,38,66]. Bu çalışmaların birçoğunda örüntü tanıma prosedürleri uygulanmış ve değişik başarı oranları elde edilmiştir. Bu tez çalışmasında farklı olarak, arka plan yaklaşımı kullanılarak örüntü tanıma işlemlerine geçmeden önce parlak ve koyu lezyonlar ayrıştırılmış ve işlem yükü azaltılmıştır. Ayrıca bu sayede koyu ve parlak lezyonların birbirleriyle oluşturacağı yanlış pozitif alanlar en başta önlenmiştir.

Arka plan kestirimi sonucunda elde edilen KAG ve PAG üzerinde Gamma düzeltmesi yapıldıktan sonra bu iki ikili görüntüdeki nesnelere şekilsel öznitelikler çıkarılmıştır. Ek olarak PAG'dan sert ve yumuşak eksudaları ayırt edebilmek için parlaklık dağılımları ile ilgili üç adet öznitelik daha çıkarılmıştır. Öznitelikler, DRIMDB veritabanında iyi sınıfındaki 34 görüntünün uzman oftalmologlar gözetiminde elle etiketlenen görüntülerden çıkarılmıştır. Etiketleme işlemi, koyu yapılardan hemoraji, mikroanevrizma ve kan damarları, parlak yapılardan ise sert ve yumuşak eksudalar işaretlenerek yapılmıştır.

DR için öznitelik çıkarımı, DRIMDB veritabanından MATLAB yazılımı yardımıyla kodlanarak Intel Core i7 3930K altı çekirdek işlemci ve 16 GB belleğe sahip PC'de gerçekleştirilmiştir. Öznitelik çıkarımı, sadece seri kodlama yöntemi ile ön bellek etkisini elimine etmek için 10 kez çalıştırılmış ve 34 etiketli görüntü ortalama 25,3218 sn sürede 19 koyu ve 22 parlak lezyon özniteliği olmak üzere, toplamda 41 öznitelik çıkarılarak yapılmıştır. Burada çıkarılan öznitelik sayısı az olduğundan ve koyu lezyonlar ile parlak lezyonlar için çıkarılan öznitelik sayıları eşit olmadığından öznitelik çıkarımı için paralel kodlama yapılmamıştır.

Bu tez çalışmasında, DR lezyonlarının tespiti için çıkartılan özniteliklerin sınıflandırma performansları açık kaynak kodlu RapidMiner v.5.3 veritabanı madenciliği yazılımıyla gerçekleştirilmiştir [146]. DR lezyonlarının tespiti için, k-En Yakın Komşuluk (k-EYK), Yapay Sinir Ağları (YSA), Naive Bayes (NB), Karar Ağaçları (KA), Rastgele Orman (RO) ve Adaboost yaklaşımı kullanılarak öznitelik öğrenimi ve sınıflandırılması yapılmıştır [102,109–111,149–151].

k-EYK sınıflandırıcısı, kalite değerlendirilmesinde olduğu gibi k değeri yapılan optimizasyon deneyleri sonucunda  $k = 1$  olduğunda en başarılı sınıflandırma performansı elde edilmiştir. YSA için yapılan deneylerde, katman boyutu girdi vektörünün boyutu ve sınıf sayısı aracılığı ile hesaplanan bir gizli katman kullanılmıştır. NB için yapılan deneylerde ise sıfır olasılıkların yüksek etkilerinden kurtulmak için Laplace düzeltmesi yöntemi kullanılmıştır. Laplace düzeltmesi ile tüm sınıflara ek olarak birer örnek eklenir ve sıfır olasılık değerlerinin oluşması engellenir. KA sınıflandırıcısı ayrıştırma için CHAID algoritmasını ve ağaçlanmayı sağlayan entropi tabanlı bilgi kazancı yöntemini kullanmaktadır. RO sınıflandırıcısında ise, KA'da olduğu gibi ağaçlanmayı sağlayan bilgi kazancı yöntemi kullanılmış ve ürettiği rastgele ağaç sayısı 10 olarak seçilmiştir. Ayrıca RO yönteminde maksimum ağaç derinliği 20 olarak seçilmiştir. Adaboost yaklaşımı ise zayıf bir sınıflandırıcının performansını arttırmak için kullanılmaktadır. Bu çalışmada sınıflandırıcı olarak KA kullanılmıştır. Adaboost algoritmasının maksimum iterasyon sayısı da 10 olarak seçilmiştir.

Kalite değerlendirmesinde olduğu gibi DR lezyonlarının sınıflandırılmasında da öznitelik seçiminden yararlanılmıştır. Ancak burada öznitelik sayısı düşük olduğundan çok fazla bir performans kazancı olmamıştır. Öznitelik kümesinden sınıflandırma işlemi için en etkin öznitelikleri seçmek için *İleri Doğru Seçim Metodu* ve *Genetik Algoritma* yaklaşımı kullanılmıştır. Öznitelik seçimi ilgili hesaplama zamanları Tablo 32'de görülmektedir [76].



Tablo 32. Koyu DR lezyonları ve damarlar için öznitelik seçimi yaklaşımlarının zaman karşılaştırmaları.

Sınıflandırıcı	Tüm Öznitelikler için test süresi (sn)	Genetik Algoritma		İleri Doğru Seçim	
		Öznitelik Vektör Boyutu	Test Süresi (sn)	Öznitelik Vektör Boyutu	Test Süresi (sn)
k-EYK (k=1)	<1	11	<1	4	<1
YSA	85	14	2757	2	1020
NB	<1	12	<1	1	<1
KA	<1	13	<1	4	<1
RO	<1	9	<1	4	<1
Adaboost	<1	10	<1	3	<1


Bu çalışmada, çoklu sınıflandırma işleminin değerlendirilmesinde kullanılan hassasiyet (precision) ve duyarlılık (recall) ölçütlerinden faydalanılmıştır. Değerlendirme ölçütü olarak hassasiyet ve duyarlılık oranlarının harmonik ortalaması alınarak  $F_1$  ölçütü kullanılmıştır [141].

Öncelikle sınıflandırma işlemi etiketli görüntüler üzerinde yapılmıştır. Bunun amacı, KAG ve PAG için en iyi sınıflandırıcı ve en iyi ayrıştırma modelinin bulunması hedeflenmektedir. En başarılı sınıflandırıcı bulunduktan sonra, DRIMDB veritabanında *iyi* sınıfındaki tüm görüntülerin KAG ve PAG'larından elde ettiğimiz nesnelere (lezyonlar), bu başarılı sınıflandırıcı kullanılarak sınıflandırılmıştır. Etiketli görüntülerin öznitelikleri çıkartıldıktan sonra yarısı eğitim verisi yarısı da test verisi olarak kullanılmıştır. Sınıflandırıcılar eğitilirken 10-kere çapraz doğrulama yöntemi kullanılarak eğitimin doğruluğu arttırılmıştır. Tüm öznitelikler, genetik algoritma yaklaşımı ve ileriye doğru seçim yaklaşımları ile öznitelik seçimi yapıldıktan sonra alınan sınıflandırma performansları aşağıdaki tablo ve grafiklerde görülmektedir.

Tablo 33. Tüm öznitelikler kullanıldığında koyu lezyonların ve damarların sınıflandırma performansları (H: Hemoraji, M: Mikroanevrizma, V: Damarlar)

Sınıflandırıcı	Sınıf	TP	TN	FP	FN	Hassasiyet	Duyarlılık	F1-Ölçütü
1-EYK	H	743	559	99	128	88,24%	85,30%	86,75%
	M	515	794	127	93	80,22%	84,70%	82,40%
	V	44	1478	1	6	97,78%	88,00%	92,63%
AdaBoost	H	866	656	2	5	99,77%	99,43%	99,60%
	M	607	919	2	1	99,67%	99,84%	99,75%
	V	47	1474	5	3	90,38%	94,00%	92,16%
KA	H	867	657	1	4	99,88%	99,54%	<b>99,71%</b>
	M	608	920	1	0	99,84%	100,00%	<b>99,92%</b>
	V	48	1475	4	2	92,31%	96,00%	<b>94,12%</b>
NB	H	714	654	4	157	99,44%	81,97%	89,87%
	M	604	780	141	4	81,07%	99,34%	89,28%
	V	49	1462	17	1	74,24%	98,00%	84,48%
YSA	H	859	635	23	12	97,39%	98,62%	98,00%
	M	591	909	12	17	98,01%	97,20%	97,61%
	V	43	1478	1	7	97,73%	86,00%	91,49%
RO	H	869	652	6	2	99,31%	99,77%	99,54%
	M	606	920	1	2	99,84%	99,67%	99,75%
	V	45	1477	2	5	95,74%	90,00%	92,78%

Tüm öznitelikler kullanıldığında en iyi koyu lezyonları ve damarı sınıflandıran yöntem ortalama % 97,91 ile Karar Ağaçları olmuştur.



Şekil 50. Koyu DR lezyonları ve damar için tüm öznitelikler kullanıldığında elde edilen başarı

Şekil 50’den de görüldüğü üzere sınıflandırıcıların başarı oranları %82’nin üzerinde olmaktadır.

Genetik algoritma ve ileriye doğru seçim yöntemleri sonucu seçilen özniteliklerin adlarının kodlanması Tablo 34’de verilmiştir.

Tablo 34. Koyu DR’ler için çıkartılan özniteliklerin kodlanması

KODU	Öznitelik Adı
Area	Alan
CentroidX	Ağırlık Merkezi X (Centroid)
CentroidY	Ağırlık Merkezi Y (Centroid)
BBX1	Sınırlayıcı Çerçeve X (Bounding Box)
BBY1	Sınırlayıcı Çerçeve Y (Bounding Box)
BBX2	Sınırlayıcı Çerçeve Boyu (Bounding Box)

Tablo 34'ün devamı

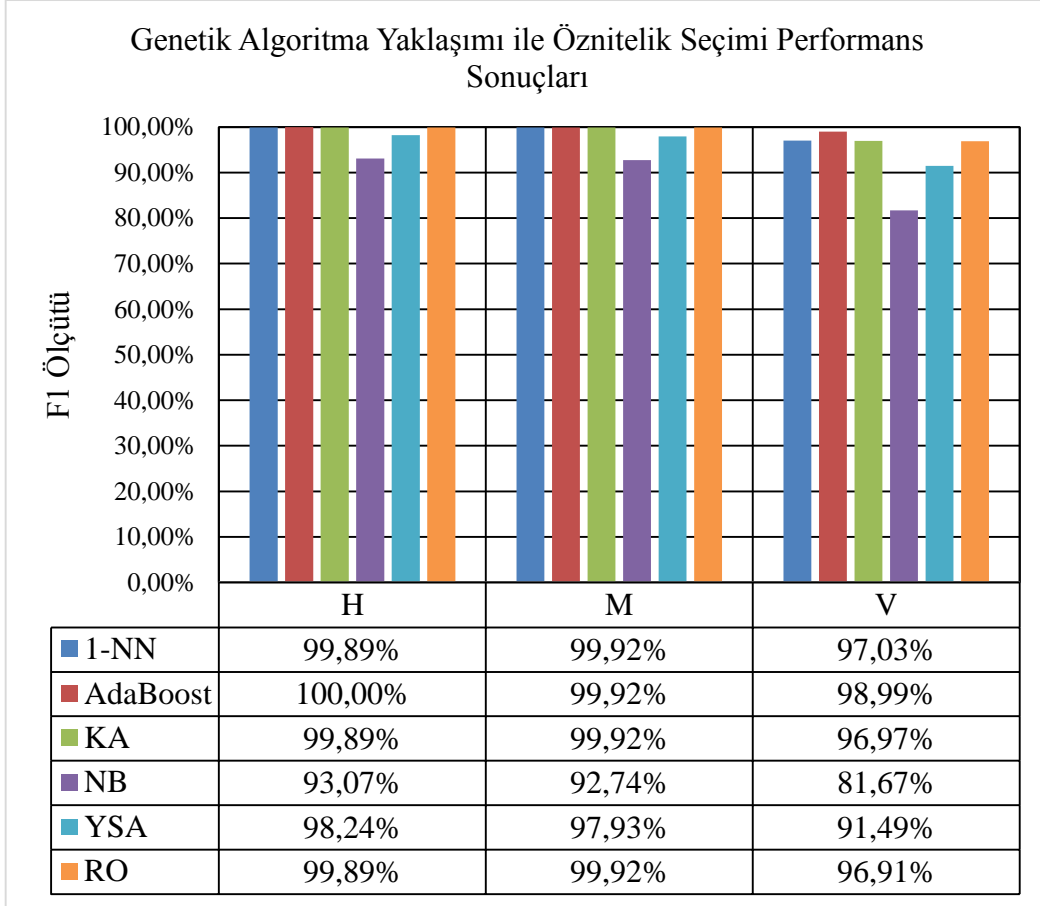
KODU	Öznitelik Adı
BBY2	Sınırlayıcı Çerçeve En (Bounding Box)
MAJAL	Büyük Eksen Boyutu (Major Axis Length)
MINAL	Küçük Eksen Uzunluğu (Minor Axis Length)
ECC	Dış Merkezlilik (Eccentricity)
ORI	Yönelme (Orientation)
CONAREA	Dışbükey Alan (Convex Area)
FILAREA	Dolu Alan (Filled Area)
EUNUM	Euler Sayısı (Euler Number)
EQUIDIA	Eşdeğer Çap (EquivDiameter)
SOLDTY	Sağlamlık (Solidity)
EXTENT	Kapsam (Extent)
PERIM	Çevre (Perimeter)
ROUNDNESS	Yuvarlaklık (Roundness)
CENTDIST	Öznitelik 1 (Centdist)
WHRATIO	Öznitelik 2 (WHRatio)
BBAREARATIO	Öznitelik 3 (BBAreaRatio)
SHAREARATIO	Öznitelik 4 (ShapeAreaRatio)

Tablo 35. Genetik algoritma yaklaşımı ile seçilen özniteliklerin sınıflandırma performansları

Sınıflandırıcı	Sınıf	TP	TN	FP	FN	Hassasiyet	Duyarlılık	F1-Ölçütü	Seçilen Öznitelikler
1-NN	H	869	658	0	2	100,00%	99,77%	99,89%	Area, MINAL, ECC, CONAREA, FILLAREA,
	M	608	920	1	0	99,84%	100,00%	99,92%	EUNUM, EQUIDIA, SOLDTY, ROUNDNESS,
	V	49	1477	2	1	96,08%	98,00%	97,03%	WHRATIO, BBAREARATIO
AdaBoost	H	871	658	0	0	100,00%	100,00%	<b>100,00%</b>	Area, CentroidY, BBX1, BBY1, MINAL, ECC,
	M	608	920	1	0	99,84%	100,00%	<b>99,92%</b>	EQUIDIA, SOLDTY, WHRATIO, BBAREARATIO
	V	49	1479	0	1	100,00%	98,00%	<b>98,99%</b>	
KA	H	870	657	1	1	99,89%	99,89%	99,89%	CX, CY, BBX1, BBX2, BBY2, MAJAL, MINAL,
	M	608	920	1	0	99,84%	100,00%	99,92%	FILLAREA, SOLDTY, EXTENT, WHRATIO,
	V	48	1478	1	2	97,96%	96,00%	96,97%	CENTDIST, BBAREARATIO
NB	H	765	650	8	106	98,97%	87,83%	93,07%	CX, BBX1, BBY1, BBX2, MAJAL, ECC, ORI,
	M	600	835	86	8	87,46%	98,68%	92,74%	FILAREA, EQUIDIA, EXTENT, ROUNDNESS,
	V	49	1458	21	1	70,00%	98,00%	81,67%	BBAREARATIO
YSA	H	863	635	23	8	97,40%	99,08%	98,24%	BBX1, BBY1, BBX2, BBY2, MINAL, ECC, ORI, EQUIDIA,
	M	591	913	8	17	98,66%	97,20%	97,93%	SOLDTY, EXTENT, PERIMETER, ROUNDNESS,
	V	43	1478	1	7	97,73%	86,00%	91,49%	CENTDIST, SHAREARATIO

Tablo 35'in devamı

Sınıflandırıcı	Sınıf	TP	TN	FP	FN	Hassasiyet	Duyarlılık	F1-Ölçütü	Seçilen Öznitelikler
RO	H	871	656	2	0	99,77%	100,00%	99,89%	Area, CY, BBX2, ORI, SOLDTY, EXTENT,
	M	608	920	1	0	99,84%	100,00%	99,92%	ROUNDNESS, WHRATIO, SHAREARATIO
	V	47	1479	0	3	100,00%	94,00%	96,91%	



Şekil 51. GA yaklaşımı sonucu seçilen özniteliklerin sınıflandırma performansını gösteren grafik

Genetik algoritma yaklaşımı ile 10 adet öznitelik seçimi sonucunda Adaboost sırasıyla Hemorajiler için %100, Mikroanevrizmalar için %99,92 ve Damarlar için %98,99 oranında sınıflandırma başarısı elde edilmiştir. Genetik algoritma yaklaşımı, tüm öznitelikleri kullanarak elde edilen sınıflandırma performansından genel olarak daha iyi performans vermiştir. Ancak genetik algoritma yaklaşımı, NB sınıflandırıcısının başarı oranının düşmesine de neden olmuştur.

Şekil 51’de görüldüğü üzere, Adaboost yaklaşımı KA sınıflandırıcısının daha güçlü bir sınıflandırıcı olması için kullanılmıştır. Bilindiği gibi, Adaboost zayıf sınıflandırıcıları daha güçlü kılmak için uygulanan bir algoritmadır. Beklendiği üzere Adaboost, KA yönteminden daha başarılı sonuçlar vermiştir.


Tablo 36. İleriye Doğru Seçim yaklaşımı ile seçilen özneliklerin sınıflandırma performansları

Sınıflandırıcı	Sınıf	TP	TN	FP	FN	Hassasiyet	Duyarlılık	F1-Ölçütü	Seçilen Öznelikler
1-NN	H	864	654	4	7	99,54%	99,20%	99,37%	EUNUM, SOLDTY, EXTENT, ROUNDNESS
	M	604	913	8	4	98,69%	99,34%	99,02%	
	V	49	1479	0	1	100,00%	98,00%	98,99%	
AdaBoost	H	869	657	1	2	99,89%	99,77%	99,83%	Area, FILAREA, ROUNDNESS
	M	608	920	1	0	99,84%	100,00%	99,92%	
	V	48	1477	2	2	96,00%	96,00%	96,00%	
KA	H	870	657	1	1	99,89%	99,89%	<b>99,89%</b>	FILAREA, SOLDTY, EXTENT, PERIMETER
	M	608	920	1	0	99,84%	100,00%	<b>99,92%</b>	
	V	48	1478	1	2	97,96%	96,00%	<b>96,97%</b>	
NB	H	856	620	38	15	95,75%	98,28%	97,00%	ROUNDNESS
	M	571	910	11	37	98,11%	93,91%	95,97%	
	V	48	1474	5	2	90,57%	96,00%	93,20%	
YSA	H	866	641	17	5	98,07%	99,43%	98,75%	EXTENT, ROUNDNESS
	M	592	916	5	16	99,16%	97,37%	98,26%	
	V	48	1478	1	2	97,96%	96,00%	96,97%	
RO	H	869	657	1	2	99,89%	99,77%	99,83%	AREA, BBX2, CONAREA, ROUNDNESS
	M	608	920	1	0	99,84%	100,00%	99,92%	
	V	48	1477	2	2	96,00%	96,00%	96,00%	

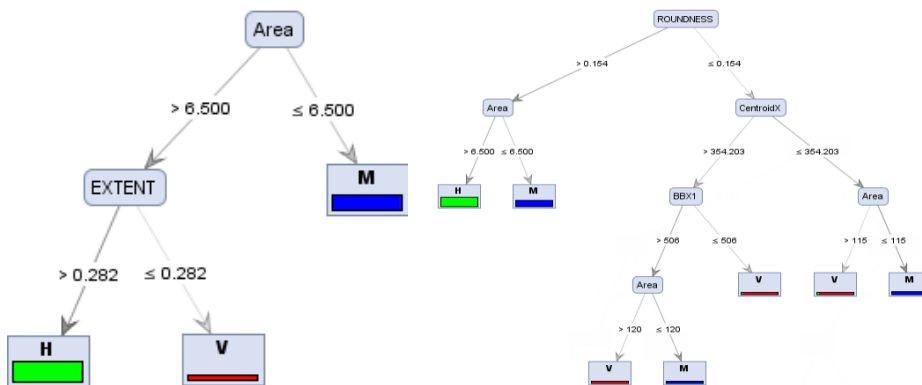
Şekil 52’den de görüldüğü üzere KA sınıflandırıcısı ortalama olarak İDS yaklaşımı ile öznelik seçimi sonrasında 4 öznelikle en başarılı performansı vermiştir. İDS yaklaşımı sonucu seçilen öznelikler Tablo 36’da son sütunda görülmektedir. İDS yaklaşımı GA yaklaşımına göre daha az öznelikle yüksek performanslara ulaşabilmektedir. Özellikle tek öznelik kullanarak NB sınıflandırıcısı %90’nın üzerinde sınıflandırma başarısına ulaşmıştır.

Genel olarak İDS yaklaşımı ile öznelik seçimi sonrası yapılan sınıflandırmada, sınıflandırıcıların başarı performansları bir birine yakındır. Bu da, deneyler esnasında test edilen 6 sınıflandırıcının DR lezyonlarının tespiti için kullanılabileceğini göstermektedir. Ancak otomatik bir DR analiz sistemi geliştirileceğinde en başarılı olan tek bir sınıflandırıcı

seçilmesi gerekecektir. Tüm deneyler sonucunda en az öznelilik ve en yüksek performansla İDS yaklaşımı kullanılarak 4 öznelilikle KA sınıflandırıcısı sırayla, % 99,89 ile Hemoraji, % 99,92 ile Mikroanevrizma ve % 96,97 ile Damarların sınıflandırılması yapmıştır.

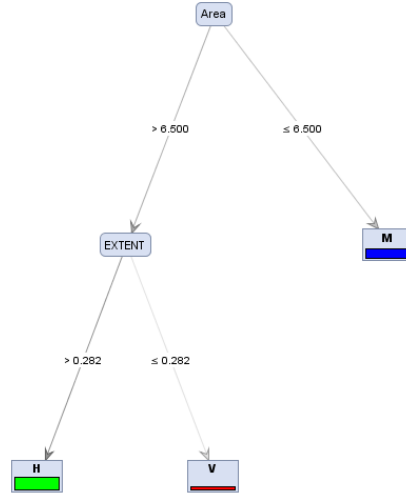


Şekil 52. İDS yaklaşımı sonucu seçilen özneliliklerin sınıflandırma performansını gösteren grafik.




Şekil 53. Adaboost'un oluşturduğu modeller

İDS yaklaşımı ile kullanılan sınıflandırıcıların, bazı sınıflandırma modelleri Şekil 53, Şekil 54 ve Şekil 55'te verilmiştir. KA sınıflandırıcısının 2 öznitelik kullandığı Şekil 54'deki ağaç modeli DR tespiti için kullanılabilir bir modeldir.



Şekil 54. KA'nın oluşturduğu en iyi model




Şekil 55. RO'nun oluşturduğu model

Bu modellerde de görüldüğü gibi, Adaboost, KA ve RO yaklaşımları alan, eşdeğer çap ve kapsam özniteliklerini kullanarak başarılı sınıflandırmalar yapmışlardır. Bu tez çalışmasında, bölütleme yaklaşımıyla nesnelere ayrılan KAG ve PAG'lara, KA'nın Şekil 54'teki modeli kullanılarak sınıflandırma işlemi yapılmıştır.



DRIMDB veritabanında *iyi* sınıfındaki 35 etiketsiz görüntünün arka plan kestirimi yapıldıktan sonra bağlı bileşenlerine ayrılıp, KA sınıflandırıcısının Şekil 54'deki modeli kullanılarak sınıflandırılmıştır.



Şekil 56. Hemorajinin KA ile sınıflandırılması, (a) Orijinal görüntü (b) Elle etiketlenmiş görüntü, (c) KA ile sınıflandırılmış görüntü, (d) KA'nın bulamadığı lezyonlar


Şekil 56'da görüldüğü üzere KA sınıflandırıcısı ile sadece alan ve kapsam öznitelikleri kullanılarak oluşturulan model kullanılarak hemoraji tespiti yapılmıştır. Bu modelin sınıflandırmada başarısız olduğu kısımlar, damarlara yakın olan hemorajileri damar ile birlikte değerlendirmesidir. Bunun nedeni de aday lezyonları çıkartmak için kullanılan yaklaşımın damar ile lezyonu ayırt edememesinden kaynaklanmaktadır. Bu ayrışımın sağlanabilmesi için ayrı bir çalışma ile damar ağı çıkarımı yapılmalı ve damar uzantısında kanama sonucu oluşan şekil bozuklukları tespit edilmelidir. Uygulanan bu sınıflandırma modeli diğer hemoraji lezyonlarının tespitinde oldukça başarılı olmuştur.



(a)



(b)




(c)

Şekil 57. Mikroanevrizmaların KA ile sınıflandırılması, (a) Orijinal görüntü, (b) KA ile sınıflandırılmış lezyonların ikili görüntüsü, (c) KA'nın bulunduğu lezyonlar

Şekil 57'de görüldüğü üzere, KA sınıflandırıcısı ile mikroanevrizmaların tespiti yapılmıştır. Mikroanevrizmalar için elle etiketleme oldukça zor ve zahmetli olduğundan

sınıflandırıcının tespit ettiği lezyonlar uzman oftalmologlar tarafından kontrol edilerek başarı performansına karar verilmiştir. Burada bölütleme yaklaşımı sonucu bazı damarların yanlış pozitif alanlar oluşturduğu görülmüştür. Ancak sınıflandırıcının kaçırmış olduğu yanlış negatif alan bulunmamaktadır. Bu da arka plan kestiriminin ve bölütlemenin yanlış negatif alanlar bakımından başarılı olduğunu göstermektedir.

Koyu lezyonlardaki başarılı sınıflandırma performansına göre, parlak lezyonlarda sınıflandırma başarısı oldukça düşük çıkmıştır. Bunun nedeni olarak, sert eksudalar ile yumuşak eksudaların birbirlerine çok benzemeleri ve ayırt edici etkin öznelikler bulunamamasıdır. Şekilsel olarak birbirlerine benzeyen bu lezyonlar, parlaklık dağılımları olarak az da olsa fark etmektedir. Şekil 58’de görüldüğü gibi, yumuşak eksudalar biraz daha beyaza yakın bir değerde görünmektedir. Ancak, çıkartılan parlaklık dağılımları özneliklerinden, ortalama, standart sapma ve medyan değerlerinin çok başarılı ayırt edici özelliklerinin olmadığı görülmüştür.




Şekil 58. Parlak lezyonlar, (a) Yumuşak eksuda, (b) Sert eksuda

Parlak lezyonların sınıflandırılması için, 1-EYK, AdaBoost, DVM, KA, NB, RO, YSA sınıflandırıcıları kullanılmış ve en iyi performansı Naive Bayes sınıflandırıcısı vermiştir.

Şekil 59’da verilen performans değerlerinden yumuşak eksudaların düşük olmasının nedenlerinden biri de örnek sayısının az olmasından kaynaklanmaktadır. DRIMDB veritabanında yeterli yumuşak eksudaya sahip görüntü mevcut değildir. Bu sınıflandırmada, 527 adet sert eksuda lezyonu ile 9 adet yumuşak eksuda lezyonu sınıflandırıcılar tarafından eğitilip test edilmiştir.

Tablo 37. Tüm öznitelikler kullanıldığında parlak lezyonların sınıflandırma performansları (SE: Sert Eksuda, YE: Yumuşak Eksuda)


Sınıflandırıcı	Sınıf	TP	TN	FP	FN	Hassasiyet	Duyarlılık	F1
DVM	SE	526	0	9	1	98,32%	99,81%	99,06%
	YE	0	526	1	9	0,00%	0,00%	0,00%
AdaBoost	SE	524	2	7	3	98,68%	99,43%	99,05%
	YE	2	524	3	7	40,00%	22,22%	28,57%
YSA	SE	523	1	8	4	98,49%	99,24%	98,87%
	YE	1	523	4	8	20,00%	11,11%	14,29%
KA	SE	522	1	8	5	98,49%	99,05%	98,77%
	YE	1	522	5	8	16,67%	11,11%	13,33%
RO	SE	525	0	9	2	98,31%	99,62%	98,96%
	YE	0	525	2	9	0,00%	0,00%	0,00%
NB	SE	511	6	3	16	99,42%	96,96%	<b>98,17%</b>
	YE	6	511	16	3	27,27%	66,67%	<b>38,71%</b>
INN	SE	521	1	8	6	98,49%	98,86%	98,67%
	YE	1	521	6	8	14,29%	11,11%	12,50%



Şekil 59. Parlak lezyonların sınıflandırma performansları

Tablo 38. İDS yaklaşımı ile seçilen özneliklerle parlak lezyonların sınıflandırma performansları (SE: Sert Eksuda, YE: Yumuşak Eksuda)


Sınıflandırıcı	Sınıf	TP	TN	FP	FN	Hassasiyet	Duyarlılık	F1	Seçilen Öznelikler
AdaBoost	SE	524	5	4	3	99,24%	99,43%	<b>99,34%</b>	BBX1, CONAREA, CENTDIST
	YE	5	524	3	4	62,50%	55,56%	<b>58,82%</b>	
YSA	SE	523	0	9	4	98,31%	99,24%	98,77%	ORI, CONAREA, SHAREARATIO, MEANINT, MEDINT
	YE	0	523	4	9	0,00%	0,00%	0,00%	
KA	SE	523	1	8	4	98,49%	99,24%	98,87%	BBX2, EXTENT
	YE	1	523	4	8	20,00%	11,11%	14,29%	
RO	SE	525	0	9	2	98,31%	99,62%	98,96%	FILLAREA, EUNUM
	YE	0	525	2	9	0,00%	0,00%	0,00%	
NB	SE	522	3	6	5	98,86%	99,05%	98,96%	AREA, BBY1
	YE	3	522	5	6	37,50%	33,33%	35,29%	
1NN	SE	523	1	8	4	98,49%	99,24%	98,87%	AREA
	YE	1	523	4	8	20,00%	11,11%	14,29%	



Şekil 60. İDS yaklaşımı sonucu seçilen özneliklerin parlak lezyonları sınıflandırma performansını gösteren grafik

Tablo 39. GA yaklaşımı ile seçilen özneliklerle parlak lezyonların sınıflandırma performansları (SE: Sert Eksuda, YE: Yumuşak Eksuda)


Sınıflandırıcı	Sınıf	TP	TN	FP	FN	Hassasiyet	Duyarlılık	F1	Seçilen Öznelikler
AdaBoost	SE	516	1	8	1	98,47%	99,81%	99,14%	CENTROIDX, CENTROIDY, BBY1, BBX2, ECC, CONAREA, FILAREA, EUNUM, SOLDTY, BBAREARATIO, SHAREARATIO, MEANINT, MEDINT
	YE	1	526	1	8	50,00%	11,11%	18,18%	BBY1, BBX2, BBY2, MAJAL, ECC, ORI, EUNUM, EQU디아, PERIM, BBAREARATIO, MEANINT, SDEVINT
YSA	SE	523	4	5	4	99,05%	99,24%	<b>99,15%</b>	BBY1, BBX2, BBY2, MAJAL, ECC, ORI, EUNUM, EQU디아, PERIM, BBAREARATIO, MEANINT, SDEVINT
	YE	4	523	4	5	50,00%	44,44%	<b>47,06%</b>	AREA, BBX1, BBX2, BBY2, MINAL, ECC, ORI, SOLDTY, EXTENT, PERIM, BBAREARATIO, SHAREARATIO, SDEVINT, MEDINT
KA	SE	525	2	7	2	98,68%	99,62%	99,15%	AREA, CENTROIDX, CENTROIDY, BBX1, BBY1, BBX2, BBY2, ORI, CONAREA, EXTENT, ROUNDNESS
	YE	2	525	2	7	50,00%	22,22%	30,77%	CENTROIDY, BBX1, EUNUM, SOLDTY, EXTENT, PERIM, ROUNDNESS, WHRATIO, CENTDIST, MEANINT
RO	SE	526	1	8	1	98,50%	99,81%	99,15%	CENTROIDX, BBX1, BBX2, MAJAL, ECC, ORI, EQU디아, PERIM, CENTDIST, BBAREARATIO, SHARERATIO, MEANINT
	YE	1	526	1	8	50,00%	11,11%	18,18%	
NB	SE	515	6	3	12	99,42%	97,72%	98,56%	
	YE	6	515	12	3	33,33%	66,67%	44,44%	
1NN	SE	526	2	7	1	98,69%	99,81%	99,25%	
	YE	2	526	1	7	66,67%	22,22%	33,33%	



Şekil 61. GA yaklaşımı sonucu seçilen özneliklerin parlak lezyonları sınıflandırma performansını gösteren grafik




Şekil 59, Şekil 60, Şekil 61'deki parlak lezyonların sınıflandırma performanslarına bakıldığında, sert eksudaların sınıflandırma başarı ortalaması sırasıyla, tüm öznelilikler kullanıldığında % 98,79, GA yaklaşımı ile % 99,07, İDS yaklaşımı ile % 98,96 olmuştur. Yumuşak eksudaların sınıflandırma başarı ortalaması ise sırasıyla, tüm öznelilikler kullanıldığında % 15,34, GA yaklaşımı ile % 20,45, İDS yaklaşımı ile % 31,99 olmuştur.



Şekil 62. Sert eksudanın bölütlenmesi, (a) Orijinal görüntü (b) Elle etiketlenmiş görüntü, (c) Arka plan yaklaşımı ile bölütlenmiş görüntü, (d) Yanlış pozitif (yeşil ile çevrilen) ve yanlış negatif (siyah ile çevrilen ) alanlar

Sert eksuda ve yumuşak eksudaların sınıflandırmadaki performans düşüklüğü nedeniyle parlak lezyonların tespiti, Şekil 62'de görüldüğü gibi arka plan kestirimi yaklaşımıyla elde edilen bölütlenmiş görüntü üzerinde gösterilmektedir. Burada alınan sonuçlar aday parlak lezyonların tespitini göstermektedir. Ancak burada yanlış pozitif bölgeler de ortaya çıkmıştır. Bu durumu da, aday lezyonların tespitinde kullanılan eşikleme değerinin etkin ve lokal bir yöntemle seçilerek aşılabileceği düşünülmektedir. Bunun yanı sıra, medyan filtresinin çekirdek büyüklüğü nedeniyle görüntü kenarlarında gürültüler

oluşabilmektedir. Bu nedenle, Şekil 62(d)'de görüldüğü üzere, görüntünün kenar kısımlarındaki parlak lezyonlar yanlış negatif alanlara düşebilmektedir.



Şekil 63. Yumuşak eksudanın bölütlenmesi (açık mavi ile çevrilen), (a) Orijinal görüntü, (b) Elle etiketlenmiş görüntü (yeşil ile etiketlenen), (c) Arka plan yaklaşımı ile bölütlenmiş görüntü, (d) Yanlış pozitif (yeşil ile çevrilen) ve yanlış negatif (siyah ile çevrilen) alanlar

Şekil 63'de görüldüğü üzere, sert ve yumuşak lezyonların bulunduğu retina görüntüsüne bölütleme işlemi yapılarak aday parlak lezyonlar tespit edilmiştir. Şekil 63(b)'de yeşil ile etiketlenen yumuşak eksudaların Şekil 63(d)'de tespit edilmiş hali açık mavi çerçeve içerisinde gösterilmiştir. Burada yine yanlış pozitif ve yanlış negatif alanlar da mevcuttur.



Tablo 40. Literatürdeki çalışmalar ile önerilen yöntemin karşılaştırma tablosu

Lezyonlar	Çalışmayı Yapan	Literatürdeki Yaklaşım		Önerilen Yaklaşım (İDS ile KA ve GA ile NB)	
		Özgüllük	Duyarlılık	Özgüllük	Duyarlılık
<b>Hemoraji</b>	Hatanaka ve diğerleri [158]	% 80	% 80	% 99,89	% 99,89
<b>Mikroanevrizma</b>	Fleming ve diğerleri [27]	% 85	% 83	% 100	% 99,94
<b>Sert Eksuda</b>	Sanchez ve diğerleri [159]	% 100	% 90	% 99,42	% 97,72
<b>Yumuşak eksuda</b>	Zhang ve Chutatape [31,160]	% 88	% 84	% 33,34	% 66,67

#### 4. SONUÇLAR

Günümüzde, medikal görüntülerin otomatik analizi üzerine oldukça yoğun çalışmalar yapılmaktadır. Bu tez çalışmasında, retina görüntülerinin kalite değerlendirmesi, uygun görüntü tespiti ve gözün retina tabakasında diyabet sonucu oluşan Diyabetik Retinopati hastalığının otomatik tespiti üzerine çalışılmıştır. Buradaki amaç, kaliteli retina görüntülerinde DR sonucu oluşan lezyonların bilgisayar sistemleri tarafından otomatik olarak tespit edilmesini sağlamaktır. Retina için geliştirilen bir otomatik analiz sistemine gelen görüntü, kalite ve uygunluk bakımından yetersiz olsa bile, sistem gereksiz yere analiz işlemi yapacak ve bu istenmeyen görüntüyü veritabanına ekleyecektir. Bu olumsuz durumu en başta engelleyebilmek için, bu çalışmada literatüre katkı sağlayacak yöntemler de kullanarak, retina görüntülerinin kalite değerlendirilmesi yapılmış ve kaliteli görüntüler içerisinde, teşhis ve tanı için yeterli bilgiye sahip uygun görüntüler de tespit edilmiştir.

Bu tez çalışması, retina görüntülerinin kalite değerlendirmesi, uygun görüntülerin tespiti ve DR lezyonlarının sınıflandırılması şeklinde üç aşamadan oluşmaktadır. Görüntülerin kalite değerlendirmesi olan ilk aşama da öncelikle retina görüntülerinde en iyi karşıtlık değerlerini veren yeşil kanal görüntü seçilmiştir. Ardından retina görüntüsü üzerinde parlaklık düzeltimi, Kontrast Sınırlı Adaptif Histogram Eşitleme (KSAHE) ve normalizasyon teknikleri kullanarak iyileştirme işlemi yapılmıştır. Buraya kadar yapılan iyileştirme işlemleri retina üzerindeki damar ağının bölütlenmesi içindir. Damar ağının net olarak görülebilmesi, görüntüyü kalite açısından değerlendirmedeki en önemli etkenlerden biridir. Literatürdeki retina görüntü kalitesi üzerine yapılan çalışmaların çoğunda, damar ağının yapısı ele alınarak kalite sınıfları oluşturulmuştur. Kalite değerlendirmesi için kullanılacak olan damar ağı, işlem yükü az olan ve hızlı çalışan morfolojik yöntemler yardımıyla tespit edilmiştir. Retinadaki görüntü kalitesini retinanın yapısından dolayı global olarak değerlendirmek yanlış olacaktır. Bu nedenle, damar ağının lokal etkilerini ölçebilmek için retina görüntüsü ISNT denilen dört bölgeye ayrılmıştır. Böylece, her bölgedeki damar ağı öznelikleri ayrı ayrı ele alınarak lokal değerler de kalite değerlendirmesine katılmıştır. Global olarak, tüm görüntüden de dokusal, konumsal ve bölgesel öznelikleri çıkartılmış ve kalite bu öznelik yardımıyla *iyi*, *kötü* ve *aykırı* olarak üç sınıfa ayrılmıştır.

Kalite deęerlendirmesi, 125 iyi, 69 kötü ve 22 aykırı sınıfındaki görüntülerde çıkartılan 177 öznitelik kullanılarak yapılmıştır. Sınıflandırma işleminde kullanılan verilerden her sınıfın yarısı eğitim yarısı da test verisi olarak kullanılmıştır. Sınıflandırıcıların eğitimi sırasında 10-kere çapraz doğrulama yöntemi uygulanarak eğitim seti kendi içerisinde test edilerek doğrulaması yapılmıştır. Bu yöntemin uygulanmasıyla sınıflandırıcılar ezberleme gibi olumsuzluklardan etkilenmemesi sağlanmıştır. Sınıflandırma işleminin performansı üç şekilde ölçülmüştür. Öncelikle tüm öznitelikler sınıflandırıcılara eğitirilerek performans deęerleri alınmıştır. Dięer ölçme deneyleri ise Genetik Algoritma ve İleriye Doğru Seçim yaklaşımları kullanılarak öznitelik seçimi yapılmış ve sınıflandırıcıların performans deęerleri karşılaştırılmıştır. Çalışmada, literatürde en çok bilinen sınıflandırıcılardan k-En Yakın Komşu, Doğrusal Ayrıştırma Analizi, Naive Bayes, Yapay Sinir Ağları ve Destek Vektör Makinesi kullanılmış ve kalite deęerlendirmesi için en iyi performansı İleriye Doğru Seçim algoritması kullanarak 8 öznitelik ve % 93,41 ortalama başarı oranı Doğrusal Ayrıştırma Analizi yaklaşımı vermiştir.

Çalışmanın literatüre kattığı bir başka yenilik ise kaliteli görüntülerin ne kadarının uygun olduğunun tespitidir. Retinadaki hastalıkların derecelendirilmeleri ve konumlarının belirtilebilmesi için referans bölgeler olmalıdır. Örneğin, oftalmologlar rapor hazırlarken bir hemoraji lezyonunun konumsal yerinin belirtilmesi için, retinadaki anatomik yapıları (optik disk, fovea, makula veya vasküler ark) kullanarak lezyonun yerini tanımlamaktadır. Ayrıca bu lezyonların bu anatomik yapılar üzerinde bulunması önemli görme kayıplarına yol açabilir. O halde, kontrol ve DR lezyonlarının konumlandırılması için bu anatomik yapıların retina görüntüsü üzerinde bulunması gerekmektedir. Literatür incelendiğinde, bu anatomik yapıların tespiti için birçok yaklaşım önerilmiştir. Bu tez çalışmasında önerilen optik diskin tespiti için geliştirilen yöntemler yeni bir yaklaşım olarak deęerlendirilebilir. Dokusal özellikler kullanılmadan, damarların konumsal özelliklerinden yararlanıp, optik diskin bulunduğu bölgenin lokalizasyonu, optik diskin tespit işleminin başarısı artırmıştır. Fovea ve optik diskin sabit konumlarından dolayı, optik diskin tespitinden sonra foveanın tespiti de oldukça kolay olmuştur. Ancak burada, bazı DR lezyonlarının oluşturmuş olduğu yanlış pozitif alanlar nedeniyle yanlış tespitlerle de karşılaşmıştır. Bu kısımdaki bir başka yenilikte, uygunluk deęeri adı verilen bir ölçü birimi tanımlanmıştır. Uygunluk deęeri, optik diskin retina üzerindeki konumuna göre hesaplanmıştır. Bu yaklaşımın performans ölçümü hem yeni önerilen DRIMDB veritabanında hem de açık erişimli DRIVE ve DIARETDB1

veritabanlarında yapılmıştır. Sırasıyla, % 97.60, % 100, % 96,63 oranında tespit başarısı elde edilmiştir.

Retina görüntülerinin kalite değerlendirmesi ve uygun görüntünün tespiti, özellikle otomatik görüntü analizi sistemlerinin ilk aşaması olarak kullanılabilir. Ayrıca görüntülerin elde edildiği fundus kamera sisteminin bir parçası olarak görüntü çekimi sırasında, bir karar sistemi şeklinde kullanılabilir. Önerilen bu yaklaşım sayesinde, otomatik görüntü analiz sistemlerindeki doğruluk oranı artacak ve gereksiz görüntüler veritabanlarında saklanmayıp, zaman kaybı önlenecektir.

Arka plan kestirimi için medyan filtresi kullanılmıştır. 64x64'lük medyan filtresi uygulanarak elde edilen arka plan kestirim görüntüsü, yeşil kanal orijinal görüntüden çıkartıldığında, koyu aday lezyonların bulunduğunu görüntü elde edilmiştir. Arka plan kestirimi görüntüsünden yeşil kanal orijinal görüntü çıkartıldığında ise, parlak aday lezyonların olduğu görüntü elde edilmiştir. Her iki görüntü, gama düzeltmesi ile iyileştirilmiş ve basit bir adaptif eşikleme yöntemiyle gürültüler yok edilmiştir. Bu aşamadan sonra her iki görüntü üzerindeki nesnelere bağlı bileşenler yöntemiyle ayrılıp numaralandırılmıştır.

DR lezyonlarının tespiti ile ilgili çalışmalar genellikle bölütleme veya öznitelik kullanılarak sınıflandırma şeklindedir. Bu tez çalışmasında karmaşık bölütleme algoritmaları kullanmadan, arka plan kestirim yaklaşımı ile aday lezyonlar çıkartılmış ve sınıflandırıcılar yardımıyla lezyonlar tespit edilmiştir. Görüntü tanıma problemlerinde sınıflandırıcıların doğru eğitilmesi en önemli aşamadır. Bu amaçla DRIMDB veritabanından seçilen 34 görüntü, oftalmologlar gözetiminde elle etiketlenmiş ve bu görüntülerden çıkartılan 22 şekilsel öznitelik eğitim için kullanılmıştır. Literatürde bilinen sınıflandırıcılardan k-EYK, YSA, NB, KA, RO ve Adaboost yaklaşımları DR lezyonlarının sınıflandırılması için seçilmişlerdir. Eğitim aşamasında, kalite değerlendirmesinde uygulanan deneyler bu çalışmada da yapılmıştır. Sınıflandırma için öncelikle tüm öznitelikler kullanılmış, daha sonra öznitelik seçimi yaklaşımlarından genetik algoritma ve ileriye doğru seçim yöntemi kullanarak öznitelik sayısı azaltılmıştır. Burada en iyi performansı, İleriye Doğru Seçim yaklaşımıyla 4 öznitelik seçilerek Karar Ağaçlarının elde ettiği sınıflandırma yöntemi göstermiştir.

## 5. ÖNERİLER

Medikal görüntü analizi ile ilgili birçok çalışma, otomatik tespit ve ölçme üzerine yapılmıştır. Bu çalışmaların çoğunda analiz edilecek görüntülerin kalite değerlendirmesi ve uygun görüntü tespiti gibi bir ön aşama bulunmamaktadır. Bu nedenle, gerek cihazlardan gerekse uzmanlardan kaynaklanan bozuk görüntüler, otomatik analiz sistemlerinin doğru sonuçlar üretmesini engelleyecek ve gereksiz verilerin saklanması neden olacaktır. Bu tez çalışmasında, retina görüntülerinin kalite değerlendirmesi ve analizi için uygun görüntülerin tespiti yapılmıştır. Bu tür kalite değerlendirme çalışmaları diğer medikal görüntüler üzerinde de yapılabilir. Ayrıca bu tür çalışmalar direk olarak görüntüleme cihazlarının kalibrasyonu için de kullanılabilir. Bu sayede, bu tip problemler görüntüleme sisteminin en başında çözülebilir.

Bu tez çalışmasında ele alınan kalite değerlendirmesi yaklaşımı, hem yerel hem de global kalitenin birlikte ele alınması ile gerçekleştirilmiştir. Retina görüntüsü gibi parlaklık dağılımı homojen olmayan medikal görüntülerin kalite değerlendirmesinde yerel değerlerinde göz önünde bulundurulması gereklidir.

Literatürdeki optik disk tespiti çalışmalarının birçoğu, optik diskin parlaklık değerlerinde yararlanarak yapılmıştır. Ancak, DR gibi hastalıklar sonucu oluşan Eksuda lezyonları şekil ve parlaklık bakımından optik diskle bire bir benzerlikte olabilmektedir. Bu nedenle bu çalışmalarda kullanılan yaklaşımlar başarılı olamamaktadır. Bu tez çalışmasında, ana damarların optik diske olan dikey konumlarından faydalanarak optik diskin bulunduğu bölge lokalize edilmiştir. Bu bölge içerisinde optik diskin dairesel yapısından faydalanarak sınırlarının tespiti gerçekleştirilmiştir. Dolayısı ile optik disk tespitindeki başarının artırılabilmesi için sadece parlaklık bilgisi yetmemekte ve konumsal bilgiden de yararlanmak gerekmektedir.

DR hastalığı sonucu oluşan hemoraji lezyonu, retina damar ağının başarılı bir biçimde tespitini engellemektedir. Literatürdeki birçok damar bölütleme yöntemleri sağlıklı retina görüntüleri üzerinden yapılmıştır. Bu çalışmada, koyu DR lezyonlarının tespiti aşamasında damar ağının eliminasyonu gerekmektedir. Kalite değerlendirmesi aşamasında

kullanılan damar ağı, basit morfolojik yöntemler ile çıkartıldığından, koyu lezyonların damarlara birleşik olarak tespit edildiği görülmüştür. Eğer tespit edilen bu damar ağı, arka plan kestirimi sonucunda elde edilen koyu aday görüntüden çıkartılırsa, damarlarla beraber bazı koyu lezyonlarda çıkartılacaktır. Bu nedenle koyu aday görüntülerden damar ağı çıkartılmamış ve damarlardan öznitelikler çıkartılarak damar tespiti sınıflandırıcılara bırakılmıştır. Ancak burada damar izleme algoritması gibi bir damar bölütleme yöntemi kullanılıp damar ağı başarılı bir biçimde çıkartılırsa, geriye kalan koyu lezyonların sınıflandırma başarıları oldukça yüksek olacaktır.

Parlak DR lezyonlarından sert ve yumuşak eksudalar dokusal ve şekilsel olarak birbirlerine oldukça benzemektedirler. Bu nedenle, bu lezyonlardan çıkartılan öznitelikler ayırt edici özelliği zayıf olmaktadır. Bu çalışmada, koyu lezyonlardan farklı olarak, parlak lezyonlardan parlaklık dağılımı ile ilgili istatistiksel öznitelikler çıkartılmıştır. Ancak çıkartılan bu öznitelikler yumuşak eksudaları ayırt etmede yetersiz kalmıştır. DRIMDB veritabanında yumuşak eksudalarla ilgili örnekler oldukça az olduğundan sınıflandırıcıların eğitimi de zayıf olmuştur. Eğer yeteri kadar yumuşak eksuda örnekleri çıkartılırsa sınıflandırma başarısının yükseleceği öngörülmektedir.

Bu tez çalışmasında tespit edilen fovea ve makula bölgeleri uygun görüntülerin tespiti aşamasında kullanılmaktadır. Bunun yanı sıra, retinanın makula bölgesinde diyabet sonucu oluşan sert eksudaların yol açtığı makulapati hastalığı da tespit edilebilir. Makulapati hastalığının tespiti ile ilgili çalışmaların yapılması amaçlanmaktadır.

Bu tez çalışması ve daha önceki retina analizi çalışmalarımızın tümü göz önüne alındığında, baştan sona bir retina analiz sistemi yazılımı geliştirmek için yeterli akademik alt yapı çalışması yapılmıştır. Bu tür yazılımlar genelde görüntüleme cihazları ile birlikte yüksek fiyatlarla ithal edilmektedir. Ülkemize katma değer sağlanabilmesi adına bu çalışmalar projelendirilip, bir sistem haline getirilmesi planlanmaktadır.

## 6. KAYNAKÇA

1. Giger, M. L., Karssemeijer, N. ve Armato, S. G., Guest editorial computer-aided diagnosis in medical imaging IEEE Trans. Med. Imaging, 20, 12 (2001) 1205–1208.
2. Isabel Clara Gutiérrez, S., Retinal Image Analysis By Mixture Model Based Clustering And Discriminant Analysis For Automatic Detection Of Hard Exudates And Haemorrhages. A Tool For Diabetic Retinopathy Screening, Doktora Tezi, Universidad de Valladolid, 2008.
3. Faust, O., Acharya U, R., Ng, E. Y. K., Ng, K.-H. ve Suri, J. S., Algorithms for the automated detection of diabetic retinopathy using digital fundus images: a review. J. Med. Syst., 36, 1 (2012) 145–157.
4. Fraz, M. M., Remagnino, P., Hoppe, A., Uyyanonvara, B., Rudnicka, A. R., Owen, C. G. ve Barman, S. A., Blood vessel segmentation methodologies in retinal images-a survey. Comput. Methods Programs Biomed., 108, 1 (2012) 407–33.
5. Sánchez, C. I., Hornero, R., López, M. I., Aboy, M., Poza, J. ve Abásolo, D., A novel automatic image processing algorithm for detection of hard exudates based on retinal image analysis. Med. Eng. Phys., 30, 3 (2008) 350–357.
6. Oruçoğlu, F., Gözün Anatomik Yapısı <http://www.drfaikorucoglu.com/2012/05/gozlerimiz.html> 21 Mart 2013.
7. MacHenry, R., Goetz, P. W. ve Hoiberg, D. H., Sensory Reception: Human Vision: Structure and function of the Human Eye, in Encyclopaedia Britannica, 15th ed., Michigan: Encyclopaedia Britannica, 1987 1–935.
8. İstanbul Retina Enstitüsü, Retina ve Gözün Arkası <http://www.istanbulretina.com/tr/index.php?nav=3&id=1#> 3 Nisan 2013.
9. Florence Nightingale Hastaneleri, Diyabetik Retinopati Nedir? <http://www.florence.com.tr/saglik-rehberi/diyabetik-repinotapi.html> 15 Mayıs 2014.
10. Kauppi, T., Eye Fundus Image Analysis For Automatic Detection Of Diabetic Retinopathy, Doktora Tezi, Lappeenranta University of Technology, 2010.
11. Ayan, B., Diyabetik Retinopati <http://www.hastane.com.tr/diyabetik-retinopati-Nedir.html> 25 Eylül 2012.
12. Vafidis, G. C., Features of diabetic eye disease, in Diabetic Eye Disease, null, null, A. R. Rudnicka ve J. Birch, Eds. Oxford: Elsevier, 2000 52–67.

13. Varcan, P., Diabetik Retinopatili Hastalarda Otonomik Nöropatinin Pupilla Bulguları Açısından Değerlendirilmesi, Uzmanlık Tezi, Dr. Lütfi Kırdar Kartal Eğitim ve Araştırma Hastanesi, 2004.
14. Benson, W. E., Blodi, B. A., Boldt, H. C., Murray, T. G., Regillo, C. D., Scott, I. U. ve Christmann, L. M., Diabetic Retinopathy, 2012.
15. Harney, F., Diabetic retinopathy Medicine (Baltimore), 34, 3 (2006) 95–98.
16. Laser Eye Center, Diabetic Retinopathy <http://www.lasereyecentre.co.ke/diabetic-retinopathy> 21 Nisan 2013.
17. Yanyalı, A., Diyabete Bağlı Göz Hastalığının Tedavisi <http://www.atesyanyali.com/tr/blog.asp?AID=14&CID=2&ID=3&do=show> 7 Nisan 2013.
18. Fulya Retina, Diyabet [www.fulyaretina.com/diabet.asp](http://www.fulyaretina.com/diabet.asp) 13 Nisan 2013.
19. Patton, N., Aslam, T. M., MacGillivray, T., Deary, I. J., Dhillon, B., Eikelboom, R. H., Yogesan, K. ve Constable, I. J., Retinal image analysis: concepts, applications and potential. Prog. Retin. Eye Res., 25, 1 (2006) 99–127.
20. Winder, R. J., Morrow, P. J., McRitchie, I. N., Bailie, J. R. ve Hart, P. M., Algorithms for digital image processing in diabetic retinopathy. Comput. Med. Imaging Graph., 33, 8 (2009) 608–622.
21. Baudoin, C. E., Lay, B. J. ve Klein, J. C., Automatic detection of microaneurysms in diabetic fluorescein angiography. Rev. Epidemiol. Sante Publique, 32, 3–4 (1984) 254–61.
22. Baudoin, C., Maneschi, F., Quentel, G., Soubrane, G., Hayes, T., Jones, G., Coscas, G. ve Kohner, E. M., Quantitative evaluation of fluorescein angiograms: microaneurysm counts. Diabetes, 32, 2 (1983) 8–13.
23. Spencer, T., Olson, J. a, McHardy, K. C., Sharp, P. F. ve Forrester, J. V, An image-processing strategy for the segmentation and quantification of microaneurysms in fluorescein angiograms of the ocular fundus. Comput. Biomed. Res., 29, 4 (1996) 284–302.
24. Spencer, T., Phillips, R. P., Sharp, P. F. ve Forrester, J. V., Automated detection and quantification of microaneurysms in fluorescein angiograms Graefe's Arch. Clin. Exp. Ophthalmol., 230, 1 (1992) 36–41.
25. Walter, T., Klein, J.-C., Massin, P. ve Erginay, A., 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, 21, 10 (2002) 1236–43.
26. Streeter, L. ve Cree, M., Microaneurysm detection in colour fundus images, Proceeding of Image and Vision Computing, 2003, 280–285.



27. Fleming, A. D., Philip, S., Goatman, K. a, Olson, J. a ve Sharp, P. F., Automated Microaneurysm Detection Using Local Contrast Normalization and Local Vessel Detection. IEEE Trans. Med. Imaging, 25, 9 (2006) 1223–1232.
28. Ege, B. M., Hejlesen, O. K., Larsen, O. V, Møller, K., Jennings, B., Kerr, D. ve Cavan, D. a, Screening for diabetic retinopathy using computer based image analysis and statistical classification. Comput. Methods Programs Biomed., 62, 3 (2000) 165–75.
29. Sinthanayothin, C., Boyce, J. F., Williamson, T. H., Cook, H. L., Mensah, E., Lal, S. ve Usher, D., Automated detection of diabetic retinopathy on digital fundus images. Diabet. Med., 19, 2 (2002) 105–112.
30. Usher, D., Dumskyj, M., Himaga, M., Williamson, T. H., Nussey, S. ve Boyce, J., Automated detection of diabetic retinopathy in digital retinal images: a tool for diabetic retinopathy screening Diabet. Med., 21, 1 (2004) 84–90.
31. Zhang, X. Z. X. ve Chutatape, O., Top-down and bottom-up strategies in lesion detection of background diabetic retinopathy, 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition CVPR05, 2005, Ieee II: 422–428.
32. Niemeijer, M., van Ginneken, B., Staal, J., Suttorp-Schulten, M. S. a ve Abràmoff, M. D., Automatic detection of red lesions in digital color fundus photographs. IEEE Trans. Med. Imaging, 24, 5 (2005) 584–92.
33. Ward, N. P., Tomlinson, S. ve Taylor, C. J., Image analysis of fundus photographs. The detection and measurement of exudates associated with diabetic retinopathy. Ophthalmology, 96, 1 (1989) 80–86.
34. Phillips, R., Forrester, J. ve Sharp, P., Automated detection and quantification of retinal exudates Graefe's Arch. Clin. Exp. Ophthalmol., 231, 2 (1993) 90–94.
35. Liu, Z., Opas, C. ve Krishnan, S., Automatic image analysis of fundus photograph, Engineering in Medicine and Biology Society, 1997, 524–525.
36. Otsu, N., A threshold selection method from gray-level histograms Syst. Man Cybern., 9, 1 (1979) 62–66.
37. Li, H. ve Chutatape, O., Automated feature extraction in color retinal images by a model based approach. IEEE Trans. Biomed. Eng., 51, 2 (2004) 246–254.
38. Gardner, G. G., Keating, D., Williamson, T. H. ve Elliott, T., Automatic detection of diabetic retinopathy using an artificial neural network: a screening tool. Br. J. Ophthalmol., 80, 11 (1996) 940–944.
39. Goh, K. G., Hsu, W., Lee, M. L. ve Wang, H., ADRIS: an automatic diabetic retinal image screening system, in Medical Data Mining and Knowledge Discovery, K.J., New York: Springer - Verlag, 2000 181–210.

40. Osareh, A., Automated Identification of Diabetic Retinal Exudates and the Optic Disc, Doktora Tezi, University of Bristol, 2004.
41. Niemeijer, M., van Ginneken, B., Russell, S. R., Suttorp-Schulten, M. S. A. ve Abramoff, M. D., Automated detection and differentiation of drusen, exudates, and cotton-wool spots in digital color fundus photographs for diabetic retinopathy diagnosis. Invest. Ophthalmol. Vis. Sci., 48, 5 (2007) 2260–2267.
42. Hoover, A., Structured analysis of the retina (STARE) <http://www.ces.clemson.edu/~ahoover/stare/> 12 Ekim 2012.
43. Hoover, a, Kouznetsova, V. ve Goldbaum, M., Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. IEEE Trans. Med. Imaging, 19, 3 (2000) 203–10.
44. Hoover, A. ve Goldbaum, M., Locating the optic nerve in a retinal image using the fuzzy convergence of the blood vessels. IEEE Trans. Med. Imaging, 22, 8 (2003) 951–8.
45. Ginneken, B. van, Digital retinal images for vessel extraction (DRIVE) <http://www.isi.uu.nl/Research/Databases/DRIVE/> 15 Ekim 2012.
46. Staal, J., Abramoff, M. D., Niemeijer, M., Viergever, M. a ve van Ginneken, B., Ridge-based vessel segmentation in color images of the retina. IEEE Trans. Med. Imaging, 23, 4 (2004) 501–9.
47. Methods to evaluate segmentation and indexing techniques in the field of retinal ophthalmology (MESSIDOR) <http://messidor.crihan.fr> 16 Ekim 2012.
48. Collection of multispectral images of the fundus (CMIF) <http://www.cs.bham.ac.uk/research/projects/fundus-multispectral/> 20 Ekim 2012.
49. Styles, I. B., Calcagni, a, Claridge, E., Orihuela-Espina, F. ve Gibson, J. M., Quantitative analysis of multi-spectral fundus images. Med. Image Anal., 10, 4 (2006) 578–97.
50. Retinopathy online challenge (ROC) <http://roc.healthcare.uiowa.edu/> 22 Ekim 2012.
51. Niemeijer, M., van Ginneken, B., Cree, M. J., Mizutani, A., Quellec, G., Sanchez, C. I., Zhang, B., Hornero, R., Lamard, M., Muramatsu, C., Wu, X., Cazuguel, G., You, J., Mayo, A., Li, Q., Hatanaka, Y., Cochener, B., Roux, C., Karray, F., Garcia, M., Fujita, H. ve Abramoff, M. D., Retinopathy online challenge: automatic detection of microaneurysms in digital color fundus photographs. IEEE Trans. Med. Imaging, 29, 1 (2010) 185–95.
52. REVIEW: Retinal vessel image set for estimation of widths (REVIEW) <http://reviewdb.lincoln.ac.uk/> 22 Ekim 2012.

53. Al-Diri, B., Hunter, A., Steel, D., Habib, M., Hudaib, T. ve Berry, S., REVIEW - a reference data set for retinal vessel profiles. Conf. Proc. IEEE Eng. Med. Biol. Soc., (2008) 2262–2265.
54. Diabetic retinopathy database and evaluation protocol (DIARETDB1) <http://www.it.lut.fi/project/imageret/files/diaretdbv0201/> 5 Kasım 2012.
55. Reza, A. M., Realization of the Contrast Limited Adaptive Histogram Equalization (CLAHE) for Real-Time Image Enhancement J. VLSI Signal Process. Signal, Image, Video Technol., 38, 1 (2004) 35–44.
56. Gonzalez, R. C. ve Woods, R. E., Digital Image Processing (3rd Edition). Prentice Hall, 2007 976.
57. Gonzalez, R. C., Woods, R. E. ve Eddins, S. L., Digital Image Processing Using MATLAB, 2nd ed. Gatesmark Publishing, 2009 827.
58. Karhan, M., Oktay, M. O., Karhan, Z. ve Demir, H., Morfolojik Görüntü İşleme Yöntemleri ile Kayıslarda Yaprak Delen ( Çil ) Hastalığı Sonucu Oluşan Lekelerin Tespiti, 6th International Advanced Technologies Symposium (IATS'11), 2011, 16–18.
59. Zhang, E., Zhang, Y. ve Zhang, T., Automatic retinal image registration based on blood vessels feature point, Proceedings. International Conference on Machine Learning and Cybernetics, 2002, IEEE IV: 2010–2015.
60. Chanwimaluang, T., Fan, G. ve Fransen, S. R., Hybrid Retinal Image Registration IEEE Trans. Inf. Technol. Biomed., 10, 1 (2006) 129–142.
61. Chaudhuri, S., Chatterjee, S., Katz, N., Nelson, M. ve Goldbaum, M., Detection of blood vessels in retinal images using two-dimensional matched filters. IEEE Trans. Med. Imaging, 8, 3 (1989) 263–669.
62. Martinez-Perez, M., Hughes, A., Stanton, A., Thom, S., Bharath, A. ve Parker, K., Scale-space analysis for the characterization of retinal blood vessels, Medical Image Computing and Computer-Assisted Intervention - MICCAI'99, 1999, 90–97.
63. Zana, F. ve Klein, J. C., Segmentation of vessel-like patterns using mathematical morphology and curvature evaluation. IEEE Trans. Image Process., 10, 7 (2001) 1010–1019.
64. Jiang, X. ve Mojon, D., Adaptive local thresholding by verification-based multithreshold probing with application to vessel detection in retinal images IEEE Trans. Pattern Anal. Mach. Intell., 25, 1 (2003) 131–137.
65. Niemeijer, M., Staal, J., Ginneken, B. van, Loog, M. ve Abramoff, M. D., Comparative Study of Retinal Vessel Segmentation Methods on a New Publicly Available Database SPIE Med. Imaging, 5370 (2004) 648–656.

66. Niemeijer, M., Automatic Detection of Diabetic Retinopathy in Digital Fundus Photographs, 2006.
67. Canny, J., A computational approach to edge detection. IEEE Trans. Pattern Anal. Mach. Intell., 8, 6 (1986) 679–98.
68. Rizon, M., Yazid, H., Saad, P., Shakaff, A. Y. M., Saad, A. R., Sugisaka, M., Yaacob, S., Mamat, M. R. ve Karthigayan, M., Object Detection using Circular Hough Transform Am. J. Appl. Sci., 2, 12 (2008) 1606–1609.
69. Liangwongsan, S., Marungsri, B., Oonsivilai, R. ve Oonsivilai, A., Extracted Circle Hough Transform and Circle Defect Detection Algorithm World Acad. Sci. Eng. Technol., 5, 12 (2011) 316–321.
70. Sinthanayothin, C., Boyce, J. F., Cook, H. L. ve Williamson, T. H., Automated localisation of the optic disc, fovea, and retinal blood vessels from digital colour fundus images. Br. J. Ophthalmol., 83, 8 (1999) 902–10.
71. Nayak, J., Bhat, P. S. ve Acharya, U. R., Automatic identification of diabetic maculopathy stages using fundus images. J. Med. Eng. Technol., 33, 2 (2009) 119–29.
72. Günal, S., Örüntü Tanıma Uygulamalarında Altuzay Analiziyle Öznitelik Seçimi ve Sınıflandırma, Doktora Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir, 2008.
73. Jestin, V., Anitha, J. ve Hemanth, D., Textural feature extraction for retinal image analysis Electron. Comput., (2012) 548–551.
74. Chanwimaluang, T., Advanced Retinal Imaging: Feature Extraction, 2-D Registration, And 3-D Reconstruction, 2006.
75. Berber, T., Integration of Content-Based Image Retrieval and Database Management System: A Case Study with Digital Mammography, Doktora Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir, 2013.
76. Sevik, U., Köse, C., Berber, T. ve Erdöl, H., Identification of suitable fundus images using automated quality assessment methods. J. Biomed. Opt., 19, 4 (2014) 46006.
77. Haralick, R. M., Shanmugam, K. ve Dinstein, I. H., Textural features for image classification IEEE Trans. Syst. Man Cybern., 3, 6 (1973) 610–621.
78. Hu, M. K., Visual pattern recognition by moment invariants IEEE Trans. Inf. Theory, 8, 2 (1962) 179–187.
79. Khotanzad, A. ve Hong, Y. H., Rotation invariant image recognition using features selected via a systematic method Pattern Recognit., 23, 10 (1990) 1089–1101.

80. Tahmasbi, A., Saki, F. ve Shokouhi, S. B., Classification of benign and malignant masses based on Zernike moments. Comput. Biol. Med., 41, 8 (2011) 726–35.
81. Hwang, S. K. ve Kim, W. Y., A novel approach to the fast computation of Zernike moments Pattern Recognit., 39, 11 (2006) 2065–2076.
82. Won, C. S. W., Park, D. K. P. ve Park, S.-J. P., Efficient Use of MPEG-7 Edge Histogram Descriptor ETRI J., 24, 1 (2002) 23–30.
83. Sikora, T., The MPEG-7 visual standard for content description-an overview Circuits Syst. Video Technol. IEEE, 11, 6 (2001) 696–702.
84. Mitchell, T. M., Machine Learning. McGraw-Hill Science/Engineering/Math; 1 edition, 1997 432.
85. Alpaydın, E., Introduction to Machine Learning, 2nd Editio. The MIT Press, 2009 584.
86. Jobson, J. D., Applied Multivariate Data Analysis, 2nd ed. New York, NY: Springer New York, 1992 732.
87. Özer, O., EEG İşaretlerinin Diskriminant Analizi ile Sınıflandırılması, Yüksek Lisans Tezi, Kahramanmaraş Sütçü İmam Üniversitesi, Fen Bilimleri Enstitüsü, Kahramanmaraş, 2010.
88. Ünal, M., Ayırma Analizi ve Bir Uygulama, Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara, 2006.
89. Nixon, A. S. ve Aguado, M. S., Feature Extraction and Image Processing, 1st Editio. Woburn: Newness Butterworth-Heinemann, 2002.
90. Theodoridis, S. ve Koutroumbas, K., Pattern Recognition, Forth Edit. Academic Press, 2008 984.
91. Duda, R. O., Hart, P. E. ve Stork, D. G., Pattern Classification, 2nd Editio. Wiley-Interscience, 2000 680.
92. Yakut, E., Veri Madenciliği Tekniklerinden C5.0 Algoritması ve Destek Vektör Makineleri ile Yapay Sinir Ağlarının Sınıflandırma Başarılarının Karşılaştırılması: İmalat Sektöründe Bir Uygulama, Doktora Tezi, Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Erzurum, 2012.
93. Haykin, S., Neural Networks and Learning Machines, 3rd Editio. Prentice Hall, 2008 936.
94. Lippmann, R. P., An introduction to computing with neural nets ACM SIGARCH Comput. Archit. News, 16, 1 (1988) 7–25.

95. Myung, I. J., Tutorial on maximum likelihood estimation J. Math. Psychol., 47, 1 (2003) 90–100.
96. Yumak, B., Elektronik Postaların Ayrıştırılmasında Naive Bayes ve Bulanık Mantık Yöntemlerinin Karşılaştırılması, Yüksek Lisans Tezi, Gazi Üniversitesi, Bilişim Enstitüsü, Ankara, 2011.
97. Vapnik, V. N., The nature of statistical learning theory. New York: Springer-Verlag New York, Inc., 1995.
98. Cortes, C. ve Vapnik, V., Support-vector networks Mach. Learn., 20, 3 (1995) 273–297.
99. Güçlü, T., Pozlandırılmış Görüntüleri Sınıflandırarak Etiketleme, Yüksek Lisans Tezi, Eskişehir Osmangazi Üniversitesi, Fen Bilimleri Enstitüsü, Eskişehir, 2010.
100. Burges, C. J. C., A Tutorial on Support Vector Machines for Pattern Recognition Data Min. Knowl. Discov., 2, 2 (1998) 121–167.
101. Müller, K. R., Mika, S., Rätsch, G., Tsuda, K. ve Schölkopf, B., An introduction to kernel-based learning algorithms. IEEE Trans. Neural Networks, 12, 2 (2001) 181–201.
102. Jenhani, I., Amor, N. B. ve Elouedi, Z., Decision trees as possibilistic classifiers Int. J. Approx. Reason., 48, 3 (2008) 784–807.
103. Sökmen, N., Bilişim Alanında Proje Esaslı Çılaşan Firmalarda Ürün Geliştirme Süreçlerindeki Bozucu Etmenlerin Modellenmesi ve Etkilerinin Belirlenmesi, Doktora Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2011.
104. Kass, G. V., An Exploratory Technique for Investigating Large Quantities of Categorical Data Appl. Stat., 29, 2 (1980) 119–127.
105. Diepen, M. ve Franses, P. H., Evaluating chi-squared automatic interaction detection Inf. Syst., 31, 8 (2006) 814–831.
106. Pendharkar, P. C., An exploratory study of object-oriented software component size determinants and the application of regression tree forecasting models Inf. Manag., 42, 1 (2004) 61–73.
107. Quinlan, J. R., Simplifying decision trees Int. J. Man. Mach. Stud., 27, 3 (1987) 221–234.
108. Atasever, Ü. H., Uydu Görüntülerinin Sınıflandırılmasında Hızlandırma (Boosting), Destek Vektör Makineleri, Rastgele Orman (Random Forest) ve Regresyon Ağaçları Yöntemlerinin Kullanılması, Yüksek Lisans Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Kayseri, 2011.

109. Pal, M., Random forest classifier for remote sensing classification Int. J. Remote Sens., 26, 1 (2005) 217–222.
110. Freund, Y. ve Schapire, R. E., A Decision-Theoretic Generalization of On-Line Learning and an Application to Boosting J. Comput. Syst. Sci., 55, 1 (1997) 119–139.
111. Schapire, R. E., Avenue, P. ve Room, A., The Boosting Approach to Machine Learning: An Overview, New Jersey, 2002.
112. Güneş, T., Görüntü Dizelerinden İnsan Yüz İfade Analizi, Yüksek Lisans Tezi, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Kırıkkale, 2009.
113. Fleming, A. D., Philip, S., Goatman, K. a, Olson, J. a ve Sharp, P. F., Automated assessment of diabetic retinal image quality based on clarity and field definition. Invest. Ophthalmol. Vis. Sci., 47, 3 (2006) 1120–5.
114. Giancardo, L., Abramoff, M. D., Chaum, E., Karnowski, T. P., Meriaudeau, F. ve Tobin, K. W., Elliptical local vessel density: a fast and robust quality metric for retinal images., Proceedings Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Ocak 2008, IEEE MMVIII: 3534–7.
115. Lalonde, M., Gagnon, L. ve Boucher, M., Automatic visual quality assessment in optical fundus images, Proceedings of Vision Interface, 2001, Canadian Image Processing and Pattern Recognition Society, 259–264.
116. Lee, S. C. ve Wang, Y., Automatic retinal image quality assessment and enhancement, Medical Imaging '99, Mayıs 1999, MDLXXXI: 1581–1590.
117. Niemeijer, M., Abràmoff, M. D. ve van Ginneken, B., Image structure clustering for image quality verification of color retina images in diabetic retinopathy screening. Med. Image Anal., 10, 6 (2006) 888–98.
118. Nayak, J., Acharya U., R., Bhat, P. S., Shetty, N. ve Lim, T.-C., Automated Diagnosis of Glaucoma Using Digital Fundus Images J. Med. Syst., 33, 5 (2008) 337–346.
119. Köse, C., Sevik, U. ve Gençalioğlu, O., Automatic segmentation of age-related macular degeneration in retinal fundus images. Comput. Biol. Med., 38, 5 (2008) 611–9.
120. Köse, C., Şevik, U., Gençalioğlu, O., İkibaş, C. ve Kayıkıcıoğlu, T., A Statistical Segmentation Method for Measuring Age-Related Macular Degeneration in Retinal Fundus Images J. Med. Syst., 34, 1 (2010) 1–13.
121. Walter, T. ve Klein, J., Segmentation of color fundus images of the human retina: Detection of the optic disc and the vascular tree using morphological techniques, in Medical Data Analysis, Springer-Verlag, 2001 282–287.
122. Al-Rawi, M., Qutaishat, M. ve Arrar, M., An improved matched filter for blood vessel detection of digital retinal images. Comput. Biol. Med., 37, 2 (2007) 262–267.

123. Ricci, E. ve Perfetti, R., Retinal blood vessel segmentation using line operators and support vector classification. IEEE Trans. Med. Imaging, 26, 10 (2007) 1357–65.
124. Marin, D., Aquino, A., Gegundez-Arias, M. E. ve Bravo, J. M., A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features. IEEE Trans. Med. Imaging, 30, 1 (2011) 146–58.
125. Honale, S. S. ve Kapse, V. S., A Review of Methods for Blood Vessel Segmentation in Retinal images Int. J. Eng. Res. Technol., 1, 10 (2012) 1–6.
126. Kirbas, C. ve Quek, F. K. H., A Review of Vessel Extraction Techniques and Algorithms 1 (2002).
127. Polikar, R., Pattern Recognition. New York: Wiley Encyclopedia of Biomedical Engineering, 2006.
128. Biricik, G., Metin Sınıflama İçin Yeni Bir Özellik Çıkarım Yöntemi, Doktora Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul, 2011.
129. Cai, R., Hao, Z., Yang, X. ve Wen, W., An efficient gene selection algorithm based on mutual information Neurocomputing, 72, 4–6 (2009) 991–999.
130. Saeys, Y., Inza, I. ve Larrañaga, P., A review of feature selection techniques in bioinformatics Bioinformatics, 23, 19 (2007) 2507–17.
131. Kira, K. ve Rendell, L. A., A practical approach to feature selection (1992) 249–256.
132. Sun, X., Liu, Y., Li, J., Zhu, J., Chen, H. ve Liu, X., Feature evaluation and selection with cooperative game theory Pattern Recognit., 45, 8 (2012) 2992–3002.
133. Bellman, R., Adaptive Control Processes; A Guided Tour Oper. Res., 10, 1 (1962) 143–146.
134. Jain, A. ve Zongker, D., Feature selection: evaluation, application, and small sample performance IEEE Trans. Pattern Anal. Mach. Intell., 19, 2 (1997) 153–158.
135. Whitney, A. W., A Direct Method of Nonparametric Measurement Selection IEEE Trans. Comput., C–20, 9 (1971) 1100–1103.
136. Pudil, P., Novovičová, J. ve Kittler, J., Floating search methods in feature selection Pattern Recognit. Lett., 15, 11 (1994) 1119–1125.
137. Siedlecki, W. ve Sklansky, J., A note on genetic algorithms for large-scale feature selection Pattern Recognit. Lett., 10, 5 (1989) 335–347.
138. Yang, J. ve Honavar, V., Feature subset selection using a genetic algorithm IEEE Intell. Syst., 13, 2 (1998) 44–49.



139. Kittler, J., Feature set search algorithms, C.H. Chert, Ed Pattern Recognition and Signal Processing, 1978, Sijthoff and Noordhoff,, 41–60.
140. Goldberg, D. E., Genetic Algorithms in Search, Optimization and Machine Learning. Boston MA: Addison-Wesley Longman Publishing Co., Inc., 1989 432.
141. Powers, D. M. W., Evaluation: From precision, recall and f-measure to roc., informedness, markedness & correlation J. Mach. Learn. Technol., 2, 1 (2011) 37–63.
142. Sekhar, S., Al-Nuaimy, W. ve K. Nandi, A., Automated localisation of retinal optic disk using Hough transform, 2008 5th IEEE International Symposium on Biomedical Imaging: From Nano to Macro, Mayıs 2008, 1577–1580.
143. Akram, M. U., Khan, A., Iqbal, K. ve Butt, W. H., Retinal Images : Optic Disk Localization, Proceedings of International Conference on Image Analysis and Recognition, 2010, Springer Berlin Heidelberg, 40–49.
144. Qian Zhao, Y., Hong Wang, X., Fang Wang, X. ve Shih, F. Y., Retinal vessels segmentation based on level set and region growing Pattern Recognit., 47, 7 (2014) 2437–2446.
145. Vlachos, M. ve Dermatas, E., Multi-scale retinal vessel segmentation using line tracking. Comput. Med. Imaging Graph., 34, 3 (2010) 213–27.
146. Mierswa, I., Wurst, M. ve Klinkenberg, R., Yale: Rapid prototyping for complex data mining tasks, Proceedings of the 12th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, 2006, 935–940.
147. Mika, S., Ratsch, G., Weston, J., Scholkopf, B. ve Mullers, K., Fisher discriminant analysis with kernels, Proceedings of the 1999 IEEE Signal Processing Society Workshop, 1999, IEEE, 41–48.
148. Yang, J. ve Yang, J., Why can LDA be performed in PCA transformed space? Pattern Recognit., 36, 2 (2003) 563–566.
149. Bremner, D., Demaine, E., Erickson, J., Iacono, J., Langerman, S., Morin, P. ve Toussaint, G., Output-Sensitive Algorithms for Computing Nearest-Neighbour Decision Boundaries Discrete Comput. Geom., 33, 4 (2005) 593–604.
150. Bhadeshia, H. K. D. H., Neural networks in materials science ISIJ Int., 39, 10 (1999) 966–979.
151. Zhang, H., The Optimality of Naive Bayes, Proceedings of the 17th International FLAIRS conference, 2004, The AAAI Press, 562–567.
152. Paulus, J., Meier, J., Bock, R., Hornegger, J. ve Michelson, G., Automated quality assessment of retinal fundus photos. Int. J. Comput. Assist. Radiol. Surg., 5, 6 (2010) 557–64.

153. Wen, Y.-H., Bainbridge-Smith, A. ve Morris, A. B., Automated Assessment of Diabetic Retinal Image Quality Based on Blood Vessel Detection, Proceedings of Image and Vision Computing, Şubat 2007, XXXVI: 132–136.
154. Müller, H., Michoux, N., Bandon, D. ve Geissbuhler, A., A review of content-based image retrieval systems in medical applications-clinical benefits and future directions. Int. J. Med. Inform., 73, 1 (2004) 1–23.
155. Rosa, N. A., Felipe, J. C., Traina, A. J. M., Traina, C., Rangayyan, R. M. ve Azevedo-Marques, P. M., Using relevance feedback to reduce the semantic gap in content-based image retrieval of mammographic masses., Proceedings of 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Ocak 2008, IEEE MMVIII: 406–9.
156. Zheng, B., Computer-Aided Diagnosis in Mammography Using Content-based Image Retrieval Approaches: Current Status and Future Perspectives. Algorithms, 2, 2 (2009) 828–849.
157. Dagan Feng, D., Automatic medical image categorization and annotation using LBP and MPEG-7 edge histograms, Proceedings of International Conference on Technology and Applications in Biomedicine, Mayıs 2008, IEEE, 51–53.
158. Hatanaka, Y., Nakagawa, T., Hayashi, Y., Hara, T. ve Fujita, H., Improvement of automated detection method of hemorrhages in fundus images., IEEE Engineering in Medicine and Biology Society, Ocak 2008, MMVIII: 5429–5432.
159. Sánchez, C. I., García, M., Mayo, A., López, M. I. ve Hornero, R., Retinal image analysis based on mixture models to detect hard exudates. Med. Image Anal., 13, 4 (2009) 650–658.
160. Zhang, X. ve Chutatape, O., Detection and classification of bright lesions in color fundus images Image Process. ICIP2004, 1 (2004) 139–142.

## ÖZGEÇMİŞ

1981 yılında Mersin’de doğan Uğur ŞEVİK; ilköğrenimini Gülnar Atatürk İlköğretim okulunda, orta ve lise eğitimini Anamur Anadolu Lisesi’nde tamamladı. 1999 yılında girdiği KTÜ Fen Edebiyat Fakültesi, İstatistik ve Bilgisayar Bilimleri Bölümü’nden 2003’te ikincilik derecesiyle mezun oldu. Aynı yıl KTÜ Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Anabilim Dalı’nda yüksek lisans eğitimine başladı. 2004-2005 yılları arasında Ankara’da özel bir firmada çalıştıktan sonra 2005 yılında KTÜ Fen Edebiyat Fakültesi, İstatistik ve Bilgisayar Bilimleri Bölümü’nde Araştırma Görevlisi olarak göreve başladı. 2007 yılında “Retina Görüntülerinde Yaşa Bağlı Makula Dejenerasyonunun Otomatik Bölütlenmesi” adlı yüksek lisans tezini tamamlayarak, aynı yıl KTÜ Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Anabilim dalında doktora eğitimine başladı. 2008 yılında aynı enstitüde bulunan Bilgisayar Mühendisliği Anabilim Dalı’na yatay geçiş yaptı. 2007-2012 yılları arasında TÜBİTAK Yurtiçi Doktora Bursu aldı. Doktora sürecinde KTÜ BAP destekli 1216 numaralı projede araştırmacı olarak görev aldı. Lisansüstü eğitimi sırasında birçok ulusal ve uluslararası makale ve bildiriler yapan Uğur ŞEVİK; halen KTÜ Fen Fakültesi, İstatistik ve Bilgisayar Bilimleri Bölümü’nde Araştırma Görevlisi olarak çalışmakta ve evli olup, iyi derecede İngilizce bilmektedir.

Şevik U.; Köse C.; Berber T. and Erdöl H."Identification of suitable fundus images using automated quality assessment methods", J. Biomed. Opt. 19, 4, (2014) 046006.

Köse C., Şevik U., İkibaş C., Erdöl H., “Simple methods for segmentation and measurement of diabetic retinopathy lesions in retinal fundus images”, July 2011, Computer Methods and Programs in Biomedicine, 107, 2, (2011) 274-293.

Sivrikaya F., Baskent E.Z., Şevik U., Akgül C., Kadiogulları A.I., Degermenci A.S. , "A GIS-based decision support system for forest management plans in Turkey", Environmental Engineering and Management Journal, 9, 7, (2010) 889 – 1020.

Köse C., Şevik U., Gençaliolu O., İkibaş C. and Kayıkıçioğlu T., “A Statistical Segmentation Method for Measuring Age-Related Macular Degeneration in Retinal Fundus Images”, *Journal of Medical Systems*, 34, 1, (2010) 1-13.

Köse C., Gençaliolu O., Şevik U., “ An Automatic Diagnosis Method for The Knee Meniscus Tears in MR Images”, *Expert Systems with Applications*, 36, 2, (2009) 1208-1216.

Köse C., Şevik U., Gençaliolu O, “Automatic Segmentation of Age-Related Macular Degeneration in Retinal Fundus Images”, *Computers in Biology and Medicine*, 38, (2008) 611-619.