

**DIYABETİK RETİNOPATİNİN GERÇEK ZAMANLI  
TESPİTİ İÇİN KARAR DESTEK SİSTEMİ**

**2016  
DOKTORA TEZİ  
BİLGİSAYAR MÜHENDİSLİĞİ**

**Kemal AKYOL**

**DIYABETİK RETİNOPATİNİN GERÇEK ZAMANLI TESPİTİ İÇİN  
KARAR DESTEK SİSTEMİ**

**Kemal AKYOL**

**Karabük Üniversitesi  
Fen Bilimleri Enstitüsü  
Bilgisayar Mühendisliği Anabilim Dalında  
Doktora Tezi  
Olarak Hazırlanmıştır**

**KARABÜK  
Haziran 2016**

Kemal AKYOL tarafından hazırlanan "DİYABETİK RETİNOPATİNİN GERÇEK ZAMANLI TESPİTİ İÇİN KARAR DESTEK SİSTEMİ" başlıklı bu tezin Doktora Tezi olarak uygun olduğunu onaylarım.

Yrd. Doç. Dr. Şafak BAYIR  
Tez Danışmanı, Bilgisayar Mühendisliği Anabilim Dalı



Bu çalışma, jürimiz tarafından oy birliği ile Bilgisayar Mühendisliği Anabilim Dalında Doktora Tezi olarak kabul edilmiştir. 24/06/2016

Unvanı, Adı SOYADI (Kurumu)

İmzası

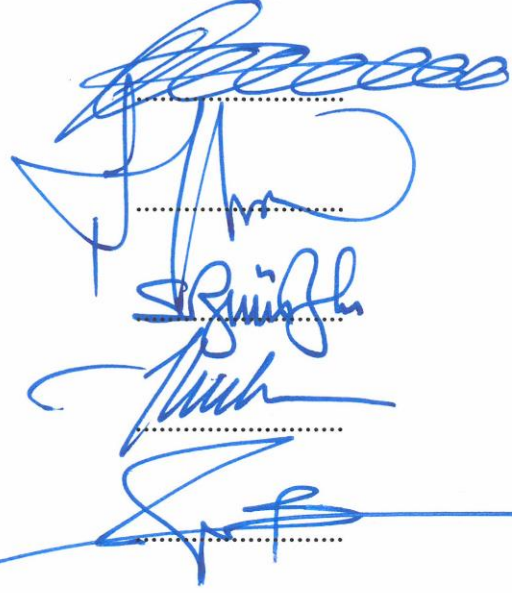
Başkan : Prof. Dr. Fatih V. ÇELEBİ (YBÜ)

Üye : Yrd. Doç. Dr. Şafak BAYIR (KBÜ)

Üye : Yrd. Doç. Dr. Salih GÖRGÜNOĞLU (KBÜ)

Üye : Yrd. Doç. Dr. İlker TÜRKER (KBÜ)

Üye : Yrd. Doç. Dr. Baha ŞEN (YBÜ)



...../...../2016

KBÜ Fen Bilimleri Enstitüsü Yönetim Kurulu, bu tez ile, Doktora derecesini onamıştır.

Prof. Dr. Nevin AYTEMİZ  
Fen Bilimleri Enstitüsü Müdürü





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

Kemal AKYOL

## **ÖZET**

**Doktora Tezi**

### **DİYABETİK RETİNOPATİNİN GERÇEK ZAMANLI TESPİTİ İÇİN KARAR DESTEK SİSTEMİ**

**Kemal AKYOL**

**Karabük Üniversitesi**

**Fen Bilimleri Enstitüsü**

**Bilgisayar Mühendisliği Anabilim Dalı**

**Tez Danışmanı:**

**Yrd. Doç. Dr. Şafak BAYIR**

**Haziran 2016, 93 sayfa**

Retina ışığa duyarlı hücreler içeren bir ağ katmanıdır. Görme işlemini icra eden bu katmanda oluşan hastalıklar doğrudan görme yeteneğimizi tehdit eder. Diyabetik retinopati, şeker hastalığının temel komplikasyonlarından bir tanesidir ve bu hastalığın ilerleyen evrelerinde körlüğe en önemli katkısı olan bir hastalıktır. Bu yüzden bu hastalığın otomatik tespiti ve takibi büyük önem taşımaktadır. Uzun zamandan bu yana medikal görüntü işleme alanında bu hastalık üzerine yapılmış birçok çalışma vardır.

Tıp bilimlerinde, kararların hızlı ve doğru şekilde verilmesi hayati öneme sahiptir ve bu hastalığın ilerlemesinin durdurulmasında en önemli yöntem erken tanının tespitidir. Bu amaç doğrultusunda bu çalışmada, bu hastalığın erken evresinde ortaya çıkan sert ve yumuşak eksuda, hemoraji ve mikroanevrizma lezyonlarının tespiti için uzman hekime karar desteği sağlayan görüntü işleme teknikleri ve makine

öğrenmesine dayalı bir uygulama geliştirilmiştir. Öznitelik verisetleri ve sınıflandırıcı algoritmalarının en iyi uyumu ile sistemin öğrenmesi gerçekleştirilmiştir. Bu süreçte, önışlemeden geçirilen görüntüdeki ilgi noktalarından öznitelikler çıkartılarak lezyonları temsil eden anlamlı bilgi elde edilmiştir. İlgi alanına ait özniteliklerin çıkarımı sürecinde Gabor ve Ayrık Fourier Dönüşümü öznitelikleri ile çalışılmış ve Yinelemeli Öznitelik Eleme ve Spektral Regresyon Diskriminant Analizi algoritmaları kullanılarak en iyi öznitelik kümeleri elde edilmiştir. Ardından her bir öznitelik veriseti üzerinde Rastgele Orman ve Lojistik Regresyon sınıflandırıcı algoritmalarının performansları karşılaştırmalı olarak değerlendirilmiştir.

Ayrıca deneysel çalışmalarda öznitelik seçimi veya öznitelik indirgeme ile elde edilen verisetleri üzerinde yapılan sınıflandırmanın orijinal veriseti ile yapılan sınıflandırmaya göre daha başarılı olduğu görülmüştür. Sistemin modellenmesi sürecinde DIARETDB1 verisetinden bir örneklem kümesi oluşturulmuştur. Hem DIARETDB1 hem de Ankara Atatürk Eğitim ve Araştırma Hastanesi Göz hastalıkları anabilim dalından temin edilen retinal fundus görüntüleri kullanılarak yeni retinal görüntülerin analizi gerçekleştirilmiştir.

Her bir lezyon grubu için en iyi performans sunan iki model bilgisi ile geliştirilmiş olan hibrid karar verici sistemin mevcut retinal görüntü cihazları ile bütünleştirilerek alan uzmanlarına destek vereceği düşünülmektedir.

**Anahtar Sözcükler :** Erken evre diyabetik retinopati, ilgi noktaların çıkarımı, öznitelik seçimi, rastgele orman, lojistik regresyon, karar destek sistemi.

**Bilim Kodu** : 902.1.014

## **ABSTRACT**

**Ph. D. Thesis**

### **A DECISION SUPPORT SYSTEM FOR DIABETIC RETINOPATHY'S REAL-TIME DETECTION**

**Kemal AKYOL**

**Karabük University**

**Graduate School of Natural and Applied Sciences**

**Department of Computer Engineering**

**Thesis Advisor:**

**Assist. Prof. Dr. Şafak BAYIR**

**June 2016, 93 pages**

Retina is a network layer containing light-sensitive cells. Diseases that occur in this layer which performs the eye-sight threaten our eye-sight directly. Diabetic retinopathy is one of the main complications of diabetes mellitus and it is a progressive ocular disease, the most significant factor contributing to blindness in the later stages of the disease. Therefore, this disease's automatic detection and monitoring is of great importance. There have been many studies on this subject in the medical image processing field for a long time.

In medical science, deciding quickly and accurately is vital and the most important method is the detecting of early diagnosis in stopping the progression of the disease. For this purpose, in this study, an application, which provides decision support to specialist, has been developed based on image processing

techniques and machine learning for the detection of hard exudates, cotton spots, hemorrhage and microaneurysm lesions which appeared in the early stages of this disease. Learning of system has been performed with feature datasets and classifier algorithms' best fit. In this process, the meaningful information, which represents the lesions has been obtained by extracting the attributes from the points of interest on the preprocessed image. In the process of extraction of attributes belonging to areas of interest, it has been studied with Gabor and Discrete Fourier Transform attributes and the best feature sets have been obtained by using Recursive Feature Elimination and Spectral Regression Discriminant Analysis algorithms. Then, Logistic Regression and Random Forest classifier algorithms' performances have been evaluated on each attribute dataset comparatively.

In addition, it has been seen that the classification on the datasets which are obtained with feature selection or reduction has been more successful than with the classification on the original datasets in experimental studies. A sample set from DIARETDB1 dataset has been created in the process of the modeling of the system. The analysis of new retinal fundus images has been performed using the images which were provided via both DIARETDB1 dataset and the department of Ophthalmology, Ataturk Training and Research Hospital in Ankara.

It is assumed that a hybrid deciding system developed with knowledge of two models which offer the best performance for group of each lesion will give support to the field specialists by integrating with the existing retinal imaging device.

**Key Word** : Early stage diabetic retinopathy, the extraction of points of interest, attribute selection, random forest, logistic regression, decision support system.

**Science Code** : 902.1.014



## TEŞEKKÜR

Doktora eğitimim süresince ve tez çalışmasının planlanmasında ve yürütülmesinde ilgi ve desteğini esirgemeyen, yönlendirme ve bilgilendirmeleriyle çalışmamı bilimsel temeller ışığında şekillendiren sayın hocalarım Prof. Dr. Abdullah Çavuşoğlu, Yrd. Doç. Dr. Şafak Bayır ve Yrd. Doç. Dr. Baha Şen'e sonsuz teşekkürlerimi sunarım.

Doktora tez konusunun belirlenmesi sürecinde değerli görüşlerinden ve bilgisinden istifade ettiğim, bilimsel ve manevi desteğini hiçbir zaman esirgemeyen değerli hocam Prof. Dr. Doğan Çalıkoğlu'na ve değerli tavsiyelerinden dolayı sayın hocalarım Prof. Dr. Fatih V. Çelebi ve Yrd. Doç. Dr. Salih Görgünoğlu'na çok teşekkür ederim.

Çalışmada kullanılan retinal görüntülerin temin edilmesinde yardımlarını esirgemeyen Yrd. Doç. Dr. Hilal Kaya ve Ankara Atatürk Eğitim ve Araştırma Hastanesi Göz hastalıkları anabilim dalı personeli Yrd. Doç. Dr. Mücella Arıkan'a ve ayrıca oluşturdukları retinal fundus görüntü verisetlerini araştırmacıların kullanımına sunan DIARETDB1, DRIVE ve ROC projelerinin geliştiricilerine teşekkürlerimi sunarım.

Son olarak, bugünlere gelmemde büyük pay sahibi olan annem Şerif Selman Akyol ve babam Şakir Akyol'a, bu süreçteki tüm anlayış ve destekleri için çocuklarım Kaan ve Mete Akyol'a, en çok da sevgili eşim Betül Akyol'a; sonsuz teşekkürlerimi sunarım.

## İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER .....	ix
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ .....	xiv
SİMGELER VE KISALTMALAR DİZİNİ .....	xv
BÖLÜM 1 .....	1
GİRİŞ .....	1
BÖLÜM 2 .....	4
RETİNANIN YAPISI VE DİYABETİK RETİNOPATİ HASTALIĞI .....	4
2.1. RETİNA .....	4
2.2. RETİNAL FUNDUS GÖRÜNTÜLER.....	5
2.3. DİYABETİK RETİNOPATİ VE EVRELERİ .....	6
BÖLÜM 3 .....	9
LİTERATÜR .....	9
BÖLÜM 4 .....	14
UYGULAMANIN GELİŞTİRİLMESİNDE KULLANILAN YÖNTEM VE TEKNİKLER .....	14
4.1. GÖRÜNTÜ İŞLEME TEKNİKLERİ .....	15
4.1.1. Görüntü İyileştirme.....	15
4.1.2. Görüntünün Negatifi.....	16
4.1.3. Morfoloji.....	16

	<b><u>Sayfa</u></b>
4.1.4. Baęlantılı Bileşen Etiketleme .....	16
4.2. İLGİ NOKTALARININ ÇIKARIMI .....	17
4.3. ÖZİNİTELİK ÇIKARIMI .....	17
4.3.1. Gabor Öznitelikleri .....	18
4.3.2. Ayrık Fourier Dönüşümü Öznitelikleri .....	19
4.4. ÖZİNİTELİK DEĞERLENDİRME .....	20
4.4.1. Yinelemeli Öznitelik Elemesi.....	20
4.4.2. Spektral Regresyon Diskriminant Analizi .....	22
4.5. SINIFLANDIRMA VE ÖĞRENME .....	22
4.5.1. Lojistik Regresyon.....	23
4.5.2. Rastgele Orman .....	24
4.6. KARAR DESTEK SİSTEMLERİ.....	24
4.7. PERFORMANS DEĞERLENDİRME .....	25
BÖLÜM 5 .....	28
GELİŞTİRİLEN KARAR DESTEK SİSTEMİ UYGULAMASI.....	28
5.1. VERİSETİ .....	28
5.2. MODEL OLUŞTURMA SÜRECİ.....	29
5.2.1. Uygulamanın Geliştirilmesi.....	30
5.2.2. Retinal Görüntülerin Analizi Süreci .....	37
5.3. UYGULAMANIN BÖLÜMLERİ .....	39
5.3.1. Model Seçimi Ekranı .....	39
5.3.2. Lezyonların Tespiti Ekranı .....	40
5.3.2.1. Belirgin Oluşumların Tespiti Ve Kan Damarlarının Çıkarımı .....	40
5.3.2.2. Analiz İşlemi .....	44
5.3.3. Sonuç Ekranı.....	44
5.3.4. Karşılaştırma Ekranı .....	47
BÖLÜM 6 .....	50
DENEYSEL SONUÇLAR VE TARTIŞMA.....	50
6.1. ERKEN EVRE DİYABETİK RETİNOPATİ LEZYONLARININ TESPİTİNE DAİR ELDE EDİLEN SONUÇLAR .....	52

	<b><u>Sayfa</u></b>
6.2. ERKEN EVRE DİYABETİK RETİNOPATİ LEZYONLARININ TESPİTİ İÇİN YAPILAN DİĞER ÇALIŞMALAR .....	64
6.3. RETİNA GÖRÜNTÜLERİNDEKİ BELİRGİN OLUŞUMLARIN TESPİTİ ÇALIŞMALARI .....	68
6.3.1. Optik Diskin Tespiti .....	68
6.3.2. Makulanın Tespiti.....	75
6.3.3. Kan Damarlarının Çıkarımı .....	76
BÖLÜM 7 .....	78
SONUÇ VE ÖNERİLER .....	78
KAYNAKLAR .....	81
EK AÇIKLAMALAR A. RETİNAL KAMERA TEKNİK ÖZELLİKLERİ.....	90
ÖZGEÇMİŞ .....	93

## ŞEKİLLER DİZİNİ

### Sayfa

Şekil 2.1	Işığın gözde izlediği yol ve kırılımı .....	4
Şekil 2.2	Retinanın yapısı .....	5
Şekil 2.3.	Fundus kamera ile elde edilen retina görüntüsü .....	6
Şekil 2.4.	Normal birey ve DR'li bireyin görüşü .....	6
Şekil 2.5.	DR lezyonlarının olduğu retina görüntüsü.....	7
Şekil 2.6.	EEDR yapısal bozuklukları.....	7
Şekil 4.1.	İşlem basamakları .....	14
Şekil 4.2.	BBE yönteminin uygulanması ile görüntüden elde edilen bölgeler .....	17
Şekil 4.3.	İlgi noktaları etrafındaki dörtgensel bölgelerden bir örneklem .....	18
Şekil 4.4.	Veri uzayının görselleştirilmesi .....	18
Şekil 5.1.	Geliştirilen uygulamanın çalışma şeması.....	29
Şekil 5.2.	Geliştirilen uygulamanın iş akışı .....	29
Şekil 5.3.	Önişlem süreci .....	31
Şekil 5.4.	Parlak bölgelerin çıkarımı ve eşikleme işlemleri .....	31
Şekil 5.5.	Eşikleme işleminin farklı retinal görüntülerdeki sonucu .....	32
Şekil 5.6.	Retinal görüntülerden elde edilen ilgi noktaları.....	33
Şekil 5.7.	Öznitelik çıkartma, öznitelik değerlendirme ve sınıflandırma süreci .....	35
Şekil 5.8.	Hibrid sınıflandırıcının kullanımı .....	36
Şekil 5.9.	Yeni retinal görüntülerin analizi sürecinin genel blok diyagramı .....	37
Şekil 5.10.	Kan damarı üzerindeki ilgi noktalarının tespiti .....	38
Şekil 5.11.	EEDR lezyonlarının tespiti için geliştirilen KDS ana ekranı.....	39
Şekil 5.12.	KDS model seçim ekranı .....	39
Şekil 5.13.	Retinal görüntülerde "whitening" metodunun uygulanması.....	40
Şekil 5.14.	Analize alınmaması gereken bölgelerin tespiti .....	41
Şekil 5.15.	KDS, retinadaki belirgin oluşumların tespiti ekranı. ....	42
Şekil 5.16.	OD, makula ve kan damarlarının çıkarımı.....	42
Şekil 5.17.	Kan damarlarının çıkarımı sonuçları .....	43
Şekil 5.18.	Lezyonlu bölgelerin analizi süreci .....	43

## Sayfa

Şekil 5.19. Lezyonlu bölgelerin güncellenmesi .....	44
Şekil 5.20. İlgili alanının alan uzmanı tarafından analize alınması.....	45
Şekil 5.21. Lezyonlu bölgenin detaylı incelenmesi .....	45
Şekil 5.22. KDS için tasarlanan veritabanı görüntüsü. ....	46
Şekil 5.23. DR'nin oluşma riskini artıran faktörlerin sisteme kaydedilmesi .....	47
Şekil 5.24. Sistemdeki kayıtlı verilerin sorgulanması.....	48
Şekil 5.25. Hastalığın seyri için sistemdeki kayıtlı verilerin incelenmesi .....	48
Şekil 5.26. Hastalığın seyri için sistemdeki kayıtlı verilerin detaylı incelenmesi .....	48
Şekil 5.27. Sistemdeki kayıtlı iki verinin incelenmesi.....	49
Şekil 6.1. Yoğun örneklem ile alt görüntülerin elde edilmesi.....	50
Şekil 6.2. Süperpiksel algoritması ve elde edilen bölgeler .....	51
Şekil 6.3. Eksuda lezyonları.....	62
Şekil 6.4. Hemoraji ve mikroanevrizma lezyonları .....	63
Şekil 6.5. Sistemin öğrenmesi ve retinal görüntülerin analizi .....	64
Şekil 6.6. Çalışmanın iş akışı .....	65
Şekil 6.7. Öznitelik değerlendirme.....	65
Şekil 6.8. Geliştirilen sistemin iş akış diyagramı .....	66
Şekil 6.9. Çalışmanın iş akışı .....	67
Şekil 6.10. Öznitelik değerlendirme.....	68
Şekil 6.11. DIARETDB1 verisetinden bir retinal fundus görüntüsü .....	69
Şekil 6.12. Uygulamanın akış diyagramı .....	70
Şekil 6.13. Doku analizinde kullanılan bölgeler .....	70
Şekil 6.14. OD'nin tespiti.....	71
Şekil 6.15. İlgili bölgesinin alanının hesaplanması .....	72
Şekil 6.16. Önerilen yaklaşımın iş akışı.....	73
Şekil 6.17. OD'nin tespiti için yürütülen morfolojik işlem adımları .....	74
Şekil 6.18. 6 retinal görüntünün OD bölgesinin tespitine dair sonuçlar .....	74
Şekil 6.19. Makula bölgesinin tespiti için ilgi alanlarının tespiti.....	76
Şekil 6.20. Retinal görüntüden damar çıkarımı süreci.....	76
Şekil Ek A.1. Topcon TRC-50IX Retinal kamera .....	91

## ÇİZELGELER DİZİNİ

### Sayfa

Çizelge 4.1. 5-katlı çapraz doğrulama örneği .....	26
Çizelge 4.2. İki sınıflı bir veri kümesinde karışıklık matrisi .....	26
Çizelge 6.1. Sert ve yumuşak eksuda için BÇ-1'e göre sınıflandırma sonuçları ....	52
Çizelge 6.2. Sert ve yumuşak eksuda için BÇ-2'ye göre sınıflandırma sonuçları ..	53
Çizelge 6.3. Sert ve yumuşak eksuda için BÇ-3'e göre sınıflandırma sonuçları ....	54
Çizelge 6.4. Sert ve yumuşak eksuda için BÇ-4'e göre sınıflandırma sonuçları ....	54
Çizelge 6.5. Model 1 performansının değerlendirilmesi .....	55
Çizelge 6.6. Model 2 performansının değerlendirilmesi .....	55
Çizelge 6.7. Model 3 performansının değerlendirilmesi .....	56
Çizelge 6.8. Öznitelik vektörlerinin çıkarımı için yürütme zamanı .....	56
Çizelge 6.9. En iyi başarıyı sunan dört model için toplam yürütme zamanı .....	56
Çizelge 6.10. Hemoraji ve mikroanevrizma için BÇ-1'e göre sınıflandırma sonuçları .....	57
Çizelge 6.11. Hemoraji ve mikroanevrizma için BÇ-2'e göre sınıflandırma sonuçları .....	57
Çizelge 6.12. Hemoraji ve mikroanevrizma için BÇ-3'e göre sınıflandırma sonuçları .....	58
Çizelge 6.13. Hemoraji ve mikroanevrizma için BÇ-4'e göre sınıflandırma sonuçları .....	59
Çizelge 6.14. Model 1 performansının değerlendirilmesi .....	60
Çizelge 6.15. Model 2 performansının değerlendirilmesi .....	60
Çizelge 6.16. Model 3 performansının değerlendirilmesi .....	60
Çizelge 6.17. Öznitelik vektörlerinin çıkarımı için yürütme zamanı .....	61
Çizelge 6.18. En iyi başarıyı sunan iki model için toplam yürütme zamanı .....	61
Çizelge 6.19. İlgili noktalarının tespiti .....	69

## SİMGELER VE KISALTMALAR DİZİNİ

### SİMGELER

- $S$  : İlgili alanındaki piksel sayısı  
 $\sigma$  : Gabor çekirdeğinin standart sapması  
 $\theta$  : Uzaysal frekans  
 $\phi$  : Yönelim  
 $x$  ve  $y$  : Uzaysal düzlem koordinatları  
 $w_i$  :  $i$ . öz niteliğin ağırlığı  
 $\mu_i$  :  $i$ . öz niteliğin ortalaması  
 $\sigma_i$  :  $i$ . öz niteliğin standart sapması  
 $\mu$  : Ortalama vektör bilgisi  
(+) : Pozitif eğitim kümesi  
(-) : Negatif eğitim kümesi  
 $G$  : Graf  
 $W$  :  $m \times m$  simetri matrisi  
 $W_{i,j}$  :  $i$  ve  $j$  köşesinin ağırlığı  
 $D$  : Diyagonal matris  
 $L$  : Laplas matrisi  
 $X$  : Giriş vektörü  
 $y$  : Çıkış vektörü  
 $P$  : İncelenen bir olayın gözlenme olasılığı  
 $\beta_0$  : Sabit  
 $\beta_p$  :  $p$ . bağımsız değişkenin regresyon katsayısı  
 $X_p$  :  $p$ . bağımsız değişken  
 $p$  : Bağımsız değişken sayısı  
 $e$  : 2.718 hata terimi  
 $k$  : Verisetinden elde edilen alt veriseti sayısı



## KISALTMALAR

DR	: Diyabetik Retinopati
OD	: Optik Disk
EEDR	: Erken Evre Diyabetik Retinopati
DIARETDB1	: Standard Diabetic Retinopathy Database (Standart Diyabetik Retinopati Veritabanı)
DRIVE	: Digital Retinal Images for Vessel Extraction (Damar Çıkarımı İçin Sayısal Retinal Görüntüler)
ROC	: Retinopathy Online Challenge (Çevrimiçi Retinopati Değerlendirmesi)
DVM	: Destek Vektör Makinaları
RGB	: Kırmızı, Yeşil, Mavi
AHE	: Adaptif Histogram Eşitleme
KSAHE	: Kontrast Sınırlamalı Adaptif Histogram Eşitleme
ORB	: Oriented FAST and Rotated BRIEF (Yönlendirilmiş ve Döndürülmüş İkili Gürbüz Bağımsız Temel Özellikler)
SURF	: Speeded-Up Robust Features (Hızlandırılmış Gürbüz Özellikler)
BBE	: Bağlantılı Bileşen Etiketleme
GÖ	: Gabor Öznitelikleri
AFDÖ	: Ayrık Fourier Dönüşümü Öznitelikleri
YÖE	: Yinelemeli Öznitelik Elemesi
SRDA	: Spektral Regresyon Diskriminant Analizi
LR	: Lojistik Regresyon
RO	: Rastgele Orman
KDS	: Karar Destek Sistemi
Dp	: Doğru pozitif
Dn	: Doğru negatif
Yp	: Yanlış pozitif
Yn	: Yanlış negatif
Du	: Duyarlılık
Se	: Seçicilik
Dso	: Doğru sınıflandırma oranı (Doğruluk)

BÇ : bilgi çıkarımı  
sn : saniye  
YSA : Yapay Sinir Ağları



## BÖLÜM 1

### GİRİŞ

Dışarıdan veya içeriden kaynaklanan birçok etkenden dolayı gözün sağlığı bozulabilir ve değişik şekillerde görme bozuklukları meydana gelebilir. Retina, görme işlevinin gerçekleştiği yer olduğu için burada meydana gelecek bir bozukluğun ilerleyen safhalarında görme yeteneği kaybedilebilir. Bu nedenle mümkün olduğunca erken müdahale edilmesi gerekir.

Tamıyı doğru bir şekilde gerçekleştirebilmek için hastaların retina görüntülerinin elde edilmesine ve incelenmesine ihtiyaç vardır. Retina görüntüleri göz hastalıklarının tespitinde göz doktorlarının kullandıkları en önemli materyallerden biridir. Alan uzmanı bu görüntüleri inceleyerek hastalığın gelişimini analiz etmekte ve ileri evrelere geçmesini engellemeye çalışmaktadır.

Hastalığın seyrini takip etme açısından vereceği destek ile uzmanın anlık olarak farklı çıkarımlar yürütmesi ve karar vermesini hızlandırması gibi birçok avantajından ötürü hastalıklı bölgelerin tespitini otomatik gerçekleştiren ve kaydeden sistemler önem kazanmaktadır.

Bu tezin amacı, retinal görüntüleri kullanarak Diyabetik Retinopati (DR) hastalığının erken evresinde ortaya çıkan yapısal bozukluk yani lezyonların yerinin en doğru şekilde tespit edilmesini sağlayacak yöntem ve teknikleri uygulamalı olarak araştırmak ve en doğru sonucu veren karar destek sistemini modellemektir. Anlamlı bilginin elde edilmesi ve öğrenen sistemin karar vermesine dayalı olarak retinadaki yapısal bozuklukların algılanması ve bunlar hakkında daha detaylı bilgi edinilmesi amaçlanmıştır. Geliştirilen uygulamanın bir bileşeni de, aynı hastaya ait farklı tarihlerde çekilmiş retinal görüntülerdeki Erken Evre Diyabetik Retinopati (EEDR) lezyonlarının tespiti ve bu bölgelerin kayıt altına alınmasıdır. Karar desteği sunan bu

işlevi ile, geliştirilen uygulama hastalığın ve yapısal bozuklukların seyri hakkında alan uzmanına yardımcı olur. Böylece iş yoğunluğundan veya dikkatten kaçabilecek DR lezyonlarının sayısı en aza indirilmiş olacaktır.

Diğer yandan bu çalışmada EEDR lezyonlarının tespitinin yanı sıra Optik Disk (OD) ve makulanın tespitine yönelik yöntemlerde önerilmiştir. Önerilen yöntemler ve teknikler, başka çalışmalardaki retinal görüntü analizlerinde ve retinal hastalıkların tespitinde kullanılabilir.

Bu kapsamda yürütülen ve yedi bölümden oluşan bu tez çalışmasının düzeni şu şekildedir: Birinci bölümde, teze genel bir bakış açısı kazandırmaya yönelik olarak temel bilgiler verilmiştir.

İkinci bölümde, retinanın yapısı, DR hastalığı, EEDR hastalığı ile ortaya çıkan lezyonlar hakkında bilgiler sunulmuş ve erken tanının bu hastalığın ilerlemesinin durdurulmasındaki önemi vurgulanmıştır.

Üçüncü bölümde, EEDR lezyonlarının ve ayrıca OD bölgesinin tespitine yönelik literatür çalışmaları incelenmiştir.

Dördüncü bölümde, geliştirilen uygulamada faydalanılan yöntem ve teknikler hakkında bilgiler verilmiştir. Geliştirilen modellerin performansını ölçmek için kullanılan ölçütlerde bu bölümde incelenmiştir.

Beşinci bölümde, tez çalışması kapsamında EEDR lezyonlarının tespiti için geliştirilen "Karar Destek Sistemi (KDS)" uygulamasının her bir bölümü detaylı bir şekilde sunulmuştur.

Altıncı bölümde, çalışma süresince deneysel çalışmalar ile elde edilen veriler sunulmuştur. Her bir öznitelik vektörü ile yapılan sınıflandırma analizlerinin sonuçları ayrıntılı bir şekilde ilgili çizelgelerde verilmiştir. Ayrıca, tez çalışması boyunca üzerinde çalışılan yöntem ve teknikler ile hazırlanmış olan bildiri ve makalelerin içeriği hakkında özet niteliğinde bilgiler verilmiştir.

Sonuç ve öneriler bölümünde ise, bu çalışma süresince elde edilen kazanımlar verilmiş ve öneriler sunulmuştur. Önerilen çalışmanın bilim dünyasına katkılarına değinilmiş ve gelecekte yapılabilecek geliştirmelerden bahsedilmiştir. Kaynaklar dizini ve retinal kamera teknik özelliklerini içeren ek bilgi bu bölümü takip etmektedir.

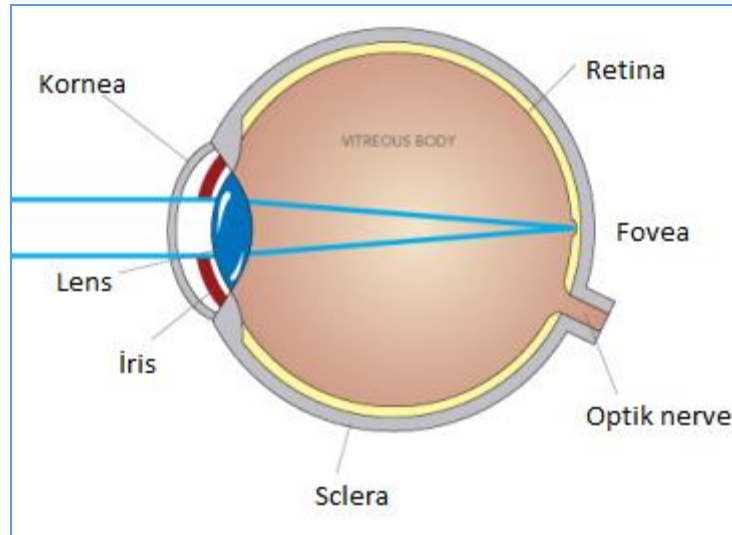


## BÖLÜM 2

### RETİNANIN YAPISI VE DİYABETİK RETİNOPATİ HASTALIĞI

Etrafımızda meydana gelen olayları beyne iletme ve görme işlemini mükemmel bir sistem içerisinde gerçekleştiren göze giren ışın ilk olarak kornea tabakasından geçerken kırılır. Sonrasında göz bebeği kısmından geçer ve tekrar lensler tarafından kırılır. Son olarak ışınlar retinaya ulaşır ve bu kısımda ışığa hassas olan foto reseptörler tarafından elektrik sinyallerine çevrilir. Daha sonra bu elektrik sinyalleri optik sinirler aracılığıyla beyne iletilir. Lens, iris ve göz bebeği arkasında bulunan şeffaf bir yapıdır. İris ise ortasında göz bebeğinin bulunduğu ince pigment tabakadan oluşmuş daire şeklindeki kısımdır ve korneanın arkasında yer alır [1].


#### 2.1. RETİNA



Şekil 2.1. Işığın gözde izlediği yol ve kırılımı [2].

Şekil 2.1’de görüldüğü üzere retina, gözün arkasında yer alan ışığa duyarlı hücreler ile görüntüye ilişkin bilgiyi beyne taşıyan sinir liflerini içeren ve görme işlevini gerçekleştiren göz tabakasıdır [3]. Şekil 2.2’de Ankara Atatürk Eğitim ve Araştırma

Hastanesi Göz hastalıkları anabilim dalı veritabanından temin edilmiş bir retina örneği görülmektedir.



Şekil 2.2. Retinanın yapısı.

Şekil 2.2’de görüldüğü üzere, bir milyondan fazla sinir lifinin toplandığı OD, optik sinirlerin retinaya bağlandığı parlak disk yapısında bölgedir. Tüm retinayı besleyen damarlar bu noktadan içeri girer ve yine bu noktadan çıkar. Gözün arka kısmında, retina tabakasının üzerinde 4-5 mm çaplı merkezi yerleşimli bir alan olan ve sarı nokta olarak da adlandırılan makula bölgesi görmenin merkezi olarak adlandırılmaktadır [4-5].

Ana damarlar, görüntülerde kılcıl damarlara göre daha koyudurlar ve kameradan gönderilen ışığı yansıtımazlar. Kılcal damarlar ise ana damarlara göre daha incedirler ve kameradan gönderilen ışığı belli oranda yansıtırlar [6].

## 2.2. RETİNAL FUNDUS GÖRÜNTÜLER

Karmaşık bir optik sistem içeren özel tıbbi cihazlar ile görüntülenen göz sisteminin fundus kısmı hastalığın teşhis ve tedavisinde kullanılır. Şekil 2.3’te örneği verilen bu cihaz, üzerinde kamera ile birleştirilmiş özel bir düşük güç mikroskobuna sahip olup retinayı aynı anda hem aydınlatma hem de görüntüleme kabiliyetine sahiptir. Ayrıca bu görüntülerde OD, makula ve retinanın arka kısmından ibaret olan gözün iç yüzeyi de yer almaktadır [7]. Fundus kamera ile üretilen fundus görüntülerin yapısındaki

değişiklikler doktorlar tarafından yorumlanmakta ve ayrıca geliştirilen birçok uygulama ile bu görüntüler üzerinde çıkarımlar yapılabilmektedir.



Şekil 2.3. Fundus kamera ile elde edilen retina görüntüsü [8].

### 2.3. DİYABETİK RETİNOPATİ VE EVRELERİ

Medikal görüntü işleme alanında birçok çalışmaya konu olan DR, diyabet mellitusun önemli komplikasyonlarından bir tanesidir. Bu hastalık, şeker hastalığına bağlı olarak kan şekerinin yükselmesi sonucu retina kılcal damarlarının etkilenmesi ile başlayan ve ilerleyen evrelerde görme duyusunun tamamen yitilmesiyle sonuçlanabilen ve genellikle iki gözü de körlük derecesinde etkileyen bir hastalıktır. Bu nedenle şeker hastalarının düzenli olarak doktor tarafından muayene edilmeleri ve retina yapısında meydana gelen değişimlerin takip edilmesi gerekmektedir [9-10]. Şekil 2.4’te normal bir birey ile DR hastalıklı bir bireyin görüşü temsili olarak sırasıyla verilmiştir.



a) Normal bireyin görüşü



b) DR’li bireyin görüşü


Şekil 2.4. Normal birey ve DR’li bireyin görüşü [11].



Bu hastalığın başlangıç evresinde ağ tabaka damarlarının tıkanması ve duvarlarının bozulması ile küçük damar genişlemeleri, küçük retina içi kanamalar ve sert eksuda adı verilen sarı birikintiler görülür. Çok kırılğan damar yapısı nedeniyle göz içi sıvısında (vitreus) kan ve sıvı sızması oluşur ve bunu takiben vitreus sıvısı büzüşerek retina damarlarını ve retinayı öne doğru çeker. Bunun sonucunda büyük göz içi kanamaları, retinanın ayrılması ve yırtılması ortaya çıkabilir [10,12]. Şekil 2.5’de bu hastalığın erken evresinde oluşan lezyonların olduğu retina görüntüsü verilmiştir. Retinal görüntülerdeki yapısal bozulmaların seviyesiyle doğru orantılı olarak ortaya çıkan DR hastalığı, EEDR (nonpoliferatif) ve ileri evre diyabetik retinopati (İEDR-poliferatif) olmak üzere ikiye ayrılır [13].



Şekil 2.5. DR lezyonlarının olduğu retina görüntüsü [14].



Şekil 2.6. EEDR yapısal bozuklukları, a) mikroanevrizma, b) hemoraji, c) sert eksuda, d) yumuşak eksuda [15].

DR hastalığının erken evresinde ortaya çıkan hemoraji, mikroanevrizma, sert eksuda ve yumuşak eksuda yapısal bozulmaları Şekil 2.6'da sırasıyla verilmiştir.

Mikroanevrizma: Şekil 2.6.a'da görüldüğü üzere DR'nin klinik olarak ilk teşhis edilebilir işaretleri, küçük yuvarlak kırmızı noktalar şeklinde ve nispeten belirsiz kılcal damarlar çevresinde görülen yapılardır. Bu bozukluk kılcal damarlarda küçük şişmeler ya da kabartılar şeklinde oluşarak kanın yakın dokulara sızmasına sebep olur. Bu lezyonların doğru tespiti DR hastalığının erken tespiti için kritik bir adımdır [5-6].

Hemoraji: Şekil 2.6.b'de görüldüğü üzere retinal tabakadaki damarlarda oluşan mikro sızıntıya göre daha yüksek düzeyde meydana gelen bir kanamadır ve farklı boyutlardaki koyu kırmızı renk yoğunluklarında gözlemlenirler. Retinopatinin derecesi artarken hemorajiler de belirgin bir şekilde ortaya çıkar. Bu bozulmaların sayısı arttıkça, retinal damarlarda da bozulma ve sızma daha da artarak, sıvı, yağ ve protein sızmasına kadar ilerleyebilir [5-6].

Sert Eksuda: Yağ ve protein toplanması olarak ifade edilen bu bozulma Şekil 2.6.c'de görüldüğü üzere görüntüye oranla genellikle parlak renkte bir yapıya sahiptir. Ayrıca, bu bozulma damar geçirgenliği anlamına gelir ve retinal ödem şeklinde görülebilir [5-6].

Yumuşak Eksuda: Retinal tabakada oluşan sızmalar ve sinir liflerindeki bozulmalar olarak ifade edilir [6]. Şekil 2.6.d'de görüldüğü üzere sert eksuda gibi parlak renktedir.

## BÖLÜM 3

### LİTERATÜR

İlerleyen evrelerinde görme duyusunun tamamen yitilmesiyle sonuçlanabilen ve genellikle iki gözü de etkileyen DR hastalığının erken tanı ile durdurulması amaçlanır. OD bölgesinin sistem tarafından otomatik tespiti de bu hastalıkta oluşan lezyonların tespiti açısından önemlidir. DR hastalığının ve bunun yanı sıra OD bölgesinin bulunmasına dair literatürdeki çalışmalar sırasıyla aşağıda verilmiştir.

Kumar vd., DR'nin önemli bir göstergesi olan sert eksuda lezyonlarının tespiti için yaptıkları çalışmalarında morfolojik ön işleme, görüntü sınır izleme ve Otsu eşikleme tekniklerini kullanarak elde ettikleri bölgelerden çıkarttıkları özellikleri Destek Vektör Makinaları (DVM) ile sınıflandırmışlardır [16]. Sopharak vd.(a) yaptıkları çalışmalarında; düşük kontrastlı görüntüler ve genleşmeyen göz bebekli DR hastaları üzerinde eksuda tespiti için morfolojik operatörlerin uygun bir şekilde ayarlanması üzerine araştırma yapmışlardır [17]. Bir başka çalışmalarında Sopharak vd.(b), morfoloji, segmentasyon ve "naif Bayes" sınıflandırıcısını kullanarak mikroanevrizmaların tespitini gerçekleştirmişlerdir [18]. Quellec vd., otomatik görüntü sınıflandırma için doktorlar tarafından rastgele boyutlardaki işaretlenmiş görüntülerin tanınması için sistemi eğitmişler ve sonrasında benzer desene sahip görüntüleri lezyonludur veya değildir şeklinde sınıflandırarak DR lezyonlarını hassasiyetle tespit etmişlerdir [19]. Mookiah vd. yaptıkları çalışmada; EEDR, İEDR ve normal görüntüler için otomatik tarama sistemi sunmuşlardır. Anormal sinyallerin çıkarımı için göz dibi görüntülerinin işlenmesini içeren bir sistem önermişlerdir. Sınıflandırma için olasılık sinir ağları, karar ağacı ve DVM ile çalışmışlar ve istatistiksel olarak önemli 13 adet özellikten yararlanmışlardır. Ayrıca çalışmalarında, parçacık sürü optimizasyonu ve genetik algoritma optimizasyon tekniklerini kullanmışlardır [20]. Akram vd., çalışmalarında retinal lezyonların

tespiti için önışleme, aday lezyonların çıkarımı ve özellik setinin elde edilmesi aşamalarından sonra m-Medios tabanlı modelleme yaklaşımının genişletilmesini ve Gaussian karışım modelini birleştirerek hibrid sınıflandırıcı önermişlerdir. Önışleme aşamasında kan damarlarını ve OD'yi retinal bölgeden çıkartarak arka plandaki pikselleri yok etmişler ve lezyonlu bölgelerin çıkarımı için filtre bankaları kullanmışlardır. Başarılı bir sınıflandırma için her bir aday bölgeden elde ettikleri şekil, yoğunluk ve istatistiki bilgilerin olduğu bir öznitelik kümesi oluşturmuşlardır [21]. Yun vd., normal retina, orta düzeyde çoğalmayan DR, ağır çoğalmayan DR ve çoğalmacı DR olarak gruplandıkları ve 124 adet retinal görüntünün analizini gerçekleştirdikleri çalışmalarında orjinal görüntülerden görüntü işleme teknikleri ile elde ettikleri öznitelikleri ileri beslemeli yapay sinir ağlarını kullanarak sınıflandırmışlardır [22]. Winder vd., DR alanındaki görüntü işleme çalışmalarını önışleme, OD'nin segmentasyonu, retinal damarların bölütlenmesi, makula ve çukurların lokalizasyonu, retinopatinin bölütlenmesi ve lokalizasyonu olmak üzere 5 adımda kategorilendirmişlerdir [23]. Tavakoli vd., çalışmalarında floresan anjiyografi ile elde edilmiş göz dibi görüntülerinden mikroanevrizmaların otomatik tespiti için çoklu üst-üste pencereler ve Radon dönüşümü tabanlı yeni bir algoritma sunmuşlardır. Optik sinir başlarının tespiti ve maskelenmesi, arka planın görüntüden çıkarılması önışlem aşamalarından geçirilmiş görüntüden alt görüntüler elde etmişler ve bu her bir alt görüntüye Radon dönüşümü uygulayarak örtülü damar ağacının segmentasyonunu gerçekleştirmişlerdir [24]. Askew vd., çalışmalarında DR'nin erken evrelerinde tespiti, yönetimi ve bunun faydalarını değerlendirmeyi amaçlayan ve hastanın bilgisi, genel uygulama personeli, göz doktorları, tarama oranları ve hastalığın erken evrelerinin uygun bir şekilde izlenmesi gibi durumları ele alan bir çalışma sunmuşlardır [25]. Başka bir çalışmada, Adal vd., mikroanevrizmaların tespiti için öğrenme yaklaşımı çerçevesinde otomatik yerel ölçeklemeli tekniğini kullanarak yarı denetimli bir sistem modellemişlerdir [26]. Antal ve Hadju, önışleme ve aday çıkarma yöntemlerinin karışımı olan yeni bir yaklaşım önerisinde bulunmuşlardır. Uygun kombinasyonu bulmak için benzetilmiş tavla tabanlı arama algoritmasından yararlanmışlardır. Ardından sınıflandırma işlemini yürütmüşlerdir [27]. Niemeijer vd. DR tespiti için yürüttükleri çalışmada; parlak lezyonların tespitinin ve lezyonlar arasındaki ayrımın nasıl yapılacağını belirlemek için denetimli algoritma olarak adlandırdıkları makine öğrenmesi tekniğini kullanmışlardır [28].

Garcia vd.(a) retinal görüntülerdeki sert eksuda bölgelerini birbirinden en iyi şekilde ayıran özellik kümesini ve lojistik regresyon yöntemini kullanarak bu bölgelerin otomatik tespitini gerçekleştirmişlerdir [29]. Garcia vd.(b), yaptıkları bir başka çalışmada; çeşitli renk ve parlaklıktaki retinal görüntülerdeki sert eksudaların tespiti için çok katmanlı algılayıcı, radyal tabanlı fonksiyon ve DVM sınıflandırıcılarının performanslarını araştırmışlardır [30]. Kayal ve Banerjee median filtreleme, görüntü eşik değeri gibi çeşitli görüntü işleme tekniklerini kullanarak sert eksuda bölgelerinin tespitini gerçekleştirmişlerdir [31]. Xu ve Luo yaptıkları çalışmada; "stationary transform" ve "gray level co-occurrence" öznitelik verilerinin kombinasyonu ile oluşturdukları verisetini Gaussian Radyal Temelli Fonksiyonlu DVM ile sınıflandırarak sert eksuda bölgelerinin tespitini gerçekleştirmişlerdir [32]. Naqvi vd., çalışmalarında ölçekten bağımsız öznitelik dönüşümü, K-means kümeleme, görsel sözlük ve DVM tekniklerini kullanarak sert eksudaların tespitini gerçekleştiren bir sistem sunmuşlardır [33]. Chen vd. çalışmalarında; histogram segmentasyonu ve morfolojik işlemleri içeren aşamalarla sert eksuda aday bölgelerini çıkartmışlardır. Sonrasında, her bir aday bölgeden elde ettikleri önemli özelliklere dayalı olarak bu bölgelerin sert eksuda olup olmadığının tespitini gerçekleştirmişlerdir [34]. Ranamuka ve Meegama, morfolojik görüntü işleme ve bulanık mantık algoritmalarına dayalı olarak sert eksudaların tespitini gerçekleştirmişlerdir [35]. Tjandrasa vd., matematiksel morfoloji ve sonrasında özelliklerin elde edilmesi, ardından DVM sınıflandırıcı algoritması ile bu özelliklerin sınıflandırılmasına dayalı olarak sert eksudaların tespitini gerçekleştirmişlerdir [36]. Kavitha ve Shenbaga Devi, damarların çıkarımı, parlak bölgelerin çıkarımı ve sonrasında bu parlak bölgelerden OD ve sert eksudaların tespitine dayalı hızlı ve etkili bir yöntem sunmuşlardır [37]. JayaKumari ve Maruthi, görüntü işleme teknikleri ve kontrast sınırlı adaptif histogram eşitleme ön işlem aşamaları sonrasında bağlamsal kümeleme algoritması ile elde ettikleri önemli özellikleri kullanarak "Echo State Neural Network" sınıflandırıcı algoritması ile sert eksudaların tespitini gerçekleştirmişlerdir [38]. Mishra vd., geliştirdikleri yöntemde doğrusal olmayan çekirdek fonksiyonlarını kullanarak sert eksuda lezyonlarını ve ayrıca OD bölgesini tespit etmişlerdir [39]. Eadgahi ve Pourreza sert eksudaların otomatik tespitini gerçekleştirmek için ilk olarak OD ve kan damarlarının tespitini gerçekleştirmişler ve sonrasında görüntüden bu bölgelerin kaldırılmasını sağlamışlardır. Ardından Top-hat, Bottom-hat gibi

morfolojik işlemlerin karışımını uygulayarak sert eksuda lezyonlarının tespitini gerçekleştirmişlerdir [40]. Zhang vd., çoklu ölçekli korelasyon filtreleme ve dinamik eşikleme metotlarını uygulayarak aday bölgeleri çıkartmışlardır. Ardından aday bölgelerin sayısını düşürmek için damar tespiti ve bölge büyütme algoritmalarını uygulamışlardır. Sonrasında bu bölgelerin lezyonlu olup olmadığına karar vermişlerdir [41]. Hipwell vd., 102 adet görüntünün eğitimi ile elde ettikleri kurallar çerçevesinde mikroanevrizma aday bölgeleri yoğunluk ve boyut bilgilerini kullanarak sınıflandırmışlardır [42]. Saleh ve Eswaran çalışmalarında 98 adet retinal görüntüden koyu bölgelerin tespiti için OD, fovea ve retinal doku bilgilerini içeren retinal özellikleri çıkartmışlar ve sonrasında mikronevrizma ve hemorajilerin doğru bir şekilde segmentasyonu için sınıflandırma algoritmasını kullanmışlardır [43]. Sharma vd., retinal görüntülerdeki hemoraji bölgelerinin tespiti için görüntü işleme tekniklerine dayalı dinamik eşikleme algoritmasını uygulamışlardır. Uyguladıkları algoritma ile hemoraji bölgelerinin renk ve büyüklük bilgilerini kullanarak bu bölgeleri tespit etmişlerdir [44]. Saleem ve Usman Akram yaptıkları çalışmada önışleme, ışık eşikleme, aday bölgelerin çıkarımı, özellik çıkarımı ve sınıflandırılması aşamalarını içeren renk özellikleri tabanlı hemoraji lezyonlarının tespitini önermişlerdir [45]. Spencer vd., mikroanevrizmaların segmentasyonu için tophat morfolojik dönüşümünü ve sonrasında eşleştirme filtresini uygulayarak elde ettikleri görüntü üzerinde eşikleme işlemini uygulamışlar ve ikili görüntü elde etmişlerdir. Sonrasında bölgesel büyütme işlemini uygulamışlar ve elde ettikleri bölgelerin özellik bilgilerini inceleyerek mikronevrizma lezyonlarının tespitini gerçekleştirmişlerdir [46]. Zhang ve Chutatape yaptıkları çalışmada parlak ve karanlık bölgelerin farklı özelliklerini elde ettikten sonra aday parlak bölgelerin segmentasyonu için Luv renk uzayında iki aşamalı geliştirilmiş "Fuzzy C-Means" metodunu uygulamışlardır [47].

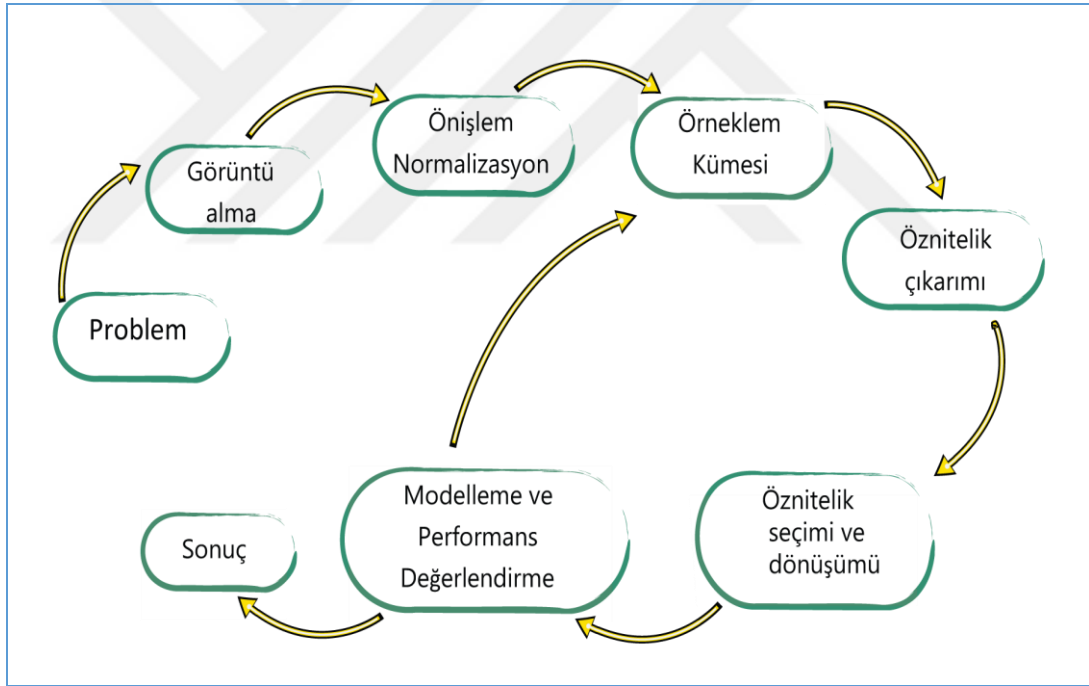
Yapılan çalışmalardan da görüleceği üzere, temel görüntü işleme algoritmaları ve morfolojik işlemlerden geçirilen görüntüler üzerinde çeşitli ayırt edici özellikler ve farklı sınıflandırıcı algoritmaları kullanılarak lezyonlu bölgeler tespit edilmektedir. Bu tez çalışmasında; temel görüntü işleme tekniklerinden farklı olarak, ilgi noktalarının çıkarımı algoritmaları ile retinal görüntülerden elde edilen ilgi alanlarının analizi hedeflenmiştir.

Birçok retinal hastalığın otomatik tespiti için retinadaki OD, damarlar ve makula gibi önemli bölgelerin tespiti ve yorumlanması son derece önemlidir. Bölüm 2.3’de detaylı bir şekilde verildiği üzere sert eksuda gibi lezyonlar genellikle belli bölgelerde kümeler halinde olur. Bu yapısal bozukluklar büyüklük ve parlaklık açısından bazen OD ile benzer özellikler de sergileyebilmektedir. Lupascu vd. %95 oranında OD’yi ve %70 oranında da OD’nin sınırlarını tespit ettikleri çalışmada, doku tanımlaması ve regresyon tabanlı metotlar kullanarak OD’yi sınırlayan en uygun daireyi bulmaya çalışmışlardır [48]. Esmaeili vd., otomatik retina taramasında önemli bir aşama olan OD’nin lokalizasyonu ve segmentasyonu işleminde sayısal "curvelet" dönüşümü ve "Canny" kenar algılama yöntemlerinden faydalanmışlardır. Daha sonra, görüntüdeki istenmeyen bölgeleri kaldırmak için morfolojik işlemleri kullanmışlardır [49]. Sinthanayothin vd., komşu pikseller arasındaki yüksek yoğunluk değişimine dayalı olarak OD bölgesinin tespitini gerçekleştirmişlerdir. Görüntüden temel bileşenler analizi ile elde ettikleri bilgileri çok katmanlı yapay sinir ağlarını kullanarak sınıflandırarak kan damarlarının tespitini yapmışlardır [50]. Park vd., eşikleme gibi basit görüntü işleme teknikleri ve Hough dönüşümü yoluyla yuvarlak bölgelerin tespitine dayalı OD tespiti yapmışlardır [51]. Lalonde vd., düşük çözünürlüklü renkli retinal fundus görüntülerini ve Hausdorff tabanlı şablon eşleme yöntemini kullanarak OD tespitini gerçekleştirmişlerdir [52]. Lu ve Him, yaptıkları çalışmada retinal görüntünün arka planını yinelemeli Savitzky-Golay yumuşatma prosedürünü uygulayarak elde etmişlerdir. Sonrasında da global eşikleme yöntemini uygulayarak OD bölgesini bulmaya çalışmışlardır [53]. Godse ve Bormane alan ve yoğunluk bilgilerini içeren kriterler çerçevesinde parlak bölgelerin çıkarımı ve eşikleme algoritmasını uygulayarak OD bölgesini tespit etmişlerdir [54]. Bir diğer çalışmada Perez vd., Haar özelliklerini ve kaskad sınıflandırıcı algoritmasını kullanarak segmente edilen ilgi alanlarından OD’yi bulmaya çalışmışlardır [55].

## BÖLÜM 4

### UYGULAMANIN GELİŞTİRİLMESİNDE KULLANILAN YÖNTEM VE TEKNİKLER

Sayısal retina görüntüleri göz hastalıklarının tespitinde alan uzmanlarının kullandıkları en önemli materyaldir. Bu materyalin işlenmesi ve lezyonlu bölgelerin tespitine yönelik tez çalışması boyunca izlenen işlem basamakları Şekil 4.1’de görülmektedir.



Şekil 4.1. İşlem basamakları.

Bir işlemler dizisi olarak yorumlanan bu süreçte anlamlı bilginin elde edilmesi ve sınıflandırılması hedeflenmiştir. Bu hedef doğrultusunda tasarım ve yazılım alanında gerçekleştirilen çalışmaların dayanağı olan teorik bilgiler bu bölümde genel çerçevede sunulmuştur.



## 4.1. GÖRÜNTÜ İŞLEME TEKNİKLERİ

Analog ortamdaki görüntünün yakalanarak sayısallaştırılması süreciyle elde edilen iki boyutlu bir vektör dizisi olarak ifade edilen ve sonlu sayıda elementten oluşan sayısal görüntünün en küçük yapı taşı pikseldir. Her bir piksele karşılık gelen bir renk değeri vardır. En çok kullanılan renk uzayı kırmızı, yeşil ve mavi ana renklerinden oluşan RGB (Red, Green, Blue) olmakla birlikte bu görüntü formatı başka formatlara da dönüştürülebilmektedir [56]. Bu alandaki uygulamalar bilgisayarlı öğrenme bilimi alanıyla doğrudan ilişkilidir. İnsanoğlunda var olan görme ve analiz etme yeteneğinin bilgisayar sistemlerine kazandırılması için görüntü işleme ve matematiksel modellere dayalı algoritmalar ile işlenen görüntülere yönelik öğrenme ve karar verme kuralları çerçevesinde sistemler tasarlanır.

### 4.1.1. Görüntü İyileştirme

Sayısal görüntüler elde edildikten sonra önışlemden geçirilir. Bu adım, bilgisayarlı görü sistemlerinin performansını en az seçilecek olan model kadar önemli derecede etkileyen ve görüntü hakkındaki verilecek olan kritik karar için çok önemli bir aşamadır.

Görüntü iyileştirme ile işleme alınan görüntüden en iyi performans elde edilmesi amaçlanır. Bu yöntem, örneğin görüntünün çok koyu, çok parlak olması gibi durumlar için renk yoğunluğunu ayarlama işlemini içerebilir. Görüntü iyileştirme işleminde kullanılan ve etkili bir yöntem olan Adaptif Histogram Eşitleme (AHE) yönteminde, görüntü üzerindeki her bir piksele tek bir global eşikleme yöntemini uygulamak yerine lokal eşikleme değerine göre en yakın komşuları kullanılarak dinamik bir şekilde piksellerin değişiklikleri gerçekleştirilir. Her  $n$  piksel komşuluğundaki her bir bölge için standart histogram eşitleme işlemi uygulanır. Optimum bölge boyutları görüntüye göre değişmektedir [57]. AHE'nin geliştirilmiş olan, Kontrast Sınırlamalı Adaptif Histogram Eşitleme (KSAHE) yöntemi ile tüm görüntü üzerinde işlem yapmaktan ziyade görüntü küçük bölgelere ayrılır ve bu bölgeler üzerinde AHE prosedürü yürütülür [58].

Görüntüdeki pikseller arası korelasyonları ortadan kaldırmak için kullanılan "whitening" metodu, görüntüdeki benzersizliklerin artmasına yardımcı olur. Böylece, en iyi düzeyde karşılaştırma sağlanmış olur. Bu nedenle, bu metot yumuşak yüzeyler için üstün bir özellik sunar [59]. Bu metot ile pikseller birbiriyle ilişkisiz yeni bir veri kümesine dönüştürülür. Temel bileşenler analizi yönteminde kullanılacak olan veriler bu metot ile elde edilen verilerdir. Böylece, görüntünün temel bileşenlerinin değişimleri normalize edilmiş olur [60].

#### **4.1.2. Görüntünün Negatifi**


Görüntünün tersinin elde edilmesi olarak bilinen negatif görüntü üretme işlemi genellikle bir görüntünün karanlık kısımlarında gizli kalan beyaz ya da gri seviyeli ayrıntıları açığa çıkarmak için kullanılmaktadır [56].

#### **4.1.3. Morfoloji**


Yapı elemanının büyüklüğü ve şekli seçilerek giriş görüntüsünde belirli şekillere duyarlı bir işlem yürüten morfoloji işlemi, giriş görüntüsü ile aynı boyutta bir çıkış görüntüsünün elde edilmesi esasına dayanır. Çıkış görüntüsündeki her bir pikselin değeri giriş görüntüsündeki ilgili pikselin komşularıyla karşılaştırılması sonucu elde edilir [57,61].

#### **4.1.4. Bağlantılı Bileşen Etiketleme (BBE)**

Bir görüntüdeki birbirinden bağımsız yapıların etiketlenmesi ve bu yapıları oluşturan piksellerin koordinatlarının kayıt altına alınması işlemidir [57]. Örneğin Şekil 4.2.a'daki RGB görüntüsünden elde edilen Şekil 4.2.b ikili görüntüsünde "1" yoğunluk değerine sahip piksellerin ayrı ayrı oluşturdukları gruplar birbirlerinden bağımsız yapıları oluşturmakta ve dört ayrı bağlantılı bileşen bulunmaktadır. BBE yöntemi kullanılarak elde edilen Şekil 4.2.b'deki gibi küçük bölgelerin ortadan kaldırılması işlemi; literatürdeki [62] nolu referans doğrultusunda S adet pikselden oluşan ilgi alanının matematiksel alan değeri belirtilen büyüklükten az ise bu bölgedeki piksellerin değerlerinin "0" a eşitlenmesidir.



a) Retina görüntüsü



b) Retinadan elde edilen bölgeler


Şekil 4.2. BBE yönteminin uygulanması ile görüntüden elde edilen bölgeler.

## 4.2. İLĞİ NOKTALARININ ÇIKARIMI

İlgi noktaları bir görüntüde değişimin olduğu bölgelerde en büyük tepkiyi veren noktalardır. [63-66] arasındaki literatür çalışmalarında görüleceği üzere ilgi alanları, görüntü ile ilgili anlamlı bilgileri elde etmemize yarayan ilgi nokta çıkarım algoritmaları ile otomatik olarak tespit edilir [67]. Bu tez çalışmasında görüntüdeki ilgi noktaları, literatürde yaygın olarak kullanılan ve sırasıyla [68] ve [69]'da tanıtımı yapılan yönlendirilmiş ve döndürülmüş ikili gürbüz bağımsız temel özellikler algoritması olan ORB (Oriented FAST and Rotated BRIEF) ve hızlandırılmış gürbüz özellikler algoritması olan SURF (Speeded Up Robust Features) ile elde edilmiştir.

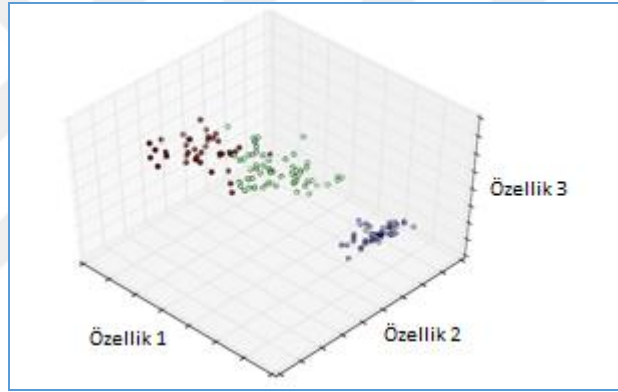
## 4.3. ÖZNETELİK ÇIKARIMI

İlgi noktalarının bulunmasından sonra bu noktaların içinde yer aldığı ilgi alanlarından anlamlı bilgi elde edilir. Şekil 4.3'te bir retinal görüntüden elde edilen örnek bir ilgi alanı kümesi görülmektedir. Öznitelik çıkarımı da denilen bu aşamada ilgi alanını en iyi temsil edecek olan öznitelikler vektörü oluşturulurken "en doğru sonucu veren öznitelik algoritması hangisidir?" sorusunun cevabı için birçok algoritma ile çalışılır. Öznitelik çıkarımı veya öznitelik seçimi işleminden önce yürütülen ve problemin çözümünün çekirdeğini oluşturduğu için önemli bir adım olan öznitelik tanımlama süreci, problemin doğasına bağlı olarak deneysel çalışmalar ile yürütülen ve yüksek öneme sahip bir konudur.



Şekil 4.3. İlgili noktaları etrafındaki dörtgensel bölgelerden bir örneklem.

Bir amaç doğrultusunda yürütülen bu prosedür ile elde edilen anlamlı bilgi görüntünün karakteristik özneliklerini içerir [70]. Örneğin 3 öznelik bilgisi içeren bir öznelik uzayına ait bilgilerin grafiksel gösterimi temsili olarak Şekil 4.4’de görülmektedir. Bu özellikler kullanılarak ilgili alanın sınıflandırılması veya analizi gerçekleştirilebilir.



Şekil 4.4. Veri uzayının görselleştirilmesi.

#### 4.3.1. Gabor Öznelikleri (GÖ)

Öznelik çıkarımında yaygın olarak kullanılan Gabor filtresi ile görüntüde var olan ışık dağılımının homojen olmamasının oluşturduğu negatif etkiler yok olmaktadır [71].  $\theta$  uzaysal frekansı,  $\exp=2.718$  hata terimini,  $\phi$  yönelimi ifade etmek üzere iki boyutlu görüntüler için Gabor filtresi Eşitlik 4.1’deki gibi ifade edilir. Bu eşitlikteki  $\sigma$ ,  $\theta$  uzaysal frekansına bağlı olarak Gabor çekirdeğinin standart sapmasını ifade eder [72].

$$g(x, y, \theta, \phi) = \exp\left(-\frac{x^2+y^2}{\sigma^2}\right) \exp(2\pi\theta i(x\cos\theta + y\sin\theta)) \quad (4.1)$$

Gabor filtresinin görüntü üzerinde uygulanmasının sonucu iki boyutlu konvolüsyon işlemi olarak ifade edilir.  $I(x,y)$  görüntüyü temsil etmek üzere  $G(x,y,\theta,\phi)$ ;  $x,y$  koordinatındaki görüntünün  $\theta$  frekanslı,  $\phi$  yönelimli Gabor filtresinin sonucunu gösterir ve Eşitlik 4.2'deki gibi ifade edilir [72].

$$G(x,y,\theta,\phi) = \iint I(p,q)g(x-p,y-q,\theta,\phi)dp dq \quad (4.2)$$

Gabor filtresinin uygulandığı bir görüntüde filtre ile aynı yerel frekans ve yöndeki nokta en güçlü cevap verecek nokta olacaktır. Değişik açı ve frekanslar kullanılarak değişik niteliklere sahip Gabor filtreleri ile filtre bankası oluşturulabilmekte ve görüntünün detaylı bir şekilde analizi yapılabilmektedir [71-72].

#### 4.3.2. Ayrık Fourier Dönüşümü Öznitelikleri (AFDÖ)

Görüntüyü sinüs ve kosinüs bileşenlerine ayıran ve önemli bir görüntü işleme tekniği olan Fourier dönüşümü ile periyodik olmayan fonksiyonlar, belli bir ağırlık fonksiyonu ile çarpılmış sinüs veya kosinüslerin integrali şeklinde ifade edilir. Fourier dönüşümü şeklinde ifade edilmiş bir işarete ters dönüşüm işlemi uygulanarak hiçbir bilgi kaybı olmadan bu işaret tekrar elde edilebilir. Yani, Fourier dönüşümü ile frekans düzlemine geçilir ve gerekli işlemler yapılarak ardından ters dönüşüm işlemi ile uzaysal düzleme geri dönülebilir. Fourier dönüşümü çıktısı frekans uzayındadır ve çıktındaki her bir nokta görüntü üzerinde belirli bir frekansı ifade eder. Ayrık Fourier dönüşümünde, tüm frekanslar kullanılmadan görüntünün uzaysal olarak ifade edilmesine yetecek sıklıkta örneklenmiş frekans aralıkları üzerinde çalışılır [57].  $M \times N$  boyutundaki bir matriste,  $\exp=2.718$  hata terimini ifade etmek üzere ayrık fourier dönüşüm çifti Eşitlik 4.3 ve 4.4'te verilmiştir [57].

$$F(u,v) = \frac{1}{MN} \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x,y) \exp(-j.2\pi((ux/M) + (vy/N))) \quad (4.3)$$

$$f(x,y) = \sum_{u=0}^{M-1} \sum_{v=0}^{N-1} F(u,v) \exp(j.2\pi((ux/M) + (vy/N))) \quad (4.4)$$

#### 4.4. ÖZİNİTELİK DEĞERLENDİRME

Bir verisetini onun orijinal ilk halini temsil eden daha küçük bir boyuta indirmeyi amaçlayan öznelik seçimi makine öğrenmesinde iyi bilinen bir konudur ve bu konuda sayısız çalışma yapılmaktadır.

Sınıflandırma algoritmalarının yürütme zamanlarının hızlı olmasını sağlayacak olan önemli özneliklerin seçilmesi ile boyutu azalan veri, ideal olarak yüksek ayırım gücü ve yüksek güvenilirliğe sahip esas bilgiyi korumalıdır. Böylece daha iyi performanslı sınıflandırma modellerinin elde edilmesi sağlanır [73]. Bu doğrultuda, tanımlayıcı algoritmaları ile elde edilen özellikler kümesinden önemli özelliklerin elde edilmesiyle veri uzayının indirgenmesi ve de bu sayede sistemin performansının yüksek olması amaçlanır. İlgili nokta tespit algoritmaları ile elde edilen ilgili nokta sayısı lezyonlu bölgelerin sayısına bağlı olarak oldukça çok olabilmektedir. Bu da, "Bu bölge lezyonlu mudur?" sorusuna yanıt bulabilmek için ilgili nokta sayısınca bölgenin analizinin yapılacağı anlamında gelmektedir. Çok boyutlu veriler üzerinde birçok boyut düşürme algoritması bulunmakla birlikte bu tez çalışmasında kullanılan metotlar şunlardır:

##### 4.4.1. Yinelemeli Öznelik Elemesi (YÖE - Recursive Feature Elimination)

YÖE algoritması  $r < n$  girdi boyutlarında olmak üzere sınıf ayırımını en iyi gerçekleştiren en iyi alt küme  $r$  özneliğini seçmeye çalışır [73-74]. Orijinal özneliklerin doğrusal kombinasyonları ile elde edilen öznelikler kümesi orijinal verinin özelliklerini taşımaz. Bu nedenle çalışmayı negatif yönde etkiler. Ayrıca, tanımlayıcı algoritmalar ile elde edilen öznelik vektörleri her zaman tam olarak bilgiyi tanımlamaz ve öğrenme sürecinin yavaş olması, gürültü ve ezberleme negatif durumlarını doğurabilir [74]. Bu sakıncaların üstesinden gelebilmek için orijinal özneliklerden önemli özneliklerin elde edilmesi amaçlanır. Özellik oylama teknikleri bilhassa özellik seçimini yürütürken çok faydalıdır. Kullanılmayan özellikler tam olarak özellikler kümesini temsil etmediği için yok edilir. Bu özellik seçimi yaklaşımında bir veriseti içerisindeki özelliklerin önem sırasına göre sıralandırılmasında ve anlamsız özelliklerin belirlenmesinde özyinelemeli olarak geri

yönlü seçim yöntemi kullanılmaktadır [74-75]. Bu oylama kriteri için Eşitlik 4.5'deki gibi çeşitli korelasyon katsayıları kullanılır [74].

$$w_i = (\mu_i (+) - \mu_i (-)) / (\sigma_i (+) + \sigma_i (-)) \quad (4.5)$$

Burada,  $w_i$  her bir özneliğin ağırlığını ifade etmek üzere hasta ve hasta değil olarak sınıflandırılan tüm verisetindeki her bir özneliğin ortalaması ve standart sapması sırasıyla  $\mu_i$  ve  $\sigma_i$ 'dir. Bu eşitlik ile elde edilen büyük negatif  $w_i$  değerleri hasta olanlar arasında güçlü bir korelasyon olduğunu belirtir. Her bir katsayının hesaplanmasında her bir özneliği tanımlayan anlamlı bilgi kullanılır ve öznelikler arasındaki karşılıklı ilişkinin bir önemi yoktur. Bu nedenle, öznelikler arasındaki karşılıklı ilişki yok sayılır. Öznelik oylamasının bir yolu sınıf tanımlayıcısını özneliklerin oylaması ile ağırlıklandırmaya dayalı tasarlamaktır. Ağırlıklandırılmış oylama şeması, Eşitlik 4.6'da ifade edildiği üzere özel bir doğrusal ayırıcı sınıflandırıcısını sağlar [74].

$$D(x) = w \cdot (x - \mu) \quad (4.6)$$

Bu eşitlikteki  $w$ , Eşitlik 4.5'de ifade edilmiştir ve  $\mu$  Eşitlik 4.7'de ifade edildiği gibidir [74].

$$\mu = (\mu(+)) + \mu(-) / 2 \quad (4.7)$$

Burada  $\mu$ , tüm eğitim kümeleri ile hesaplanan ortalama vektör bilgisidir. (+) ve (-) sırasıyla pozitif ve negatif eğitim kümesini ifade eder. İlk yöntem, doğrusal ayırıcı sınıflandırıcısının ağırlıkları doğrultusunda oylanan özelliklerdir. İdeal olanı elde etmek için eğitim verileri üzerinde her bir özneliğin ağırlığı hesaplanır. Bu aşamaların sonucunda öznelik setinden elde edilen iyi özellikler en iyi düzeyde elde edilmiş olur ve bu şekilde öznelik seçimi diğer bir deyişle öznelik eleme süreci tamamlanmış olur [74].

#### 4.4.2. Spektral Regresyon Diskriminant Analizi (SRDA - Spectral Regression Discriminant Analysis)

Doğrusal regresyon problemleri kümesinden dönüşüm vektörlerinin elde edildiği etkili ve yeni bir yöntem olan SRDA [76], boyut düşürme yöntemlerinden biri olan doğrusal diskriminant analizinin graf tabanlı formülasyonlarını içerir. Bu yöntem ile boyut düşürmenin amacı X veri uzayını en iyi temsil edebilmek ve anlamlı bilgiyi çıkarabilmektir [76-77]. Bu metod, özdeğer bilgilerini içerir. İnşa edilen regresyon yapıları ile düzenleme tekniklerinin birçoğu kolay bir şekilde SRDA ile birlikte çalıştırılarak üzerinde çalışılan veri grubu için daha fazla esneklik kazandırılmaktadır. Bu yöntem, denetimli, denetimsiz ve yarı denetimli sistemlerde kullanılmaktadır [77].

Her bir vektör bilgisini düşük boyutta göstermek için kullanılan ve verilerin vektör olarak temsil edildiği M köşeli G grafında; W mxm simetrik matrisini ve  $W_{i,j}$  i,j köşesinin ağırlığını ifade eder. Gerçek graf yapısından  $y=[y_1,y_2,y_3\dots y_m]$  haritalaması gerçekleştirilir. D diyagonal matris olmak üzere, L Laplas matrisi Eşitlik 4.8 ile elde edilir ve Eşitlik 4.9'da ifade edilen uygun bir sınırlamama ile en iyi y elde edilir [77-78].

$$L = D - W \quad (4.8)$$

$$\sum_{i,j} (y_i - y_j)^2 W_{i,j} \quad (4.9)$$

Eşitlik 4.10'da ifade edildiği üzere bu graf yapısında i,j köşesinin  $y_i$ 'ye çok yakın olması amaçlanır [77].

$$\sum_{i,j} (y_i - y_j)^2 W_{i,j} = 2y^T Ly \quad (4.10)$$

#### 4.5. SINIFLANDIRMA VE ÖĞRENME

Görüntü işleme ve bilgisayarlı görü uygulamaları ile yapılan çalışmalarda analizi yapılan ilgi alanının doğru bir şekilde tespit edilmesi amaçlanır. Bu doğrultuda,



makine öğrenmesi için gerekli ve önemli bir süreç olan sınıflandırıcı algoritmalarının öğrenmesi süreci icra edilir. Bu süreç, eğitim ve test aşamalarını içerir. Eğitim aşamasında verilerin öznitelik vektörü ve gerçek sonuç değerleri girdi olarak verilir ve sistem o öznitelik vektörü ile hangi çıktının üretilmesi gerektiğini öğrenir. Bu şekilde kendini eğitir ve önceki bilgilerin ışığında yeni gelen verinin hangi sınıfa ait olduğuna karar verir. Eğitim verileri uzayı ne kadar iyi örneklerse sistemin başarımı o kadar artar.

Yapılan sınıflandırmanın doğruluğunun analizinin deneysel çalışmalar ile yürütüldüğü ve uzun soluklu bir süreç olan bu süreçte "hangi veri uzayı ile çalışılmalıdır?" sorusu çerçevesinde seçilen özelliklerin veriyi sınıflandırmaya elverişli olup olmadığı bulunmaya çalışılır. Sınıflandırmada belirlenmesi gereken bir diğer konu da hangi sınıflandırıcı algoritması ile "model" oluşturulacağı sorusunun cevaplanmasıdır. Bu süreçte farklı sınıflandırıcı algoritmaları kullanılarak sınıflandırmaya dâhil olan tüm içerik aynı iş akışından geçirilir ve böylece dâhil oldukları sınıfları bulma işlemi tamamlanmış olur. Böylece, her bir sınıflandırıcının performansı analiz edilmiş olur.

#### **4.5.1. Lojistik Regresyon (LR)**

Epidemiyolojik araştırmalarda çok değişkenli problemlerin tanımı yapılır. Bu araştırmalardaki genel soru, "hastalık ile hastalığa neden olan, hastalığa maruz bırakan bir veya daha fazla değişkenler arasındaki ilişki nedir?" sorusudur ve hastalığın olması "1", hastalığın olmaması "0" ile ifade edilir [79-80].

Normal dağılım varsayımı ve süreklilik varsayımı ön koşulu olmayan LR yöntemi, sınıflandırma ve atama işlemi yapmaya yardımcı olan bir regresyon yöntemidir [81]. Eşitlik 4.11'deki P incelenen olayın gözlenme olasılığını göstermek üzere, incelenen bir olayın olma olasılığının kendi dışında kalan diğer olayların olasılığına oranına Odds değeri denir ve LR bu değeri temel alır [82-83].

$$\text{Odds} = \frac{p}{(1-p)} \quad (4.11)$$

LR modeli, genel doğrusal modellerin binom dağılımlı bağımlı değişkenler için elde edilmiş olan özel bir biçimidir ve Eşitlik 4.12'deki gibi ifade edilir [81,84].

$$P = \frac{e^{\beta_0 + \beta_1 X_1 + \dots + \beta_p X_p}}{1 + e^{\beta_0 + \beta_1 X_1 + \dots + \beta_p X_p}} \quad (4.12)$$

Bu eşitlikteki [81];

- P : İncelenen olayın gözlenme olasılığını,  
 $\beta_0$  : Bağımsız değişkenler sıfır değerini aldığı anda bağımlı değişkenin değerini başka bir ifadeyle sabiti,  
 $\beta_1 \beta_2 \dots \beta_p$  : Bağımsız değişkenlerin regresyon katsayılarını,  
 $X_1 X_2 \dots X_p$  : Bağımsız değişkenleri,  
p : Bağımsız değişken sayısını,  
e : 2,718 hata terimini ifade etmektedir.

#### 4.5.2. Rastgele Orman (RO)

Karar ağaçlarının birleştirilmesi ile elde edilen ve Breiman tarafından tanımlanan RO [85] algoritmasında her bir düğümdeki rastgele seçilen değişkenler arasından en iyisi seçilir. Bu algoritma ile her bir düğümde kullanılacak örneklerin ve oluşturulacak ağacın sayısı belirlenerek ağaç yapısı oluşturulur. Her bir düğümde en iyi dallanmayı sağlamak için seçilen özniteliklerin başarısı araştırılır. RO, bu ağaçlar içerisinde en fazla oya sahip olan sınıfa geçer ve bu şekilde yeni verisetinin sınıflandırma işlemi tamamlanmış olur [86-88].

Bu tez çalışması boyunca birçok sınıflandırıcı algoritması ile çalışılmış olmakla birlikte nihai olarak LR ve RO algoritmaları geliştirilen uygulamaya dâhil edilmiştir.

#### 4.6. KARAR DESTEK SİSTEMLERİ

Tıbbi uygulamalarda etkin ve verimli bir tıbbi tanı için karar verme çok önemlidir. Çünkü hastalığın bu aşamadan sonraki seyri uygulanacak adımlar doğrultusunda olumlu veya olumsuz bir şekilde değişecektir. Karar destek sistemleri, belirli bir

amaç doğrultusunda tasarlanan ve anlamlı bilginin çıkarımı ve analizi ile uzman kişinin karar vermesine yardımcı olan sistemlerdir. Bu sistemler hastanın tedavisi için bir öneri ve gelecek için iyi bir değerlendirme sunabilecekleri gibi karar verme aşamasında olan alan uzmanlarına yardımcı olurlar. Ayrıca bu sistemleri, tıp alanındaki bilgilerin çıkarımı, değerlendirilmesi, analizi ve saklanması süreçlerinin tamamı ile ilişkilendirmek mümkündür. Diğer yandan, medikal görüntülerin yorumlanmasında alan uzmanlarına yardımcı olan bu sistemler, hastalığı öğrenme ve algılama sürecinde işlem yükünü azaltmak ve tespit doğruluğunu arttırmak için etkili bir çözüm sunarlar [89].

#### **4.7. PERFORMANS DEĞERLENDİRME**

"İşleme alınan bölge hastalıklı mı değil mi?" sorusu tıp alanında cevaplanması gereken en önemli sorudur. Bu sorunun cevabını öğrenebilmek için üzerinde çalışılan sayısal görüntünün çeşitli yöntem ve tekniklerle analiz edilerek hastalık var ya da yok şeklinde iki sınıfa ayrılması amaçlanır. Kurgulanan modellerin başarı testinin, öğrenme veri kümesinin dışında bir veri kümesi ile yapılması gerekir. Bu kümeye test kümesi denir. Bu sebeple orijinal veriseti, öğrenme ve test veri kümesi olmak üzere ikiye ayrılır.

Birçok sınıflandırma çalışmasında test sonuçlarının çok daha güvenilir ve belirleyici olabilmesi için k-kat (fold) çapraz doğrulama yaygın olarak kullanılır. Eğitimin rastgele örneklenmesi ile ilgili hataların en aza indirildiği ve makine ezberlemesinin önüne geçildiği bu yöntem ile Çizelge 4.1'de temsili olarak gösterildiği üzere eğitim ve test verileri çapraz olarak yer değiştirilir. Yani, tüm veri k sayısı kadar yaklaşık olarak eşit büyüklükteki alt verisetlerine bölünür ve ardından sınıflandırıcı algoritması k defa eğitilir ve test edilir. Test verisi olarak her defasında katlardan bir tanesi alınırken geriye kalan katlar ile eğitim verisi oluşturulur [90-91]. Sonuç itibarıyla her eğitim-test yapılandırması için k tane farklı test sonucu bulunmuş olur. Algoritmanın test doğruluğunu, [90] çalışması referans alınarak bu sonuçların ortalaması vermektedir.

Çizelge 4.1. 5-katlı çapraz doğrulama örneği.

Test veriseti	Eğitim veriseti	Eğitim veriseti	Eğitim veriseti	Eğitim veriseti
Eğitim veriseti	Test veriseti	Eğitim veriseti	Eğitim veriseti	Eğitim veriseti
Eğitim veriseti	Eğitim veriseti	Test veriseti	Eğitim veriseti	Eğitim veriseti
Eğitim veriseti	Eğitim veriseti	Eğitim veriseti	Test veriseti	Eğitim veriseti
Eğitim veriseti	Eğitim veriseti	Eğitim veriseti	Eğitim veriseti	Test veriseti

Doğruluk analizi, sınıflandırma işlemi sonrasında oluşan sınıfların doğruluklarını belirlemek amacı ile yapılan işlemdir. Literatürde "altın standart" tekniği diye adlandırılan bu test ile elde edilen deneysel sonuçlar ve kesin doğru sonuçlar kıyaslanarak algoritmaların başarısı değerlendirilir. Çizelge 4.2'de iki sınıflı bir veri kümesinde oluşturulmuş bir modelin karışıklık matrisi verilmiştir. Bu matriste satırlar örneklere ait gerçek bulguları, sütunlar ise modelin tahminlemesini ifade eder [92].

Çizelge 4.2. İki sınıflı bir veri kümesinde karışıklık matrisi.

		Öngörülen Sınıf	
		Lezyon var (1)	Lezyon yok (0)
Gerçek Sınıf	Lezyon var (1)	D <sub>p</sub>	Y <sub>n</sub>
	Lezyon yok (0)	Y <sub>p</sub>	D <sub>n</sub>

Bir görüntüde işleme alınan ilgi alanı ile ilgili olarak "pozitif" gözlem yapısal bozukluk var (1), "negatif" gözlem ise yapısal bozukluk yok (0) anlamına gelir ve tanı testini değerlendirirken karşılaşılabilecek durumlar şunlardır:

- D<sub>p</sub>, gerçek pozitif olan hastaların pozitif olarak bulunması,
- D<sub>n</sub>, gerçek negatif olan hastaların negatif olarak bulunması,
- Y<sub>p</sub>, gerçek negatif olan hastaların pozitif olarak bulunması,
- Y<sub>n</sub>, gerçek pozitif olan hastaların negatif olarak bulunması.

Hastalık vardır ya da yoktur tespiti verisetindeki tüm öğeler için yapılır ve Duyarlılık (Du), Seçicilik (Se) ve Doğru sınıflandırma oranı (Dso) değerlendirmeleri ile sistemin performansı test edilir.

Eşitlik 4.13'deki  $D_u$ , toplam hasta olanların içinde gerçek doğru bulunan hasta sayısının oranıdır yani hasta olan bölgelerin hasta olarak sınıflandırılması yüzdesini ifade eder. Eşitlik 4.14'deki  $S_e$ , toplam hasta olmayanların içinde gerçek doğru bulunan hasta olmayanların sayısının oranıdır. Model başarısının ölçülmesinde en çok kullanılan belirleyici ölçüt olan Eşitlik 4.15'deki  $D_{so}$  değeri, doğru tanı konmuş örnek sayısının toplam örnek sayısına oranı şeklinde ifade edilebilir [92].

$$D_u = D_p / (D_p + Y_n) \quad (4.13)$$

$$S_e = D_n / (D_n + Y_p) \quad (4.14)$$

$$D_{so} = (D_p + D_n) / (D_p + Y_p + D_n + Y_n) \quad (4.15)$$

Bu değerler ideal düzeyde değilse Şekil 4.1'de görüldüğü üzere sistemin iş akışındaki her bir süreç gözden geçirilerek iyileştirmeler sağlanır.

## BÖLÜM 5

### GELİŞTİRİLEN KARAR DESTEK SİSTEMİ UYGULAMASI

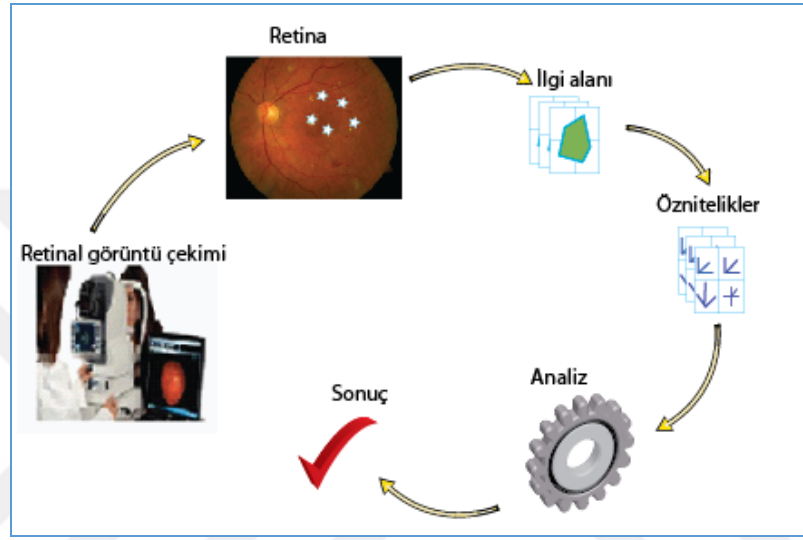
Bu tez çalışması boyunca geliştirilen uygulama ve deneysel çalışmalar Python 2.7 platformunda gerçekleştirilmiştir. Görüntü işleme için scikit-image ve numpy kütüphaneleri, öğrenme için "scikit-learn" ve "mlpy" makine öğrenmesi kütüphaneleri sisteme dâhil edilerek yazılım kodları geliştirilmiştir. Verilerin saklanması ve ilgili arayüzlerde bu saklı verilerin kullanılabilmesi için MySQL 6.3 yazılımı da sisteme dâhil edilmiştir. Bu yazılım üzerinde varlık-ilişki modeli çerçevesinde veritabanı ve tablolar hazırlanmıştır.

#### 5.1. VERİSETİ

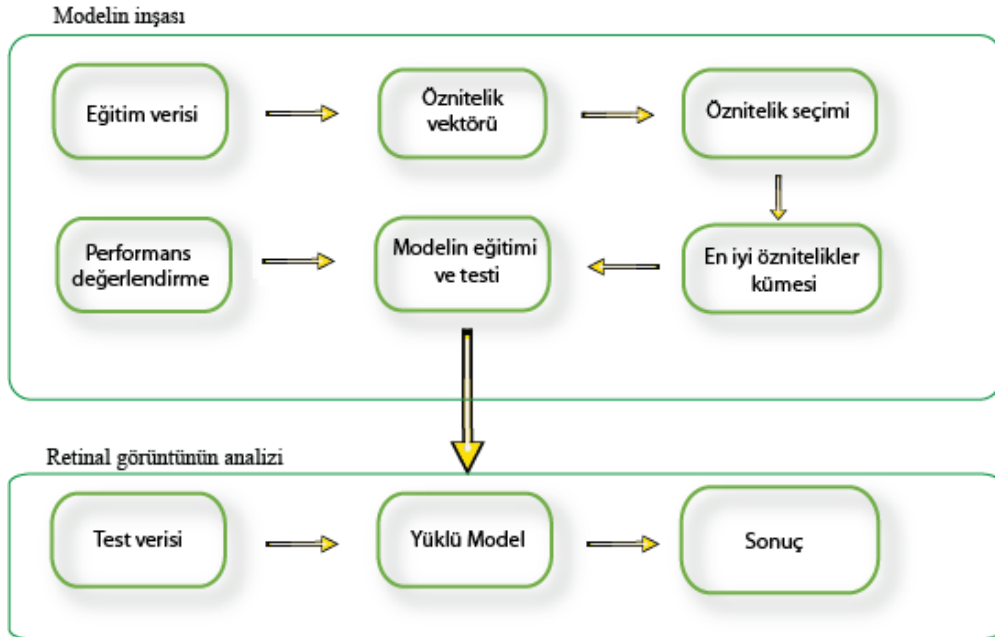
Bu çalışmada Ankara Atatürk Eğitim ve Araştırma Hastanesi Göz anabilim dalından alınan 178 adet retina görüntüsü ile genel kullanıma açık olan DIARETDB1 (Standard Diabetic Retinopathy Database) verisetindeki 89 adet retina görüntüsü kullanılmıştır. Her iki verisetindeki görüntüler 24 bit derinliğe sahip olmak üzere, yerel görüntüler 2304x1536, DIARETDB1 görüntüleri ise 1500x1152 boyutlarındadır. Bu iki verisetindeki görüntülerden faydalanılarak elde edilen örneklem kümesi ile sistemin öğrenme süreci tamamlanmıştır. Yeni retinal görüntülerin analizi ile deneysel bulgular elde edilerek sistemin ezberlemesinin ya da belirli görüntüler üzerinde çalışılmasının önüne geçilmiştir. Ayrıca, tez çalışması kapsamında OD'nin tespiti için önerilen yöntemin eğitim ve test aşamalarında DIARETDB1, DRIVE (Digital Retinal Images for Vessel Extraction) ve ROC(Retinopathy Online Challenge) verisetleri kullanılmıştır. DRIVE ve ROC verisetlerinde sırasıyla 40 ve 100 adet RGB retina görüntüsü bulunmaktadır.

## 5.2. MODEL OLUŞTURMA SÜRECİ

EEDR hastalığı ile ilgili olarak, otomatik tespit ve bölütleme çalışmaları son yıllarda büyük ivme kazanmış olmakla birlikte her geçen gün yöntemlere yeni yetkinlikler eklenmektedir. Ayrıca, bu hastalığın düzenli muayene gerektirmesi ve uzman azlığı, otomatik sistemler ile yürütülmesi gereken işlemleri zorunlu hale getirmektedir.



Şekil 5.1. Geliştirilen uygulamanın çalışma şeması.



Şekil 5.2. Geliştirilen uygulamanın iş akışı.

Literatür arařtırmalarından yola çıkılarak ve doku sınıflandırma yaklaşımı referans alınarak geliştirilen EEDR lezyonlarının tespiti uygulaması temel olarak modelin inşası ve yeni retinal görüntülerin analizi süreçlerini içermektedir. İlgili alanlarına ait özniteliklerin çıkarımı, öznitelik seçimi, en iyi başarıyı sağlayan modellerin elde edilmesi ve görüntüdeki lezyonların tespiti için karar desteęi sağlayan bu uygulamada alan uzmanının anlama ve kavrama ile ilgili bilişsel yeteneklerini geliştirerek karar vermesine yardımcı olan arayüzler de bulunmaktadır.


Geliştirilen bu uygulamanın genel çalışma şeması Şekil 5.1’de, uygulamanın geliştirilmesinde izlenmiş olan iş akışı Şekil 5.2’de verilmiştir.

### **5.2.1. Uygulamanın Geliştirilmesi**


Hastalardan alınan retinal görüntülerin çekilmesi sırasında retina tabakası üzerine düşen ışığın farklı yoğunlukta olmasından dolayı elde edilen retina görüntüleri üzerinde birtakım gürültüler ve eşit olmayan aydınlatmalar meydana gelmektedir. Lezyonların tespitini başarılı bir şekilde gerçekleştirebilmek için retina görüntüsünün bu gibi durumlardan mümkün olduğunca arındırılması gerekmektedir. Bu nedenle RGB renk uzayındaki retina görüntüsü üzerinde "whitening" ve KSAHE ön işleme teknikleri uygulanarak iyileştirme sağlanması ve böylece görüntünün analize hazır hale getirilmesi hedeflenmiştir.

Dięer yandan, lezyonların belirli ölçeklerde bir yapıya sahip olmaması ve hastalığın seyrine göre yayılım göstermesi nedeniyle görüntü segmentasyonu bu çalışmada tercih edilmemiştir. Görüntüdeki renk deęişimlerinin olduğu keskin hatların bilgisini verebilecek olan ilgi nokta algoritmaları ile elde edilen ilgi alanlarının analizi tercih edilmiştir. Uzman görüşü referans alınarak elde edilen sonuçlar doğrultusunda sistemin başarısı değerlendirilmiştir.





Şekil 5.3. Önişlem süreci, a) RGB görüntüsü, b) RGB görüntüsünün "whitening" ile iyileştirilmesi (önişlem-1), c) b görüntüsünün KSAHE ile iyileştirilmesi (önişlem-2), d) c görüntüsünün tersi.



Şekil 5.4. Parlak bölgelerin çıkarımı ve eşikleme işlemleri, a) Eksuda için, b) Hemoraji ve mikronaevrizma için, c) a görüntüsünün eşiklenmesi ile elde edilen görüntü, d) b görüntüsünün eşiklenmesi ile elde edilen görüntü.

Burada dikkat edilen husus, Şekil 5.3.a'daki RGB görüntüsüne Şekil 5.3.b,c ve d'de görüldüğü üzere sırasıyla sert ve yumuşak eksuda lezyonları için "whitening" ve KSAHE yöntemleri, hemoraji ve mikroanevrizma lezyonları için ise KSAHE algoritması ile elde edilen görüntünün tersi işlemi uygulanmıştır. Ardından, Şekil 5.3.c ve d'deki görüntülere parlak bölgelerin çıkarımı algoritması uygulanarak Şekil 5.4.a ve b'deki gibi elde edilen görüntüler üzerinde eşikleme işlemi uygulanmış ve Şekil 5.4.c ve d'deki ikili görüntüler elde edilmiştir. Sonrasında, Şekil 5.4.a ve b görüntüleri üzerindeki ilgi noktaları, ilgi nokta çıkarım algoritmaları ile elde edilmiştir.

Literatürde çeşitli morfolojik işlemlerle bu bölgelerin tespitine yönelik çalışmalar yapılmış olduğu görülmekle birlikte, Şekil 5.5'te iki farklı retinal görüntüden çıkartılan parlak bölgelerin eşiklenmesi işlemi sonucu elde edilen görüntüler görülmektedir. Buradan da anlaşılacağı üzere sadece eşikleme işlemi uygulayarak istenilen sonuç elde edilememektedir.

Bu bilgi doğrultusunda, sonraki aşamada ilgi noktaların tespiti algoritması Şekil 5.4.a ve 5.4.b görüntüleri üzerinde uygulanarak renk değişimlerinin olduğu bölgeler için ilgi noktaları elde edilmiştir. Bunun için ayrı ayrı ORB ve SURF algoritmaları ile çalışılmıştır. Deneysel çalışmalarda bu algoritmaların performansının bazı retina görüntülerinde yetersiz, bazılarında oldukça başarılı olduğu görülmüştür. Bu nedenle, bu algoritmalar ile elde edilen ilgi noktalarının tümünün yer aldığı bir ilgi noktası listesi oluşturularak analiz süreci yürütülmüştür.



Şekil 5.5. Eşikleme işleminin farklı retinal görüntülerdeki sonucu.


OD ve makula bölgesindeki ilgi noktalarının işleme alınmaması için yürütülen aşağıdaki sözde kod prosedürü gerçekleştirilerek Şekil 5.6.a ve b'de görüleceği üzere bu alanların sınırları dâhilinde bulunan ilgi noktalarının işleme alınmaması sağlanmıştır. Böylece işleme alınan ilgi noktaları Şekil 5.6.c ve d'deki gibi olmuştur. Yani, Şekil 5.6.c ve d'deki sarı renkteki çembersel alanlar sırasıyla optik disk ve makula bölgeleridir. Bu alanlar üzerindeki ilgi noktalarının işleme alınmaması sağlanmıştır.

```
def point_in_optik_disk_and_macula_region(Nokta):
```


```
    Noktanın X-Y koordinatlarını elde et.
```

```
    X ve Y bilgisinin optik disk sınırları içinde olup olmadığını kontrolünü yap
```


```
    Sonuç pozitif ise bu koordinat bilgisini analize alma. Aksi durumda bu  
    koordinatın içinde bulunduğu ilgi alanını analiz et.
```




(a)



(b)



(c)



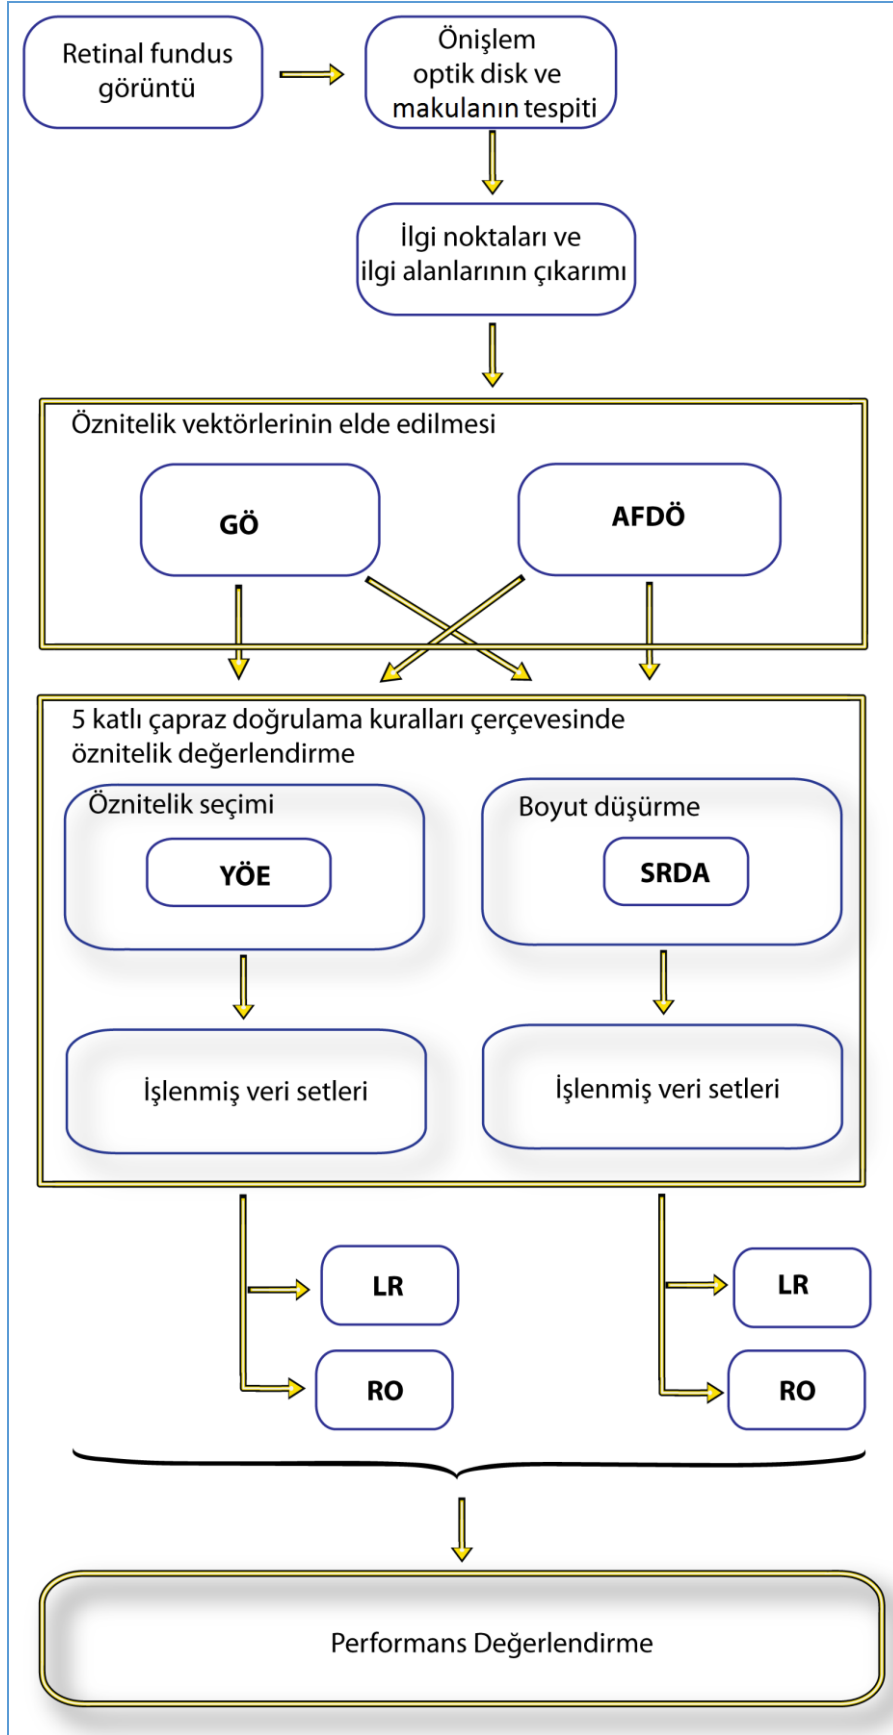
(d)

Şekil 5.6. Retinal görüntülerden elde edilen ilgi noktaları, a) Eksuda için ilgi noktaları, b) Hemoraji ve mikroanevrizma için ilgi noktaları, c) ve d) Belirgin oluşumlar üzerindeki ilgi noktalarının elimine edilmesi.

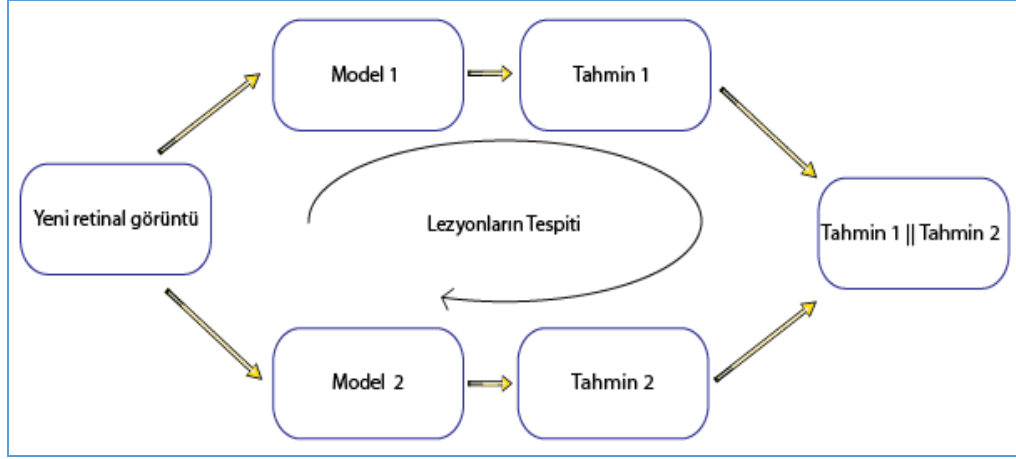
Görsel verilerin sınıflandırılması, iyi bir temsil yöntemi gerektirmektedir. Bilindiği üzere, model oluştururken veya analiz yaparken verilerin ilgi alanını en iyi şekilde temsil edecek nitelikte olması, modelin güvenilir olması için ön koşuldur ve daha sonraki aşamaların performansını doğrudan etkilemektedir. Uzun soluklu deneysel çalışmaların sonucunda anlamlı bilginin çıkarımı için diğer birçok öznelik algoritmalarıyla çalışmakla birlikte en iyi performansı sunan GÖ ve AFDÖ ile çalışılmasına karar verilmiştir.

Bölüm 2 Şekil 2.6.c ve 2.6.d’de görüldüğü üzere retinal görüntüdeki sert ve yumuşak eksuda lezyonlarının renk yoğunluğu yaklaşık olarak aynıdır. Aynı şekilde hemoraji ve mikroanevrizma lezyonlarının renk yoğunluğu da yaklaşık olarak aynıdır. Bu nedenle  $m \times n$  boyutundaki 75’er adet pozitif ve negatif ilgi alanı olmak üzere 150’şer adet ilgi alanı bilgisi sert ve yumuşak eksuda için 1. grup lezyon türü, hemoraji ve mikronevrizma için 2. grup lezyon türü olarak gruplandırılarak iki grup örneklem kümesi hazırlanmıştır. Bu örneklem kümelerinin her biri için elde edilen GÖ veriseti [150x512] boyutlu ve AFDÖ veriseti [150x400] boyutludur. Literatüre [93-94] uygun olarak 5 katlı çapraz doğrulama kuralları çerçevesinde bu verisetlerinin %70’i sistemin eğitilmesi ve %30’u da testi için ayrılmıştır.

Öznelik veri uzayının çok büyük olması sınıflandırıcı algoritmalarının başarısını olumsuz etkilemektedir. Bu nedenle, EEDR lezyonlarını en iyi temsil eden öznelik kümesinin seçimi bu çalışmadaki temel motivasyonlardan bir tanesidir. Ayırt edici özneliklerden oluşan bir öznelik alt kümesi seçilebilirse sınıflandırıcının başarısı artırılmış olur. Buna ek olarak daha az sayıda öznelik, gerçek zamanlı işlem için de avantajlıdır. Verisetinin sınıflandırması sürecinde hem işlem yükünün azaltılması hem de aşırı boyut probleminin önüne geçilerek sınıflandırma doğruluğunun artırılması amacıyla öznelik seçimi ve boyut düşürme algoritmalarının performansı araştırılmıştır. Bu doğrultuda; önemli özelliklerin seçimi için YÖE ve boyut düşürerek veri uzayı dönüşümü için SRDA metodunun başarısı öğrenme kuralları çerçevesinde oluşturulan sınıflandırma modelleri üzerinde test edilmiştir. EEDR lezyonlarının tespitini tahmin etmek üzere tasarlanan sistemin öğrenmesi süreci Şekil 5.7’deki iş akışına göre tasarlanmıştır.



Şekil 5.7. Öznitelik çıkartma, öznitelik değerlendirme ve sınıflandırma süreci.

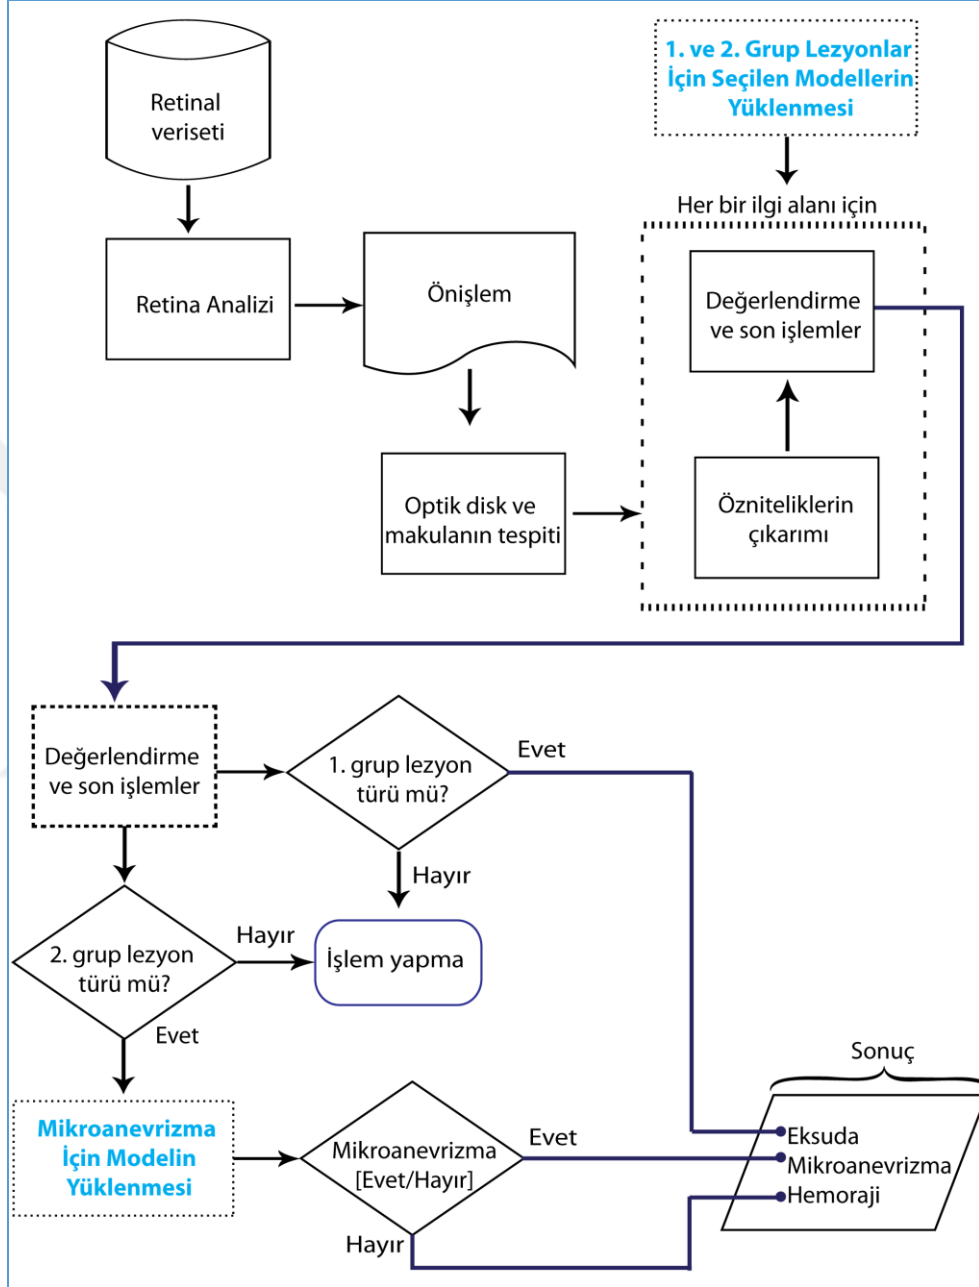


Şekil 5.8. Hibrid sınıflandırıcının kullanımı.

Bu süreçte, en başarılı model hangi öznelik vektörü, öznelik seçimi algoritması ve sınıflandırıcı algoritması ile elde edilir sorusunun cevabı araştırılmıştır ve Bölüm 3’de detaylı bir şekilde anlatımı yapılan yöntem ve tekniklerle inşa edilen her bir modelden alınan ve Çizelge 6.1 ile 6.4 ve Çizelge 6.10 ile 6.13’de karışıklık matrisi yapısında sunulan sonuçlar detaylı bir şekilde incelenerek karşılaştırılmış ve her bir lezyon grubu için Dso en iyi olan üç model bilgisi sisteme kaydedilmiştir. Bu çizelgelerdeki veriler doğrultusunda sert ve yumuşak eksuda bölgeleri için en iyi performans sunan Model 1 ve Model 2 ile Şekil 5.8’de temsili olarak gösterilen hibrid karar verici bir sistemin inşası gerçekleştirilmiştir. Bu sistem ile analize alınan ilgi alanı, mantıksal olarak Model 1 veya Model 2’den en az bir tanesinin pozitif sonuç vermesi doğrultusunda sonuç pozitif bulunmuştur. Diğer yandan, hemoraji ve mikroanevrizma lezyonları içinde aynı süreç yürütülmüştür.

1. grup lezyon türü için pozitif sonucun elde edildiği ilgi alanında sert veya yumuşak eksuda yapısal bozukluğu bulunmaktadır. Aynı şekilde, 2. grup lezyon türü için pozitif sonucun elde edildiği ilgi alanında hemoraji veya mikroanevrizma yapısal bozukluğu bulunmaktadır. Şekil 5.9’daki iş akışında görüleceği üzere, renk yoğunluğu benzerliği ve retinal görüntülerdeki aydınlık oranları farklılıklarından ötürü sert ve yumuşak eksuda lezyonları aynı kategoride yer almıştır. Diğer yandan, hemoraji ve mikroanevrizmaların ayrımı için ikinci aşamada, AFDÖ bilgisine dayalı oluşturulan model ile bu ilgi alanları analiz edilmektedir. Retinal görüntüdeki renk yoğunluğu bilgisinin yaklaşık olarak benzer olması nedeniyle tespitlerdeki hatalı

durumlar, hazırlanan arayüzler aracılığı ile alan uzmanı tarafından güncellenebilmektedir.




Şekil 5.9. Yeni retinal görüntülerin analizi sürecinin genel blok diyagramı.

### 5.2.2. Retinal Görüntülerin Analizi Süreci

Şekil 5.9’da görüldüğü gibi yeni bir retinal fundus görüntüsünün işleme alınması süreci şu şekildedir: Öncelikle Şekil 5.3’deki önişlemden geçirilen görüntüdeki 1. ve

2. grup lezyonlu bölgelerin elde edilebilmesi için parlak bölgelerin çıkarımı algoritması "whitening" ve KSAHE işlemlerinden geçirilmiş görüntüye ve bu görüntünün tersi alınarak elde edilen görüntüye uygulanmıştır. İlgili noktaları için ORB ve SURF algoritmalarının her ikisi ile elde edilen ilgili noktalarının tümü analize alınmıştır. Ayrıca Şekil 5.10'da görüldüğü üzere kan damarları üzerindeki ilgili noktalarının analize alınmaması gerekmektedir. Bu noktaların analize alınmaması için yürütülen damar çıkarım algoritması ve belirgin oluşumların tespiti için yürütülen algoritmaların ardından retinal görüntüdeki lezyonlu bölgelerin otomatik tespiti gerçekleştirilmiştir. Kan damarları üzerindeki ilgili noktalarının işleme alınmaması için gerçekleştirilen kodları ifade eden sözde kod aşağıda verilmiştir.

```
def ilgi_noktasi_damar_uzerinde_mi(point_x,point_y):  
    damar_yapısını_yükle()  
    X-Y ilgi_noktası, damar_yapısı_üzerinde_mi?  
    Cevap, Evet ise, bu ilgi_noktasını_listeden_çıkar.
```



Şekil 5.10. Kan damarı üzerindeki ilgili noktalarının tespiti.

Yukarıda bahsedilen adımlar çerçevesinde yapılan analizlerin ve ilgili verilerin girileceği, hastalığın seyri hakkında bilgi edinilebilecek bir kayıt ve takip sistemi geliştirilmiştir. Ayrıca, alan uzmanı geliştirilen arayüzleri kullanarak gerektiğinde lezyonlu yapılar ile ilgili değişiklik yapabilmekte ve hastalığın gelişimi bilgilerini sisteme kaydedebilmektedir. Geliştirilen uygulamaya ait ekran arayüzleri ile devam eden aşağıdaki bölümler yeni bir retinal görüntünün analizi ve sonrasında yapılan işlemleri içermektedir.



### 5.3. UYGULAMANIN BÖLÜMLERİ

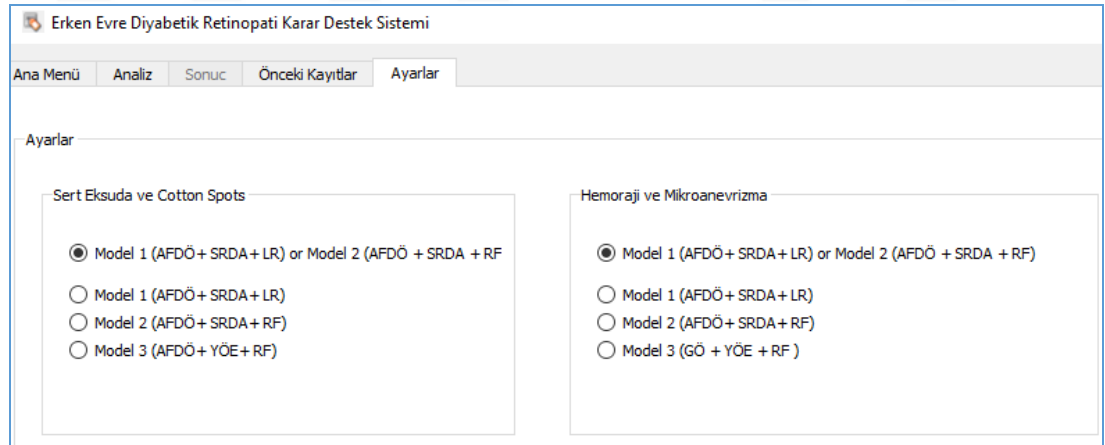
Geliştirilen uygulamadaki işlemlerin yürütüldüğü arayüzlere ulaşmak için kullanılan ana ekran görüntüsü Şekil 5.11’de görülmektedir.



Şekil 5.11. EEDR lezyonlarının tespiti için geliştirilen KDS ana ekranı.

#### 5.3.1. Model Seçimi Ekranı

Şekil 5.12’de görüldüğü üzere sistemi kullanacak olan alan uzmanı bu ekranda varsayılan seçimler ile işlem yapılabileceği gibi her bir lezyonun tespitine yönelik geliştirilen diğer modeller ile de analiz yapabilmektedir.




Şekil 5.12. KDS model seçim ekranı.

Model seçimi aşaması gerçekleştirildikten sonra "Lezyonların Tespiti" arayüzünde retinal görüntünün analizi gerçekleştirilir.

## 5.3.2. Lezyonların Tespiti Ekranı

### 5.3.2.1. Belirgin Oluşumların Tespiti Ve Kan Damarlarının Çıkarımı

Retinal görüntünün analizi ile ilgili neredeyse tüm işlemlerin yürütüldüğü ve sistemin temel yapıtaşı olan bu ekranda retinal görüntü sisteme yüklendiği anda sırasıyla "whitening" ve KSAHE metotları ile önışlemden geçirilir. Ardından, önışlemden geçen görüntünün tersi arka planda oluşturularak sisteme kaydedilir. Deneysel çalışmalarda, "whitening" metodunun uygulandığı bazı görüntülerdeki renk yoğunluğunun 1. grup renk yoğunluğuna yakın olduğu görülmüştür. Bunun nedeni, retinal görüntülerdeki renk yoğunluğunun farklılığıdır. Yani, bu metodun bazı retinal görüntülerde başarılı olduğu, bazılarında ise başarıyı düşürdüğü görülmüştür. Örneğin Şekil 5.13.a görüntüsünden "whitening" metodu ile elde edilmiş sonuç görüntüdeki bazı alanlar 1. grup lezyonlar ile benzer karakteristiğe sahiptir. Bu sorunu aşmak için, alan uzmanının retinal görüntü üzerinde "whitening" metodunun uygulanmasına karar vereceği seçenek sunulmuştur.



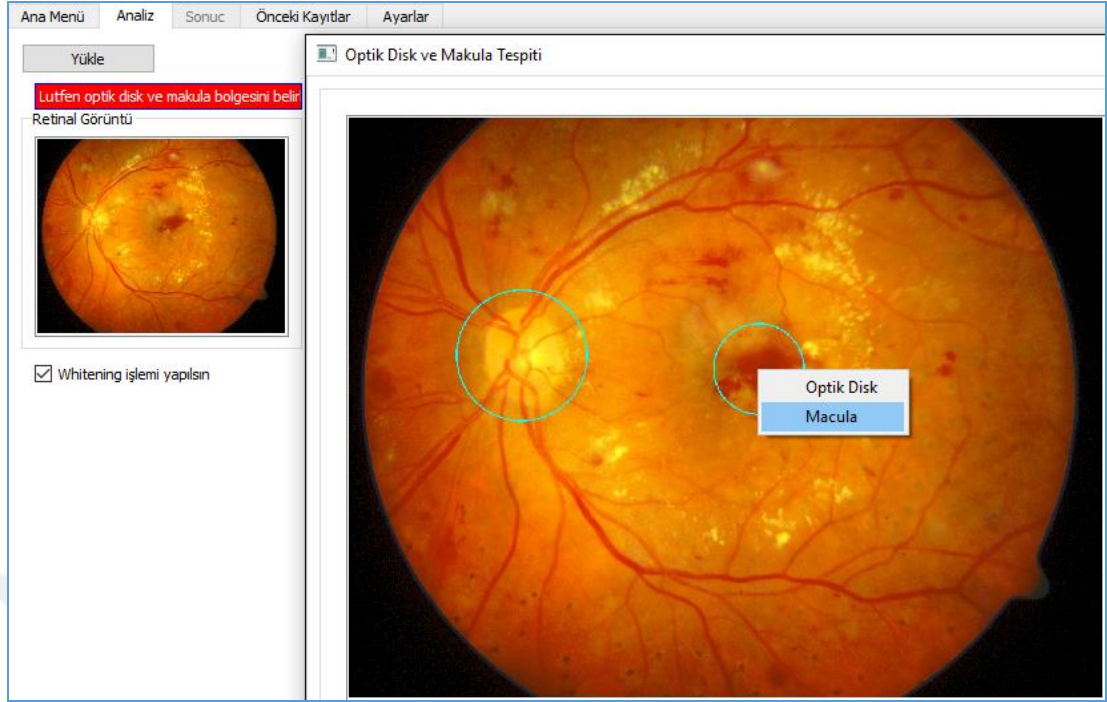
Şekil 5.13. Retinal görüntülerde "whitening" metodunun uygulanması, a) Retinal görüntü 1, b) a görüntüsü üzerinde "whitening" metodunun uygulanması sonucu elde edilen görüntü, c) Retinal görüntü 2, d) c görüntüsü üzerinde "whitening" metodunun uygulanması sonucu elde edilen görüntü.

İlgi bölgelerinin analizinde OD, makula bölgesi ve damar yapısının analize alınmaması gerekmektedir. Bunun için Şekil 5.14’de gösterilen bu oluşumların tespiti ve kan damarlarının çıkarımı çalışmanın birinci aşamasını kapsamaktadır. Bu nedenle, sistem OD ve makula oluşumlarının yerinin tespit edilmesi gerektiği konusunda uzmanı uyarır. Bu uygulama ile belirgin oluşumların tespiti otomatik olarak yürütülebilmektedir. Ancak retinal görüntünün elde edilmesi sırasında farklı aydınlanma koşulları, gürültü, açısal sorunlar gibi nedenlerden ötürü OD, makula ve damar yapısının elde edilmesi için otomatik yürütülen algoritmaların gücünü azaltmaktadır. Görüntüdeki bu oluşumların yeri otomatik yapılabildiği gibi bu gibi dezavantajlı durumlarda göz önünde bulundurularak sistemi kullanan uzmanın retinal görüntülerdeki belirgin oluşumları manuel olarak tespit edebilmesine imkân verilmiştir.




Şekil 5.14. Analize alınmaması gereken bölgelerin tespiti.

Şekil 5.15’de görüldüğü üzere alan uzmanı, ilgili arayüzde ayarlamalar yaparak belirgin oluşumların yerini tespit edebilmektedir. Böylece Şekil 5.16’da görüldüğü üzere lezyonlu bölgelerin tespitinden önce belirgin oluşumların yeri tespit edilmiş ve kan damarlarının çıkarımı sağlanmış olur.




Şekil 5.15. KDS, retinadaki belirgin oluşumların tespiti ekranı.




Şekil 5.16. OD, makula ve kan damarlarının çıkarımı.

Şekil 5.17’de görüldüğü üzere, retinal görüntülerdeki renk yoğunluğu farklılıklarından ötürü kan damarlarının çıkarımı için yürütülen algoritmanın her görüntüde aynı sonucu üretmesi beklenemez. Bu nedenle, sistemi kullanan alan uzmanının kan damarlarının çıkarımı ile elde edilen görüntü üzerinde manuel olarak düzenleme yapabilmesine ve böylece daha iyi sonuçlar elde edilebilmesine imkân tanıyan arayüz geliştirilmiştir. Bu arayüz kullanılarak Şekil 5.17’deki kırmızı çerçeveli alanlar gibi kan damarları üzerindeki eksik pikseller tamamlanabileceği gibi kan damarı dışındaki oluşumlar da silinebilmektedir.



Şekil 5.17. Kan damarlarının çıkarımı sonuçları, a) Yapısal eleman değeri=5 ile elde edilen sonuç, Yapısal eleman değeri=3 ile elde edilen sonuç.




Şekil 5.18. Lezyonlu bölgelerin analizi süreci.

### 5.3.2.2. Analiz İşlemi

Bölüm 5.3’de bahsi geçen hibrid model ile Şekil 5.18’de görüldüğü üzere her bir lezyon grubu için analiz gerçekleştirilmektedir. Analizin yürütme zamanı ilgi noktalarının sayısı ile doğru orantılı olarak artacağı durumu dikkate alınarak eşit paylaşımlı olarak paylaştırılmış 4 iş parçacıklı bir yapı ile ilgi noktalarının analizi süreci gerçekleştirilmiştir.

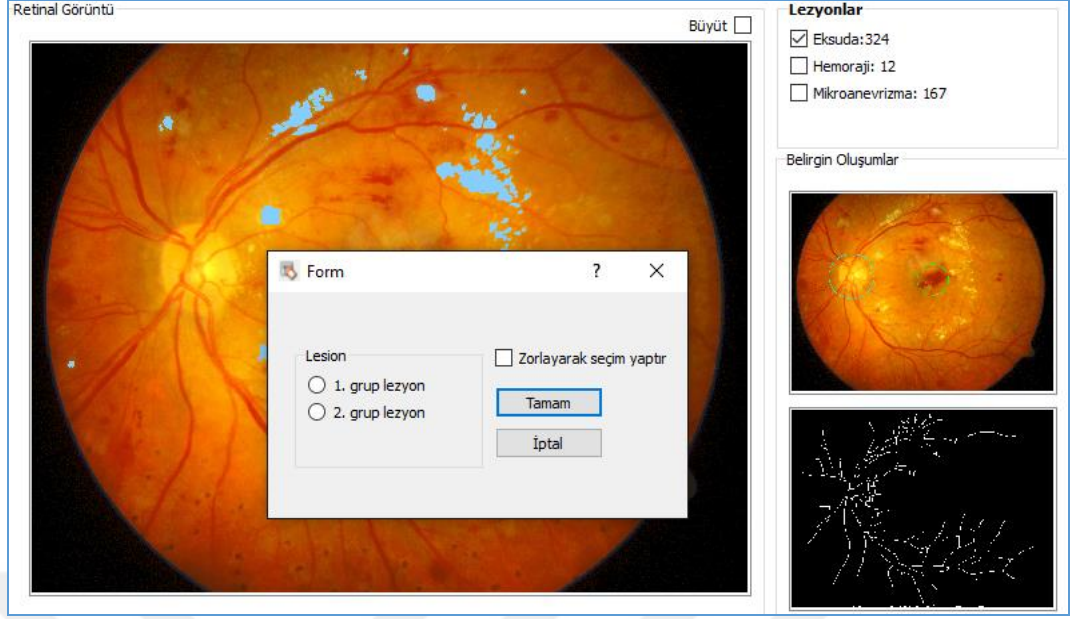
### 5.3.3. Sonuç Ekranı

Şekil 5.19’deki retina görüntüsünde 1. grup eksuda lezyonlarının tespitini gerçekleştiren algoritmanın çıktısı görülmektedir. Mavi renkteki alanlar tespit edilen lezyonları ifade etmektedir. Alan uzmanı, bu ekran üzerinde lezyonlu veya diğer bölgeleri inceleyebilmekte ve ayrıca retinadaki söz konusu bölge için silme işlemlerini veya sistemin tanımlayamadığı lezyonlu bölge için "bu bölgede şu lezyon vardır" tanımlamasını yapabilmektedir.




Şekil 5.19. Lezyonlu bölgelerin güncellenmesi (İlgi alanların güncellenmesi).





Şekil 5.20. İlgili alanının alan uzmanı tarafından analize alınması.

Şekil 5.20’de görüldüğü üzere analiz sonucunda bulunamayan lezyonlu bölgeler için alan uzmanının analiz yapabilmesine imkân veren diyalog ekranları da bulunmaktadır. Diğer yandan, alan uzmanı Şekil 5.21’de temsili olarak gösterilen arayüz aracılığı ile görüntüyü daha detaylı bir şekilde inceleyebilmektedir.



Şekil 5.21. Lezyonlu bölgenin detaylı incelenmesi.

Görüntü kayıtlama, sağlık alanında özellikle hastalıkların gelişiminin takibinde kullanılmak üzere tedavi kararlarını alan doktora yardımcı olmak için kullanılır. Bu çalışmada tasarlanan KDS ile lezyonlu bölgelerin alan uzmanı tarafından güncellenmesi ve hatalı ilgi alanlarının kaldırılması gibi işlemlere imkân verilmiştir.

Analiz ile elde edilen tüm bilgiler, Şekil 5.22’de görüldüğü üzere varlık-ilişki modeli çerçevesinde tasarlanan "hasta bilgileri" veritabanına kaydedilmekte ve daha sonra bu kayıtlara ulaşılabilmesi sağlanmaktadır. Bilgilerin kaydı için görüntü verilerinin saklanmasına imkân veren "LONGBLOB" veri türü tercih edilmiştir. Ayrıca, ilgi alanlarına ait bilgiler de sözlük yapısında oluşturularak "BLOB" veri türünde sisteme kaydedilmiştir.

Column Name	Datatype	PK	NN	UQ	B	UN	ZF	AI	G	Default/Expression
tcNo	VARCHAR(12)									NULL
ad	VARCHAR(45)									NULL
soyad	VARCHAR(45)									NULL
tarih	DATE									NULL
zaman	TIME									NULL
goruntu	LONGBLOB									NULL
keypoint_for_hexodate	BLOB									NULL
optikdisk	VARCHAR(45)									NULL
makula	VARCHAR(100)									NULL
keypoint_for_hemoraji	BLOB									NULL
keypoint_for_mikroanevrizma	BLOB									NULL
reg_maxima_for_normal_goru...	LONGBLOB									NULL
reg_maxima_for_invert_goruntu	LONGBLOB									NULL
diabet_suresi	VARCHAR(45)									NULL
kan_sekeri_duzeyi	VARCHAR(45)									NULL

Şekil 5.22. KDS için tasarlanan veritabanı görüntüsü.

Diğer yandan, belirli aralıklarla DR şüphesi olan kişilerin sistem tarafından çağrılması bu tezin kapsamı içindedir. Çalışmamızda, [13] nolu referans doğrultusunda DR'nin oluşma riskini artıran şu faktörler sisteme dâhil edilmiştir.

- Diyabet hastalığının süresi,
- Yüksek kan şekeri düzeyi,
- Yüksek kan basıncı,
- Gebelik,
- Şişmanlık,
- Böbrek hastalığı.

Şekil 5.23’deki kırmızı çerçeveli alandaki bilgilerin sisteme kaydedilmesi sayesinde retinal görüntünün veya hastanın seçilen tarih ve zamandaki risk faktörü değerlerinin



incelenbilmesine ve çıkarsama yapılabilmesine imkân vermesi özelliğiyle alan uzmanına yardımcı olması hedeflenmiştir.

Retinal Görüntü Büyüt

**Lezyonlar**

Eksuda: 324  
 Hemoraji: 12  
 Mikroanevrizma: 167

**Risk Faktörleri**

Diabet hastalığının süresi   
Kan şekeri düzeyi   
Kan basıncı düzeyi   
Gebelik   
Şişmanlık   
Böbrek Hastalığı

**Kişisel Veriler**

Şekil 5.23. DR'nin oluşma riskini artıran faktörlerin sisteme kaydedilmesi.

#### 5.3.4. Karşılaştırma Ekranı


En önemli görevi, hastalığın seyrindeki gelişmelere dair gerekli bilgileri sunmak olan Şekil 5.24, 5.25 ve 5.26'daki arayüzler ile alan uzmanı;

- İlgili retina görüntüsü için sistemde bulunan kayıtlara ulaşabilir,
- Yeni bir retina görüntüsü araması gerçekleştirebilir,
- Lezyonlu bölgeleri inceleyebilir.


Ayrıca, iki farklı tarih veya zamanda işleme alınmış olan retinal görüntülerin analiz edilebilmesine ve karşılaştırılabilmesine imkân tanıyan arayüzün de bu noktada alan uzmanına yardımcı olacağı düşünülmektedir. Örnek olarak Şekil 5.27'deki kırmızı renkteki lezyonlar yeni bulguları yeşil renktekiler ise daha önceden kayıt altına alınmış olan bulguları göstermektedir. Bu sayede, hastalığın takibi süresince hastalardan alınan farklı görüntüler karşılaştırılarak hastalığın ilerleyişi hakkında bilgi sahibi olunabilmektedir.

Hasta Bilgileri		Önceki Kayıtlar				
<input type="text" value="8"/> <input type="text"/> <input type="text"/> <input checked="" type="checkbox"/> Arama Yap		<b>Sistemde 9 adet kayıt bulunmuştur.</b>				
TC No	Ad	Soyad	Tarih	Zar		
1	00082280814	YBRNHBSOY	7SMUMA4YUOJD	07/06/2016	14:20:56	
2	00082280814	YBRNHBSOY	7SMUMA4YUOJD	07/06/2016	9:58:47	
3	00082280814	YBRNHBSOY	7SMUMA4YUOJD	06/06/2016	13:39:56	
4	00082280814	YBRNHBSOY	7SMUMA4YUOJD	05/06/2016	23:49:07	
5	00082280814	YBRNHBSOY	7SMUMA4YUOJD	04/06/2016	16:49:41	
6	00082280814	YBRNHBSOY	7SMUMA4YUOJD	04/06/2016	1:34:12	

Şekil 5.24. Sistemdeki kayıtlı verilerin sorgulanması.

Önceki Kayıtlar		Sistemde 9 adet kayıt bulunmuştur.					Retinal Görüntü		Lezyonlar		Risk Faktörleri	
TC No	Ad	Soyad	Tarih	Zar		 <input checked="" type="checkbox"/> Zoom		<input type="checkbox"/> Eksuda: 31 <input checked="" type="checkbox"/> Hemoraji: 89 <input type="checkbox"/> Mikroanevrizma: 27		Diabet hastalığının süresi: <input type="text" value="23"/> Kan şekeri düzeyi: <input type="text" value="21"/> Kan basıncı düzeyi: <input type="text" value="123"/> Gebelik: <input type="text" value="Hayır"/> Sismanklık: <input type="text" value="Hayır"/> Böbrek Hastalığı: <input type="text" value="Hayır"/>		
1	00082280814	YBRNHBSOY	7SMUMA4YUOJD	07/06/2016	14:20:56							
2	00082280814	YBRNHBSOY	7SMUMA4YUOJD	07/06/2016	9:58:47							
3	00082280814	YBRNHBSOY	7SMUMA4YUOJD	06/06/2016	13:39:56							
4	00082280814	YBRNHBSOY	7SMUMA4YUOJD	05/06/2016	23:49:07							
5	00082280814	YBRNHBSOY	7SMUMA4YUOJD	04/06/2016	16:49:41							
6	00082280814	YBRNHBSOY	7SMUMA4YUOJD	04/06/2016	1:34:12							

Şekil 5.25. Hastalığın seyri için sistemdeki kayıtlı verilerin incelenmesi.

Retinal Görüntü		Lezyonlar		Risk Faktörleri	
 <input checked="" type="checkbox"/> Zoom		<input checked="" type="checkbox"/> Eksuda: 324 <input type="checkbox"/> Hemoraji: 12 <input type="checkbox"/> Mikroanevrizma: 167		Diabet hastalığının süresi: <input type="text" value="3g"/> Kan şekeri düzeyi: <input type="text" value="123"/> Kan basıncı düzeyi: <input type="text" value="234"/> Gebelik: <input type="text" value="Hayır"/> Sismanklık: <input type="text" value="Hayır"/> Böbrek Hastalığı: <input type="text" value="Hayır"/>	

Şekil 5.26. Hastalığın seyri için sistemdeki kayıtlı verilerin detaylı incelenmesi.

**Görüntü Karşılaştırma Ekranı**

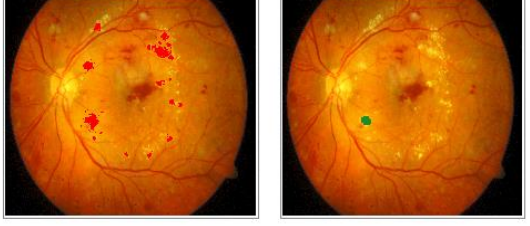
	TC No	Tarih	Zaman	Karşılaştır
1	00082280814	05/06/2016	23:49:07	<input checked="" type="checkbox"/>
2	00082280814	04/06/2016	16:49:41	<input type="checkbox"/>
3	00082280814	04/06/2016	1:34:12	<input type="checkbox"/>
4	00082280814	02/06/2016	22:00:44	<input type="checkbox"/>
5	00082280814	02/06/2016	21:46:21	<input checked="" type="checkbox"/>
6	00082280814	02/06/2016	14:57:44	<input type="checkbox"/>

**Lezyon Seçimi Yapınız**

Eksuda  
 Hemoraji  
 Mikroanevrizma

Önceki  
 Sonraki

**Karşılaştır**



Şekil 5.27. Sistemdeki kayıtlı iki verinin incelenmesi.




## BÖLÜM 6

### DENEYSEL SONUÇLAR VE TARTIŞMA

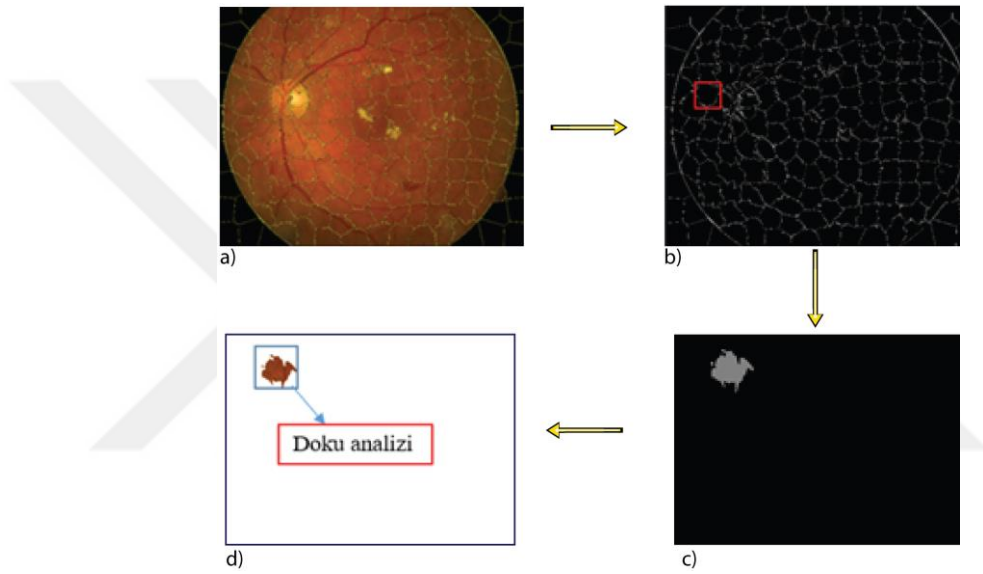
Bu tez çalışmasında EEDR lezyonlarından sert eksuda, yumuşak eksuda, hemoraji ve mikroanevrizma bulgularının analizi gerçekleştirilmiştir. Lezyonları temsil eden ilgi alanlarını en başarılı şekilde temsil edebilmek ve makine öğrenmesinde en iyi performansı yakalayabilmek için üzerinde yoğunlaşılacak ve araştırmalar yapılacak sorular şunlardır:

- Görüntü iyileştirme süreci nasıl olmalıdır?
- Seyrek örneklem ve yoğun örneklem tekniklerinden hangisi uygulanmalıdır?
- İlgi noktalarının çıkarımında hangi algoritma ya da algoritmalar uygulanmalıdır?
- Öznitelik elde etme algoritmalarından hangisi ya da hangileri tercih edilmelidir?
- Öznitelik vektörlerini indirgemenin yolları nelerdir ve önemli öznitelikler nasıl elde edilir?
- En başarılı sınıflandırıcı algoritması hangisidir?



Şekil 6.1. Yoğun örneklem ile alt görüntülerin elde edilmesi, a) 128x128 piksel alt görüntüler, b) 256x256 piksel alt görüntüler.

Retinal görüntüye yoğun örneklemin uygulanmasıyla Şekil 6.1’de görüldüğü üzere tüm görüntüden 128x128, 256x256 vb. boyutlarda alt görüntüler elde edilir. Bu alt görüntüleri temsil eden karakteristik bilgiler işleme alınır ve ilgili görüntü analiz edilir. Bir diğer segmentasyon algoritması olan Süper piksel yöntemiyle, Şekil 6.2’deki gibi görüntüden alt görüntüler elde edilir. Ardından, bu görüntülerden öznelikler çıkartılır ve sınıflandırması yapılır. Süper piksel algoritması, lokal olarak piksellerin anlamlı bir şekilde gruplandırılması için kullanılır. Benzer renk ve doku dağılımlarına sahip yerel bölgeler aynı süper piksel bölgesinde yer alır [95].



Şekil 6.2. Süper piksel algoritması ve elde edilen bölgeler, a) Süper piksel algoritması ile ilgi alanlarının elde edilmesi, b) İkili renk uzayında ilgi alanlarının gösterimi, c) İlgi alanı sınırlarının tespiti, d) İlgi alanının bölütlenmesi.

Ancak, işleme alınan veri için yürütme zamanının çok uzun sürmesi ve yoğun işlem den ötürü bu tekniklerden vazgeçilmiştir. Uzun soluklu deneysel uygulamalar ile yukarıdaki soruların cevaplarının arandığı bu süreçte yürütülen işlemler dizisi yoğun örnekleme alternatif bir diğer yöntem olan seyrek örnekleme içermektedir. Yani ilgi alanlarının analizi ilgi noktaları referans alınarak yapılmakta, ilgi alanı dışındaki diğer bölgelerin analizi yapılmamaktadır. Bölüm 5’te ayrıntılı bir şekilde anlatılan model oluşturma sürecinde en iyi başarıyı sunan öznelik vektörleri ve sınıflandırıcı algoritmaları ile modeller oluşturularak uygulama geliştirilmiştir.

## 6.1. ERKEN EVRE DİYABETİK RETİNOPATİ LEZYONLARININ TESPİTİNE DAİR ELDE EDİLEN SONUÇLAR

%70'i sistemin eğitilmesi ve %30'u da sistemin testi olmak üzere 5 katlı çapraz doğrulama kuralları çerçevesinde elde edilmiş olan alt verisetleri üzerinde EEDR lezyonlarının tespiti için yapılan deneysel çalışmalardaki analiz sonuçları ve performans değerlendirmeleri Çizelge 6.1 ve 6.7 ve Çizelge 6.10 ve 6.16 arasında sunulmuştur. Örnek olarak, Çizelge 6.1.'deki 1 nolu veriseti üzerinde LR ile yapılan sınıflandırma analizine dair sonuçlar ve Dso değeri 3 sütun ve 4 satırlı karışıklık matrisi yapısında verilmiştir. Ayrıca, her bir sınıflandırıcının ortalama sınıflandırma başarısı ve ortalama yürütme zamanı ilgili çizelgelerde son iki satırda sunulmuştur.

Çizelge 6.1. Sert ve yumuşak eksuda için bilgi çıkarımı (BÇ)-1'e göre sınıflandırma sonuçları.

		GÖ ve YÖE					
		Sınıflandırıcı Algoritmaları					
Verisetleri		LR			RO		
Veriseti No:1			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		14	9	<b>1</b>	13	10
	<b>0</b>		4	19	<b>0</b>	5	18
			Dso	<b>%71.74</b>		Dso	<b>%67.39</b>
Veriseti No:2			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		12	11	<b>1</b>	14	9
	<b>0</b>		5	18	<b>0</b>	4	19
			Dso	<b>%67.39</b>		Dso	<b>%71.74</b>
Veriseti No:3			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		11	12	<b>1</b>	16	7
	<b>0</b>		6	17	<b>0</b>	6	17
			Dso	<b>%65.21</b>		Dso	<b>%71.74</b>
Veriseti No:4			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		14	9	<b>1</b>	16	7
	<b>0</b>		5	18	<b>0</b>	7	16
			Dso	<b>%69.56</b>		Dso	<b>%69.57</b>

Çizelge 6.1. (devam ediyor).

Veriseti No:5						
		1	0		1	0
	1	13	10	1	14	9
	0	5	18	0	5	18
		Dso	<b>%67.39</b>		Dso	<b>%69.57</b>
Ortalama Başarı	<b>% 68.26</b>			<b>% 70.0</b>		
Ortalama Geçen Süre	0.16 sn			0.45 sn		

Çizelge 6.2. Sert ve yumuşak eksuda için BÇ-2'ye göre sınıflandırma sonuçları.

		<b>GÖ ve SRDA</b>					
		Sınıflandırıcı Algoritmaları					
Verisetleri		LR			RO		
Veriseti No:1			1	0		1	0
		1	14	9	1	19	4
		0	8	15	0	5	18
			Dso	<b>%63.04</b>		Dso	<b>%80.43</b>
Veriseti No:2			1	0		1	0
		1	17	6	1	19	4
		0	3	20	0	7	16
			Dso	<b>%80.44</b>		Dso	<b>%76.08</b>
Veriseti No:3			1	0		1	0
		1	12	11	1	12	11
		0	2	21	0	3	20
			Dso	<b>%71.73</b>		Dso	<b>%69.57</b>
Veriseti No:4			1	0		1	0
		1	15	8	1	16	7
		0	2	21	0	5	18
			Dso	<b>%78.26</b>		Dso	<b>%73.91</b>
Veriseti No:5			1	0		1	0
		1	13	10	1	17	6
		0	6	17	0	5	18
			Dso	<b>%65.22</b>		Dso	<b>%76.08</b>
Ortalama Başarı	<b>% 71.74</b>			<b>%75.21</b>			
Ortalama Geçen Süre	0.17 sn			0.48 sn			

Çizelge 6.3. Sert ve yumuşak eksuda için BÇ-3'e göre sınıflandırma sonuçları.

		<b>AFDÖ ve YÖE</b>					
		Sınıflandırıcı Algoritmaları					
Verisetleri		LR			RO		
Veriseti No:1			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		15	8	<b>1</b>	19	4
	<b>0</b>		8	15	<b>0</b>	1	22
			Dso	<b>%65.21</b>		Dso	<b>%89.13</b>
Veriseti No:2			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		13	10	<b>1</b>	20	3
	<b>0</b>		5	18	<b>0</b>	2	21
			Dso	<b>%67.39</b>		Dso	<b>%89.13</b>
Veriseti No:3			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		12	11	<b>1</b>	19	4
	<b>0</b>		5	18	<b>0</b>	3	20
			Dso	<b>%65.21</b>		Dso	<b>%84.78</b>
Veriseti No:4			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		12	11	<b>1</b>	21	2
	<b>0</b>		6	17	<b>0</b>	1	22
			Dso	<b>%63.04</b>		Dso	<b>%93.48</b>
Veriseti No:5			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		12	11	<b>1</b>	22	1
	<b>0</b>		8	15	<b>0</b>	2	21
			Dso	<b>%69.56</b>		Dso	<b>%93.48</b>
Ortalama Başarı		<b>%66.08</b>			<b>% 90.0</b>		
Ortalama Geçen Süre		0.15 sn			0.46 sn		

Çizelge 6.4. Sert ve yumuşak eksuda için BÇ-4'e göre sınıflandırma sonuçları.

		<b>AFDÖ + SRDA</b>					
		Sınıflandırıcı Algoritmaları					
Verisetleri		LR			RO		
Veriseti No:1			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		18	5	<b>1</b>	19	4
	<b>0</b>		0	23	<b>0</b>	0	23
			Dso	<b>%89.13</b>		Dso	<b>%91.30</b>



Çizelge 6.4. (devam ediyor)

Veriseti No:2		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	19	4	<b>1</b>	19	4
	<b>0</b>	1	22	<b>0</b>	1	22
		Dso	<b>%89.13</b>		Dso	<b>%89.13</b>
Veriseti No:3		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	21	2	<b>1</b>	21	2
	<b>0</b>	0	23	<b>0</b>	1	22
		Dso	<b>%95.65</b>		Dso	<b>%93.48</b>
Veriseti No:4		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	21	2	<b>1</b>	21	2
	<b>0</b>	1	22	<b>0</b>	3	20
		Dso	<b>%93.48</b>		Dso	<b>%89.13</b>
Veriseti No:5		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	22	1	<b>1</b>	19	4
	<b>0</b>	1	22	<b>0</b>	1	22
		Dso	<b>%95.65</b>		Dso	<b>%89.13</b>
Ortalama Başarı	<b>% 92.60</b>			<b>% 90.43</b>		
Ortalama Geçen Süre	0.22 sn			0.95 sn		

Çizelge 6.5. Model 1 performansının değerlendirilmesi.

Verisetleri	Model 1 (AFDÖ + SRDA + LR)		
	Du	Se	Dso
Veriseti No:1	% 78.26	% 100.0	% 89.13
Veriseti No:2	% 82.60	% 95.65	% 89.13
Veriseti No:3	% 91.30	% 100.0	% 95.65
Veriseti No:4	% 91.30	% 95.65	% 93.48
Veriseti No:5	% 95.65	% 95.65	% 95.65
Ortalama	% 87.82	% 97.39	% 92.60

Çizelge 6.6. Model 2 performansının değerlendirilmesi.

Verisetleri	Model 2 (AFDÖ + SRDA + RO)		
	Du	Se	Dso
Veriseti No:1	% 82.60	% 100.0	% 91.30
Veriseti No:2	% 82.60	% 95.65	% 89.13
Veriseti No:3	% 91.30	% 95.65	% 93.48
Veriseti No:4	% 91.30	% 86.96	% 89.13
Veriseti No:5	% 82.60	% 95.65	% 89.13
Ortalama	% 86.08	% 94.78	% 90.43

Çizelge 6.7. Model 3 performansının değerlendirilmesi.

Verisetleri	Model 3 (AFDÖ + YÖE + RO)		
	Du	Se	Dso
Veriseti No:1	% 82.60	% 95.65	% 89.13
Veriseti No:2	% 86.96	% 91.30	% 89.13
Veriseti No:3	% 82.60	% 86.96	% 84.78
Veriseti No:4	% 91.30	% 95.65	% 93.48
Veriseti No:5	% 95.65	% 91.30	% 93.48
Ortalama	% 87.82	% 92.17	% 90.0

[90] nolu referans doğrultusunda, her bir verisetindeki sınıflandırma başarı oranlarının ortalaması alınarak elde edilen deneysel sonuçlar doğrultusunda, AFDÖ ve SRDA metotları ile RO ve LR sınıflandırıcı algoritmalarının sert ve yumuşak lezyonlarının sınıflandırılmasında oldukça başarılı olduğunu ifade edebiliriz. Ayrıca, AFDÖ, YÖE ve RO metotlarının da başarılı olduğunu söyleyebiliriz. Bu doğrultuda bu üç model bilgisine ait Du, Se ve Dso değerleri Çizelge 6.5, 6.6 ve 6.7’de sunulmuştur. Ayrıca, her bir öznitelik vektörünün elde edilmesine dair yürütme zamanlarının değerlendirilmesi Çizelge 6.8’de ve en iyi başarıyı veren üç modelin toplam yürütme zamanı Çizelge 6.9’da sunulmuştur.

Çizelge 6.8. Öznitelik vektörlerinin çıkarımı için yürütme zamanı (sn).

	YÖE ile öznitelik değerlendirme	SRDA ile öznitelik değerlendirme
GÖ	80.13 sn	28.15 sn
AFDÖ	41.20 sn	3.14 sn

Çizelge 6.9. En iyi başarıyı sunan üç model için toplam yürütme zamanı (sn).

	Modeller		
	Model 1	Model 2	Model 3
Toplam süre	4.24 sn	7.89 sn	43.5 sn

Çizelge 6.10. Hemoraji ve mikroanevrizma için BÇ-1'e göre sınıflandırma sonuçları.

		<b>GÖ ve YÖE</b>					
		Sınıflandırıcı Algoritmaları					
Verisetleri		LR			RO		
Veriseti No:1			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		14	9	<b>1</b>	19	4
	<b>0</b>		6	17	<b>0</b>	2	21
			Dso	<b>%67.39</b>		Dso	<b>%86.96</b>
Veriseti No:2			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		15	8	<b>1</b>	21	2
	<b>0</b>		7	16	<b>0</b>	2	21
			Dso	<b>%67.39</b>		Dso	<b>%91.30</b>
Veriseti No:3			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		15	8	<b>1</b>	21	2
	<b>0</b>		9	14	<b>0</b>	3	20
			Dso	<b>%63.04</b>		Dso	<b>%89.13</b>
Veriseti No:4			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		15	8	<b>1</b>	19	4
	<b>0</b>		9	14	<b>0</b>	1	22
			Dso	<b>%63.04</b>		Dso	<b>%89.13</b>
Veriseti No:5			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		20	3	<b>1</b>	17	6
	<b>0</b>		9	14	<b>0</b>	4	19
			Dso	<b>%73.91</b>		Dso	<b>%78.26</b>
Ortalama Başarı		<b>% 66.95</b>			<b>%86.96</b>		
Ortalama Geçen Süre		0.12 sn			0.49 sn		

Çizelge 6.11. Hemoraji ve mikroanevrizma için BÇ-2'ye göre sınıflandırma sonuçları.

		<b>GÖ ve SRDA</b>					
		Sınıflandırıcı Algoritmaları					
Verisetleri		LR			RO		
Veriseti No:1			<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>		21	2	<b>1</b>	16	7
	<b>0</b>		5	18	<b>0</b>	5	18
			Dso	<b>%84.78</b>		Dso	<b>%73.91</b>

Çizelge 6.11. (devam ediyor).

Veriseti No:2		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	21	2	<b>1</b>	20	3
	<b>0</b>	8	15	<b>0</b>	3	20
		Dso	<b>%78.26</b>		Dso	<b>%86.96</b>
Veriseti No:3		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	20	3	<b>1</b>	17	6
	<b>0</b>	8	15	<b>0</b>	11	12
		Dso	<b>%76.09</b>		Dso	<b>%63.04</b>
Veriseti No:4		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	20	3	<b>1</b>	18	5
	<b>0</b>	9	14	<b>0</b>	7	16
		Dso	<b>%73.91</b>		Dso	<b>%73.91</b>
Veriseti No:5		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	20	3	<b>1</b>	19	4
	<b>0</b>	7	16	<b>0</b>	8	15
		Dso	<b>%78.26</b>		Dso	<b>%73.91</b>
Ortalama Başarı	<b>% 78.26</b>			<b>% 74.35</b>		
Ortalama Geçen Süre	0.18 sn			0.48 sn		

Çizelge 6.12. Hemoraji ve mikroanevrizma için BÇ-3'e göre sınıflandırma sonuçları.

AFDÖ ve YÖE						
Sınıflandırıcı Algoritmaları						
Verisetleri	LR			RO		
Veriseti No:1		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	21	2	<b>1</b>	14	9
	<b>0</b>	7	16	<b>0</b>	5	18
		Dso	<b>%80.44</b>		Dso	<b>%69.57</b>
Veriseti No:2		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	16	7	<b>1</b>	21	2
	<b>0</b>	9	14	<b>0</b>	2	21
		Dso	<b>%67.39</b>		Dso	<b>%91.30</b>
Veriseti No:3		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	22	1	<b>1</b>	16	7
	<b>0</b>	8	15	<b>0</b>	5	18
		Dso	<b>%80.44</b>		Dso	<b>%73.91</b>

Çizelge 6.12. (devam ediyor).

Veriseti No:4		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	22	1	<b>1</b>	19	4
	<b>0</b>	7	16	<b>0</b>	4	19
		Dso	<b>%82.60</b>		Dso	<b>%82.60</b>
Veriseti No:5		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	23	0	<b>1</b>	20	3
	<b>0</b>	4	19	<b>0</b>	3	20
		Dso	<b>%91.30</b>		Dso	<b>%86.97</b>
Ortalama Başarı	<b>% 80.43</b>			<b>% 80.87</b>		
Ortalama Geçen Süre	0.16 sn			0.50 sn		

Çizelge 6.13. Hemoraji ve mikroanevrizma için BÇ-4'e göre sınıflandırma sonuçları.

AFDÖ ve SRDA						
Sınıflandırıcı Algoritmaları						
Verisetleri	LR			RO		
Veriseti No:1		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	23	0	<b>1</b>	23	0
	<b>0</b>	1	22	<b>0</b>	1	22
		Dso	<b>%97.83</b>		Dso	<b>%97.83</b>
Veriseti No:2		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	23	0	<b>1</b>	23	0
	<b>0</b>	5	18	<b>0</b>	5	18
		Dso	<b>%89.13</b>		Dso	<b>%89.13</b>
Veriseti No:3		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	22	1	<b>1</b>	19	4
	<b>0</b>	3	20	<b>0</b>	3	20
		Dso	<b>%91.30</b>		Dso	<b>%84.78</b>
Veriseti No:4		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	21	2	<b>1</b>	20	3
	<b>0</b>	4	19	<b>0</b>	3	20
		Dso	<b>%86.96</b>		Dso	<b>%86.96</b>
Veriseti No:5		<b>1</b>	<b>0</b>		<b>1</b>	<b>0</b>
	<b>1</b>	22	1	<b>1</b>	22	1
	<b>0</b>	4	19	<b>0</b>	3	20
		Dso	<b>%89.13</b>		Dso	<b>%91.30</b>
Ortalama Başarı	<b>% 90.87</b>			<b>% 90.0</b>		
Ortalama Geçen Süre	0.23 sn			0.63 sn		

Çizelge 6.14. Model 1 performansının değerlendirilmesi.

Verisetleri	Model 1 (AFDÖ + SRDA + LR)		
	Du	Se	Dso
Veriseti No:1	% 100.0	% 95.65	% 97.83
Veriseti No:2	% 100.0	% 78.26	% 89.13
Veriseti No:3	% 95.65	% 86.96	% 91.30
Veriseti No:4	% 91.30	% 82.60	% 86.96
Veriseti No:5	% 95.65	% 82.60	% 89.13
Ortalama	% 96.52	% 85.21	% 90.87

Çizelge 6.15. Model 2 performansının değerlendirilmesi.

Verisetleri	Model 2 (AFDÖ + SRDA + RO)		
	Du	Se	Dso
Veriseti No:1	% 100.0	% 95.65	% 97.83
Veriseti No:2	% 100.0	% 78.26	% 89.13
Veriseti No:3	% 82.60	% 86.96	% 84.78
Veriseti No:4	% 86.96	% 86.96	% 86.96
Veriseti No:5	% 95.65	% 86.96	% 89.13
Ortalama	% 93.04	% 86.96	% 90.0

Çizelge 6.16. Model 3 performansının değerlendirilmesi.

Verisetleri	Model 3 (GÖ + YÖE + RO)		
	Du	Se	Dso
Veriseti No:1	% 82.60	% 91.30	% 86.96
Veriseti No:2	% 91.30	% 91.30	% 91.30
Veriseti No:3	% 91.30	% 86.96	% 89.13
Veriseti No:4	% 82.60	% 95.65	% 89.13
Veriseti No:5	% 73.91	% 82.60	% 78.26
Ortalama	% 84.34	% 89.56	% 86.96

Her bir verisetindeki sınıflandırma başarıları oranlarının ortalaması alınarak en iyi başarıyı veren sonuçlar doğrultusunda, AFDÖ ve SRDA metotları ile elde edilen verisetleri üzerinde LR ve RO sınıflandırıcı algoritmalarının hemoraji ve mikroanevrizma lezyonlarının sınıflandırılmasında oldukça başarılı olduğunu ifade edebiliriz.

Ayrıca, GÖ, YÖE ve RO metotlarının da başarılı olduğunu söyleyebiliriz. Bu doğrultuda bu üç modele ait Du, Se ve Dso değerleri de Çizelge 6.14, 6.15 ve 6.16'da sunulmuştur. Diğer yandan, her bir öznitelik vektörünün elde edilmesine dair yürütme zamanları Çizelge 6.17'de ve en iyi başarıyı veren modellerin toplam yürütme zamanı da Çizelge 6.18'de sunulmuştur.

Çizelge 6.17. Öznitelik vektörlerinin çıkarımı için yürütme zamanı (sn).


	YÖE ile öznitelik değerlendirme	SRDA ile öznitelik değerlendirme
GÖ	75,7 sn	27,49 sn
AFDÖ	42,59 sn	3,13 sn

Çizelge 6.18. En iyi başarımı sunan üç model için toplam yürütme zamanı (sn).

	Modeller		
	Model 1	Model 2	Model 3
Toplam süre	4.28 sn	6.28 sn	78.15 sn


Sağlık disiplninde alınacak kararlar, seçiciliği ve hassasiyeti en üst düzeyde olan sınıflandırma yöntemleri kullanılmasını gerektirmektedir. Çünkü kullanılan sınıflandırma yönteminin lezyonların doğru bir şekilde tespitini gerçekleştirmesi gerekmektedir. Diğer yandan, hastalığın ilerlemesi hakkında uzman hekimin önceki kayıtlar ile şu andaki durumu karşılaştırması esnasında destek vermesi açısından da bu algoritmalar dolaylı olarak süreci etkilemektedir. Bu nedenle, bu sonuçlar ve uzman görüşü referans alınarak her bir lezyon grubu için en iyi performansı sunan Model 1 ve Model 2 modelleri kullanılarak hibrid bir model gerçekleştirilmiştir. Uzman görüşüne başvurularak yürütülen süreçte yürütme zamanı uzun olan ancak daha doğru sonuç veren algoritmalar tercih edilmiştir.

Öznitelik değerlendirme yöntemleri referans alınarak hazırlanan bu çalışmada elde edilen öznitekt vektörleri kullanılarak öğrenme kuralları çerçevesinde geliştirilen uygulamanın performansı yeni retinal görüntüler üzerinde test edilmiştir. Bu süreçte Şekil 5.9'daki iş akışı adımları yürütülmüştür. Aşağıdaki Şekil 6.3 ve 6.4'de retinal görüntü verisetindeki retinaların işleme alınması sonucu elde edilen sonuçlardan bazıları görülmektedir.



Şekil 6.3. Eksuda lezyonları, a) Retinal fundus görüntüsü, b) a görüntüsündeki lezyonların tespiti (Mavi noktalı bölgeler).

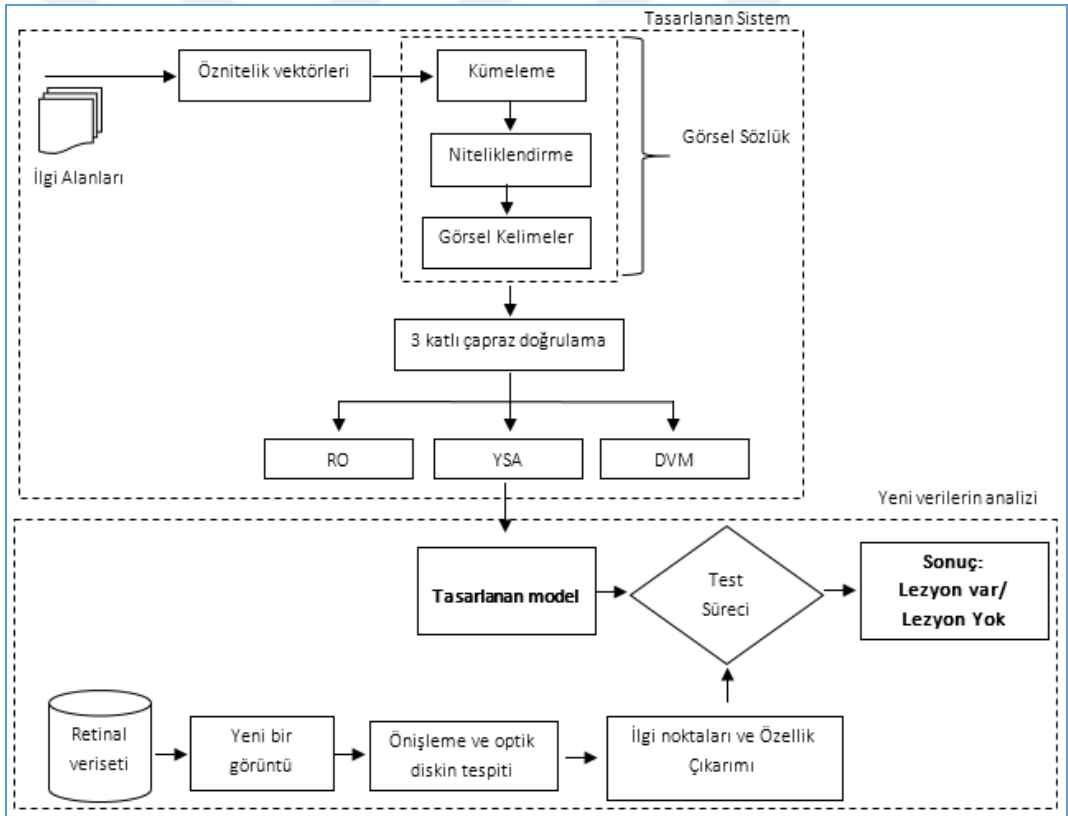




Şekil 6.4. Hemoraji ve mikroanevrizma lezyonları, a) Retinal fundus görüntüsü, b) a görüntüsündeki lezyonların tespiti (Mavi noktalı bölgeler).

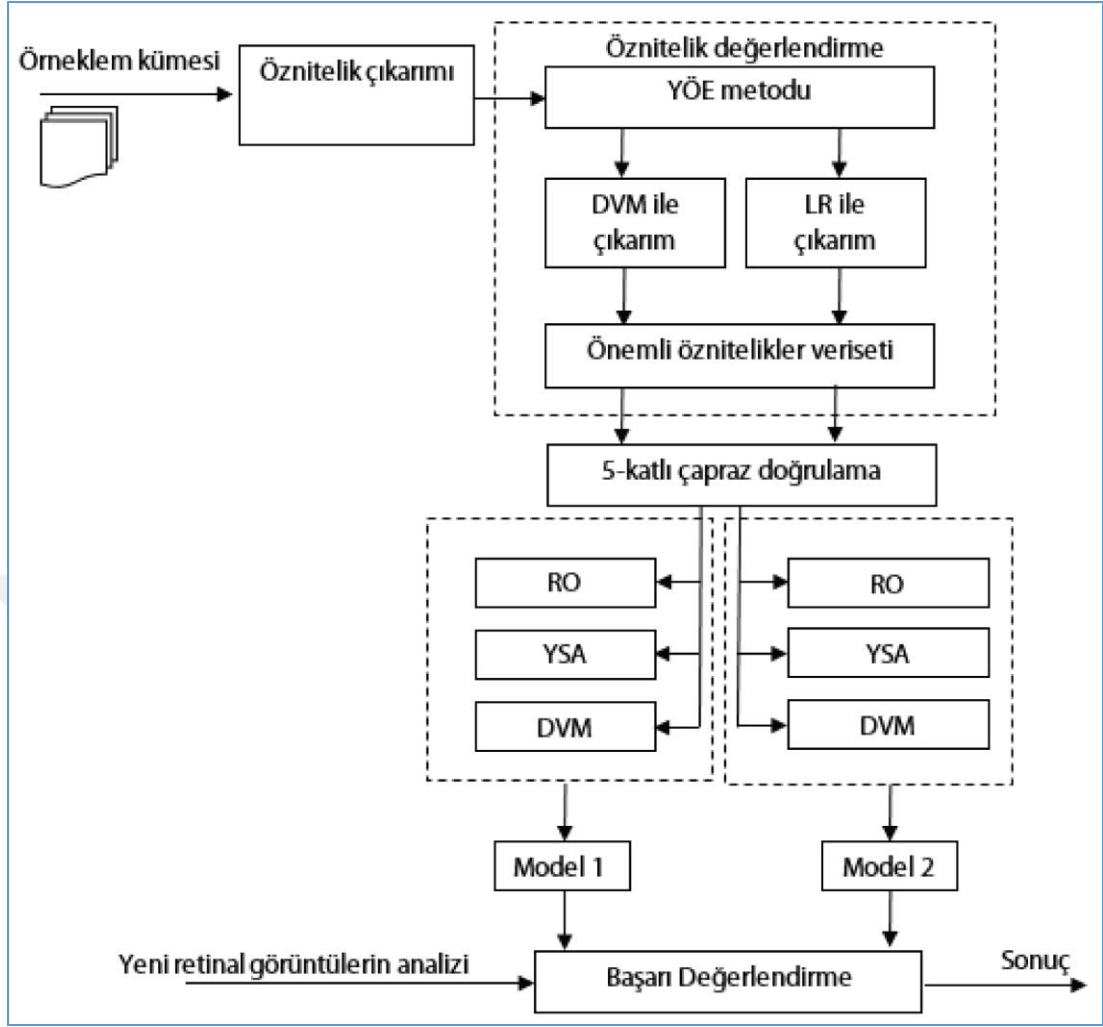
Ayrıca, bu tez çalışması boyunca üzerinde çalışılan yöntem ve tekniklerle hazırlanan çalışmalar ve deneysel sonuçlar ([96-102]) ilgili konferanslarda sunulmuş ve makale olarak uluslararası dergilerde yayınlanmıştır. İlerleyen bölümlerde bu çalışmaların iş akışı hakkında açıklamalar bulunmaktadır. Devamında bu tez çalışması süresince geliştirilen makulanın tespiti ve kan damarlarının çıkarımı hakkında bilgiler verilmiştir. Diğer yandan, literatüre uygun olarak EEDR KDS için geliştirilen bu uygulamadaki tüm arayüzleri kapsayan bir içeriğe sahip yayın niteliğinde çalışma yapılması da planlanmaktadır.

## 6.2. ERKEN EVRE DİYABETİK RETİNOPATİ LEZYONLARININ TESPİTİ İÇİN YAPILAN DİĞER ÇALIŞMALAR

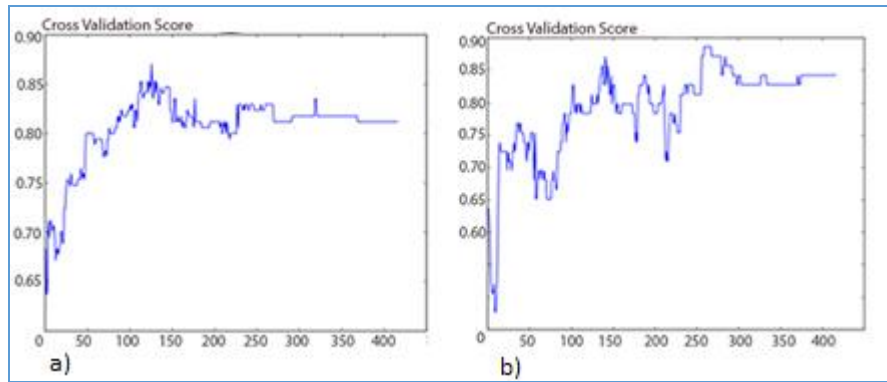


Şekil 6.5. Sistemin öğrenmesi ve retinal görüntülerin analizi.

[96-98] arasındaki çalışmalarda, EEDR lezyonlarından olan sert eksudanın otomatik tespiti Şekil 6.5’de görüldüğü üzere sistemin öğrenmesi ve yeni retinal görüntülerin analizi aşamaları ile gerçekleştirilmiştir. Bu süreç, her üç çalışma için de ilgilenilen bölgeler, öznitelik çıkarımı, görsel sözlük ve sınıflandırma adımlarını içermektedir.



Şekil 6.6. Çalışmanın iş akışı.



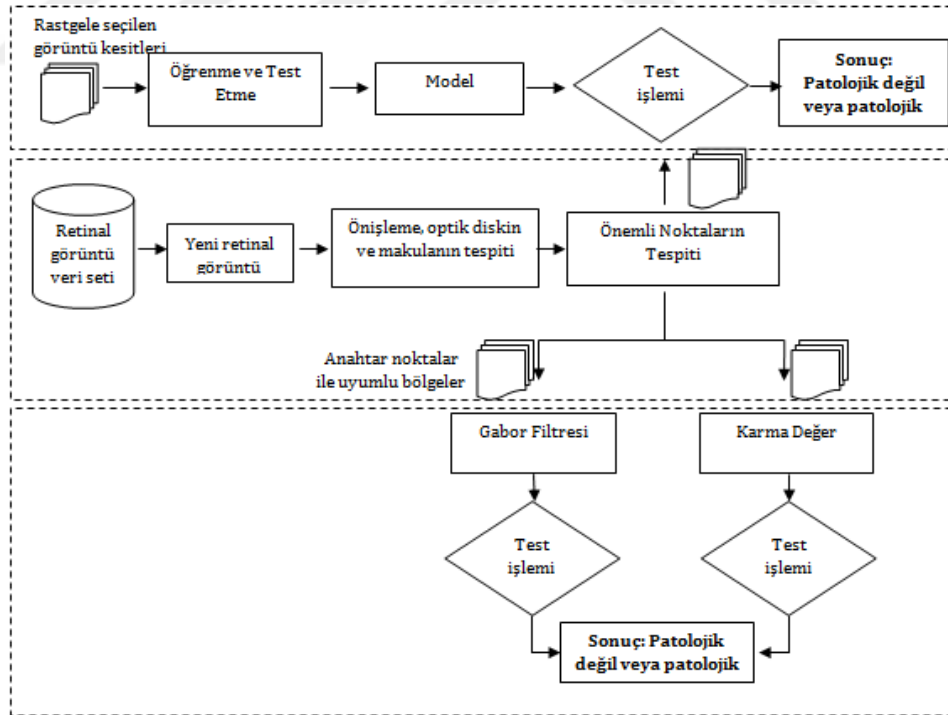
Şekil 6.7. Öznitelik değerlendirme, a) LR metodu ile, b) DVM metodu ile.

[99] nolu çalışmada, ilgi noktaları etrafındaki dörtgensel ilgi alanlarının öznitelikleri Daisy [103] algoritması ile elde edilmiştir. Ardından Şekil 6.7’de görüldüğü üzere

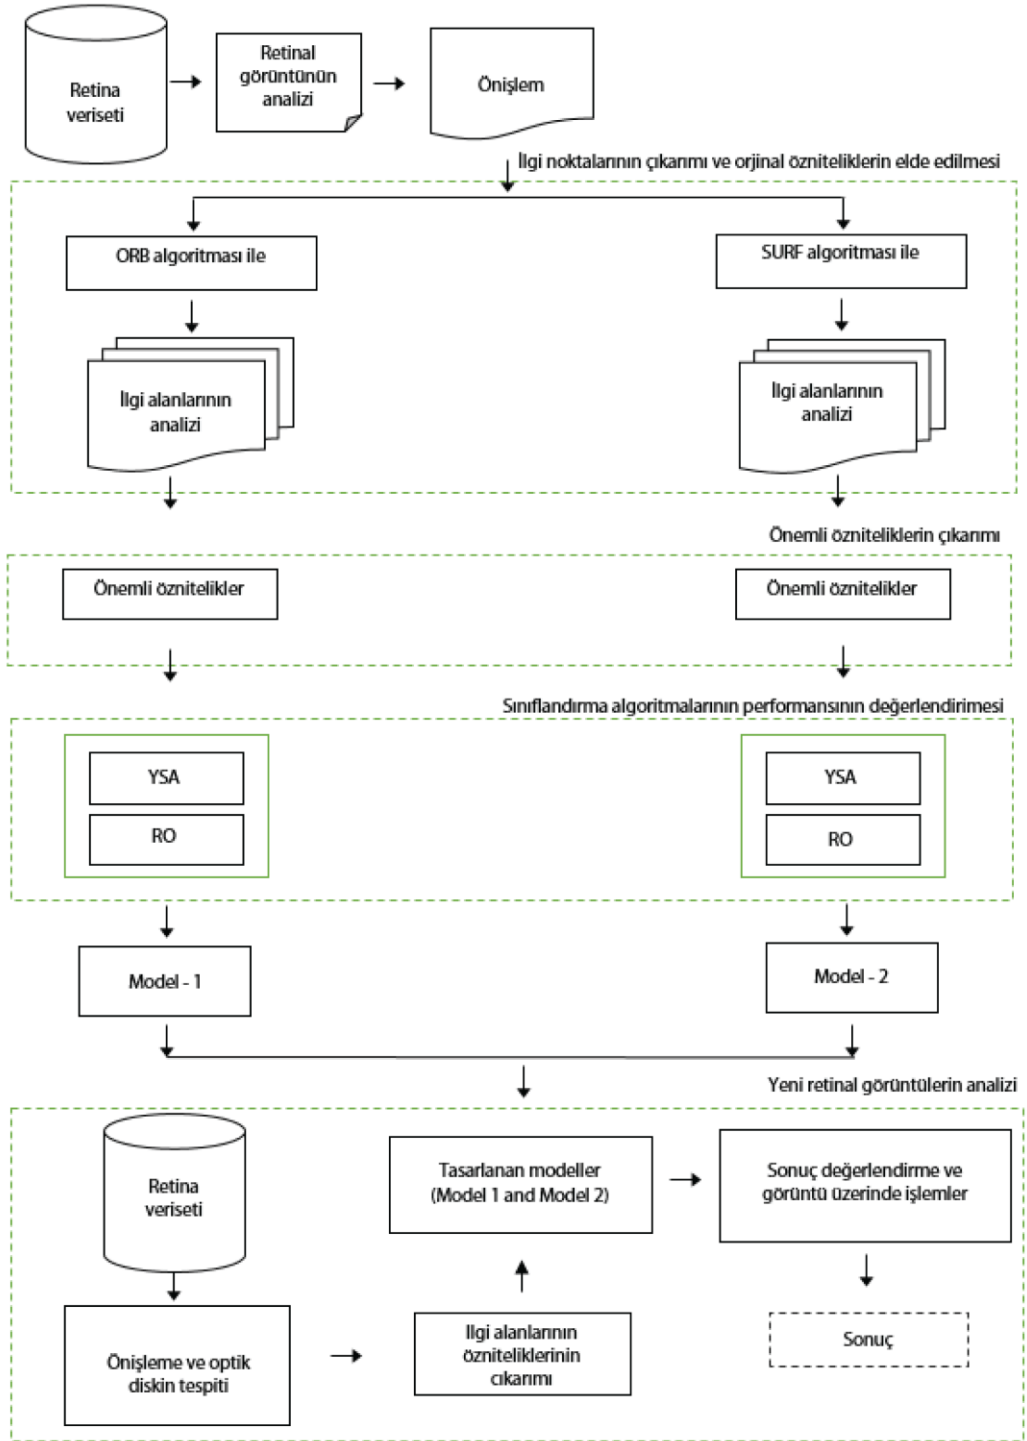
YÖE yöntemi ile bu öznelikler vektöründen kullanışsız olan ve sıralamada düşük seviyelerde olan öznelikler elimine edilerek daha düşük boyutta öznelik uzayı elde edilmiştir.

Şekil 6.6'daki iş akışına göre 5 katlı çapraz doğrulama yöntemi çerçevesinde önemli öznelik uzayı üzerinde DVM, Yapay Sinir Ağları (YSA) ve RO sınıflandırıcı algoritmalarının başarısı test edilmiştir. En iyi başarıyı sunan RO ile sistemin modellenmesi gerçekleştirilmiş ve yeni retinal görüntülerin analizi yapılmıştır.

[100] nolu çalışmada, Şekil 6.8'de görüldüğü üzere mikroanevrizma ve hemoraji lezyonlarının otomatik olarak tespitini gerçekleştiren bir sistem tasarlanmıştır. Karma değer (hash value), doku analizi ve sınıflandırma algoritmalarının performansları analiz edilmiştir. Elde edilen sonuçlar, Gabor özellikleri ile doku sınıflandırma ve RO sınıflandırıcı algoritması ile yapılan deneysel çalışmaların karma değer algoritmasına göre daha başarılı olduğunu göstermiştir.



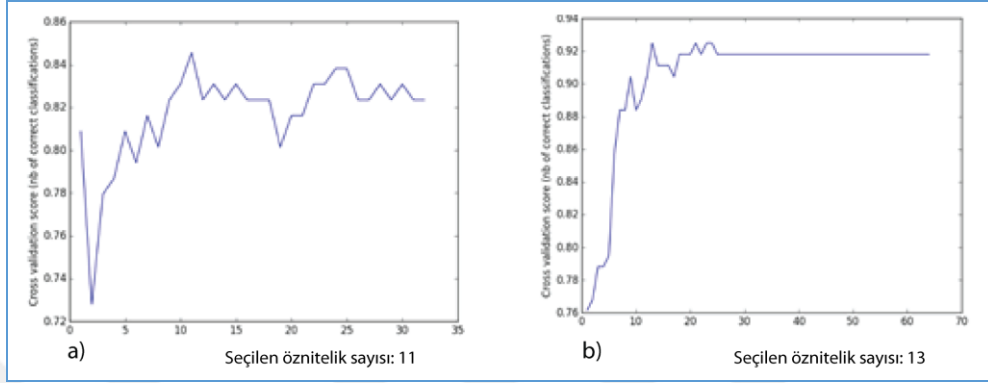
Şekil 6.8. Geliştirilen sistemin iş akış diyagramı.



Şekil 6.9. Çalışmanın iş akışı.

Şekil 6.9’da görüldüğü üzere sert eksudaların tespiti için temel olarak modelleme süreci ve yeni retinal görüntülerin analizi olmak üzere iki aşama içeren öğrenme yaklaşımına dayalı yürütülen çalışmada, ORB ve SURF algoritmaları ile özellik vektörleri elde edilmiştir. Elde edilen özellik vektöründen YÖE yöntemiyle

öznitelik seçimi yapılarak önemli öznitelikler vektörü elde edilmiştir. Şekil 6.10'da görüldüğü üzere bu yöntem ile ORB yerel tanımlayıcısından 11, SURF yerel tanımlayıcısından 13 önemli öznitelik elde edilmiştir.



Şekil 6.10. Öznitelik değerlendirme, a) ORB tanımlayıcısından elde edilen önemli öznitelik sayısı: 11, b) SURF tanımlayıcısından elde edilen önemli öznitelik sayısı: 13.


Sonraki aşamada Şekil 6.9'daki iş akışı doğrultusunda her iki tanımlayıcı algoritmasına ait orjinal ve önemli öznitelikler verisetinin %60'lık kısmı eğitim için, %40'lık kısmı da test için ayrılarak eğitim ve test süreçleri çerçevesinde RO ve YSA algoritmalarının başarısı analiz edilmiştir. Bu süreçte %92,19'luk başarılı sınıflandırma oranıyla RO sınıflandırıcısı ve SURF yerel tanımlayıcısının önemli özellikleri ile oluşturulan model ile yeni retinal görüntülerin analizi gerçekleştirilmiştir.

### 6.3. RETİNA GÖRÜNTÜLERİNDEKİ BELİRGİN OLUŞUMLARIN TESPİTİ ÇALIŞMALARI

#### 6.3.1. Optik Diskin Tespiti

Özellikle sert ve yumuşak eksuda lezyonlu retinal görüntülerde OD'nin otomatik bulunması lezyonların otomatik tespiti için önemli bir aşamadır. Çünkü OD bölgesinin renk yoğunluğu ile bu lezyonların renk yoğunluğu yaklaşık olarak aynıdır. OD'nin tespiti konusunda geliştirilen yöntemler her zaman iyileştirilmeli, retinal görüntülerde karşılaşılabilecek yapısal bozulma, görüntü kalitesi, açısız sorun gibi

durumlar için daha etkin ve başarılı yöntemler geliştirilmelidir. Diğer yandan, bu bölgelerin tespiti bu bölgelere bağlı hastalıkların tespitinde de kullanılabilir. Şekil 6.11’de görüldüğü üzere OD bölgesi dairesel bir yapıya sahip iken eksuda lezyonlarının görüntü üzerinde bazı yerlerde yayılım niteliğinde bir yapı içermesi nedeniyle iki oluşum arasında şekilsel yönden bir farklılık söz konusudur.



Şekil 6.11. DIARETDB1 verisetinden bir retinal fundus görüntüsü.

Bu anlamda OD’nin tespiti, retinal görüntü analizi çalışmalarında birinci basamakta yer alır diyebiliriz. Bu tez çalışmasının önemli bir aşaması olan ilgi noktalarının elde edilmesine dair yürütülen algoritmalar ile elde ettiğimiz ilgi noktaları bilgileri içerisinde OD ve makulanın bulunduğu bölgeye ait koordinatlarda vardır. Örnek olarak ele alınan 3 adet retinal fundus görüntüsündeki ilgi noktalarının çıkarımı algoritmasının yürütülmesi sonucu OD ve makula bölgesindeki ilgi noktası sayısı Çizelge 6.19’da 3 nolu sütunda verilmiştir.

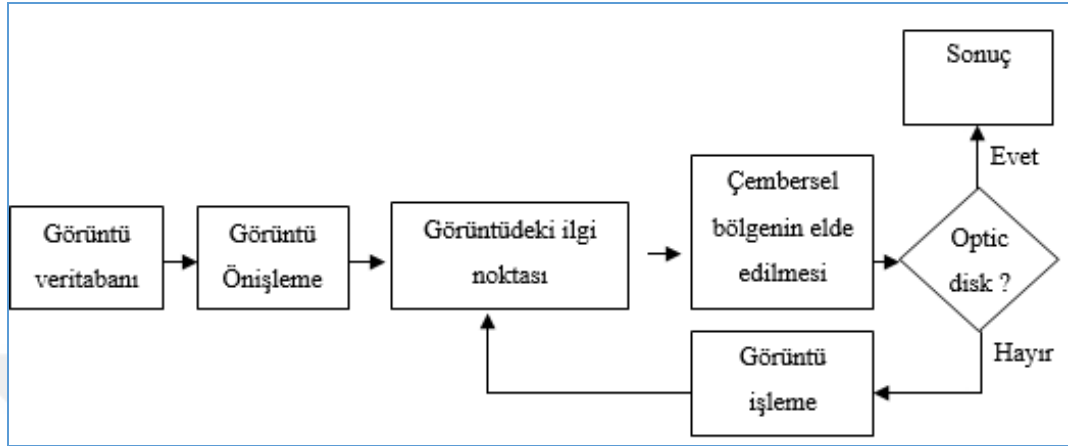
Çizelge 6.19. İlgi noktalarının tespiti.

	Toplam ilgi nokta sayısı	İşleme alınan ilgi nokta sayısı	İşleme alınmayan ilgi nokta sayısı
Retinal görüntü-1	653	397	256
Retinal görüntü-2	609	390	219
Retinal görüntü-3	286	212	74


İlgili çizelgede görüldüğü üzere bu oluşumların tespitinin yapılmaması, hem fazladan işlem yapma hem de yanlış tespit sonucunu beraberinde getirecektir. Retinal görüntüye ait ilgi noktaların çıkarımı algoritması ile elde edilen koordinat bilgilerinin OD ve makula bölgesi içinde yer alması ve gereksiz yere bu bölgelerin analize



alınmasını ve de daha önemlisi "bu bölgeler için lezyonlu bölgelerdir" sınıflandırması yapılmasının önüne geçilmesi yürütülen bu çalışmanın amaçları arasındadır.



Şekil 6.12. Uygulamanın akış diyagramı.




Şekil 6.13. Doku analizinde kullanılan bölgeler, a) 5 adet OD görüntüsü, b) 5 adet optik disk olmayan görüntü.

OpenCV kütüphanesinden yararlanılarak gerçekleştirilen [101] nolu çalışmada, retinal görüntüdeki OD adayları ilgi alanının konum bilgisi ve bu konuma ait Gabor özelliklerine dayalı olarak en iyi benzerlik değerine sahip olan ilgi alanının OD bölgesi olduğuna karar veren algoritmanın akış diyagramı Şekil 6.12'de görülmektedir. Bu akış diyagramından görüldüğü üzere önilemeden geçirilen retinal fundus görüntüsündeki maksimum renk değişiminin olduğu noktanın konum



bilgisine dayalı olarak bu noktanın etrafındaki 120 piksel yarıçapındaki dairesel bölgenin doku özellikleri elde edilmiştir.



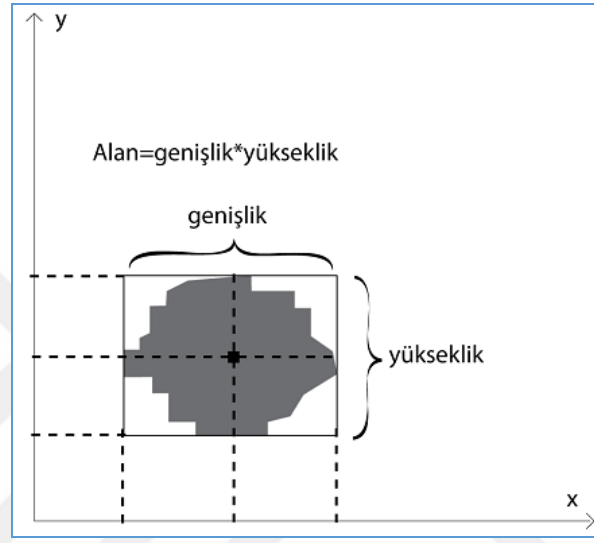
Şekil 6.14. OD'nin tespiti, a) Yürütülen adımlar, b) Başarılı bir OD tespiti.

Sonrasında dokusal analiz yöntemiyle Şekil 6.14'de verilen ve sistemde saklı olan OD ve diğer alanların bilgilerini içeren örneklem kümesi ile bu ilgi alanının öznitelik bilgilerinin karşılaştırması yapılarak bu bölgenin OD olup olmadığı tespit edilmektedir. Sonuç pozitif çıkarsa bu ilgi alanının konum bilgisi sisteme kaydedilerek OD bölgesinin tespiti yapılmış olur. Aksi durumda, bir sonraki ilgi alanı koordinatının elde edilmesi aşamasında, üzerinde çalışılan koordinatın tekrar işleme alınmaması için bu koordinata ait 40 piksel çapındaki dairesel bölgenin piksel değerine bu bölgenin ortalama piksel değeri atanmaktadır. Bu değer, deneme yanılma metoduyla belirlenmiş olan bir değerdir. OD'nin tespiti için uygulanan bu algoritmanın iş akışı, ilgi alanı sınırları görüntü sınır değerleri dışına çıkmadığı sürece özyineli olarak devam etmektedir.

Önişlem, ilgi noktaların çıkarımı, morfoloji ve görsel sözlüğün oluşturulması aşamalarından oluşan [102] çalışmasında deneysel uygulamalar neticesinde KSAHE

metodu ile retinal görüntülerden elde edilen sonuç görüntüler üzerinde çalışılmıştır. Çalışma, temel olarak 2 bölüm içermektedir.

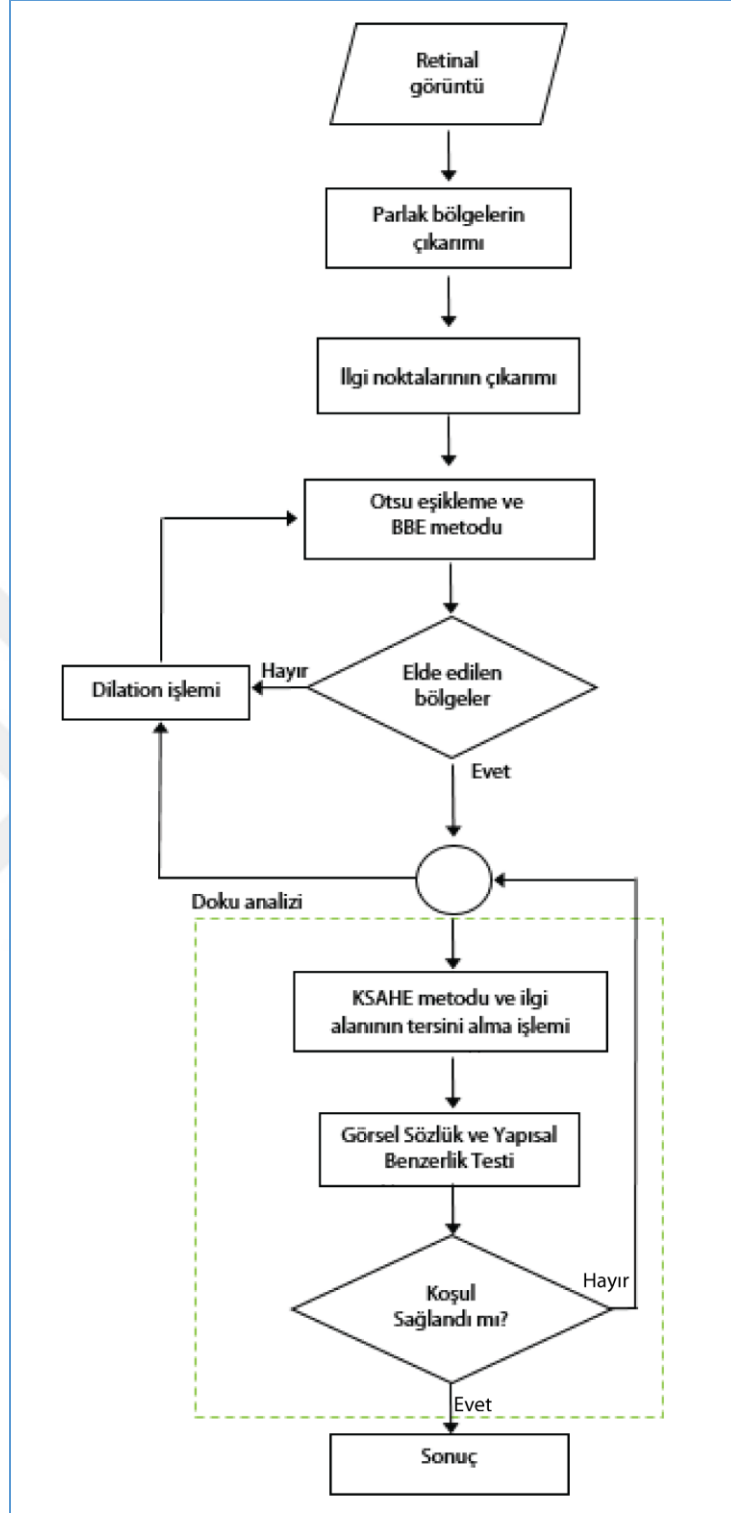
Sistemin Öğrenmesi Aşaması: Sistemin OD bölgesine ait özellikleri diğer bölgelerden ayırt edebilmesi için görsel sözlük oluşturulmuş ve sonrasında görsel kelimelerin sınıflandırılması için RO sınıflandırıcı algoritması ile çalışılmıştır.



Şekil 6.15. İlgi bölgesinin alanının hesaplanması.

Bir ilgi alanının büyüklüğü belirlenen değerlerin dışındaysa bu bölge, OD veya makula bölgesi değildir. Ayrıca, en boy oranı da önemlidir. Tez çalışması süresince OD ve makula bölgelerinin otomatik olarak tespitinde kullanılan alan bilgisi hesaplaması Şekil 6.15’de görülmektedir.


Yeni retinal görüntülerin analizi aşaması: Bu aşamada, Şekil 6.16’daki iş akışından görüleceği üzere bir retinal görüntüdeki parlak bölgelerin çıkarımından sonraki aşamada bu görüntüye eşikleme işlemi uygulanarak ikili görüntü elde edilmiştir. Parlak bölgelerin çıkarımı algoritmasının uygulandığı görüntü üzerinde SURF ilgi nokta çıkarımı ile elde edilen ilgi noktaları sınırlarındaki ilgi alanlarının tespiti eşiklenmiş görüntü üzerinde yapılmıştır. Ardından, BBE yöntemi ile bu ilgi alanlarının boyut bilgileri dikkate alınarak OD alanı sınırları dışında kalan bölgelerin işleme alınmaması sağlanmıştır. OD aday bölgelerin analizi için görsel sözlük, RO sınıflandırıcı algoritması ve yapısal benzerlik indeksinden faydalanılmıştır.




Şekil 6.16. Önerilen yaklaşımın iş akışı.

Yapısal benzerlik indeksi algoritması, aday ilgi alanlarının karşılaştırılması esnasında birden çok aday bölgelerin olduğu durumlarda en iyi benzerlik bilgisini yakalayabilmek için kullanılmıştır. Bu adımlar çerçevesinde yapılan deneme

çalışmalarında görülmüştür ki, yürütülen çalışma bazı retinalarda başarılı sonuç üretirken diğerlerinde bu başarı görülemedi. OD bölgesi, damarların çıkış noktası olduğu için parçalı olmaktadır. Bu sorunu aşabilmek için yürütülen ve çalışmaya önemli bir katkısı olan prosedür, Şekil 6.17’de görüldüğü üzere bu bölgedeki parçalı alanların "dilation" morfoloji işlemiyle OD formuna uygun bölgeler haline getirilmesidir.



Şekil 6.17. OD'nin tespiti için yürütülen morfolojik işlem adımları.



Şekil 6.18. 6 retinal görüntünün OD bölgesinin tespitine dair sonuçlar.

OD sınırları içinde olan ve analiz sonucu pozitif olan ilgi alanı bulunamadığında bu süreç özyineli olarak devam etmektedir. OD bölgesinin tespitinin başarısını karşılaştırabilmek için öncelikle her bir görüntüdeki OD bölgesi kordinat bilgileri manuel olarak sisteme kaydedilmiştir. Sonrasında, birkaç örneği Şekil 6.18'de görüldüğü üzere, Lalonde vd. ([52]), tarafından önerilen yöntem ile her bir retinal görüntüden elde edilen sonucun sistemdeki sonuç ile piksel piksel karşılaştırması yapılarak, önerdiğimiz çalışmanın başarısı analiz edilmiştir.


### 6.3.2. Makulanın Tespiti

[50] nolu çalışmanın referans alındığı "makula bölgesinin OD'ye olan uzaklığı yaklaşık olarak OD'nin yarıçapının iki buçuk katıdır" bilgisine dayanılarak yürütülen bu çalışmada OD'nin tespitinin ardından öklid uzaklığı formülü uygulanarak makula bölgesinin tespiti yapılmıştır. Bu süreçte uygulanan kural şudur: İki ilgi alanı merkezi arasındaki öklid uzunluğu "öklid uzunluk eşiği" değerinden büyükse veya küçükse, söz konusu ilgi alanı aranan bölge olamaz.

İki boyutlu bir düzlemdeki  $(x_1, y_1)$  ve  $(x_2, y_2)$  koordinatları arasındaki Öklid uzaklığı denklemi Eşitlik 6.1 ile verilmiştir [57].

$$d(x, y) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (6.1)$$


Şekil 6.19'da tersi alınan retina görüntüsü verilmiştir. Makula bölgesinin tespiti için bu görüntüye parlak bölgelerin çıkarımı işlemi uygulandıktan sonra Otsu eşikleme işleminin uygulanmasıyla elde edilen ikili görüntü üzerinde BBE metodu uygulanmıştır. Bu aşamadan sonra elde edilen ilgi alanları içindeki OD'ye olan uzaklık bilgisi kriterine sahip olan ve belirlenen büyüklük sınırlarında olan ilgi alanının doku analizi gerçekleştirilerek makula bölgesi olup olmadığına karar veren prosedür gerçekleştirilmiştir. Sonrasında, OD ve makula bölgesine ait koordinat bilgileri sisteme kaydedilmiştir.



Şekil 6.19. Makula bölgesinin tespiti için ilgi alanlarının tespiti.

### 6.3.3. Kan Damarlarının Çıkarımı

Retinal görüntüdeki kan damarlarının çıkarımı için yürütülen çalışmada, Şekil 6.20'de görüldüğü üzere, KSAHE işleminden geçirilmiş retinal görüntüye matematiksel morfoloji operatörü olan "white tophat" işlemi uygulanmış ve sonrasında Otsu eşikleme algoritması uygulanarak ikili görüntü elde edilmiştir. Bu görüntüdeki kesik pikselleri birleştirmek için dilation morfolojik işlemi uygulanmıştır. Sonrasında, BBE etiketleme işlemi uygulanarak matematiksel alan değeri küçük olan bölgeler görüntüden kaldırılmıştır.



Şekil 6.20. Retinal görüntüden damar çıkarımı süreci, a) KSAHE metodunun uygulanması, b) White tophat prosedürü ile elde edilen görüntü, c) Otsu algoritması ile elde edilen görüntü, d) Küçük bölgelerin görüntüden kaldırılması ile elde edilen sonuç görüntü.

Aydınlık bölgeleri ortaya çıkartabilmek için uygulanan "tophat" morfolojik işlemi Eşitlik 6.2'de ifade edildiği üzere "opening" morfolojik işlemi ile elde edilmiş görüntünün orijinal görüntüden çıkarılmasıdır [62].

$$\text{Tophat transformation} = \text{Image} - \text{Open}(\text{Image}) \quad (6.2)$$

Retinal damarların değişik bir yapı içermeleri ve yerel kontrastlarının kararsız olmasından ötürü otomatik damar çıkarımı beraberinde zorluklar getirmektedir. Bu zorlukları aşmak için "tophat" dönüşümü ile elde edilen görüntü üzerinde Otsu eşikleme algoritması ile en iyi başarıyı sağlayabilmek için "yapısal element" değeri uzman tarafından manuel olarak değiştirilebilmektedir. Damar çıkarımı için önerdiğimiz bu çalışmada yürütülen morfolojik işlemlerin ardından alan uzmanının onayı ile kan damarı yapısı sisteme kaydedilecek ve retinal lezyonlarla ilgili diğer işlemlere geçilebilecektir.

## BÖLÜM 7

### SONUÇ VE ÖNERİLER

Çok yaygın bir göz hastalığı olan DR, şeker hastalığına bağlı olarak kan şekerinin yükselmesi sonucu retina kılcal damarlarının etkilenmesi ile başlayan ve ilerleyen evrelerde görme duyusunun tamamen yitilmesiyle sonuçlanabilen ve genellikle iki gözü de körlük derecesinde etkileyen bir hastalıktır.

DR hastalığı ile ilgili olarak, otomatik tespit çalışmaları büyük ivme kazanmış olmasına rağmen her geçen gün yöntemlere yeni yetkinlikler eklenmektedir. Ayrıca, bu hastalığın düzenli muayene gerektirmesi ve uzman azlığı otomatik tespit sistemlerini zorunlu hale getirmektedir.

Tıp bilimlerinde kararların hızlı ve doğru şekilde verilmesi hayati öneme sahiptir ve DR hastalığının ilerlemesinin durdurulmasında en önemli yöntem, erken tanıdır. Bu doğrultuda bu hastalığın erken evresinde ortaya çıkan sert eksuda, yumuşak eksuda, hemoraji ve mikroanevrizma lezyonlarının tespiti konusunda uzman hekime karar desteği sağlayan görüntü işleme teknikleri ve makine öğrenmesine dayalı bir uygulama geliştirilmiştir. Geliştirilen uygulamanın öğrenme süreci; retinal görüntülerin iyileştirilmesi, ilgi alanlarının tespiti ve özniteliklerinin çıkarımı ve bu ilgi alanlarının gerçekte lezyon mu yoksa normal bir doku mu olduğunun ayrımını yapan analiz aşamalarından oluşmaktadır. Bunun yanı sıra lezyonların sınıflandırılması için farklı öznitelik çıkarma ve sınıflandırıcı algoritmaları uygulanarak başarılı sonuçlar elde edilmesi için yöntem ve teknikler uygulanmış, modeller geliştirilmiş ve bu modellerin başarıları ayrıntılı bir şekilde incelenmiştir. Ayrıca yapılan deneysel çalışmalarda her bir lezyon grubu için üzerinde çalışılan modellerden en iyi performans sunan iki model bilgisinin içinde yer aldığı hibrid karar verici sistem ile geliştirilen uygulamanın oldukça başarılı sonuçlar verdiği görülmüştür. Bu doğrultuda karar destek sistemlerinde tek model ile



çıkarsama yapmak yerine iki modelin bir arada kullanılması ile daha başarılı bir şekilde destek sağlanabileceğine ilişkin bir çalışma önerilmiştir. Diğer yandan, alan uzmanının her bir lezyonun tespiti için ayrı ayrı kaydedilen model bilgileri içerisinden seçim yapabilmesini ve hastanın sistemdeki önceki kayıtlarını anlık karşılaştırabilme imkânı vererek belirli tarih ve zamandaki gelişimleri inceleyebilmesini sağlayan arayüzler tasarlanmıştır. Bu noktada, hastalığın muhtemel ilerlemesinin önüne geçilebilmesi için alan uzmanına imkân vereceği düşünülmektedir.

Tez çalışması süresince Atatürk Eğitim ve Araştırma Hastanesi Göz hastalıkları anabilim dalından alınmış olan retinal görüntüleri ve ayrıca DIARETDB1, DRIVE ve ROC retinal verisetleri ile çalışılmıştır. Bu süre boyunca hazırlanan çalışmalar uluslararası dergilerde yayınlanmış ([96-97,99]) ve ayrıca ilgili konferanslarda ([98,100]) sunulmuştur. Ayrıca, özellikle sert eksuda lezyonları ile aynı renk dağılımına sahip olan OD bölgesinin tespitine dair yöntemler geliştirilmiştir. İki farklı bakış açısıyla görüntü işleme yöntemleri temel alınarak OD bölgesinin tespitini içeren çalışmalardan [101] nolu çalışma uluslararası bir konferans bildirisi olarak sunulmuş ve [102] nolu çalışma bir makale olarak yayınlanmıştır. Ayrıca, makula ve kan damarlarının tespitine yönelik çalışmalar da bu süreç boyunca üzerinde çalışılan konular arasındadır.

Uygulanan yöntem ve tekniklerle ve uzman desteği ve görüşü alınarak geliştirilen KDS'nin başarısı retinal görüntünün netliği ile doğru orantılıdır. Bir retinada birçok lezyon ve hastalık türü bulunabilir ve bu görüntülerde renk yoğunluğundaki farklılıklar ve gürültü gibi sorunlar lezyonların tespitini bir o kadar zorlaştırmaktadır. Bu nedenle, retinalardaki yapısal bozuklukların zaman içindeki gelişiminin takip edilebilmesi için retinal görüntü çekimini yapacak olan uzmanın aydınlanma oranı, açısı, çözünürlük gibi kriterleri dikkate alarak belirli standartlara göre görüntüyü elde etmesi gerekir. Özellikle, OD ve makula merkezlerinin aynı hizada olması ve makulanın merkezi bir konumda olması analizin sağlıklı gerçekleşebilmesi için oldukça önemlidir.

Bu çalışmanın, DR hastalığının erken evresinde ortaya çıkan lezyonların tespitinin yapılmasına ve hastaya uygulanacak tedavinin başarı yüzdesinin artışına zemin hazırlayacağı ve sonraki çalışmalara ışık tutacağı düşünülmektedir.

Gelecekte, yeni öznitelikler ve sınıflandırma algoritmaları ile çalışılarak uygulamanın etkinliğinin artırılması hedeflenmektedir. Diğer yandan, DR'nin ileri evresinde ortaya çıkan lezyonların tespiti de hedeflenen çalışmalar arasındadır.

Ayrıca, iki boyutlu retinal görüntüler üzerinde yürütülen bu yöntem ve tekniklerin, farklı verisetleri ve üç boyutlu görüntüleme tekniği gibi daha iyi görüntüleme teknolojileriyle elde edilen retinal görüntüler üzerinde daha başarılı sonuçlar vereceği düşünülmektedir.

## KAYNAKLAR

1. İnternet: Üsküdar Üniversitesi, "Gözün Anatomisi ve Fizyolojisi", <http://www.uskudar.edu.tr/file/optisyenlik/Goz-Anatomisi.pdf> (2015).
2. Xu, X. "Simultaneous automatic detection of optic disc and fovea", M.Sc. Thesis, *The University of Iowa, Biomedical Engineering in the Graduate College* (2010).
3. İnternet: Wikipedia, "Retina", <https://tr.wikipedia.org/wiki/Retina> (2015).
4. Çetinkaya, C. "Retina görüntülerinde radyal tabanlı fonksiyon sinir ağları ile damar tipik noktalarının tespit edilmesi", Yüksek Lisans Tezi, *Ege Üniversitesi Fen Bilimleri Enstitüsü*, Bornova (2011).
5. Doğanay, E. "The development of an automated detection algorithm for the hypertensive patients by using artery narrowing on fundus images", Master of Science, *Fatih University Graduate Institute of Sciences and Engineering*, İstanbul (2010).
6. İkibaş, C. "Retinal İmgelerde Optik Disk ve Makulanın Tespiti ve Değerlendirilmesi", Doktora Tezi, *Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü*, Trabzon (2012).
7. Cox, M. J. and Wood, I. C. J. "Computer-assisted optic nerve head assessment", *Ophthal Physiol Opt*, 11: 27-35 (1991).
8. İnternet: Review of Optometry, "Automated Fundus kamera", <https://www.reviewofoptometry.com/article/product-review-15415> (2016).
9. İnternet: NHS Choices your health, your choices, "Diabetic retinopathy", <http://www.nhs.uk/Conditions/Diabetic-retinopathy/Pages/Introduction.aspx> (2015).
10. İnternet: İstanbul Cerrahi, "Diyabetik Retinopati", <http://www.lasikinturkey.com/diyabetik-retinopati> (2007).
11. İnternet: Wikipedia, "Diabetic\_retinopathy", [https://en.wikipedia.org/wiki/Diabetic\\_retinopathy](https://en.wikipedia.org/wiki/Diabetic_retinopathy) (2015).
12. Mohamed, Q., Gillies, M. C. and Wong, T. Y. "Management of diabetic retinopathy: A systematic review", *The Journal of the American Medical Association*, 298(8): 902-916 (2007).

13. İnternet: Türk Diabet ve Obezite Vakfı, "Diabetik Retinopati", <http://diabetvakfi.org/inf.php?partid=5&catid=5&pid=26> (2015).
14. İnternet: IMAGERET Optimal Detection and Decision-Support Diagnosis of Diabetic Retinopathy, "DIARETDB1 - Standard Diabetic Retinopathy Database", <http://www.it.lut.fi/project/imageret/diaretdb1/> (2015).
15. Kauppi, T., Kamarainen, J. K., Lensu, L., Kalesnykiene, V., Sorri, I., Uusitalo, H. and Kalviainen, H. "Constructing benchmark databases and protocols for medical image analysis: Diabetic Retinopathy", *Computational and Mathematical Methods in Medicine*, 2013: 368514 (2013).
16. Kumar, A., Gaur, A. K. and Srivastava, M. "A segment based technique for detecting exudate from retinal fundus image", *Procedia Technology*, 6, 1-9 (2012).
17. (a) Sopharak, A., Uyyanonvara, B., Barman, S. and Williamson, T. H. "Automatic detection of diabetic retinopathy exudates from non-dilated retinal images using mathematical morphology methods", *Computerized Medical Imaging and Graphics*, 32 (8): 720-727 (2008).
18. (b) Sopharak, A., Uyyanonvara, B. and Barman, S. "Simple hybrid method for fine microaneurysm detection from non-dilated diabetic retinopathy retinal images", *Computerized Medical Imaging and Graphics*, 37 (5-06): 394-402 (2013).
19. Quellec, G., Lamard, M., Abràmoff, M. D., Decencièrè, E., Lay, B., Erginay A., Cochener, B. and Cazuguel, G. "A multiple-instance learning framework for diabetic retinopathy screening", *Medical Image Analysis*, 16(6): 1228-1240 (2012).
20. Mookiah, M. R. K., Rajendra-Acharya, U., Martis, R. J., Chua, K. C., Lim, C. M., Ng, E. Y. K. and Laude, A. "Evolutionary algorithm based classifier parameter tuning for automatic diabetic retinopathy grading: A hybrid feature extraction approach", *Knowledge-Based Systems*, 39: 9-22 (2013).
21. Usman Akram, M., Khalid, S., Tariq, A., Khan, S. A. and Azam, F. "Detection and classification of retinal lesions for grading of diabetic retinopathy", *Computers in Biology and Medicine*, 45 (1): 161-171 (2014).
22. Yun, W. L., Rajendra Acharya, U., Venkatesh, Y. V., Chee, C., Min, L. C. and Ng, E. Y. K. "Identification of different stages of diabetic retinopathy using retinal optical images", *Information Sciences*, 178 (1):106-121 (2008).
23. Winder, R. J., Morrow, P. J., McRitchie, I. N., Bailie, J. R. and Hart, P. M. "Algorithms for digital image processing in diabetic retinopathy", *Computerized Medical Imaging and Graphics*, 33 (8): 608-622 (2009).

24. Tavakoli, M., Shahri, R. P., Pourreza, H., Mehdizadeh, A., Banaee, T. and Bahreini Toosi, M. H. "A complementary method for automated detection of microaneurysms in fluorescein angiography fundus images to assess diabetic retinopathy", *Pattern Recognition*, 46 (10): 2740-2753 (2013).
25. Askew, D. A., Crossland, L., Ware, R. S., StephenBegg, P. C., Mitchell, P. and Claire L. J. "Diabetic retinopathy screening and monitoring of early stage disease in general practice: design and methods", *Contemporary Clinical Trials*, 33 (5): 969-975 (2012).
26. Adal, K. M., Sidibé, D., Ali, S., Chaum, E., Karnowski, T. P. and Mériaudeau, F. "Automated detection of microaneurysms using scale-adapted blob analysis and semi-supervised learning", *Computer Methods and Programs in Biomedicine*, 114 (1): 1-10 (2014).
27. Antal, B. and Hajdu, A. "Improving microaneurysm detection using an optimally selected subset of candidate extractors and preprocessing methods", *Pattern Recognition*, 45 (1): 264-270 (2012).
28. Niemeijer, M., van Ginneken, B. and Russell, S. R. "Automated detection and differentiation of drusen, exudates, and cotton-wool spots in digital color fundus photographs for diabetic retinopathy diagnosis", *Investigative Ophthalmology & Visual Science*, 48: 2260-2267 (2007).
29. Garcia, M., Valverde, C., Lopez, M. I., Poza, J. and Hornero, R. "Comparison of logistic regression and neural network classifiers in the detection of hard exudates in retinal images", *35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, July (2013).
30. Garcia, M., Sanchez, C. I., Lopez, M. I., Abasolo, D. and Hornero, R. "Neural network based detection of hard exudates in retinal images", *Computer Methods and Programs in Biomedicine*, 93 (1): 9-19 (2009).
31. Kayal, D. and Banerjee, S. "A new dynamic thresholding based technique for detection of hard exudates in digital retinal fundus image", *International Conference on Signal Processing and Integrated Networks*, February, 141-144 (2014).
32. Xu L. and Luo S. "Support vector machine based method for identifying hard exudates in retinal images", *IEEE Youth Conference on Information, Computing and Telecommunication*, Beijing, September (2009).
33. Naqvi, S. A., Zafar, M. F. and Haq, I. U. "Referral system for hard exudates in eye fundus", *Comput Biol Med*, 64: 217-235 (2015).
34. Chen, X., Bu, W., Wu, X., Dai, B. and Teng, Y. "A novel method for automatic hard exudates detection in color retinal images", *IEEE International Conference on Machine Learning and Cybernetics*, 1175-1181, July (2012).

35. Ranamuka, N. G. and Meegama, R. G. N. "Detection of hard exudates from diabetic retinopathy images using fuzzy logic", *IET Image Process*, 7 (2): 121-130 (2013).
36. Tjandrasa, H., Putra, R. E., Wijaya, A. Y. and Ariesianti, I. "Classification of non-proliferative diabetic retinopathy based on hard exudates using soft margin SVM", *IEEE International Conference on Control System, Computing and Engineering*, December, 376-380 (2013).
37. Kavitha, D. and Shenbaga Devi, S. "Automatic detection of optic disc and exudates in retinal images", *Proceedings of 2005 International Conference on Intelligent Sensing and Information Processing*, 501-506 (2005).
38. JayaKumari, C. and Maruthi, R. "Detection of hard exudates in color fundus images of the human retina", *Procedia Engineering*, 30: 297-302 (2011).
39. Mishra, A. M., Singh, P. K. and Chawla, K. S. "An information geometry based scheme for hard exudate detection in fundus images", *India Conference*, 1-4, Hyderabad (2011).
40. Eadgahi, M. G. F. and Pourreza, H. "Localization of hard exudates in retinal fundus image by mathematical morphology operations", *2nd International Conference on Computer and Knowledge Engineering*, 185-189, Mashhad (2012).
41. Zhang, B., Wu, X., You, J., Li, Q. and Karray, F. "Detection of microaneurysms using multi-scale correlation coefficients", *Pattern Recognition*, 43 (6): 2237-2248 (2010).
42. Hipwell, J. H., Strachan, F., Olson, J. A., McHardy, K. C., Sharp, P. F. and Forrester, J. V. "Automated detection of microaneurysms in digital red-free photographs: a diabetic retinopathy screening tool", *Diabet Med*, 17 (8): 588-594 (2000).
43. Saleh, M. D. and Eswaran, C. "An automated decision-support system for non-proliferative diabetic retinopathy disease based on MAs and HAs detection", *Computer Methods and Programs in Biomedicine*, 108 (1): 186-196 (2012).
44. Sharma, A., Dutta, M. K., Singh, A., Parthasarathi, M. and Travieso, C. M. "Dynamic thresholding technique for detection of hemorrhages in retinal images", *Seventh International Conference on Contemporary Computing*, Noida, 113-116 (2014).
45. Saleem, M. and Usman Akram, M. "Detection of hemorrhages for diagnosis of malarial retinopathy", *Cairo International Biomedical Engineering Conference*, Giza, 141-144 (2014).
46. Spencer, T., Olson, J. A., McHardy, K. C., Sharp, P. F. and Forrester, J. V. "An image-processing strategy for the segmentation and quantification of

- microaneurysms in fluorescein angiograms of the ocular fundus", *Computers and Biomedical Research*, 29 (4): 284-302 (1996).
47. Zhang, X. and Chutatape, O. "Top-down and bottom-up strategies in lesion detection of background diabetic retinopathy", *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, 2: 422-428 (2005).
  48. Lupascu, C. A., Tegolo, D. and Rosa, L. D. "Automated detection of optic disc location in retinal images", *21st IEEE International Symposium on Computer-Based Medical Systems*, Jyvaskyla, June (2008).
  49. Esmaeili, M., Rabbani, H. and Dehnavi, A. M. "Automatic optic disk boundary extraction by the use of curvelet transform and deformable variational level set model", *Pattern Recognition*, 45 (7): 2832-2842 (2012).
  50. Sinthanayothin, C., Boyce, J. F., Cook, H. L. and Williamson T. H. "Automated location of the optic disc, fovea, and retinal blood vessels from digital color fundus images", *Br J Ophthalmol*, 83 (8): 902-910 (1999).
  51. Park, M., Jin, J. S. and Luo, S. "Locating the optic disc in retinal images", *IEEE International Conference on Computer Graphics, Imaging and Visualisation*, Sydney, July (2006).
  52. Lalonde, M., Beaulieu, M. and Gagnon L. "Fast and robust optic disc detection using pyramidal decomposition and hausdorff-based template matching", *IEEE Transaction on Medical Imaging*, 20 (11): 1193-1200 (2001).
  53. Lu, S. and Lim, J. H. "Automatic optic disc detection through background estimation", *17<sup>th</sup> IEEE International Conference on Image Processing*, Hong Kong, September (2010).
  54. Godse, D. A. and Bormane D. S. "Automated localization of optic disc in retinal images", *International Journal of Advanced Computer Science and Applications*, 4 (2): 65-71 (2013).
  55. Perez, C. A., Schulz, D. A., Aravena, C. M., Perez, C. I. and Verdaguer, T. J. "A new method for online retinal optic-disc detection based on cascade classifiers", *IEEE International Conference on Systems, Man, and Cybernetics*, Manchester, October (2013).
  56. Gonzalez, R. C. and Woods, R. E. "Digital Image Processing, 2nd ed.", *Prentice-Hall*, Upper Saddle River, N.J., USA, 54-55, 78-79 (2002).
  57. Dougherty, G. "Digital Image Processing for Medical Applications", *Cambridge University*, 205, 273, 274, 319-321, 340-342, 403 (2009).

58. Sasi, N. M., Jayasree, V. K. "Contrast Limited Adaptive Histogram Equalization for Qualitative Enhancement of Myocardial Perfusion Images", *Engineering*, 5: 326-331 (2013).
59. Osadchy, M., Lindenbaum, M. and Jacobs, D. "Whitening for photometric comparison of smooth surfaces under varying illumination", *8th European Conference on Computer Vision*, Prague, May (2004).
60. Hyvarinen, A., Hurri, J. and Hoyer, P. O. "Natural image statistics: A probabilistic approach to early computational vision", *Springer*, 109 (2009).
61. Russ, J. C. "The Image Processing Handbook 6rd ed.", *CRC Press*, 468, 582 (2011).
62. Bovik, A. "The essential guide to image processing", *Elsevier Inc.*, 78: 115-116 (2009).
63. Jiang, Y. G., Ngo, C. W. and Yang, J. "Towards optimal bag-of-features for object categorization and semantic video retrieval", *Conference on Image and Video Retrieval*, New York, July (2007).
64. Lazebnik, S., Schmid, C. and Ponce, J. "Beyond bags of features: spatial pyramid matching for recognizing natural scene categories", *IEEE Computer Society Conference on Computer Vision and Pattern Recognition(CVPR'06)*, 2: 2169-2178 (2006).
65. Fei-Fei, L. and Perona, P. "A bayesian hierarchical model for learning natural scene categories", *IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'05)*, 2: 524-531 (2006).
66. Sivic, J. and Zisserman, A. "Video google: A text retrieval approach to object matching in videos", *IEEE 2003 International Conference on Computer Vision*, Nice, October (2003).
67. Mikolajczyk, K. and Schmid, C. "A performance evaluation of local descriptors", *IEEE T Pattern Anal*, 27 (10): 1615-1630 (2005).
68. Rublee, E., Rabaud, V., Konolige, K. and Bradski, G. "ORB: an efficient alternative to SIFT or SURF", *IEEE International Conference on Computer Vision (ICCV)*, Barcelona, November (2011).
69. Bay, H., Ess, A., Tuytelaars, T. and Gool, L. V. "Speed-up Robust Features (SURF)", *Computer Vision and Image Understanding*, 110(3): 346-359 (2008).
70. Vedaldi, A., Ling, H. and Soatto, S. "Knowing a Good Feature When You See It: Ground Truth and Methodology to Evaluate Local Features for Recognition", *Computer Vision*, 285: 27-49 (2010).



71. Jemaa, Y. B. and Khanfir, S. "Automatic local Gabor features extraction for face recognition", *International Journal of Computer Science and Information Security*, 3 (1): (2009).
72. Shiv Naga Prasad, V. and Domke, J. "Gabor filter visualization", *Technical Report*, University of Maryland (2005).
73. Güneş, T. ve Polat, E. "Yüz ifade analizinde öznelik seçimi ve çoklu SVM sınıflandırıcılarına etkisi", *Gazi Üniv. Müh. Mim. Fak. Der.*, 24 (1): 7-14 (2009).
74. Guyon, I., Weston, J., Barnhill, S. and Vapnik, V. "Gene selection for cancer classification using support vector machines", *Mach Learn*, 46 (1): 389-422 (2002).
75. Çölkesen, İ., Kavzaoğlu T. ve Yomralıoğlu, T. "Uzaktan algılanmış görüntülerde optimum bantların seçiminde destek vektör makinelerinin kullanımı", *Türkiye Ulusal Fotogrametri ve Uzaktan Algılama Birliği VIII. Sempozyumu*, Konya (2015).
76. Deng, C., Xiaofei, H. and Han, J. "SRDA: An efficient algorithm for large-scale discriminant analysis", *IEEE Transactions on Knowledge and Data Engineering*, 20 (1): 1-12 (2008).
77. Pan, Y., Wu, J., Huang, H. and Liu, J. "Spectral regression discriminant analysis for hyperspectral image classification", *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, Melbourne, September (2012).
78. Yan, S., Xu, D., Zhang, B., Zhang, H. J., Yang, Q. and Lin, S. "Graph embedding and extensions: A general framework for dimensionality reduction", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29 (1): 40-51 (2007).
79. Boyacıoğlu, H. ve Güneri, P. "Sağlık araştırmalarında kullanılan temel istatistik yöntemler", *Hacettepe Dişhekimliği Fakültesi Dergisi*, 30 (3): 33-39 (2006).
80. Kleinbaum, D. G. and Klein, M. "Logistic regression: a self-learning text, 3rd ed.", *Springer*, New York Dordrecht Heidelberg, London, 4 (2010).
81. Özdamar, K. "Paket Programlar İle İstatistiksel Veri Analizi", *Kaan Kitabevi*, Eskişehir, 625, 626-627 (2002).
82. Alan, A. "An introduction to categorical data analysis", *Wiley Series In Probability And Statistics*, Canada, 22 (1996).
83. Gujarati, D. N. "Basic Econometrics", *Mc Graw Hill*, New York, 596 (2004).

84. Hosmer, D. W. and Lemeshow, S. "Applied logistic regression, 2nd ed.", *Wiley Series in Probability and Statistics*, Canada, 6 (2000).
85. Breiman, L. "Random forests", *Mach Learn*, 45 (1): 5-32 ( 2001).
86. Kaya, H., Erçetin, A. M., Salah, A. A. ve Gürgen, S. F. "Rassal ormanlar, değişken seçimi ve normal yumuşatma kullanarak kahkaha ve dolguların tespiti", *Akademik Bilişim Konferans Bildirileri*, Mersin (2014).
87. Çölkesen, İ. "Yüksek çözünürlüklü uydu görüntülerini kullanarak benzer spektral özelliklere sahip doğal nesnelerin ayırt edilmesine yönelik bir metodoloji geliştirme", Doktora Tezi, *İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul (2015).
88. Akar, Ö. ve Güngör, O. "Rastgele orman algoritması kullanılarak çok bantlı görüntülerin sınıflandırılması", *Karadeniz Teknik Üniversitesi*, 1 (2): 139-146 (2012).
89. Pala, T. "Tıbbi karar destek sisteminin veri madenciliği yöntemleriyle gerçekleştirilmesi", Yüksek Lisans Tezi, *Marmara Üniversitesi Fen Bilimleri Enstitüsü*, İstanbul (2013).
90. Kohavi, R. "A study of cross-validation and bootstrap for accuracy estimation and model selection", *Proceedings of the 14th international joint conference on Artificial intelligence*, 2: 1137-1143 (1995).
91. Yücelbaş, C. "Elipsoid tanıma çemberli bir yapay bağışıklık sistemi tasarımı ve sınıflama problemlerindeki performans analizi", Yüksek Lisans Tezi, *Selçuk Üniversitesi Fen Bilimleri Enstitüsü*, Konya (2012).
92. İnternet: Biyoistatistik, "Sensitivite, Spesifite ve Testin Tahmin Gücü", <http://www.infobik.com/2014/04/23/sensitivite-spesifite-ve-testin-tahmin-gucu/> (2015).
93. Wei, Q. and Dunbrack, R. L. "The role of balanced training and testing data sets for binary classifiers in bioinformatics", *PLoS One*, 8 (7): e67863 (2013).
94. Dobbin, K. K. and Simon, R. M. "Optimally splitting cases for training and testing high dimensional classifiers", *BMC Medical Genomics*, 4 (31): 1-8 (2011).
95. Achanta, R., Shaji, A., Smith, K., Lucchi, A., Fua, P. and Süsstrunk, S. "SLIC Superpixels Compared to State-of-the-art Superpixel Methods", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 34 (11): 2274-2282 (2012).
96. Akyol K., Şen, B. and Bayır, Ş., "Detection of hard exudates in diabetic retinopathy retinal images by utilizing visual dictionary and classifier approaches", *Mugla Journal of Science and Technology*, 3(1): 1-6 (2016).

97. Akyol, K., Şen, B. and Bayır, Ş., "Automatic Identification of Hard Exudates in Retinal Fundus Images using Techniques of Information Retrieval", *International Journal of Computer Applications*, 120 (13): 11-16 (2015).
98. Akyol, K., Şen, B. ve Bayır, Ş. "Gabor Özellikleri ve Görsel Sözlük Kullanarak Retinal Görüntülerdeki Sert Eksudaların Tespiti", *Akademik Bilişim Konferansları*, Aydın, Şubat (2016).
99. Akyol, K., Şen, B., Bayır, Ş. and Çakmak, H. B. "Assessing the importance of features for detection of hard exudates in retinal images", *Turk J Elec Eng & Comp Sci doi: 10.3906/elk-1508-71* (2016).
100. Akyol, K., Şen, B. ve Bayır, Ş. "Retinal Görüntülerdeki Mikroanevrizmaların ve Hemorajilerin Tespiti", *Akademik Bilişim Konferansları*, Aydın, Şubat (2016).
101. Akyol, K., Kaya, H., Bayır Ş. and Şen B. "Automated Detection of Optic Disk in Retinal Fundus Images using Gabor Filter Kernels", *5th World Conference on Innovation and Computer Sciences*, Antalya, May (2015).
102. Akyol, K., Şen, B. and Bayır, Ş. "Automatic detection of optic disc in retinal image by using keypoint extraction, texture analysis and visual dictionary techniques", *Computational and Mathematical Methods in Medicine*, 2016: 6814791 (2016).
103. Tola, E., Lepetit, V. and Fua, P. "DAISY: An efficient dense descriptor applied to wide baseline stereo", *IEEE T Pattern Anal*, 32: 815-830 (2010).
104. İnternet: Eye Care, "Retinal Camera", <http://www.topcon.com.sg/medical/trc.html> (2016).

**EK AÇIKLAMALAR A.**

**RETİNAL KAMERA TEKNİK ÖZELLİKLERİ**

## TOPCON TRC-50IX TEKNİK ÖZELLİKLERİ



Şekil EK A.1. Topcon TRC-50IX Retinal kamera [104].

IMAGEnet 2000 ile bağlantısı, sayısal görüntüleme sisteminin geniş aralıkta konfigure edilmesi, görüntü verilerinin otomatik olarak iletimi ve 21 adımda flaş yoğunluğunu ayarlama özellikleri ile retinal görüntüleme için çok iyi performans sunan bir cihazdır [104].

Teknik özellikleri:

1. Çalışma mesafesi: 39 mm
2. Fotografik büyütme: 0 noktasında ışığı kırma derecesi ile 35mm kamera:  
50° de 1.84X, 35° de 2.45X ve 20° de 4.28X
3. Toplam gözlem büyütme: 50° de 10X, 35° de 13.3X, 20° de 23.3X
4. Göz için diyoptri karşılama aralığı: 0 ayarı: -10 +6 diyoptri, - ayarı: -9 -23 arası diyoptri, + ayarı: +5 +23 arası diyoptri, Ayar: +22 +41 diyoptri.

5. Filtreler: Floresan anjiyografi, ICG anjiyografi, Red free görüntüleme, Diğer filtreler
6. Diyoptri düzeltme aralığı: -6D ile +5D
7. Stereo görüntüleme:  $\pm 1$  mm
8. Optik kafa salınımı:  $\pm 30^\circ$  ye kadar
9. Işık kaynağı: Gözlem için: 12V 100W halojen lamba, Görüntüleme için: 21 kademeli ayarlamalı maksimum 300WS Xenon lamba, şarj süresi: 1 saniye
10. Optik baş eğimi: yukarıya  $15^\circ$  ve aşağıya  $10^\circ$
11. Güç kaynağı ünitesi: AC 120V, AC 220V, AC230V ve AC 240V ayarlanabilir voltaj seçici özelliği ile
12. Güç tüketimi: Max 2000VA / Normal 150 VA
13. Boyutlar (Temel gövde) : Genişlik: 340 mm, derinlik: 505 mm, yükseklik: 589 mm.
14. Ağırlık (Temel gövde) : 37 Kg.

## **ÖZGEÇMİŞ**

Kemal AKYOL, 1980 yılında Muğla ilinin Ula ilçesinde doğdu. İlkokulu Ula Cumhuriyet İlköğretim Okulu'nda, ortaokulu ise Ula Atatürk Ortaokulu'nda tamamladı. Lise eğitimini Muğla Teknik Lisesi Elektrik Bölümü'nden mezun olarak tamamladı. 1998 yılında Gazi Üniversitesi Teknik Eğitim Fakültesi Elektronik ve Bilgisayar Eğitimi Bölümü'nde öğrenimine başlayıp 2002 yılında iyi derece ile mezun oldu. 2002 yılında Samsun Atakum Mesleki ve Teknik Anadolu Lisesi'nde Bilişim Teknolojileri öğretmeni olarak göreve başladı. 2010 yılında Karabük Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda başlamış olduğu yüksek lisans programını 2012 yılında tamamladı ve ardından Karabük Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı'nda doktora eğitimine başladı. Halen Samsun Atakum Mesleki ve Teknik Anadolu Lisesi'nde Bilişim Teknolojileri öğretmeni olarak görev yapmaktadır.

### **ADRES BİLGİLERİ**

Adres : Karabük Üniversitesi  
Fen Bilimleri Enstitüsü  
Demir-Çelik Kampüsü Yüksek Okullar Binası Zemin Kat / KARABÜK

Tel : (530) 341 13 09

E-posta : kemalakyol48@gmail.com