

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

**RETİNAL FUNDUS GÖRÜNTÜLERDE PİKSEL TABANLI SINIFLANDIRMA
YÖNTEMLERİ İLE KAN DAMARLARININ ÇIKARILMASI**

DOKTORA TEZİ

Bilgisayar Yük. Müh. Zafer YAVUZ

**NİSAN 2018
TRABZON**



KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsünce

Unvanı Verilmesi İçin Kabul Edilen Tezdir.

Tezin Enstitüye Verildiği Tarih : / /

Tezin Savunma Tarihi : / /

Tez Danışmanı :

Trabzon

**KARADENİZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**Bilgisayar Mühendisliği Anabilim Dalında
Zafer YAVUZ Tarafından Hazırlanan**

**RETİNAL FUNDUS GÖRÜNTÜLERDE PİKSEL TABANLI SINIFLANDIRMA
YÖNTEMLERİ İLE KAN DAMARLARININ ÇIKARILMASI**

**başlıklı bu çalışma, Enstitü Yönetim Kurulunun 10 /04/2018 gün ve 1748 sayılı
kararıyla oluşturulan jüri tarafından yapılan sınavda
DOKTORA TEZİ
olarak kabul edilmiştir.**

Jüri Üyeleri


Başkan : Prof. Dr. Derviş KARABOĞA

Üye : Prof. Dr. İbrahim TÜRKOĞLU

Üye : Prof. Dr. Temel KAYIKÇIOĞLU

Üye : Prof. Dr. Murat EKİNCİ

Üye : Prof. Dr. Cemal KÖSE

The block contains four handwritten signatures in blue ink, each written over a horizontal dotted line. The signatures are: 1. Karaboğa (top), 2. Türkoğlu, 3. Kayıkçioğlu, and 4. Ekinci (bottom). The signature of Köse is not visible.

**Prof. Dr. Sadettin KORKMAZ
Enstitü Müdürü**

ÖNSÖZ

Günümüzde medikal görüntüleme tekniklerinde ve bu tekniklerle elde edilen görüntülerin bilgisayar yardımıyla analiz edilerek çeşitli hastalıkların tanısı ve teşhisi amacıyla kullanıldığı uygulamalar giderek artmaktadır. Göz görüntülerini içeren retinal fundus görüntülerdeki kan damarlarının tespit edilerek doktorlara yardımcı araçlar geliştirilmesi bu uygulamalardandır. Bu tez çalışmasında renkli retinal fundus görüntülerde damar iyileştirme ve piksel tabanlı sınıflandırma yöntemleri kullanılarak kan damarlarının otomatik olarak bulunması konusu işlenmiştir.

Tez çalışması süresince bilimsel desteği ve değerli düşünceleriyle bana her konuda ve her aşamada yardımlarını esirgemeyen danışmanım Sayın Prof. Dr. Cemal KÖSE'ye ve yine tez çalışmam süresince değerli katkılarından ötürü Prof. Dr. Murat EKİNCİ ve Prof. Dr. Temel KAYIKÇIOĞLU'na teşekkür ederim.

Çalışmalarımın son aşamalarında değerli bilgi ve manevi desteğiyle her zaman yanımda olan değerli hocam Dr. Öğr. Üyesi İbrahim SAVRAN'a, Öğr. Gör. Ömer ÇAKIR'a, Sait AGAHIAN'a ve değerli arkadaşım Mühendis Hayati TÜRE'ye ve manevi desteklerini esirgemeyen KTÜ Bilgisayar Mühendisliği Bölümü'ndeki tüm hocalarıma ve mesai arkadaşlarıma şükranlarımı sunarım.

Tüm eğitim-öğretim hayatım boyunca maddi ve manevi desteklerini esirgemeyen başta rahmetli annem Havva YAVUZ olmak üzere tüm aileme, sabrından ve tahammüllerinden dolayı sevgili eşim Zeynep YAVUZ'a, çocuklarım Elif YAVUZ, Betül YAVUZ ve Ahmet Emin YAVUZ'a teşekkür ederim,

Bu doktora tezi, Karadeniz Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Doktora Programı'nda hazırlanan bu tezin bundan sonraki çalışmalara katkı sağlamasını temenni ederim.

Zafer YAVUZ

Trabzon 2018

TEZ ETİK BEYANNAMESİ

Doktora Tezi olarak sunduğum “Renkli Retinal Fundus Görüntülerde Damar İyileştirme ve Piksel Tabanlı Sınıflandırma Yöntemleri ile Kan Damarı Bölütleme” başlıklı bu çalışmayı baştan sona kadar danışmanım Prof. Dr. Cemal KÖSE’nin sorumluluğunda tamamladığımı, verileri/örnekleri kendim topladığımı, deneyleri/analizleri ilgili laboratuvarlarda yaptığımı/yaptırdığımı, başka kaynaklardan aldığım bilgileri metinde ve kaynakçada eksiksiz olarak gösterdiğimi, çalışma sürecinde bilimsel araştırma ve etik kurallara uygun olarak davrandığımı ve aksinin ortaya çıkması durumunda her türlü yasal sonucu kabul ettiğimi beyan ederim. 30/04/2018.

Zafer YAVUZ

İÇİNDEKİLER

Sayfa No

ÖNSÖZ	III
TEZ BEYANNAMESİ.....	IV
İÇİNDEKİLER.....	V
ÖZET	IX
SUMMARY	X
ŞEKİLLER DİZİNİ.....	XI
TABLolar DİZİNİ.....	XIII
SEMBOLLER DİZİNİ	XIV
1. GENEL BİLGİLER.....	1
1.1. Giriş	1
1.2. Tezin Amacı ve Kapsamı.....	2
1.3. Göz ve Gözün Yapısı.....	5
1.4. Retinal Görüntü Analizi ve Üzerindeki Yapılar	7
1.4.1. Retinal Fundus Görüntüleme.....	7
1.4.2. Retinal Fundus Görüntü Üzerindeki Yapılar.....	10
1.5. Retinal Kan Damarlarının Özellikleri.....	12
1.6. Retinal Kan Damarlarının Bulunmasında Zorluklar.....	13
1.7. Literatür Çalışmaları.....	14
1.7.1. Kural Tabanlı Yöntemler.....	15
1.7.1.1. Uyum Filtresi Yaklaşımları	16
1.7.1.2. Damar İzleme ve İz Sürme Yaklaşımları.....	18
1.7.1.3. Matematiksel Morfoloji Tabanlı Yaklaşımlar	21
1.7.1.4. Çok Ölçekli Yaklaşımlar	22
1.7.1.5. Model Tabanlı Yaklaşımlar	24
1.7.1.6. Donanım Tabanlı Yaklaşımlar.....	27
1.7.2. Makine Öğrenmesine (Örüntü Tanıma) Dayalı Yöntemler.....	27
1.7.2.1. Denetimli Sınıflandırma Yaklaşımları.....	27
1.7.2.2. Denetimsiz Sınıflandırma (Kümeleme - Öbekleme) Yaklaşımları	33
1.8. Retinal Görüntü Veritabanları	35
1.8.1. STARE Veritabanı.....	36
1.8.2. DRIVE Veritabanı	37

1.8.3.	ARIA Veritabanı.....	37
1.8.4.	HRF Veritabanı.....	38
1.8.5.	CHASE_DB1 Veritabanı.....	38
1.8.6.	RetinaCheck Veritabanı.....	38
2.	YAPILAN ÇALIŞMALAR.....	40
2.1.	Görüntü Ön İşleme Adımları.....	41
2.1.1.	Retinal Bölge Seçimi.....	41
2.1.2.	Retinal Bölge Büyütme.....	44
2.1.3.	Gri Seviye Dönüşüm.....	44
2.1.4.	Damar Işık Refleksi Eleme.....	45
2.2.	Kan Damarı Belirginleştirme.....	46
2.2.1.	İki Boyutlu Gauss Süzgeci.....	47
2.2.2.	İki Boyutlu Gabor Süzgeci.....	49
2.2.3.	Frangi Süzgeci.....	51
2.2.4.	Gri Seviye Morfolojik Top-hat Dönüşümü.....	53
2.3.	Piksel Sınıflandırma Yaklaşımı ile Retinal Kan Damarı Bölütleme.....	56
2.4.	Kural Tabanlı Piksel Sınıflandırma.....	57
2.4.1.	Otsu Eşikleme Yöntemi.....	57
2.4.2.	Yüzdeli (p-tile) Eşikleme Yöntemi.....	60
2.5.	Denetimsiz Sınıflandırma.....	62
2.5.1.	K-ortalama Kümeleme Yöntemi.....	63
2.5.2.	Bulanık C-ortalama Kümeleme Yöntemi.....	65
2.6.	Denetimli Sınıflandırma.....	68
2.6.1.	Öznitelik Çıkarma İşlemi.....	69
2.6.1.1.	Renk Bileşenlerine Dayalı Öznitelik Çıkarma.....	69
2.6.1.2.	İstatistiksel Öznitelik Çıkarma.....	70
2.6.1.3.	Damar Belirginleştirme Yöntemlerine Dayalı Öznitelik Çıkarma.....	71
2.6.2.	Sınıflandırma Yöntemleri.....	71
2.6.2.1.	Doğrusal Ayraç Analizi Sınıflandırıcı (DAA).....	71
2.6.2.2.	En Yakın K Komşu Sınıflandırıcı (EYKK).....	73
2.6.2.3.	Naif Bayes Sınıflandırıcı (NBS).....	73
2.6.2.4.	Destek Vektör Makineleri (DVM).....	75
2.6.2.5.	Yapay Sinir Ağları Sınıflandırıcı (YSA).....	76
2.6.3.	Retinal Kan Damarı Bölütleme.....	80

2.6.3.1.	Eğitim Verisinin Hazırlanması	80
2.6.3.2.	Retinal Kan Damarı Sınıflandırma (Test İşlemi)	82
2.7.	Son İşlemler Adımı.....	82
2.7.1.	Uzunluk Süzgeci	82
2.7.2.	Damar Bölütleri Arasındaki Boşlukları Doldurma.....	83
2.8.	Damar Ölçme ile İlgili Çalışmalar.....	83
2.8.1.	Öznitelik Noktalarının Çıkarılması.....	83
2.8.2.	Komşuluk İlişki Matrisinin Çıkarılması	85
2.8.3.	Retina Görüntüsünün Temsili ve Karakteristik Matris Çıkarma.....	86
2.8.4.	Retinal Görüntü Çakıştırma.....	88
3.	BULGULAR VE İRDELEME	90
3.1.	Performans Değerlendirme Metrikleri ve Veri Kümesi	90
3.2.	Retina Bölgesi Seçimi ile İlgili Elde Edilen Sonuçlar.....	92
3.3.	Kural Tabanlı Piksel Sınıflandırma Yöntemi ile Elde Edilen Sonuçlar	96
3.4.	Denetimsiz Sınıflandırma Yöntemlerinden Elde Edilen Sonuçlar	99
3.5.	Denetimli Sınıflandırma Yöntemlerinden Elde Edilen Bulgular.....	101
3.6.	Damar Ölçme Çalışmalarından Elde Edilen Sonuçlar.....	111
3.7.	Koşma Süresi ve Algoritma Karmaşıklığı ile ilgili Değerlendirme	112
4.	SONUÇLAR.....	115
5.	ÖNERİLER.....	119
6.	KAYNAKLAR	120
ÖZGEÇMİŞ		

Doktora Tezi

ÖZET

RETİNAL FUNDUS GÖRÜNTÜLERDE PİKSEL TABANLI SINIFLANDIRMA
YÖNTEMLERİ İLE KAN DAMARLARININ ÇIKARILMASI

Zafer YAVUZ

Karadeniz Teknik Üniversitesi
Fen Bilimleri Enstitüsü
Bilgisayar Mühendisliği Anabilim Dalı
Danışman: Prof. Dr. Cemal KÖSE
2018, 128 Sayfa

Retinal kan damarı bölütleme işlemi, hipertansiyon, diyabet ve kalp-damar hastalıkları gibi çeşitli patolojilerin tanı ve tedavisinde önemli rol oynamaktadır. Bu çalışmada, retinal fundus görüntülerde kan damarlarının otomatik olarak tespit edilmesi ve elde edilen kan damarlarının temsil edilmesi için kullanılacak karakteristik matris çıkarılması işlemleri gerçekleştirilmektedir. Kan damarı bölütleme işlemi sıralı 4 işlemde oluşmaktadır: 1) Görüntü ön işleme, 2) Kan damarı iyileştirme, 3) Pikel tabanlı sınıflandırma ve 4) Son İşlemler. İlk olarak ön işlem adımında retina bölgesinin seçilmesi, retinal bölge büyütme, gri seviye dönüşüm ve damar ışık refleksi eleme işlemleri gerçekleştirilmektedir. Kan damarı iyileştirme yöntemleri olarak iki boyutlu Gauss ve Gabor süzgeçleri ile Frangi süzgeci ayrı ayrı uygulanmaktadır. Daha sonra kan damarı ayrıntılarını daha da ortaya çıkarmak amacıyla gri seviye morfolojik top-hat dönüşümü kullanılmaktadır. Pikel tabanlı sınıflandırma adımında eşikleme yöntemleri kullanan kural tabanlı, kümeleme yöntemleri kullanan denetimsiz ve makine öğrenmesi yöntemleri kullanan denetimli sınıflandırma yaklaşımları gerçekleştirilmektedir. Denetimli sınıflandırma aşamasında öznitelik olarak damar iyileştirme süzgeç çıktılarının yanında istatistiksel ve renk tabanlı öznitelikler de ayrıca kullanılmaktadır. Daha sonra elde edilen siyah-beyaz kan damarı görüntüsünde son işlemler adımı uygulanmakta ve kan damarı bölütleme yöntemlerinin performans değerlendirmesi işlemleri gerçekleştirilmektedir. Tezin son aşamasında ikili kan damarı görüntüsünde iskelet çıkarma, öz nitelik noktalarının bulunması ve karakteristik öznitelik vektörünün çıkarılması işlemleri gerçekleştirilmektedir.

Anahtar Kelimeler: Retinal görüntüler, Kan damarı bölütleme, Damar belirginleştirme, Eşikleme, Kümeleme, Denetimli sınıflandırma, Öznitelik çıkarma, Uyum süzgeçleri.

PhD. Thesis

SUMMARY

EXTRACTION OF BLOOD VESSELS WITH PIXEL BASED CLASSIFICATION METHODS IN RETINAL FUNDUS IMAGES

Zafer YAVUZ

Karadeniz Technical University
The Graduate School of Natural and Applied Sciences
Computer Engineering Graduate Program
Supervisor: Prof. Dr. Cemal KÖSE
2018, 128 Pages

Retinal blood vessel segmentation is important for diagnosis and treatment of various pathologies such as hypertension, diabetes and cardiovascular diseases. In this thesis, blood vessels in color retinal fundus images are segmented automatically and then a characteristic feature matrix is extracted in order to identify segmented binary blood vessel network. Blood vessel segmentation consists of four stages: 1) Preprocessing, 2) Blood vessel enhancement, 3) Pixel based classification and 4) Post-processing. Firstly, the retinal region is selected before retinal region expansion, gray level transform and vessel light reflex removal processes are implemented in the preprocessing stage. Two-dimensional Gauss and Gabor filter and Frangi filter are applied separately before morphological top-hat transform which extracts details from an image as blood vessel enhancement methods. In the pixel-based classification stage, rule-based methods using thresholding, unsupervised methods using clustering and supervised classification approaches using machine learning methods are implemented. Some statistical and color-based features are also used with the supervised classification methods. Afterwards, post-processing methods are applied to binary vessels and performance evaluation is performed. In the last stage of the thesis, skeleton of the binary vessels are obtained before feature points extraction and a characteristic feature matrix is structured in order to use for image registration as a future process.

Keywords: Retinal images, Blood vessel segmentation, Vessel enhancement, Thresholding, Clustering, Supervised classification, Feature extraction, Matched filters

ŞEKİLLER DİZİNİ

	<u>Sayfa No</u>
Şekil 1. Çalışmanın genel akış şeması	5
Şekil 2. Göz ve gözün yapısı [6].....	6
Şekil 3. Örnek bir retinal fundus kamera ve elde edilen renkli retinal fundus görüntü [7].	7
Şekil 4. Retinal fundus kameraların çalışma prensibi ve elde edilen temsili retinal fundus görüntü [8].	8
Şekil 5. Red-free fundus görüntü (yeşil bileşen) (solda) ve Fluorescein Angiography görüntü (sağda) [9].	9
Şekil 6. Farklı açılarda alınmış retinal fundus görüntüler [8].....	10
Şekil 7. Retinal fundus görüntülerde bulunan yapılar [10].....	11
Şekil 8. Çeşitli hastalıklar nedeniyle oluşan koyu ve açık renkli lezyonlara bir örnek [11].....	12
Şekil 9. Damar bölütleme algoritmalarının genel şeması	15
Şekil 10. Denetimli sınıflandırma yöntemlerin genel akış şeması.....	28
Şekil 11. STARE veritabanından alınmış örnek bir renkli retinal fundus görüntü.....	36
Şekil 12. DRIVE veritabanından alınmış örnek bir renkli retinal fundus görüntü	37
Şekil 13. Retinal kan damarı bölütleme yönteminin genel akış şeması.....	41
Şekil 14. Retinal maske seçim sonuçları	43
Şekil 15. Retinal maske seçim algoritmasının akış şeması.....	44
Şekil 16. (solda) Damar ışık refleksi (okla gösterilen) ve (sağda) damar ışık refleksi eleme işleminin sonucu.....	46
Şekil 17. Kan damarı belirginleştirme işleminin akış şeması	47
Şekil 18. Farklı ölçeklerde ve farklı yönlerde elde edilen Gauss çekirdekleri ($\sigma_x=1$, $\sigma_y=4$)	48
Şekil 19. Farklı yönlerdeki Gauss süzgeçlerinin maksimum tepki görüntü çıktısı.	49
Şekil 20. Farklı ölçeklerde ve farklı yönlerde elde edilen örnek Gabor süzgeçleri ($\sigma=1,2,3$ ve $\gamma=0.5$, $\lambda=2$)	50
Şekil 21. ($\sigma=1$ ve $\gamma=0.25$, $\lambda=2\pi\sigma$) parametreleri ile elde edilen Gauss, Kosinüs ve Gabor fonksiyonları (solda) ve retinal görüntünün Gabor süzgeç çıktısı (sağda).....	51
Şekil 22. Frangi süzgeç çıktısı	53
Şekil 23. Orijinal bir ikili görüntü (solda) ve bu görüntünün $n=5$ çaplı disk biçimli yapısal eleman kullanarak elde edilen top-hat dönüşümü [91].	54

Şekil 24.	Farklı süzgeç çıktılarından sonra uygulanan morfolojik top-hat dönüşüm çıktıları.....	56
Şekil 25.	Belirginleştirilmiş kan damarı görüntüsünün histogram grafiği.....	57
Şekil 26.	Belirginleştirilmiş kan damarı görüntüsüne olası tüm eşiklerin uygulanması sonucu elde edilen ROC eğrisi	58
Şekil 27.	Otsu yöntemi ile tek eşik seçilerek iki seviyeli kan damarı bölütleme.....	59
Şekil 28.	Otsu yöntemi ile iki eşik seçilerek üç seviyeli kan damarı bölütleme.....	59
Şekil 29.	İki sınıflı Otsu (solda) ve üç sınıflı Otsu yöntemleri ile elde edilen ikili damar görüntüleri.....	60
Şekil 30.	Yüzdeli eşikleme yöntemi için kullanılan parametrelerin gösterimi.....	61
Şekil 31.	Yüzdeli eşikleme ile elde edilen ikili kan damarı görüntüsü.....	61
Şekil 32.	Çalışmada uygulanan denetimsiz sınıflandırma (kümeleme) yöntemlerinin genel akış şeması	63
Şekil 33.	K-ortalama yöntemi uygulanarak elde edilen 3 bölgeli damar görüntüsü (solda) ve ikili damar görüntüsü (sağda)	65
Şekil 34.	3 farklı kümeye ait üyelik fonksiyonları ve ait oldukları kümelerin gösterimi	66
Şekil 35.	Bulanık C Ortalama yöntemi uygulanarak elde edilen 3 bölgeli damar görüntüsü (solda) ve ikili damar görüntüsü (sağda)	67
Şekil 36.	Denetimli sınıflandırma yöntemlerinin genel akış şeması.....	69
Şekil 37.	Doğrusal Ayırtaç Analizi (DAA) sınıflandırıcı yönteminin temsili gösterimi	72
Şekil 38.	En Yakın k Komşular (EYKK) yönteminin temsili çalışmasını anlatan grafik.....	73
Şekil 39.	Destek Vektör Makineleri (DVM) yönteminde örnekleri ayıran hiperdüzlem ve destek vektörleri.....	75
Şekil 40.	Basit bir sinir hücresinin (persepton) yapısı.....	77
Şekil 41.	Yapay sinir ağlarının genel yapısı	78
Şekil 42.	Hiperbolik tanjant sigmoid aktivasyon fonksiyonun ($\tanh(x)$) grafiği	79
Şekil 43.	3x3 ve 5x5 komşulukta dallanma noktasının ikili görüntüde gösterimi.....	84
Şekil 44.	İnceltilmiş damar görüntüsünde kenar nokta sayısına (kns) göre öznelik noktalarının gösterimi	85
Şekil 45.	Sentetik kan damar görüntüsü ve öznelik noktalarının komşuluk ilişkileri	86
Şekil 46.	Bir düğüm için hesaplanan karakteristik değerlerin temsili gösterimi	87
Şekil 47.	Karakteristik Matris hesabı için izlenen akış şeması.....	88
Şekil 48.	Karakteristik matris karşılaştırma işleminin akış şeması.....	89
Şekil 49.	Performans metriklerinin (DP, DN, YP, YN) bölgesel karşılıkları.....	91

Şekil 50.	Basit eşik kullanılarak elde edilen maske görüntüsü. Doğruluk değeri: %98,48 (solda) ve önerilen yöntemle elde edilen maske görüntüsü. Doğruluk değeri %99,21 (sağda).....	94
Şekil 51.	STARE veritabanından alınan bir görüntüde elde edilen retina bölgesi	95
Şekil 52.	KTÜ Farabi hastanesinden alınan bir görüntüde elde edilen retina bölgesi	95



TABLÖLAR DİZİNİ

Tablo 1.	Retinal fundus görüntü veritabanları ve özellikleri	39
Tablo 2.	Hessian matrisin öz değerlerinin işaret ve büyüklüklerine göre içerdikleri anlamlar	52
Tablo 3.	Tez çalışmasında damar bölütleme amacıyla kullanılan eğitim ve test veri setleri için kullanılan parametreler özeti.....	81
Tablo 4.	Performans değerlendirmesinde kullanılan metrikler (hata matrisi)	90
Tablo 5.	Tez çalışmasında kullanılan STARE ve DRIVE veritabanları hakkında bilgiler.....	92
Tablo 6.	DRIVE veritabanında bulunan 40 görüntü için elde edilen retina bölgesi tespiti başarımları sonuçları	93
Tablo 7.	DRIVE veritabanındaki 40 görüntü için iki farklı yöntemle elde edilen ortalama doğruluk ve standart sapma değerleri	94
Tablo 8.	Gauss süzgeci kullanılarak elde edilen performans sonuçları	97
Tablo 9.	Gabor süzgeci ve kural tabanlı piksel sınıflandırma yöntemleri kullanılarak farklı veritabanlarından elde edilen performans sonuçları	98
Tablo 10.	Frangi süzgeci ve kural tabanlı sınıflandırma yöntemleri kullanılarak farklı veritabanlarından elde edilen performans sonuçları	98
Tablo 11.	Gauss, Gabor ve Frangi süzgeçleri için seçilen parametreler.....	99
Tablo 12.	Gabor süzgecinden sonra katı ve bulanık kümeleme yöntemlerinin farklı küme sayısına göre elde edilen ortalama performans sonuçları	100
Tablo 13.	STARE ve DRIVE veritabanlarındaki görüntüler için elde edilen ortalama performans sonuçları (küme sayısı 3 olarak seçilmiştir)	101
Tablo 14.	Veritabanı ve seçilen sınıf sayısına göre kullanılan piksel sayıları	102
Tablo 15.	Doğrusal (Fisher) Ayırtaç Sınıflandırıcı ile elde edilen performans bulguları.....	104
Tablo 16.	En Yakın K Komşu Sınıflandırıcı ile elde edilen performans bulguları (k=11)	105
Tablo 17.	Naif Bayes Sınıflandırıcı ile elde edilen performans bulguları	106
Tablo 18.	Destek Vektör Makineleri Sınıflandırıcı ile elde edilen performans bulguları.....	107
Tablo 19.	Yapay Sinir Ağları Sınıflandırıcı ile elde edilen performans bulguları.....	108
Tablo 20.	Tez çalışmasında uygulanan tüm yöntemlerden elde edilen en iyi sonuçların özeti	109

Tablo 21.	STARE ve DRIVE veritabanlarındaki görüntülerden elde edilen performans sonuçları ile literatür çalışmalarında elde edilen performans sonuçlarının karşılaştırılması	110
Tablo 22.	Damar iyileştirme süzgeçlerinin farklı veritabanlarındaki görüntüler için elde edilen koşma süreleri	112
Tablo 23.	Kural tabanlı ve denetimsiz piksel sınıflandırma yöntemlerinin farklı veritabanlarındaki görüntüler için elde edilen koşma süreleri.....	112
Tablo 24.	Denetimli piksel sınıflandırma yöntemleri için elde edilen koşma süreleri ...	113
Tablo 25.	Koşma Sürelerinin diğer yöntemlerle karşılaştırılması	113



SEMBOLLER DİZİNİ

B	: Top-hat Dönüşümünde Kullanılan Yapısal Eleman
DAA	: Doğrusal Ayırtaç Analizi
DN	: Doğru Negatif
DOG	: Doğruluk
DP	: Doğru Pozitif
DUY	: Duyarlılık
DVM	: Destek Vektör Makineleri
EYKK	: En Yakın K Komşu
FOV	: Field of View, Görüş Alanı
I_{xx}	: Görüntünün x Yönünde 2. Türevi
I_{xy}	: Görüntünün Önce x - y Yönündeki 2. Türevi
I_{yy}	: Görüntünün y Yönünde 2. Türevi
K,Y,M	: Kırmızı Yeşil Mavi Renk Bileşenleri
KES	: Kesinlik
KNS	: Komşu Nokta Sayısı
NBS	: Naif Bayes Sınıflandırıcı
OD	: Optik Disk
$P(C_k x)$	: x Koşulunda C_k Sınıfının Olasılığı
$P(x)$	: x Özniteliğinin Önsel Olasılığı
$P(C_k)$	: C_k sınıfının Önsel Olasılığı
$P(x C_k)$	: C_k koşulunda x Özniteliğinin Olasılığı
R_b, S	: Frangi Süzgeci Oransal Değerler
S	: Ölçek Bileşeni
T, T_i	: Eşik Değerleri
W	: Ağırlık Katsayısı, Katsayı Vektörü
$V(s)$	: Frangi Süzgecinde Hesaplanan Damarlılık Değeri
YN	: Yanlış Negative
YP	: Yanlış Pozitif
YSA	: Yapay Sinir Ağları

c_k	: Kırmızı Renk Bileşeni Katsayısı
c_y	: Yeşil Renk Bileşeni Katsayısı
c_m	: Mavi Renk Bileşeni Katsayısı
x, y	: Görüntüdeki Piksel Koordinatları
x', y'	: Döndürülmüş Görüntüdeki Piksel Koordinatları
λ	: Dalga Boyu
θ	: Dönme Açısı
σ	: Standart Sapma
γ	: Gauss veya Gabor Fonksiyon Çekirdeğinin En/Boy Oranı
σ_x, σ_y	: Gauss veya Gabor Fonksiyon Çekirdeğinin Yatay/Düşey Standart Sapmaları
λ_1, λ_2	: Hessian Matrisin Öz Değerler
β, c	: Frangi Süzgeci Ayar Parametreleri
f_i	: İstatistiksel öznitelikler
r	: Yarıçap, Uzaklık

1. GENEL BİLGİLER

1.1. Giriş

Son yıllarda medikal görüntülerin bilgisayar yardımıyla analiz edilerek çeşitli hastalıkların tanısı ve teşhisi amacıyla kullanıldığı uygulamalar giderek artmaktadır. Örneğin Röntgen, Manyetik Rezonans (MR), Ultrasound görüntüleme (USG), Tomografi, Fundus fotoğraflama yoğun olarak kullanılan medikal görüntü alma tekniklerindendir. Bu tür görüntüleri bilgisayar yardımıyla analiz eden sistemler doktorlara veya sağlık uzmanlarına tanı koymada ve tedavi planlamada yardımcı ve tamamlayıcı araç olarak kullanılmaktadır [1],[2].

Göz, insan vücudunda önemli bir organdır ve insan gözünün retinasının resmedildiği retinal fundus görüntüler de önemli medikal görüntülerdendir. Oftalmolojide (göz hastalıkları ve cerrahisi ile ilgilenen bilim dalı) sayısal fundus görüntüleme tekniği, hipertansiyon, diyabet ve kalp-damar hastalıkları gibi çeşitli patolojilerin medikal tanısında önemli rol oynamaktadır. Retinal fundus görüntülerin bilgisayar destekli görüntü analizi birçok vaka için arzu edilen bir durumdur. Örnek olarak birçok ülkede çalışan insanlar arasındaki körlüğün patolojik sebepleri arasında diyabetik retinopati (DR) en başı çekmektedir ve bu patolojik durum şeker hastalığı (diyabet) sebebiyle retinada ortaya çıkan bir rahatsızlıktır. Diyabetik retinopati ve benzeri göz rahatsızlığı olan hastalar erken dönemde herhangi bir görme kaybı yaşamadan önce önemli bir şikayetle karşılaşmamaktadırlar. Hasta görme kaybı şikayetlerinde bulunduğu anda ise genelde bu hastalıklar ya ilerlemiş olmakta ya da uygulanacak tedavinin etkisi geç dönemlerde azalmaktadır. Bu nedenle tedavinin zamanında yapıldığından emin olmak için hastalarının en azından yılda bir kere fundus görüntülerinin incelenmesi ve analizi gerekmektedir. Ancak bu önleyici eylem bile sağlık sistemleri için büyük bir zorluk içermektedir. Çünkü bu operasyon için milyonlarca hastanın oftalmolojik revizyondan geçmesi ve büyük miktardaki verilerin incelenmesi gerekmektedir. Bu nedenle birçok hasta yeterli tedaviyi alamamaktadır. Ayrıca çok miktardaki görüntünün incelenmesi ve hastalık tarama programlarının yürütülmesi sağlık sistemi için de ayrıca önemli bir ekonomik yük getirmektedir. Tüm bu sebeplerle göz görüntülerinin bilgisayar yardımıyla otomatik olarak taranması önem kazanmaktadır [3],[4].

Retinada optik disk, makula ve kan damarları gibi farklı anatomik yapılar bulunmaktadır. Retinadaki kan damarlarından elde edilen bilgiler, diyabet, hipertansiyon, damar sertliği gibi hastalıkların etkilerinin gözlenmesinde ve derecelendirilmesinde önemli bilgiler sunmaktadır. Örneğin; kan damarları, retinadaki optik disk (OD), makula (görme olayının gerçekleştiği sarı nokta) ve diğer lezyonların konumunu belirlemek için kullanılmaktadır. Ayrıca çeşitli yerel veya sistematik hastalıklar sebebiyle kan damarlarında ölçülebilir bazı metrikler gözlenmektedir. Bu metriklere örnek olarak kan damarı çapı, renk, eğrilik, kan damarlarındaki dallanma açıları, atardamar-toplardamar geçişleri ve küçük damar örüntülerindeki farklılıklar gösterilebilir. Kan damarlarının tespit edilmesi bu metriklerin elde edilmesine yardımcı olmaktadır. Bu ölçümler teşhiste, tedavi planlamada ve klinik çalışmalarda doktorlara yardımcı ve destekleyici bir araç olarak kullanılabilir.

Merkezi atardamar tıkanması retinal atardamarların büzülmesine, hipertansiyon retinadaki atardamarların genişlemesine, retinal toplardamar tıkanması damarların eğrilerek genişlemesine neden olmaktadır. Benzer şekilde damar sertliği atardamarların bakır veya gümüş rengi almasına, diyabet ise retinada yeni kan damarlarının oluşmasına (neovaskülarizasyon) neden olmaktadır. Ayrıca kan damarları değişmez özneliklerinden dolayı aynı hastanın farklı zamanlarda ve farklı kaynaklardan elde edilen görüntülerinin karşılaştırılmasında kullanılabilir. Bu nedenlerle mevcut damar ölçülerini de koruyan güvenilir bir damar tespit yöntemine ihtiyaç duyulmaktadır [5].

1.2. Tezin Amacı ve Kapsamı

Bu çalışmada, oftalmologlar tarafından fundus kameralar ile elde edilen renkli retinal fundus görüntülerdeki retina bölgesinin tespit edilmesi, retina bölgesindeki kan damarlarının otomatik çıkarılması ve bunların sonucunda elde edilen kan damarlarının görüntü karşılaştırma, retinal kan damarı tanıma gibi uygulamalarda kullanmak üzere morfolojik özneliklerinin çıkarılması amaçlanmaktadır.

Retinal kan damarları diyabet, hipertansiyon gibi birçok sistemik hastalıklar hakkında göz doktorlarına yararlı bilgiler sunmaktadır. Bu nedenle mevcut damar ölçülerini koruyan, doktorlara ölçülebilir birtakım öznelikler sunan ve güvenilir bir retinal kan damarı bölütleme gerçekleştirmek bu çalışmanın temel hedeflerindendir. Bir başka ifadeyle bu çalışmada, retinal fundus görüntülerde kan damarlarının otomatik olarak bulunması ve

ıkarılan bu damarların yapısal  zniteliklerinin (kalınlık, dallanma noktaları vs...) ıkarılması amalanmaktadır.

alıřmanın bir diğ r amacı renkli olarak ve dikd rtgen biiminde ekilen retinal fundus g r nt lerde basık elips yapıda olan retina b lgesi iin otomatik bir maske g r nt s n n tespit edilmesidir. Elde edilen retinal fundus g r nt de retina b lgesi (g r ř alanı - Field of View - FOV) dıřında kalan alanlar gerekte retinaya ait olmasalar bile retinal fundus g r nt lerde yer almaktadırlar. Bu alıřma ile retina b lgesi iin kullanılacak bir maskenin otomatik olarak tespit edilmesi amalanmaktadır.

Retinal kan damarları tespit edildikten sonra retinal kan damarlarının morfolojik olarak değ rlendirilmesi ve  l lebilir  zniteliklerin ıkarılması bu alıřmanın bir diğ r hedeflerindendir.

Bu tezin amaları ve kapsamı maddeler halinde sıralanacak olursa;

- Kullanılacak retina g r nt lerinde retina g r ř alanının (FOV) otomatik olarak tespit edilmesi amalanmaktadır.
- Retina g r nt lerinde kan damarlarının ıkarılması iřleminin piksel tabanlı sınıflandırma yaklařımı kullanan kural tabanlı, denetimsiz ve denetimli makine  ğrenmesi y ntemleri ile gerekleřtirilmesi hedeflenmektedir.
- Kan damar b l tleme iřlemleri sonucunda elde edilen siyah-beyaz damar g r nt lerinden damar tanıma ve g r nt  akıřtırma amacıyla morfolojik  zniteliklerin bulunması ve değ rlendirilmesi alıřmanın bir diğ r amacıdır.
- Farklı parametrelerle ve y ntemlerle elde edilen deneysel sonuların raporlanması, bu sonuların birbirleri ile ve literat rdeki diğ r alıřmalarla karřılařtırılması bu alıřmanın bir diğ r amacını oluřturmaktadır.


Tezin birinci b l m nde, g z n yapısı ve retina  zerindeki yapılar hakkında genel bilgiler verilmiř, daha sonra kan damarlarının  zelliklerine değ nilmiřtir. Bu b l mde ayrıca literat rde yapılan alıřmalar farklı bir taksonometri bakıř aısı ile incelenmiř ve literat rdeki alıřmalarda oğ nlukla kullanılan retina g r nt  veritabanlarından bahsedilmiřtir.

İkinci b l mde, retina b lgesinin seilmesi ve retinal fundus g r nt lerde kan damarı tespitini olumsuz etkileyebilecek birtakım etkenlerin giderilmesi amacıyla g r nt   n iřleme adımları verilmiřtir. G r nt   n iřleme olarak sırasıyla retina b lgesi seme, retinal b lge b y tme, gri seviye d n ř m ve damar ıřık refleksi eleme adımları uygulanmıřtır. Daha sonra kan damarı belirginleřtirme y ntemleri verilmiř ve belirginleřtirilmiř damar

görüntüleri piksel sınıflandırma yöntemleri (kural tabanlı piksel sınıflandırma ve makine öğrenmesine dayalı piksel sınıflandırma) ile ikili kan damarı görüntüsü elde edilmektedir. Kan damarı belirginleştirmesi adımıyla iki boyutlu uyum süzgeci olarak Gauss ve Gabor süzgeçleri ile çok ölçekli Frangi süzgeci kullanılmıştır. Uygulanan süzgeçlerden sonra kan damarı ayrıntılarını daha da ortaya çıkarmak ve kan damarı ile retina arkaplanı arasındaki kontrast seviyesini arttırmak amacıyla gri seviye morfolojik top-hat dönüşümü uygulanmıştır. Piksel sınıflandırmaya dayalı kan damarı bölütleme amacıyla kural tabanlı ve makine öğrenmesine dayalı piksel sınıflandırma yöntemleri kullanılmıştır. Kural tabanlı piksel sınıflandırma için iki ve üç seviyeli Otsu eşikleme yöntemi ile yüzdeli eşikleme yöntemleri verilmiştir. Makine öğrenmesine dayalı piksel sınıflandırma yöntemi olarak denetimsiz sınıflandırma (K-ortalama ve Bulanık C-ortalama) ile denetimli sınıflandırma (Doğrusal (Fisher) Ayırtaç Analizi - DAA, En Yakın K Komşular - EYKK, Naif Bayes Sınıflandırıcı - NBS, Destek Vektör Makineleri – DVM, Yapay Sinir Ağları - YSA) yöntemleri kullanılmıştır. Öznitelik olarak bu süzgeç çıktıları ile istatistiksel öznitelikler ile renk tabanlı öznitelikler de ayrıca makine öğrenmesine dayalı piksel sınıflandırmada kullanılmıştır. Daha sonra elde edilen siyah-beyaz kan damarı görüntüsünde son işlemler adımı uygulanmış ve kan damarı bölütleme yöntemlerinin performans değerlendirmesi işlemleri gerçekleştirilmiştir. İkili kan damarı çıkarıldıktan sonra iskelet çıkarma, öz nitelik noktalarının çıkarılması ve damar tanıma ve görüntü çakıştırma amacıyla karakteristik öznitelik vektörünün çıkarılması işlemleri verilmiştir.

Tezin üçüncü bölümünde farklı parametrelerle ve farklı yöntemler kullanılmasıyla elde edilen deneysel bulgular raporlanmış ve bu bulgular irdelenmiştir. Ayrıca elde edilen deneysel bulgular birbiri ile ve literatürdeki benzer çalışmalarla karşılaştırılmış ve çıktılar tablo biçiminde verilmiştir.

Dördüncü ve beşinci bölümlerde bu çalışmada varılan sonuçlardan, önerilerden ve bu çalışmandan sonra yapılabilecek gelecek çalışmalardan bahsedilmiştir. Çalışmanın genel akış şeması Şekil 1’de verilmektedir.



Şekil 1. Çalışmanın genel akış şeması

1.3. Göz ve Gözün Yapısı

Göz görmeyi sağlayan beş duyu organından biridir. Göz ışığı toplar ve bu sinyalleri elektro-kimsayal sinyallere çevirerek beyne iletir ve bu şekilde görme olayı gerçekleşir. Gözde temel olarak gelen ışığın içeri girmesini sağlayan ve ışığa göre genişleyip daralan göz bebeği, gelen ışınları kırılarak görmek noktasında odaklanmasını sağlayan mercek (İens) ve gözün arkasında önemli görme yapılarını (optik disk, makula) sinir tabakası (retina) bulunmaktadır. Şekil 2’de basitçe bir gözün yapısı ve ana bileşenleri gösterilmektedir.

Gözakı (Sclera): Gözü en dıştan kaplayan saydam bir tabakadır. Gözü dış etkilere karşı koruma görevi görür.

İris: Göze rengini veren tabakadır. Yapısında ışığa göre kasılıp gevşeyen kaslar bulunmaktadır. Göz bebeğinin büyüyüp küçülmesini sağlar.

Kornea: Gözün ön kısmında bulunan bombeli şeffaf ve damarsız bir yapıdır. Göze giren ışık ilk olarak burada kırılarak ışığın retina üzerine düşmesi sağlanır.


Göz Bebeği: Işığın gözün içine alındığı iris kasları arasında kalan boşluktur. Işığa göre boyut değiştirir. Aydınlıkta küçülerek ve karanlıkta büyüyerek göre giren ışık miktarını dengeler.

Lens (Mercek): İrisin arka kısmında bulunur. Korneada kırılan ışığı uzağı ve yakını odaklayacak şekilde ikinci bir şekilde kırılmaktadır. Uzak veya yakın mesafedeki cisimleri daha net görebilmek için esneyebilmekte ve ışığı kırma özelliği değişkenlik göstermektedir.

Kamara (Aköz) Sıvısı: Gözün ön kısmında, korneanın arka yüzü ile iris arasında kalan boşluğu dolduran sıvıdır. Bu sıvı kornea ile iris arasında sürekli devridaim halinde dolaşarak çevre dokuları beslemektedir.

Koroid: Retina (göz küresinin iç tabakası) ile gözakı (göz küresini en dıştan kaplayan tabaka) arasında yer alan gözün damarsal tabakasıdır. Atar ve toplar damarlar bu tabakada bulunurlar ve bu sayede retinanın beslenmesi sağlanır.


Retina (ağ tabaka): Gözün en iç tabakasını oluşturur. Göze giren ışık uyarılarını algılayan ve görme olayının gerçekleştiği tabakadır. Bu tabakada Optik disk, makula gibi ana görme olayında görev alan yapılar bulunmaktadır. Bir sonraki bölümde bu tezin de ana konusu olan retina tabakası daha ayrıntılı incelenmektedir.



Şekil 2. Göz ve gözün yapısı [6].

1.4. Retinal Görüntü Analizi ve Üzerindeki Yapılar

Retina tabakası görme olayının gerçekleştiği ve göz küresini oluşturan üç tabakadan en içte olanıdır. Bu tabaka gözün arka kısmını temsil etmektedir ve teknik olarak bu bölge fundus olarak adlandırılmaktadır. Retinanın görüntülenmesi için fundus kamera adı verilen karmaşık bir optik sisteme ihtiyaç duyulmaktadır. Fundus kameralar, retinanın eş zamanlı aydınlatılması ve görüntülenmesi için kamera takılmış özel amaçlı bir mikroskoptan oluşmaktadır. Bu kameralar retina, optik disk, makula gibi yapıları içeren gözün arka yüzeyini görüntülemek için tasarlanmışlardır [5]. Şekil 3'te retinal fundus görüntüleme sistemlerine örnek verilmiştir.




Şekil 3. Örnek bir retinal fundus kamera ve elde edilen renkli retinal fundus görüntü [7].

1.4.1. Retinal Fundus Görüntüleme

Fundus kameralar, gözün arka tarafını fotoğraflayarak 2 boyutlu olarak retinal görüntü üretirler. Bir fundus kamera iç gözü görüntülemek için normal bir fotoğraf makinesinin bağlı olduğu bir mikroskoptan ibarettir. Fotoğraf alma esnasında gözün arka tarafını aydınlatmak amacıyla mini bir ışık kaynağı kullanılır. Bu ışık göz bebeğinden geçerek retinaya ulaşır.

Retinadan yansıyan ışık bir veya daha çok mercek ve aynalardan geçmektedir. Daha sonra Kırmızı, Yeşil, Mavi filtrelerden geçerek yansıyan ışık bu renk algılayıcıları üzerine düşürülür. Algılayıcılar üzerlerine düşen ışık miktarlarına göre Kırmızı, Yeşil, Mavi renk bileşenlerinin parlaklık değerleri belirlenmiş olur. Daha sonra tüm algılayıcılardan gelen renk bilgileri birleştirilerek görüntü gerçek zamanlı olarak bağlı bulunan bilgisayar ekranına gönderilir. Şekil 4'te retinal görüntü alınmasının optik temsili verilmektedir.



Şekil 4. Retinal fundus kameralarının çalışma prensibi ve elde edilen temsili retinal fundus görüntü [8].

Retinal fundus görüntüleme indirek fundus görüntüleme tekniğidir ve gözün arka tarafı büyütülerek görüntü elde edilir. Görüş açısına göre optik disk etrafındaki kan damarları makula ve diğer lezyonların incelenmesi için kullanılmaktadır. Genellikle damla gerektirmeyen (non-midriyatik) bir çekim yöntemi olmasına karşın hekim damla ile göz bebeğinin büyütülerek çekim yapılmasını tercih edebilir (midriyatik).

Işığın gönderilmesi ve yansımaları durumu Şekil 4'te gösterilmektedir. Görüntüsü alınan retina, düzleme yakın kavisli bir alanı 2 boyutlu olarak görüntülemektedir. Görüntüleme alanı yaklaşık olarak optik diskin 5 ile 8 katı kadar büyüklükte bir retinal alan görüntülenmektedir.

Bir fundus kamera diyabetik retinopati, glukom vb. sistematik hastalıkları takip etmek ve tanılamak için yüksek çözünürlüklü ve çoğunlukla renkli görüntüler çekebilmektedir. Bu işlem sırasında retinadan alınan görüntü eş zamanlı olarak bilgisayar ekranında görüntülenebilmektedir. Fundus kameralar genel olarak üç farklı modda çalışabilirler.

- Renkli retinal fundus görüntüleme
- Red-free (kırmızı-bağımsız) görüntüleme
- Florasan anjiyografi görüntüleme

Renkli retinal fundus görüntülemesinde retina beyaz ışık ile aydınlatılır ve tüm renklerin olduğu renkli görüntüler elde edilir. Red-free fotoğraflamada damarlar ve diğer yapıların kontrastının artırılması amacıyla kırmızı renk bileşeni filtre kullanılarak elenir. Böylece sadece gri seviyede tek renk kanallı bir görüntü elde edilir. Florasan anjiyografi görüntülerinde ise hastanın kolundan veya elinden damar içine bir ilaç enjekte ederek çekim yapılır. Enjeksiyonda genelde Sodyum floresein ya da endosiyenin maddesi kullanılır. Daha sonra bu özel ilacın kan damarları tarafından emilimi gerçekleşir ve yaklaşık 490 nanometre civarında bir dalga boyunda mavi ışık ile aydınlatılarak fotoğraflama işlemi gerçekleştirilir. Bu işlemle elde edilen görüntülerde kan damarları ile retina arasında yüksek kontrast elde edilir [5]. Şekil 3'te renkli retinal fundus görüntü ve Şekil 5'te kırmızı-bağımsız (red-free) görüntü ve floresan anjiyografi görüntüleri örnek olarak verilmektedir.




Şekil 5. Red-free fundus görüntü (yeşil bileşen) (solda) ve Fluorescein Angiography görüntü (sağda) [9].

Retinal fundus görüntüler elde edilirken, fundus kameralarla gözün arka tarafının resmi çekilmektedir. Bu çekim işlemi belli açılarla gerçekleştirilmektedir. Açılı büyüdükçe gözün arka kısmından daha çok alan görüntülenebilmektedir. Açılarına göre fundus kameralardan farklı çözünürlükte görüntüler alınabilmektedir. Buna göre alınan görüntüler şu şekilde sınıflandırılabilir:

- Dar açılı fundus görüntüler (20 dereceden daha az)
- Normal fundus görüntüler (20-40 derece arası)
- Geniş açılı fundus görüntüler (41-140 derece arası)

Şekil 6’da farklı açılarda alınan görüntüler gösterilmektedir. Buna göre sağ üstte yer alan görüntü normal açılı, sola altta yer alan görüntü dar açılı ve sağ altta yer alan görüntü geniş açılı olarak sınıflandırılmaktadır. Dar açılı görüntülerde retina üzerinde bulunan optik disk, makula ve kan damarları gibi yapılar daha büyük görüntülenmektedir ve açı büyüdükçe daha çok alan görüntülendiğinden retinal yapıların görüntüdeki büyüklükleri azalmaktadır [8].




Şekil 6. Farklı açılarda alınmış retinal fundus görüntüler [8].

1.4.2. Retinal Fundus Görüntü Üzerindeki Yapılar

Retina gözde görme olayının gerçekleştiği tabakadır ve bu tabakada Optik disk, makula gibi görme olayında görev yapılar bulunmaktadır. Sağlıklı bir retina görüntüsünde görme olayında yer alan Optik Disk, makula gibi yapıların dışında retinayı besleyen kan damarları da görüntülenebilmektedir. Şekil 7’de solda örnek bir renkli retinal fundus görüntü üzerinde

ana retinal yapılar ve sağda ise bu tezin de konusu olan retinal kan damarlarının elle etiketlenmiş hali gösterilmektedir.




Şekil 7. Retinal fundus görüntülerde bulunan yapılar [10].

Optik Disk: Retinal damarların göze girdiği ve görmeyi sağlayan sinirlerin gözden çıktığı kısımdır. Retinal fundus görüntüde genellikle retinaya ve kan damarlarına kıyasla daha parlak görünümündedir. Disk biçimindedir ve kan damarlarının retinaya dağıldığı kısımdır. Üzerinde görüntüyü algılayan sinir algılayıcıların olmadığı ışığa duyarsız kör nokta bulunur.

Makula (Sarı Nokta): Görmeyi sağlayan sinir uçlarının en yoğun olarak bulunduğu kısımdır. Yapısında bulunan sarımsı bir pigment nedeniyle makulaya sarı nokta da denilmektedir. Keskin ve renkli görme olayından sorumlu bölgedir. Makulaya göre optik disk burun tarafında konumlanmaktadır. Bir başka deyişle makula optik diskin burnun tersi yönünde yaklaşık 3-4 mm uzaklıktadır.

Kan Damarları: Görme olayının gerçekleştiği retina tabakasını besleyen damarlardır. Bu beslenme iki şekilde olur. Retinanın koroidal tabaka tarafındaki dış kısmını koroidal damarla beslerken iç kısmını retinal atardamarlar beslemektedir. Retinal kan damarları optik disk ve retinaya göre ışık yansıtma özelliklerinden dolayı daha koyu gözüktürler. Retinal damarlar atardamar (arter) ve toplar damar (vein) olmak üzere iki kısımdır. Atardamar duvarı toplardamarlara göre daha kalın olduğundan renk olarak daha solgundur. Bu nedenle atardamarların ışığı yansıtma özelliğinden dolayı damar ortasında parlak bir şerit şeklinde yansıma gözlenmektedir.

Retinal Patolojiler ve Lezyonlar: Diyabetik retinopati, damar sertliđi, kanamalar, yaşı bađlı makula dejenerasyonu, glaucoma gibi çeşitli sistematik hastalıklar nedeniyle retinada bir takım doku bozuklukları ve patolojiler gözlenebilmektedir. Bu lezyonlar retinaya göre daha koyu ya da açık renkte olabilmektedir. Şekil 8’de çeşitli hastalıklar nedeniyle oluşan hem koyu hem de açık renkteki lezyonlar gösterilmektedir.



Şekil 8. Çeşitli hastalıklar nedeniyle oluşan koyu ve açık renkli lezyonlara bir örnek [11].

1.5. Retinal Kan Damarlarının Özellikleri

Retinal kan damarları retinayı besleyen ve fundus görüntüde optik diskten başlayarak içten dışa doğru yayılan morfolojik yapılardır. Ayrıca kan damarları bir ağaç gibi görsel olarak kollara sahiptir ve uçlara doğru gidildikçe farklı yönlerde dallanarak ağaç şeklinde tüm retina bölgesine yayılmaktadır. İçerisinde akan kan nedeniyle oftalmologlar tarafından göz incelemelerinde kırmızıya yakın renkte görünürler. Retinada üç farklı türde damar gözlemlenebilmektedir. 1) Atardamarlar, 2) Kılcal damarlar ve 3) Toplardamarlar.

Atardamarların damar çeperleri diğerlerine göre daha kalın olduğundan ışığı daha fazla yansıtır ve diğerlerine göre daha kalın olmaktadır. Genel olarak retinal görüntülerdeki kan damarlarının önemli özellikleri şunlardır:

- Damarlar retina yüzeyine göre karşılaştırıldığında ışık yansıtıcılık özellikleri daha düşüktür. Bu nedenle retina arka planına göre daha koyu görünürler.
- Kan damarlarının genişlikleri değişkendir ve merkezden (optik disten) uçlara doğru gidildikçe azalmaktadır. Ortalama olarak 1-20 piksel (18-360 mikrometre) aralığındadır [3], [5].
- Damarlar genellikle küçük eğrilikler içerdiğinden birbirine paralel olmayan yaklaşık olarak doğrusal anti-paralel kıvrımlı doğru parçası çiftlerinden oluşmaktadır.
- Kan damarlarının kesitleri incelendiğinde yaklaşık olarak ters Gauss eğrisine yakın bir modele sahip olduğu gözlenmektedir.
- Herhangi bir damarın yönü ve gri seviye değeri ani bir şekilde değişmez; bundan dolayıdır ki damarlar yerel olarak doğrusaldır (curvilinear=kıvrımlı doğru) ve damar piksel parlaklık değerleri damar boyunca kademeli bir şekilde değişir.
- Damarların birbirine bağlı olmaları beklenir ve retinada ağaç benzeri bir yapıya sahiptirler. Ancak kan damarlarının şekli, büyüklüğü ve yerel gri seviyeleri değişkenlik gösterebilir ve bazı arkaplan öz nitelikleri damarlar ile benzer özellikler gösterebilir [5].

1.6. Retinal Kan Damarlarının Bulunmasında Zorluklar


Damar geçişleri ve dallanmaları profil modelini fazlasıyla karmaşık hale getirmektedir. Ayrıca çoğu medikal görüntülerde yer alan gürültü, damar piksel parlaklıklarındaki belirsizlik ve kontrast yokluğu nedeniyle kan damarlarının çıkartılmasında önemli zorluklar ortaya çıkarmaktadır. Retinal damarlar damar orta yansımından dolayı kan damarlarının ortalarında yapay bir parlak şerit barındırmaktadırlar (Bu durum daha çok genç hastalarda ve atar damarlarda ortaya çıkmaktadır).

Retinal kan damarlarının bölütlenmesi için önerilen algoritmalar çeşitli şekilde sınıflandırılabilir. Örneğin kenar tabanlı ve bölge tabanlı algoritmalar, örüntü tanıma teknikleri, model tabanlı yaklaşımlar, izleme/iz sürme tabanlı yaklaşımlar ve yapay sinir ağları tabanlı yaklaşımlar gibi.

Bu çalışmanın ana konusu retinal kan damarlarının bulunmasıdır. Yukarıda bahsedilen damar özelliklerinin dışında ortaya çıkabilecek çeşitli patolojik sebeplerden dolayı damarların kesin bir şekilde bulunması zordur. Örneğin; gürültünün varlığı, damar ve arkaplan arasındaki düşük kontrast, damar genişliği, parlaklığı ve yapısının değişken olması buna bir örnektir. Ayrıca lezyonların ekzudaların ve diğer patolojik etkilerin varlığı dolayısıyla görüntülerde oluşan anormal bölgeler de retinal kan damarlarının bulunmasını zorlaştırmaktadır ya da damar olmayan bölgelerin damar olarak bulunmasına sebep olmaktadır [12]. Benzer şekilde atar-toplardamar geçişleri ve dallanmaları damar modelini fazlasıyla karmaşık hale getirmektedir. Retinal damarlar damar orta yansımından dolayı kan damarlarının ortalarında yapay bir parlak şerit barındırmaktadırlar (bu durum daha çok genç hastalarda ve atar damarlarda ortaya çıkmaktadır). Birbirine yakın damarlar neredeyse birleşik gibi görünmekte ve kılcal damarların düşük kontrast nedeniyle bulunamaması söz konusu olmaktadır [13].

1.7. Literatür Çalışmaları

Literatürde bugüne kadar yapılan çalışmalar incelendiğinde damar bölütleme işlemi diğer bölütleme algoritmalarında olduğu gibi genel olarak iki alt aşamadan oluşmaktadır. Birinci aşama, görüntüdeki piksellerin veya alt bölgelerin damar öz niteliklerinin çıkarılarak damar bölütleme modelinin oluşturulması aşamasıdır. Önceden belirli bir kuralın probleme göre parametrelerinin belirlenmesi (kural tabanlı yöntemler) ya da makine öğrenmesi ile bir sınıflandırıcının eğitilmesi (istatistiksel sınıflandırma) gibi farklı yaklaşımlar benimsenebilmektedir. Bu aşamada bazı durumlarda ön işlem gerekebilmektedir. Böylece görüntüden varsa fazlalık bilgiler çıkarılmakta veya ön işlem sayesinde daha kolay öz nitelik çıkarımları yapılabilir. Bölütlemenin ikinci aşamasında ise belli bir model ya da kurala göre piksel veya bölgelerin kan damarına ait olup olmadıklarına karar verilmektedir. Bu karar verme işlemi makine öğrenmesi ya da daha önce belirlenmiş belli bir kurala göre yapılabilir. Şekil 9'da retinal kan damarı bölütleme için literatürde yapılan çalışmaların basit bir kategorilendirmesi işlemi verilmektedir.



Şekil 9. Damar bölütleme algoritmalarının genel şeması

Literatürde damar bölütleme için önerilen yöntemler genel olarak iki gruba ayrılmaktadır. 1) Kural tabanlı yöntemler. 2) Makine öğrenmesine dayalı yöntemler. Birinci grupta uyum filtresi yaklaşımları, damar izleme ve iz sürme yaklaşımları, matematiksel morfoloji tabanlı yaklaşımlar, çok ölçekli yaklaşımlar, model tabanlı yaklaşımlar ve donanım tabanlı yaklaşımlar yer almaktadırlar. İkinci grup yöntemler ise daha çok makine öğrenmesine dayalı yöntemlerdir ve bu grupta genellikle istatistiksel sınıflandırma işlemleri kullanılmaktadır. Kan damarlarını retina arka planından veya diğer retinal yapılardan ayırt etmek amacıyla piksel sınıflandırma işlemi gerçekleştirilmektedir. Denetimli (gözetimli - danışmanlı) sınıflandırma ve denetimsiz (gözetimsiz - danışmansız) sınıflandırma yöntemleri bu gruptandır. Devam eden bölümlerde bu yöntemlerin belli başlı olanları kategorik bir şekilde verilmektedir.

1.7.1. Kural Tabanlı Yöntemler

Kural tabanlı yöntemlerde belirli bir ön işlemten sonra damar iyileştirme işlemleri uygulanmakta ve son aşamada belli bir kurala (veya modele) göre eşikleme ya da damar bölgelerinin belirlenmesine karar verilmesi gibi adımlar uygulanmaktadır. Uyum filtresi,

damar izleme, morfolojik işlemler, çok ölçekli yaklaşımlar, model tabanlı ve donanımsal yöntemler bu grupta incelenebilmektedir.

1.7.1.1. Uyum Filtresi Yaklaşımları

Uyum filtresi yaklaşımları kullanan yaklaşımlarda damar profiline uyduğu için genellikle Gauss fonksiyonu kullanılarak elde edilen 2 boyutlu lineer bir yapısal eleman oluşturulur. Bu yapısal eleman farklı açılarda döndürülerek farklı yönlerdeki damarların çıkarılması için filtre bankası elde edilir. Yapısal eleman oluşturulurken bazen Gauss fonksiyonu bazen de Gauss fonksiyonunun türevi kullanılabilir. Literatürde çekirdek yapısal eleman çoğunlukla 8 ya da 12 kez döndürülerek (bu da 22.5 ya da 15 dereceye karşılık gelir) farklı yönlerde yapısal elemanlar elde edilmektedir. Daha sonra bu yapısal elemanların oluşturduğu filtre bankası kullanılarak damar görüntüsü filtrelenmektedir. Her bir piksel için filtre bankasında bulunan yapısal eleman sayısı kadar değer elde edilmiş olur. Bu değerlerden maksimum tepki değeri seçilerek çıktı görüntü elde edilir. Böylece kan damarları retina arkaplanına göre iyileştirilmiş olur. Son durumda iyileştirilmiş görüntü belli kriterlere göre eşiklenerek nihai damar yapıları elde edilmiş olur.

Retinal damar bölütleme konusunda yapılan ilk çalışmalardan biri Chaudhuri ve ark. [3] tarafından uyum filtresi kullanılarak gerçekleştirilmiştir. Çalışmada damar kesiti boyunca devam eden piksellerin gri seviye değerleri ters Gauss eğrisine benzediği için sabit büyüklükte 15x15 boyutunda çekirdek bir filtre oluşturmuşlardır. Daha sonra bu çekirdek filtre 15 derece aralıklarla döndürülerek 12 farklı filtre elde edilmiştir. Bu filtreler gri seviye retinal görüntüler üzerine uygulanarak maksimum değer seçilmiştir. Bu şekilde iyileştirilmiş damar görüntüsü Otsu [14] algoritması ile eşiklenerek ikili görüntü elde edilmektedir ve retinal kan damarları bölütlenmektedir.

Hoover ve ark. tarafından yapılan ve uyum filtresinin kullanıldığı bir başka çalışmada [15] Chaudhuri ve ark. tarafından önerilen uyum filtresi [3] kullanılmış ve eşikleme adımı retinal kan damarlarının yerel ve bölgesel özelliklerinin dikkate alındığı eşik sondalama (threshold probing) adında farklı bir yöntem uygulamışlardır. İteratif bir yöntem olan eşik sondalama yönteminin her bir adımında olası damar piksellerinin bölgesel özellikleri analiz edilerek belli kuralara ve parametrelere göre damar ya da değil şeklinde karar verilmiştir. Bu yöntemde ayrıca retinal kan damarı bölütleme yöntemlerinde çokça

kullanılan ve internet üzerinde halka açık olarak sunulan STARE (STructured Analysis of the RETina) [10] retinal fundus görüntü veri tabanı ilk defa kullanılmıştır.

Kan damarı kesit profiline benzeyen Gauss fonksiyonunun farklı biçimleri birçok damar bölütleme yöntemlerinde kullanılmıştır. Bu çalışmalardan biri de Gang ve ark. [16] tarafından önerilen ve genlik modifiyeli ikinci derece Gauss filtresi kullandıkları çalışmadır. Önerilen çalışmada damar genişliğinin uyumlu Gauss filtresinin yayılım faktörü (standart sapma) ile lineer olarak ilişkili olduğu vurgulanmış ve uyum filtresinin genişliğinin damar genişliğine göre ayarlanabileceği belirtilmiştir. Buna göre oluşturulan uyum filtresi damar çıkarma ve genişliğini belirleme performansını olumlu yönde etkilemiştir.

Adaptif yerel eşikleme kullananan doğrulama tabanlı bir başka çalışma Jiang ve ark. tarafından damar çıkarma amacıyla kullanılmıştır [17]. Bu çalışmada önceden belli eşik aralıkları belirlenmiş ve bu eşik aralıklarında retinal görüntünün gri seviyesi eşiklenmiştir. Elde edilen birçok ikili görüntünün her biri bir doğrulama prosedüründen geçerek damar olabilecek parçalar seçilmiştir. Seçilen parçalı bu damarlar yeniden birleştirilerek ve sonrasında son işlemler uygulanarak ikili damar görüntüsü elde edilmiştir.

Al-Rawi ve ark., [3] çalışmasında önerilen klasik uyum filtresini kapsamlı arama optimizasyonu prosedürü kullanılarak iyileştirmişlerdir. Bu çalışmada kullanılan retinal görüntüler için filtre boyutu, standart sapma, eşik değeri gibi en uygun parametrelerin ne olacağı belirlenmiş ve bu seçimin damar çıkarma performansını arttırdığı sonucuna ulaşılmıştır [18].

Renkli görüntüden damar çıkarma amacıyla önerilen bir başka çalışma Cinsdikici ve ark. tarafından yapılmıştır [19]. Bu çalışmada hibrit bir uyum filtresi ve karınca kolonisi algoritması kullanılmıştır. Önerilen çalışmada bazı ön işlemlerden sonra görüntü uyum filtresinden ve karınca kolonisi algoritmasından eş zamanlı olarak geçirilmektedir. Daha sonra elde edilen sonuçlar birleştirilir ve uzunluk filtresi uygulanarak siyah-beyaz damar görüntüsü elde edilmiştir.

Retinal kan damalarının özelliklerini daha fazla ön plana çıkarmak amacıyla Zhang ve ark. tarafından yapılan çalışmada klasik uyum filtresi (MF) genelleştirilmiş ve Gauss fonksiyonunun birinci dereceden türevi (MF-FDOG) alınarak geliştirilmiştir [20]. Böylece Gauss şekilli simetrik yapılarda MF filtre çıktı değeri büyük olmakta ve lezyonlar gibi asimetrik yapılarda filtre çıktısı görece daha küçük değerler üretmektedir. Yöntemde damar çıkarmak için iki adet filtre çifti kullanılmıştır: sıfır ortalımalı Gauss filtresi (klasik uyum filtresi - MF) ve birinci dereceden Gauss fonksiyonu kullanılarak oluşturulan filtre (FDOG).

Gerçek bir damar için MF filtre çıktısı büyük olmakta ve FDOG filtre çıktısı ise neredeyse sıfıra yakın çıkmaktadır. Damar olmayan bir piksel için (düzgün dağılımlı retina arkaplanı hariç) veya diğer yapılar için ise MF filtre çıktısı ve FDOG filtre çıktısının ikisi de yüksek değerli olmaktadır. Bu ayırmadan yararlanarak retinal kan damarları bölütlenmektedir.

Uyum filtresi kullanan bir diğer çalışmada ise Wang ve ark. [21] dalgacık çekirdekleri ve çok ölçekli hiyerarşik çözümleme kullanarak kapsamlı bir retinal kan damarı bölütleme yöntemi önermişlerdir. Çalışmalarında herhangi bir ön işlem ya da eğitim yöntemi kullanmadan retinal görüntülere doğrudan dalgacık çekirdekleri kullanan uyum filtresi uygulanmıştır. Böylece kan damarlarını retina üzerindeki diğer yapılardan ayırt edecek şekilde görüntü iyileştirilmektedir. Gürültü eleme ve damar yerelleştirme işlemi ise iyileştirilmiş görüntünün çok ölçekli hiyerarşik çözümleme işlemine tabi tutulması ile başarılmaktadır. Son olarak yerel adaptif bir eşikleme kullanarak siyah-beyaz kan damarları elde edilmektedir.

Devam eden yıllarda Odstreilic ve ark. [22] klasik uyum filtresini kavram olarak geliştirmişler ve yüksek çözünürlüklü retinal görüntülerde kan damarı çıkarma amacıyla farklı bir yöntem önermişlerdir. Parlaklık düzeltme ve kontrast eşitleme ön işlemlerinden sonra farklı genişliklerde 5 farklı uyum filtresi uygulanmıştır. Daha sonra elde edilen farklı ölçeklerdeki filtre çıktıları maksimum değer seçimi ile birleştirilmiştir. İyileştirilmiş görüntü eşiklenerek son durumda siyah beyaz damarlar elde edilmiştir. Yöntemi diğer yöntemlerden farklı olarak yüksek çözünürlüklü retinal görüntüler üzerinde uygulamışlardır [23].

Akram ve ark. tarafından diyabetik retinopati hastalığının taranması amacıyla retinal kan damarı yöntemi önermişlerdir. İlk olarak retinal kan damarlarını iyileştirmek amacıyla iki boyutlu Gabor dalgacık çekirdeği kullanan bir uyum süzgeci uygulamışlardır. Böylece görüntüdeki damar benzeri yönlü yapılar iyileştirilmiştir. Daha sonra yeni birçok katmanlı eşikleme tekniği kullanarak iyileştirilmiş damar görüntüsü siyah beyaz hale getirilmiştir. Önerdikleri yöntemin iyi tarafının farklı aydınlanma varyasyonlarına karşı dayanıklı olduğu ve ince damarları tespit noktasında başarılı bir performans gösterdiği vurgulanmıştır [24].

1.7.1.2. Damar İzleme ve İz Sürme Yaklaşımları

Damar izleme algoritmaları yerel bilgileri kullanarak iki nokta arasındaki damar parçasını bölütleme amacıyla kullanılmaktadır. Bu yaklaşımlar retinada bulunan tüm damar ağını çıkarmak yerine daha yerel damarların çıkarılmasında tercih edilmektedir. Belli bir

başlangıç noktasından ileride bir noktaya doğru takip etme işlemine damar izleme (tracking), bulunduğu noktadan başladığı noktaya doğru giderek geri takip etme işlemine ise iz sürme (tracing) denilmektedir. Damar izleme işlemi, genellikle kan damarının uzunlamasına merkezi ortalama gri parlaklık değeri ve kıvrımlık kullanılarak hesaplanabilmektedir. Bu işlem esnasında damar orta çizgilerindeki yerel bilgilerin kullanılmasıyla damar profili modeline uyan en iyi yol belirlenmektedir. Damar izleme yöntemlerinin temel avantajı damar kalınlıkları hakkında bilgi vermesi ve diğer yöntemlerle bulunması mümkün olmayan damarların daha rahat bulunmasıdır. Retinadaki damarlar birbirine bağlı bir ağaç yapısında olduğu için tüm retinayı incelemek yerine damar ağacının kökünden başlanarak sadece damar olması muhtemel yerler incelenerek zaman kazancı sağlanabilmektedir. Ayrıca damar izleme işlemi damar dallanma noktaları gibi yapısal özellikler hakkında da bilgi sunar. Ancak herhangi bir başlangıç noktasına (tohum noktası) sahip olmadan damar izleme mümkün olamamaktadır. Ek olarak herhangi bir dallanma noktasının tespit edilememesi durumunda tespit edilemeyen alt damar yapıları olabilmektedir. Literatürde genellikle damar izleme algoritmaları tek başına kullanılmak yerine uyum filtresi, morfolojik işlemler gibi diğer yöntemlerle birlikte kullanılmaktadır.

Damar izleme alanında yapılan ilk çalışmalardan biri Liu ve ark. tarafından yapılmıştır [25]. Önerilen çalışmada retinal anjiogram görüntülerinde damar yapılarını bulmak için adaptif bir izleme yöntemi kullanmışlardır. Damar yörüngeleri herhangi bir damar üzerinde başlangıç noktası seçerek tahmin edilebilmektedir ve izlenen damar pikselleri görüntüden silinerek bir sonraki izleme işlemine geçilmektedir. Bu işlem tüm retinal damar ağacını çıkarana kadar öz yinelemeli bir şekilde devam ettirilmektedir. Bu algoritma kullanıcının damar başlangıç noktalarını işaretlemesini gerektirmektedir.

Damar izleme konusunda yapılan bir diğer çalışmada Zhou ve ark. [26] ise damar orta çizgisinin rotasını belirlemek ve tek bir damar parçasının çapını ve eğriliğini ölçmek amacıyla yeni bir algoritma önermişlerdir. Çalışmada bir kan damarı parçasının izlenmesi işlemi, en son izlenen belli bir sabit uzunluktaki kan damarı yönünde aramayı genişleterek devam etmesi şeklinde gerçekleştirilmektedir. Mevcut konumdan bir sonraki konumu tahmin etmek amacıyla damar profiline dik olan çizgi üzerinde Gauss uyum filtresi uygulanmış ve sonuçlar izlenmiştir. Bu sayede bir sonraki izlenecek konum gözlenmekte, yapılan kestirim (tahmin) doğrulanmakta ve bir sonraki izlenecek konum yeniden tahmin edilebilmektedir. Tüm bu işlemler iteratif bir şekilde devam etmektedir. Ayrıca uyum filtresi küçük damar dallanmalarını ihmal ettiği için tek bir ana damar bileşeninin devamlı olarak

izlenmesi sağlanmış olur. Önerilen bu algoritma başlangıç ve bitiş noktaları ile damar izleme yönünün manuel olarak belirlenmesini gerektirmektedir.

Chutatape ve ark. yaptıkları çalışmada retinal görüntülerde kan damarı tespiti için Gauss ve Kalman filtresi kullanarak bir izleme stratejisi kullanılmışlardır. Damar merkez çizgisinin orta notasını kestirebilmek için ikinci dereceden Gauss uyum filtresi kullanılmıştır ve daha sonra optik disk çevresinden başlayarak izleme işlemi başlatılmaktadır. Bir sonraki damar parçasının (bölütünün) konumunu hesaplarken bir önceki damar bölümü parametreleri ile birlikte daha önce izlenen tüm damar konumları kullanılarak Kalman filtresi uygulanmıştır. Ayrıca bu çalışmada dallanma noktalarını tespiti de gerçekleştirilmektedir. etme işlemi izleme süresince uygulanmaktadır [27].

Kelvin ve ark. tarafından damar görüntülerinin çıkarılması amacıyla yarı-otomatik bir yöntem önerilmiştir [28]. Yöntemde optimum damar orta eksenini etkin bir şekilde hesaplamak amacıyla Hessian matris kullanan çok ölçekli Frangi filtresi [29] ile özel bir sınır çıkarma yöntemi olan Live-ware algoritması [30] kullanılmışlardır. Damar boyunca seyrek tohum noktaları belirlenmekte ve bu tohum noktalarına bitişik optimum sınırlar Dijkstra algoritması kullanarak bulunmaktadır. Bu şekilde damar boyunca hızlı bir damar izleme işlemi gerçekleştirilmektedir.

Damar bölütleme ve damar çapı çıkarma amacıyla Delibasis ve ark. tarafından otomatik model tabanlı bir damar izleme algoritması önerilmiştir. Algoritma damarların geometrik özelliklerini dikkate alarak parametrik bir model kullanmaktadır. Görüntü ve kullanılan model arasında eşleşme ölçütü gibi bir değer kullanılmaktadır. İzleme için gerekli tohum noktaları Frangi filtresi kullanılarak otomatik bir şekilde belirlenmektedir. Tohum noktası, çıkarılan şerit yönü, şerit genişliği ve eşleşme ölçütü kullanarak en uygun eşleşme belirlenmekte ve bu sayede damar izleme işlemi gerçekleştirilmektedir. İzleme esnasında damar genişliği yönü gibi parametreler dinamik olarak güncellenmekte ve herhangi bir dallanma noktasına geldiğinde izleme sonlanıp yeni bir izleme başlatılmaktadır [31].

Yine retinal görüntülerde kan damarlarının bulunması amacıyla Yin ve ark. tarafından olasılık izleme yöntemi önerilmiştir [32]. İzleme esnasında yerel gri seviye istatistikleri ve damar devamlılık özellikleri kullanılarak iteratif bir şekilde damarların kenar noktaları tespit edilmektedir. Damar profili Gauss eğrisi kullanılarak kestirilmekte ve maksimum damara uyan yapılar Bayes yöntemi kullanılarak belirlenmektedir. Yöntem gerçek ve sentetik damarlar üzerinde test edilmiştir.

1.7.1.3. Matematiksel Morfoloji Tabanlı Yaklaşımlar

Kelime anlamı olarak morfoloji biçimsel yapıları inceleyen bir bilim dalıdır. Matematiksel morfoloji ise bir görüntüden kenarlar, iskelet yapıları veya bölgesel şekillerin çıkarılmasında kullanılan bir görüntü işleme aracıdır. Başlangıçta sadece ikili görüntüler için düşünülmeye rağmen devam eden yıllarda gri seviye görüntülere de uygulanacak şekilde genişletildi. Retinal fundus görüntülerde de birçok anatomik yapılar bulunduğu için matematiksel morfoloji yöntemleri kan damarlarının bulunmasında önemli bir araç olabilmektedirler. Genellikle yapısal bir eleman kullanılarak yöntemler bir görüntüye uygulanır. Temel olarak iki önemli morfolojik işlem vardır: 1) Aşındırma (erosion) ve 2) Genişletme (dilation). Diğer morfolojik işlemler bu iki temel araçlar kullanılarak gerçekleştirilmektedir. Retinal damar çıkarma işlemlerinde kan damarlarının iyileştirilmesi amacıyla çoğunlukla kullanılan diğer matematiksel morfoloji yöntemleri arasında açma (opening), kapama (closing), top-hat ve bottom-up yer almaktadır.

Matematiksel morfoloji kullanarak retinal kan damarı çıkarma işlemi yapan ilk çalışmalardan biri Zana ve ark. [33] tarafından önerilmiştir. Çalışmada retinal görüntülerdeki damar benzeri yapılar matematiksel morfoloji kullanılarak bulunmakta ve devamında damar eğrilik değerlendirilmesi yapılmaktadır.

Morfolojik işlem kullanan bir diğer çalışmada Mendonca ve ark. [34] çok ölçekli morfolojik geri çatma (yeniden yapılandırma) kullanarak DoOG (Difference of Offset Gaussian) filtresi kullanmışlardır. Damar merkez çizgisini çıkarmak için DoOG filtresi ve damarları iyileştirmek için değişken boyutta modifiyeli top-hat dönüşümü kullanılmıştır. Daha sonra morfolojik geri çatma kullanarak dört ölçekte damar haritaları elde edilmektedir. Son aşamada damar görüntülerini elde etmek için bölge büyütme algoritması uygulanmıştır.

Çoğu durumda retinal kan damarı bölütleme amacıyla matematiksel morfoloji yöntemleri diğer yöntemlerle birleştirilmektedir. Örneğin Yang ve ark. [35] matematiksel morfoloji ile bulanık kümeleme yöntemini birleştirerek hibrit bir model önermişlerdir. Bu çalışmada morfolojik top-hat dönüşümü ile kan damarları iyileştirilmiş ve arkaplan görüntüden çıkarılmıştır. Daha sonra bulanık kümeleme ile kan damarları elde edilmiştir.

Sun ve ark. ise çok ölçekli morfolojik damar iyileştirme yöntemi, bulanık filtreleme ve watershed dönüşümü yöntemlerini birleştirerek anjiogram görüntülerinde damar ağacı çıkarmayı amaçlamışlardır [36]. Yöntemlerinde non-lineer çok ölçekli morfolojik açma

işlemi ile arkaplan kestirimi yapılmakta ve bu arkaplan görüntüsü kontrast normalizasyonu için orjinal görüntüden çıkarılmaktadır. Daha sonra normalleştirilmiş anjiogram görüntüsü 15 derece aralıklarla döndürülmüş 12 lineer yapısal eleman kullanarak bulanık morfolojik bir yöntemle işlenmektedir. Daha sonra eşikleme işlemi ile damarlar çıkarılmakta ve damar merkez çizgilerini elde etmek için inceltme işlemi uygulanmaktadır. Son olarak watershed dönüşümünden damar sınırları elde edilmektedir.

Damar merkez çizgilerinin tespit edilmesi ve morfolojik bit düzlem dilimleme yöntemlerini birleştiren bir diğer çalışma ise Fraz ve ark. [37] retinal görüntülerden kan damar ağacı çıkarımı üzerinde çalışmışlardır. Dört yönlü birinci dereceden Gauss türevi kullanılarak damar merkez çizgileri çıkarılmakta ve daha sonra türevlerin işaretleri ve genlikleri değerlendirilmektedir. Burada matematiksel morfoloji retinadaki damarları iyileştiren bir yöntem olarak ortaya çıkmaktadır. Çok yönlü morfolojik top-hat dönüşümü uygulanarak kan damarlarının şekil ve yön bilgisi elde edilmekte ve daha sonra damarların iyileştirildiği gri seviye görüntü bit düzlem dilimleme işlemine tabi tutulmaktadır. Son olarak bölütlenmiş damar ağacı elde etmek için bu görüntüler merkez çizgiler ile birleştirilmektedir.

1.7.1.4. Çok Ölçekli Yaklaşımlar

Retinal kan damarları özellik olarak optik diskten dışa doğru yayılmakta ve damar genişlikleri giderek azalmaktadır. Bu nedenle kan damarları için Gauss eğrisine benzer profile sahip, parçalı olarak birbirine bağlı ve genişliği giderek azalan şeklinde bir tanım yaygın olarak kullanılmaktadır. Yani kan damarları görüntünün her bölgesinde farklı genişlik değerlerine sahip olabilmektedir. Bu nedenle çok ölçekli damar bölütleme yaklaşımları her genişlikteki damarları tespit etmek için önem kazanmaktadır.

Çok ölçekli damar bölütleme yaklaşımı kullanarak damar tespiti gerçekleştiren ilk çalışmalardan biri Frangi ve ark. [29] tarafından gerçekleştirilmiştir. Çalışmada görüntünün ikinci derece türevlerinden oluşan Hessian matrisin öz değeri ve öz vektörleri hesaplanmakta ve bunlara bağlı olarak geliştirilen damarlılık olasılık değeri elde edilmektedir. Daha sonra bu değerler normalize edilerek iyileştirilmiş damar görüntüsü elde edilmektedir. Son durumda iyileştirilmiş görüntü eşiklenerek kan damarları elde edilmektedir.

Martinez-Perez ve ark. [38] ölçek-uzay (scale-space) analizine dayalı bir retinal kan damarı bölütleme yaklaşımı önermişlerdir. İlk olarak gri seviye parlaklık görüntüsünün

birinci ve ikinci türevleri (kenarlar ve maksimum ana eğrilik) alınmakta ve daha sonra kan damarlarının kalınlık, boyut ve yön bilgileri hesaplanmaktadır. Son olarak bu iki geometrik öz nitelik ve elde edilen diğer bilgiler özel bir bölge büyütme algoritmasında kullanılarak son durum damar görüntüsü elde edilmektedir. Devam eden yıllarda farklı ölçeklerde analiz için görüntünün birinci ve ikinci türevlerinin kullanıldığı ve mevcut yöntemin daha da geliştirilerek damar bölütleme performansının artırıldığı çalışmalar mevcuttur [9],[39].

Wink ve ark. [40], sayısal görüntülerde kullanıcı tanımlı iki ya da daha çok nokta arasındaki damar benzeri yapıların merkezi eksenini çıkarmak amacıyla Frangi filtresinde kullanılan görüntünün Hessian matrisinden elde edilen öz vektörler kullanmışlardır. İlk olarak ölçek seçimi ile görüntüden elde edilen Hessian matrisin öz vektörleri hesap edilmiş daha sonra da iki ve üç boyutlu maliyet görüntüleri çıkarılarak merkezi eksenler elde edilmiştir.

Kan damarı merkezi çizgilerini çıkarmak için önerilen benzer bir çalışma da Sofka ve ark. tarafından yapılmıştır. Çalışmada değişken genişlikteki damarları bulmak amacıyla çok ölçekli uyum filtresi, güven kat sayısı ve damar kenar bilgileri birleştirilerek damar olma olasılığını gösteren 6 boyutlu bir öz nitelik vektörü hesap edilmektedir. Bu değerler kullanılarak damar orta çizgisi çıkarılmakta ve tüm damar ağacını çıkarmak amacıyla yerel izleme işlemleri gerçekleştirilmektedir [41].

Retinal görüntülerden ikili damar görüntüsü çıkarmak amacıyla çok ölçekli yaklaşım kullanan bir başka çalışma Farnell ve ark. [42] tarafından çok ölçekli çizgi operatörü kullanılarak gerçekleştirilmiştir. Çalışmada görüntüden alt örneklenmiş Gauss piramidi oluşturulmuş ve bu piramitteki her bir seviyeye çok ölçekli çizgi operatörü ayrı ayrı uygulanmıştır. Daha sonra kübik spline kullanılarak alt seviyelerde filtrelenmiş görüntüler orjinal görüntüye iz düşürülmüştür. Son olarak Gauss piramidindeki görüntüler eşit kat sayılarla çarpılıp toplanarak bölütlenmiş damar görüntüsü elde edilmiştir. Elde edilen ikili görüntüde gürültüler basit bir bölge büyütme algoritması ile elenerek son durum damar görüntüsü elde edilmiştir.

Çok ölçekli yaklaşımlarda çoğunlukla görüntünün Hessian matrisinin öz değer ve vektörleri kullanılmaktadır. Böyle bir çalışma da Moghimirad ve ark. tarafından özel bir iki boyutlu fonksiyon kullanılarak gerçekleştirilmiştir. Bu fonksiyon sayesinde görüntü başka bir uzaya dönüştürülmüş ve bu sonuç görüntünün Hessian matrisinin öz değerleri ile çarpılmıştır. Daha sonra iskelet çıkarma, graf temsil ve yeniden bağlanma işlemleri ile damar

orta çizgileri çıkarılmıştır. Son olarak damar çapı kestirilerek retinal kan damarları bölütlenmektedir [43].

Çok ölçekli çizgi operatörü kullanan bir diğer çalışmada Nuyen ve ark. [13] kan damarlarını etkin bir şekilde çıkarmak için değişken uzunlukta ve genişlikte (ölçekte) çizgi operatörü kullanmışlardır. İlk aşamada gri seviye damar görüntüsü her bir ölçekteki çizgi operatörleri kullanılarak ayrı ayrı filtrelenmekte ve daha sonra her ölçekten elde edilen sonuçlar lineer bir şekilde birleştirilerek son durum retinal kan damarı görüntüleri elde edilmektedir.

Komplex sürekli dalgacık dönüşümü kullanan ve çok ölçekli damar iyileştirmeye dayalı bir çalışma Fathi ve ark. tarafından gerçekleştirilmiştir. İlk olarak tüm yönlerdeki damar benzeri yapıları algılamak ve bu yapıları basit kenarlardan ayırt etmek amacıyla kompleks sürekli dalgacık dönüşümü parametreleri optimize edilmektedir. Daha sonra görüntüye dalgacık dönüşümü uygulanarak elde edilen çıktıya adaptif histogram tabanlı bir eşikleme uygulanmaktadır. Son durumda hatalı tespit edilen küçük parçalar uzunluk filtresi yardımıyla elenerek ikili damar görüntüsü elde edilmektedir [44].

1.7.1.5. Model Tabanlı Yaklaşımlar

Literatürde model tabanlı yaklaşımlar, kan damarlarını çıkarmak amacıyla retinal görüntülere çeşitli damar modellerinin uygulanması şeklinde karşımıza çıkmaktadır. Genel olarak damar profilini dikkate alan damar profil modelleri ve yamulgan (biçim değiştirir) modeller olmak üzere iki alt gruba ayrılmaktadırlar.

İlk grupta bulunan damar profili modelleri, damarların çapraz-kesitlerine bakarak uydurulan modelledir. Genellikle kan damarları Gauss fonksiyonu şeklinde veya birkaç Gauss fonksiyonunun birleşimi biçiminde olabilmektedir. Ayrıca damarlar ikinci dereceden Gauss fonksiyonunun türevi, kübik spline ya da Hermite polinomsal profilleri şeklinde de modellenebilmektedir. Çoğunlukla damar profil modelleri kullanılarak uyum süzgeçleri ya da çok ölçekli filtreler tasarlanabilmektedir. Ancak kullanılan model damar olmayan yapıları da ön plana çıkarmayacak şekilde tasarlanmaktadır. Bu modellerde ayrıca damar dallanma ve çapraz-geçiş noktaları damar profil modeli oluşturmayı zorlaştırmaktadır.

İkinci grupta bulunan yamulgan (deformable) modeller ise kan damarlarının parametrik ya da geometrik olarak ifade edilebildiği durumlarda kullanılmaktadır. Parametrik modeller aktif kontur modelleri (yılanlar, snakes) olarak da bilinmektedirler. Bir

kullanıcı tarafından bölütlenmesi gerekli nesneyi çevreleyen kıvrımlı bir eğri oluşturulur ve bu eğrinin şekli iç ve dış kuvvetler sebebiyle sürekli değişmektedir. Bu değişim kıvrımlı eğrinin iç ve dış kuvvetler sayesinde nesnenin etrafını çevreleyene kadar ya da istenen nesneler bulunana kadar devam eder. Bu yöntemleri diğer yöntemlerden ayıran özellik minimum enerji stratejisine göre otonom olarak hareket etmesidir. Ancak bu tür yöntemlerin dezavantajı başlangıçta kullanıcı tarafından nesneyi çevreleyen kıvrımlı bir eğri oluşturmayı gerektirmesi ve kenar bilgisine sahip olmayan diğer retinal yapıları tespit etmede başarısız olabilmesidir. Geometrik modeller ise düzey kümesi (level set) tabanlı sayısal algoritmalar kullanarak retinal damar bölütleme gerçekleştirmektedirler. Düzey kümesi yöntemi şekilleri takip etmek için kullanılan sayısal bir yöntemdir. Bu yöntemlerin avantajı eğrileri veya yüzeyleri kapsamak için yapılan sayısal işlemlerde herhangi bir parametrik tanım gerektirmeden sabir bir kartezyen sistem kullanılmasıdır.

Vermeer ve ark. kan damarlarını iki boyutlu Laplasyan kullanarak modellemişlerdir. İlk olarak görüntü 2B Laplasyan çekirdeği kullanarak filtrelenmiş ve damarlar iyileştirilmiştir. Daha sonra iyileştirilmiş görüntüdeki damar parçaları birleştirme işlemine tabi tutulmuş ve hatalı tespit edilen küçük alanlı bölgeler elenerek ikili damar görüntüsü elde edilmiştir [45]. Bu çalışmaya benzer bir başka çalışma Lam ve ark.tarafında gerçekleştirilmiştir. Bu çalışmada da kan damarları Laplasyan operatörü ile modellenmektedir. İlk olarak Laplasyan operatörü ile kan damarlarını çıkardıktan sonra vektör alanları ıraksamasına dayalı bir yöntem kullanarak gürültülü nesneler elenmektedir [46]. Aynı yazarların yaptıkları bir diğer çalışmada kan damarları çoklu çukurluk (multi concavity) ile modellenmektedir. Çalışmada parlak ve koyu lezyon içeren patolojik görüntüler ile sağlıklı görüntülerde eş zamanlı genel bir retinal kan damarı çıkarma işlemi gerçekleştirilmiştir. Bu amaçla üç farklı çukurluk ölçümü kullanılmaktadır. Parlak lezyonları elemek için türevlenebilir çukurluk ölçümü, Damara şekil olarak benzemeyen koyu renkli lezyonlar için çizgi şekilli çukurluk ölçümü ve dengesiz dağılımlı diğer gürültüler için yerel olarak normalize edilmiş çukurluk ölçümü kullanılmaktadır. Daha sonra bu üç ölçüm istatistiksel dağılımlarına göre birleştirilerek genel retinal görüntülerde kan damarları tespit edilmektedir [47].

Retinal görüntülerden aktif kontur modelleri kullanarak kan damarı çıkarmak amacıyla Espona ve ark. [48] yılan algoritması ile damarların topolojik özelliklerini birleştirmişlerdir. Yöntemde ilk olarak damar orta çizgileri çıkarılmış ve daha sonra ortadan damar kenarlarına doğru yılan eğrisi genişletilerek kan damarları bulunmaktadır.

Bir diğerk model tabanlı yaklaşımda Al-Diri ve ark. [49] parametrik bir aktif kontur model olan ikiz şeritler (Ribbon of Twins) algoritması önermişlerdir. Bu çalışmada tutarlı bir kalınlık bilgisi dikkate alınarak her bir şeritte ikiz konturlar tanımlanmaktadır. Bu konturlardan biri damar kenarı içerisinde diğeri ise damar kenarı dışında konumlandırılmaktadır. Benzer bir yaklaşım damarın karşılık gelen diğerk kenarındaki şerit için de uygulanmaktadır. Damar içerisindeki konturlar dışa doğru, damar dışındaki konturlar ise içe doğru kuvvet uygulayarak damar kenarlarına yaklaştırılmaktadır. İçteki konturlar arasındaki uzaklık maksimum olduğunda damar kenarları bulunmakta ve bu maksimum uzaklık damar kalınlığı olarak ayarlanmaktadır. Benzer bir yaklaşım aynı yazar tarafından damar çıkarma ve kalınlık ölçme işlemlerinin birleştirilmesi amacıyla gerçekleştirilmiştir [50]. Bu çalışmada ilk olarak olası damar ortasındaki pikselleri çıkarmak amacıyla tramline filtre uygulanmaktadır. Daha sonra ikiz şerit yöntemi de kullanan segment büyütme algoritması ile tramline piksel haritası segmentler kümesine dönüştürülmektedir. Son olarak kavşak çözümleme algoritması ile kan damarlarının çapraz-geçiş ve dallanma bulunmaktadır.

Zhao ve ark. [51] retinal kan damarı haritasını çıkarmak amacıyla görüntünün melez (hibrit) bölge bilgisini kullanan sonsuz çevreli aktif kontur model kullanmışlardır. Böylelikle sadece piksel parlaklık bilgi değil aynı zamanda bölgesel özellikler de dikkate alınarak daha gürbüz bir sistem önerilmektedir.

Geometrik modeller kullanan ilk çalışmalardan biri Chan ve ark. [52] tarafından önerilmiştir. Bu yöntemde düzensiz aydınlanma dağılımının etkilerini azaltmak ve gürbüz bir kenar algılama gerçekleştirmek için düzey kümeleri tabanlı bir aktif kontur model önerilmiştir. Önerilen bu algoritma Sum ve ark. tarafından [53] geliştirilerek sentetik ve anjiogram görüntülerinde damar çıkarma amacıyla kullanılmıştır.

Düzyer kümeleri kullanan bir diğerk çalışma ise Dizdaroglu ve ark. [54] tarafından kan damarı çıkarımı amacıyla önerilmiştir. Yöntemde ön işlem olarak düzensiz parlaklık dağılımı düzeltilmektedir. Daha sonra damarların iskeletini çıkarmak ve damarları bölütlemek amacıyla geliştirilmiş faz haritası kullanan yapısal bir düzey kümesi yöntemi uygulanmaktadır. Algoritma için gerekli tohum noktaları seçilmekte ve düzey kümeleri otomatik olarak başlatılarak kan damarları bölütlenmektedir.

1.7.1.6. Donanım Tabanlı Yaklaşımlar

Retinal kan damarı bölütleme algoritmalarının yüksek hesaplama maliyetlerine sahip olması ve gerçek zamanlı performans ihtiyacı nedeniyle yazılımsal çözümler yerine bazı durumlarda donanım tabanlı çözümler geliştirilmektedir. Donanım tabanlı yöntemlere en iyi örnek çok büyük ölçekli entegre yongalar (VLSI yonga setleri) kullanılarak gerçekleştirilen hücresel sinir ağları verilebilir [55]. Bazı uygulamalarda ise C/C++, Python ve Java dili kullanılarak geliştirilen araç kutuları (Toolkit) da kullanılabilir [56].

Alonso-Montes ve ark. [57] retinal damar ağacı çıkarmak amacıyla kullandıkları yöntemde histogram eşitleme ve düzeltme, yerel adaptif eşikleme ve morfolojik açma işlemleri uygulamışlardır. Çıkardıkları öz nitelikleri hücresel sinir ağı kullanarak sınıflandırmışlar ve bu şekilde kan damarları çıkarılmıştır. Burada kullanılan yöntem [58] çalışmasında daha da hızlandırmak amacıyla paralel bir şekilde gerçekleştirilmiştir. Bunların dışında iteratif bir aktif kontur algoritması olan piksel düzeyli yılan algoritması [59] ve bu algoritmanın paralelleştirilmiş sürümleri de [60] donanımla gerçekleştirilen çalışmalardandır.


1.7.2. Makine Öğrenmesine (Örüntü Tanıma) Dayalı Yöntemler

Makine öğrenmesine dayalı yöntemler retinal fundus görüntülerdeki her bir pikselin damar üzerinde veya arka planda olup olmadığını sınıflandıran yöntemlerdir. Bu yöntemler öncelikle retinal fundus görüntü üzerinde kan damarlarını ayırt edici bir takım öz nitelikler araştırmaktadırlar. Daha sonra bu öz nitelikler kullanılarak retinal fundus görüntülerdeki pikseller damar veya arkaplan olarak sınıflandırılmaktadır. Damar segmentasyonu için kullanılan örüntü tanıma teknikleri denetimli ve denetimsiz sınıflandırma olmak üzere iki alt kategoride incelenebilir. Denetimli yöntemler karar vermek için bir takım ön bilgilerin kullanılmasını gerektirmektedir. Denetimsiz yöntemleri ise herhangi bir ön bilgi gerektirmeden verinin dağılımına göre sınıflandırma (kümeleme) yapmaktadır.

1.7.2.1. Denetimli Sınıflandırma Yaklaşımları

Bu yöntemlerde damar bölütlemek için kullanılacak model veya kural manuel olarak etiketlenmiş eğitim kümesi kullanılarak oluşturulur ve daha sonra bu model veya kural

kullanılarak retinal fundus görüntüdeki her bir piksel damar veya arka plan olarak sınıflandırılır. Manuel olarak etiketlenen görüntüler bir uzman tarafından etiketlenir ve altın standart olarak kabul edilir. Ancak burada uzman tarafından etiketlenen görüntüler uzmandan uzmana bile farklılık gösterebilmektedir ve denetimli bu yöntemlerin performansı manuel olarak etiketlenmiş bu eğitim kümelerine bağlıdır. Tüm bunlara rağmen denetimli yöntemler denetimsiz yöntemlere göre daha iyi performans sonucu verebilmektedir ve özellikle herhangi bir patoloji içermeyen sağlıklı görüntülerde bu durum daha açık görülebilmektedir. Denetimli yöntemlerde çoğunlukla istatistiksel sınıflandırma yöntemlerinden olan k-en yakın komşular (k-EYK), Bayesgil Yaklaşımlar, Destek Vektör Makineleri (DVM) ve Yapay Sinir Ağları (YSA) gibi sınıflandırıcılar kullanılmaktadır. Denetimli yöntemlerin genel akış şeması Şekil 10'da verilmektedir.



Şekil 10. Denetimli sınıflandırma yöntemlerin genel akış şeması

Denetimli yöntemler genel olarak iki alt kısımdan oluşmaktadır. İlk önce belli bir eğitim kümesi kullanarak sınıflandırılacak verinin bir modeli oluşturulmaktadır. Bu aşama model oluşturma aşamasıdır ve eğitim işlemi olarak isimlendirilmektedir. Daha sonra eğitimde oluşturulan model kullanılarak daha önce etiketlenmemiş (sınıflandırılmamış) verinin hangi sınıftan olduğuna karar verilmektedir. Genelde görüntü sınıflandırma probleminde özelde ise retinal kan damarı çıkarmak amacıyla pikselleri sınıflandırma probleminde ilk olarak giriş görüntüsü işlenerek öz nitelik çıkarma işlemi gerçekleştirilmektedir. Daha sonra çıkarılan bu öz nitelikler kullanılarak piksel sınıflandırma

işlemi gerçekleştirilmektedir. Bir başka ifadeyle sınıflandırma işleminde tüm veri (görüntülerden çıkarılan öz nitelikler) eğitim ve test kümesi olarak iki kısma ayrılmaktadır. Eğitim kümesindeki veriler kullanılarak sınıflandırıcı eğitilmektedir. Buradan öğrenilen model kullanılarak test kümesindeki veriler sınıflandırılmaktadır. Bu amaçla literatürde farklı öz nitelik çıkarma ve farklı sınıflandırıcılar kullanan birçok çalışma önerilmiştir.

Nekovei ve Ying [61] anjiyografi görüntülerinde kan damarı bölütleme amacıyla geri yayımlı bir yapay sinir ağı önermişlerdir. Bu yaklaşımda öznitelik olarak doğrudan görüntüdeki piksellerin değerleri kullanılmıştır. Yöntemde görüntüden küçük bir çerçeve anjiyografi görüntüsü üzerinde kaydırılarak elde edilen pikseller yapay sinir ağını doğrudan giriş olarak verilmektedir. Yapay sinir ağına sunulan öznitelik vektörü çerçevenin ortasına denk gelen pikselin gri seviye değerinden elde edilmiştir. Manuel olarak etiketlenmiş anjiyogram görüntüleri kullanılarak eğitim seti oluşturulmuştur. Yapay sinir ağları kullanan başka bir çalışmada ise Sinthanayothin ve ark. [62] temel bileşen analizi analizinden sonra yapay sinir ağları kullanılmıştır ve böylece retinal fundus görüntülerdeki anatomik yapıların konumları tespit edilmeye çalışılmıştır. Eğitim ve test veri kümesinde kullanılan altın standart veriler bir uzman tarafından etiketlenen fundus görüntüler kullanılarak elde edilmiştir.

Niemeijer ve ark. [63] renkli RGB görüntüsünün gri birleşeninden oluşan retinal görüntü üzerinde her bir piksel için bir öz nitelik vektörü çıkarmıştır. Bu öznitelik vektörü Gauss uyum süzgeci tepkisi ile Gauss fonksiyonunun 1. ve 2. türevlerinin 1, 2, 4, 8, 16 ölçeklerinde uygulanması sonucu elde edilmiştir. Daha sonra K en yakın komşular (k-EYK) sınıflandırma algoritması ile piksellerin damar olabilme olasılık haritası çıkarılmıştır. En sonunda bu olasılık değerleri belli bir eşik değeri kullanılarak ikili damar yapısı elde edilmiştir. Bu çalışmanın geliştirilmiş hali Staal ve ark. [64] tarafından sırt tabanlı damar bölütleme yöntemi olarak önerilmiştir. Bu teknik önce renkli görüntüdeki sırt yapılarını çıkarmaktadır. Bu sırtlar damarların orta çizgilerinin doğal bir belirteci görevi görmektedir. Sırtlar çıkarıldıktan sonra oluşan pikseller gruplandırılarak görüntü primitifleri hesaplanmaktadır. Daha sonra görüntü konveks küme bölgelerine ayrılmakta ve her bir piksel en yakın kümeye atanmaktadır. Oluşan bu yapıları kullanılarak 27 adet öznitelik çıkarılmaktadır ve bu öz nitelikler ileri yönlü ardışıl öznitelik seçme yöntemi kullanılarak seçilmektedir. En sonunda K en yakın komşular (k-EYK) sınıflandırma algoritması kullanarak retinal görüntü pikselleri damar veya damar değil olarak sınıflandırılmaktadır.

Soares ve arkadaşları tarafından yapılan çalışmada [65] 2 boyutlu gabor dalgacık dönüşümü ve denetimli sınıflandırma kullanarak retinal damar bölütleme yöntemi önermişlerdir. Her bir piksel için beş elemanlı bir öznitelik vektörü oluşturulmuştur. Bu öznitelik vektörü piksel parlaklığı ve farklı ölçeklerde alınan gabor dalgacık dönüşüm tepkileri kullanılarak oluşturulmuştur. Sınıflandırma aşamasında bir Gaussgil karışım modeli kullanan Bayesgil sınıflandırıcı kullanılarak her bir piksel damar veya damar değil şeklinde sınıflandırılmıştır.

Ricci ve Perfetti tarafından yapılan çalışmada [12] çizgi operatörünü öznitelik vektörü çıkarmak için kullanan ve destek vektör makinelerini de piksel sınıflandırıcı olarak kullanan bir uygulama yapılmıştır. Her bir piksel üzerine birbirine dik olan ve farklı yönlerde iki doğru oturtulmuştur. Doğrular üzerindeki ortalama gri seviye değerleri ile ilgili pikselin o noktadaki gri seviye değeri öznitelik vektörünü oluşturur. Diğer denetimli tekniklere göre bu yöntemin 3 avantajı olduğu rapor edilmiştir. (1) daha az öznitelik gerektiriyor, (2) öz niteliklerin hesaplanması daha basit ve (3) eğitim için daha az örnek gerektiriyor. Yöntemin düzgün olmayan aydınlatmalara ve kontrast karşı dayanıklı olduğu da ayrıca rapor edilmiştir.

Osareh ve Shadgar yaptıkları çalışmada [66] damar adaylarını tanımlamak için çok ölçekli gabor süzgeci kullanmışlardır. Daha sonra temel bileşen analizi kullanarak öz nitelikler çıkarılmıştır. Gabor filtresinin parametreleri denemelerle optimal olarak ayarlanmıştır. Görüntüdeki pikseller damar veya damar değil şeklinde karşılık gelen öznitelik vektörleri kullanılarak sınıflandırılmıştır. Sınıflandırıcı olarak Gauss karışım modeli kullanan destek vektör makinesi (DVM) kullanılmıştır.

Xu ve Luo çeşitli görüntü işleme teknikleri ile destek vektör makineleri sınıflandırma yöntemi kullanarak damar bölütleme işlemi gerçekleştirmişlerdir [67]. Bu çalışmada yeşil bileşen normalize edildikten sonra büyük damarlar adaptif yerel eşitleme yöntemi ile belirlenmektedir ve Optik disk kenarları kaldırılmaktadır. Daha sonra retinal görüntü çok ölçekli dalgacık dönüşümü ile işlenerek öznitelik çıkarma işlemi yapılmaktadır. Çizgi operatörleri kullanılarak ince damarlar bulunmaktadır. Tüm bunlar kullanılarak 12 boyutlu öznitelik vektörü oluşturulmaktadır. Kalın damarlar hariç tutularak geri kalan piksellerin öz nitelikleri Destek Vektör Makineleri (DVM) sınıflandırıcı kullanılarak ince damar ve diğerleri şeklinde ayırt edilmektedir. Damar ağaç yapısını çıkarmak için bir izleme yöntemi kullanılmaktadır. Burada Hessian matrisin öz vektörü ve damar yönünün bileşimi kullanılmaktadır.

Lupaşcu ve arkadaşları yaptıkları çalışmada [68] damar bölütleme amacıyla bir başka bilinen denetimli metot olan öz nitelik tabanlı adaboost sınıflandırıcı kullanmışlardır. Çeşitli ölçeklerin kullanıldığı 41 boyutlu geniş ölçekli bir öz nitelik vektörü oluşturulmuştur. Öz nitelik vektörü içerisinde Gauss, Gauss türevi, Uyum süzgeci, 2D gabor süzgeci, kenar olma olasılıkları, sırt yapıları gibi farklı öz nitelikler bulunmaktadır. Öz nitelik vektörü oluşturulduktan sonra Ada boost sınıflandırıcı 789,914 eğitim örneği kullanılarak eğitilmiştir. Sınıflandırıcıda geniş bir öz nitelik grubu kullanılmış şekil ve yapısal bilgiler ile farklı ölçeklerdeki yerel bilgiler öz nitelik vektörüne eklenmiştir.

You ve ark. [69] damar bölütlemek için radyal projeksiyon ve Destek Vektör Makineleri (DVM) sınıflandırıcı sınıflandırıcı kullanan yarı denetimli öz-eğitim yöntemi uygulamışlardır. Damar merkez çizgileri ile dar ve düşük kontrasta sahip kan damarları radyal projeksiyon kullanılarak bulunmaktadır. Daha sonra damar iyileştirmek için değiştirilmiş yönetilebilir karmaşık dalgacık dönüşümü uygulanmıştır. Öz nitelik çıkarmak için iyileştirilmiş damar görüntüsü üzerine çizgi kuvvet ölçüleri uygulanmıştır. Büyük damar yapılarını çıkarmak için DVM kullanan yarı denetimli öz-eğitim yöntemi kullanılmıştır. Bölütlenmiş damarlar ince ve kalın damar görüntülerinin birleştirilmesi ile elde edilmiştir. Algoritma uzmanların etiketlediği veriden öğrenmiş ve yanlış damar tespitlerini en aza indirmiştir.

Marin ve ark. [4] yaptıkları çalışmada retinal damarları çıkarmak için yapay sinir ağları (YSA) temelli denetimli bir yöntem kullanmışlardır. Kullanılan yöntem 7 boyutlu bir öz nitelik vektörü kullanmaktadır. Bu öz niteliklerin 5 tanesi gri seviye (istatistiksel) tabanlı, 2 tanesi ise moment değişmezleri tabanlıdır. Eğitim ve sınıflandırma için çok katmanlı ileri yönlü sinir ağı tercih edilmiştir. Giriş katmanında 7 nöron (doğal olarak 7 öz nitelik olduğu için), her biri 50 nörondan oluşan 3 gizli katman ve çıkış katmanında ise tek bir nöron bulunmaktadır. Yöntemin farklı görüntülerde ve çoklu veri tabanlarında verimli ve dayanıklı olduğu ispat edilmiştir.

Fraz ve ark. [70], renkli retinal görüntülerden Gabor ve benzeri filtreler ve morfolojik dönüşümler kullanarak dokuz elemanlı öz nitelik vektörü çıkarmışlardır. Daha sonra bu öz nitelik vektörleri hızlandırılmış karar ağaçları kullanan kolektif bir sınıflandırma yöntemine giriş olarak verilmiştir. Böylece daha hızlı ve daha az karmaşıklıkta bir yöntemle patolojik ve sağlıklı retinal fundus görüntülerde pikselleri damar ya da arkaplan olarak sınıflandırmışlardır. Bu çalışmada kullanılan yöntem STARE, DRIVE ve CHASE_DB1 [71] veri tabanından alınan retinal görüntüler üzerinde test edilmiştir.

Retina piksellerini damar ya da arkaplan olarak sınıflandırmak amacıyla aynı öz nitelikler farklı sınıflandırıcılara sunulmaktadır. Böyle bir çalışma Khargharian ve ark. [72] tarafından önerilmiştir. Yöntemde öz nitelik olarak bir adet gri seviye değeri, dört farklı ölçekte Gabor filtre çıktısı ve 2 adet çizgi operatöründen elde edilen değer olmak üzere 7 elemanlı bir vektör kullanılmıştır. Çıkarılan öz nitelikler Bayes sınıflandırıcıya ve Destek Vektör Makineleri (DVM) sınıflandırma yöntemlerine sunularak damar çıkarımı gerçekleştirilmiştir. Sonuç olarak bazı durumlarda DVM yönteminin daha iyi sonuç verdiği bazı durumlarda ise Bayes sınıflandırıcısının daha hızlı çalıştığı gözlenmiştir. Benzer şekilde farklı öz nitelik gruplarının bir arada kullanılması performansı arttıran bir etken olduğu sonucuna varılmıştır. Bu çalışmaya benzer şekilde hibrit öz nitelikler kullanan bir başka çalışma Cheng ve ark. [73] tarafından yapılmıştır. Darbe genişliği dönüşümü, Weber'in yerel tanımlayıcıları ve parlaklık gibi bazı klasik yerel özellikler (Gabor filtre çıktıları, Frangi damarlılık ölçütü vb.) öz nitelikler Rastgele Orman sınıflandırıcı yöntemine sunularak pikseller sınıflandırılmaktadır.

Diyabetik retinopati hastalığını teşhis ve tedavi planlaması amacıyla Franklin ve ark. [74] tarafından önerilen çalışmada Kırmızı, Yeşil ve Mavi (KYK) renk bileşenlerinden türetilen bazı öz nitelikler geri yayımlı çok katmanlı sinir ağına sunularak retinal kan damarları çıkarılmıştır.

Son yıllarda evrimsel sinir ağlarının (CNN) geliştirilmesi ile birlikte öğrenme ve sınıflandırma işlemleri retinal kan damarı bölütleme amacıyla da kullanılmaya başlandı. Bu öğrenme yöntemleri daha çok derin öğrenme başlığı altında toplanmaktadır. Grafik işlemci kullanarak evrimsel sinir ağlarını gerçekleyen [75] çalışması bu tür çalışmalardandır. Benzer şekilde, hiyerarşik öz nitelik çıkarma amacıyla evrimsel sinir ağları kullanan ve kolektif öğrenme tabanlı Rastgele Orman sınıflandırıcı ile pikselleri damar ya da değil şeklinde sınıflandıran başka bir çalışma Wang ve ark. [76] tarafından önerilmiştir. Bu çalışmaların dışında öz nitelik çıkarma işlemi gerektirmeyen derin öğrenme tabanlı evrimsel sinir ağı kullanan [77] ve [78] gibi çalışmalar da retinal kan damarı bölütleme amacıyla önerilmiştir.

Roychowdhury ve ark. [79] damar çıkarma amacıyla üç aşamalı bir bölütleme algoritması önermişlerdir. Çalışmalarında ilk aşamada yüksek geçiren bir süzgeç kullanarak ikili bir görüntü elde edilmiş ve damar bölgelerini iyileştirmek için morfolojik işlemlerle başka bir ikili görüntü elde edilmiştir. Daha sonra her iki siyah beyaz görüntüde ortak olan bölgeler ana damarlar olarak işaretlenmiştir. İkinci aşamada geri kalan pikseller GMM

sınıflandırıcı kullanarak yeniden sınıflandırılmıştır. Kullanılan 8 elemanlı öz nitelikler kümesi görüntünün birinci ve ikinci dereceden türevi kullanılarak elde edilmiştir. Son aşamada ayrı ayrı işlemlerle elde edilen damar bölgeleri birleştirilerek ikili damar görüntüsü elde edilmiştir.

Zhu ve ark. [80] damar ve arkaplanı ayırt edecek şekilde yerel ve morfolojik öz nitelikler, faz uyumu, görüntünün Hessian matrisinden elde edilen öz nitelikler gibi farklı gruptan elde edilen 39 boyutlu bir öznitelik vektörü çıkarmışlardır. Bu öz nitelikler Aşırı Öğrenme Makinesi (Extreme Learning Machine (ELM)) sınıflandırıcısına sunularak piksel sınıflandırılması gerçekleştirilmiştir.

1.7.2.2. Denetimsiz Sınıflandırma (Kümeleme - Öbekleme) Yaklaşımları

Denetimsiz sınıflandırma yöntemlerinde herhangi bir eğitim gerektirmeyen ve veriyi öbekleme yöntemi ile sınıflandıran yöntemlerdir. Bu yöntemlerde bir pikselin damar ya da arkaplana ait olmadığıın bulunması için denetimli yöntemlerde olduğu gibi öz nitelikler çıkarılmakta ancak eğitim için herhangi bir ön etiketli veri kullanılmamaktadır. Bu yöntemler, sınıflandırma yapılırken verinin dağılımını analiz edilerek uygun sınıf sayısına göre sınıflandırma yapmaktadır. Denetimsiz sınıflandırma yöntemleri kümeleme (öbekleme) yöntemleri olarak da bilinirler. Genel olarak katı kümeleme ve ılımlı kümeleme olarak iki alt kategoride incelenebilirler. Katı kümeleme (hard clustering) yöntemlerinde (örneğin; K-ortalama kümeleme yöntemi) bir örnek yalnızca bir kümeye ait olabilmektedir ve sınıfı o ait olduğu kümeye göre belirlenir. K-ortalama yönteminde K değeri küme sayısını temsil etmektedir. İlimli kümeleme (soft clustering) yöntemlerinde ise (örneğin Bulanık C-ortalama kümeleme yöntemi) bir örnek birden fazla kümeye ait olabilmektedir ve o örneğin sınıfı en yüksek aitlik derecesine sahip küme olarak belirlenir. Mesela bir örneğin bir kümeye aitlik derecesi %70 iken diğer bir kümeye aitlik derecesi %30 olabilmektedir. Bulanık C-ortalama (BCO) yönteminde C değeri küme sayısını temsil etmektedir. İlimli kümeleme yöntemleri katı kümeleme yöntemlerinin genelleştirilmiş hali olarak da bilinirler. Denetimsiz sınıflandırma yöntemleri kullanan başlıca retinal kan damarı bölütleme çalışmaları aşağıda verilmektedir.

Tolias ve ark. [81] çalışmasında anjiogram görüntülerinde damarları izlemek için dilbilimsel tanımlayıcılar kullanan Bulanık C-ortalama kümeleme yöntemi geliştirmişlerdir. Damar izleme yöntemi iki dilbilimsel değerin üyelik fonksiyonlarını bulmaya dayalıdır. İlk

olarak optik sinir ve optik sinirin belirgin olan dairesel kenarları bulunmakta, izleme işlemi için bu noktalar başlangıç noktası olarak kabul edilmektedir. Daha sonra Bulanık C-ortalama algoritması ile daire üzerindeki noktalar damar veya değil şeklinde işaretlenmektedir. 3 veya daha fazla damar noktası içeren bölgeler bulanık bir damar izleme yöntemi için aday başlangıç noktaları olarak kabul edilmektedir. Yanlış damar adayı pikselleri birkaç adımdan sonra algoritma tarafından hatalı tespit olarak işaretlenmektedir. Bu şekilde tüm aday pikseller takip edilerek son durumdaki kan damarları tespit edilmektedir.

Salem ve ark. [82] çalışmasında yarıçap tabanlı kümeleme algoritması önermişlerdir. Öznitelik olarak görüntünün gri seviye parlaklık değerleri, eğim genliğinin yerel maksimumu ve görüntünün Hessian matrisinin en büyük öz değeri kullanılmıştır. Çalışmada kullanılan yarıçap tabanlı kümeleme algoritması denetimli bir sınıflandırma yöntemi olan k en yakın komşular (k-EYK) yöntemi ile karşılaştırılmış ve ince damarlarda daha iyi sonuç verdiği gözlenmiştir.

Damar bölütleme amacıyla bulanık tabanlı bir başka denetimsiz sınıflandırma yöntemi de Kande ve ark. [83] tarafından önerilmiştir. Bu çalışmada renkli görüntülerden kırmızı ve yeşil renk kanalı bileşenleri kullanılarak düzensiz aydınlatmalar giderilmektedir. Daha sonra damarları iyileştirmek amacıyla uyum süzgeci kullanılmaktadır. Son olarak ağırlıklandırılmış bulanık C-ortalama yöntemi ile damarlar damar ya da arkaplan olarak etiketlenmektedir.

Dey ve ark. [84] yine Bulanık C-ortalama kümeleme yöntemi kullanan kan damarı bölütleme algoritması önermişlerdir. İlk olarak, renkli görüntüsünden gri seviye değerleri elde edildikten sonra adaptif histogram eşitleme yöntemi uygulanmıştır. Daha sonra öz nitelik çıkarımı için arkaplan çıkarma işlemi uygulanmış ve ikili damar görüntüsü elde etmek için bulanık C-ortalama kümeleme yöntemi kullanılmıştır.

Bir diğer denetimsiz sınıflandırma yaklaşımı Emary ve ark. [85] tarafından geleneksel bulanık kümeleme yöntemlerinde ortaya çıkabilecek problemlerin üstesinden gelmek amacıyla geliştirilmiştir. Yöntemde ilk olarak yeşil renk kanalından elde edilen yeşil bileşen değeri düzeltilmiş ve daha sonra olabilsel bulanık c-ortalama yöntemi ile pikseller damar ya da arkaplan olarak sınıflandırılmıştır. Kümeleme yapılırken başlangıç küme merkezleri rastgele belirlenmiş ve gelenekselden farklı olarak Cuckoo araması prensiplerine göre güncellenmiştir.

Saffarzadeh ve ark. [86], kan damarlarını tespit etmek amacıyla giriş olarak renkli görüntünün yeşil renk kanalını alarak geliştirdikleri çalışmada parlak dokuların negatif

etkisini azaltmak için K-ortalama yöntemini uygulamışlardır. Daha sonra çok ölçekli çizgi operatörü ile retinadaki koyu damar bölgeleri tespit edilmiştir.

Katı-kümeleme ve ılımlı-kümeleme yöntemlerinin birlikte kullanıldığı ve performans olarak karşılaştırıldığı bir diğer çalışmada Yavuz ve ark. [87], öz nitelik olarak bir takım ön işlemlerden sonra Gabor, Gauss ve görüntünün Hessian matrisine dayalı Frangi filtre çıktılarını ayrı ayrı hesaplamışlardır. Daha sonra arkaplan, ince damar ve kalın damar olacak şekilde üç farklı küme esas alınarak K-ortalama ve bulanık c-ortalama kümeleme yöntemleri uygulanmış ve performans olarak en iyi çözümün Gabor filtresi ile K-ortalama kümeleme yöntemi ile ve küme sayısının üç olarak seçildiği durumda elde edildiği gözlenmiştir.

Literatürdeki yöntemlere ve sonuçlarına bakıldığında denetimli yöntemlerin diğer yöntemlere göre daha iyi sonuçlar verdiği görülmektedir. Ancak bu yöntemler eğitim setine bağlı olarak düzensiz parlaklık dağılımları olan bölgelerde (özellikle optik disk, kanamalar ve diğer patolojiler içeren bölgelerde) hatalı tespitler üretebilmektedir. Ayrıca denetimli yöntemler Uyum filtresinin (kavramsal olarak Gauss fonksiyonu ile aynıdır) farklı sürümleri gerek kan damarı iyileştirmek gerekse sınıflandırmada öz nitelik çıkarma amacıyla oldukça fazla kullanıldığı görülmektedir. Uyum filtresi tek başına kan damarı çıkarma işleminde kullanıldığında özellikle patolojik görüntülerde başarısız olmakta, bu nedenle diğer yöntemlerle birleştirilerek kullanılması tercih edilmektedir. Bunların dışında uyum filtresinin uygulanmasına benzer şekilde esnek ve ölçeği değişen farklı filtreler de kullanılmaktadır. Bunlara örnek olarak Gabor fonksiyonuna dayalı filtreler verilebilir.

Kural tabanlı yöntemlerde belli bir kurala göre bölütleme yapıldığından herhangi bir eğitim işlemi gerektirmiyor ancak başarısı makine öğrenmesine dayalı yöntemlere göre nispeten daha düşük olmaktadır. Makine öğrenmesine dayalı yöntemlerde ise performans daha iyi olmakta ancak eğitim için bir uzman tarafından etiketlenmiş verilere ihtiyaç duyulmaktadır ve bazen seçilen sınıflandırma yöntemine göre eğitim uzun zaman alabilmektedir.


1.8. Retinal Görüntü Veritabanları

Literatürde, retinal fundus görüntülerde kan damarı bölütleme amacıyla kullanılan yöntemleri test edip elde edilen sonuçları karşılaştırabilecek internet üzerinde erişime açık birçok veritabanı bulunmaktadır. Bu veritabanlarında farklı çözünürlükte retinal fundus görüntülerin yanında uzman kişiler tarafından kan damarlarının etiketlenmiş halleri ve retina

bölgesini seçmek için kullanılabilecek maske görüntüleri bulunmaktadır. En çok kullanılan ve referans gösterilen veritabanları aşağıdaki şekilde sıralanabilir.

1.8.1. STARE Veritabanı


Structured Analysis of the RETina (STARE) [10] veritabanı, yaklaşık olarak 400 adet renkli retinal fundus görüntü içermektedir. Bu görüntüler TopCon TRV-50 fundus kamrası ile 35 derece görüş açısında ve 700x605 piksel çözünürlükte, 3 renk kanalına sahip (her bir renk için 8 bit) elde edilmiştir. Retinal kan damarı performansını test etmek amacıyla 20 adet görüntüden oluşan özel bir veri seti oluşturulmuştur ve iki uzman tarafından bu görüntülerdeki kan damarları etiketlenmiştir. Seçilen 20 görüntüden 10 adet görüntü çeşitli patolojilere sahipken kalan 10 adet görüntü ise sağlıklı retina görüntüleridir. Görüntülerdeki kan damarlarını etiketleyen uzmanlardan ilki tüm piksellerin %10,4'ünü kan damarı olarak işaretlerken diğer uzman tüm piksellerin %14,9'unu kan damarı olarak işaretlemiştir. İkinci uzman kişi etiketleme esnasında daha ince damarları da dikkate alarak etiketleme yapmıştır. Literatürde performans değerlendirmesi için genellikle birinci uzmanın etiketlediği görüntüler kesin referans (ground truth) olarak seçilmektedir. Şekil 11'de STARE veritabanından alınan örnek bir görüntü verilmektedir.



Şekil 11. STARE veritabanından alınmış örnek bir renkli retinal fundus görüntü

1.8.2. DRIVE Veritabanı

Digital Retinal Images for Vessel Extraction (DRIVE) [88] veritabanı, 25-90 yaş aralığında 400 civarında diyabetik retinopati vakasından rastgele seçilen 40 adet renkli retinal fundus görüntüden oluşmaktadır edilmiştir. Bu görüntüler Canon CR5 fundus kamerası ile 45 derece görüş açısında ve 768x584 piksel çözünürlükte ve 24 bit renk derinliğine sahiptir. 40 görüntüden 33 adedi herhangi bir patoloji içermezken 7 tanesi erken dönem diyabetik retinopati vakası içermektedir. Veritabanındaki görüntüler 2 alt kümeye ayrılmıştır. İlk 20 görüntü veritabanının oluşturan yazar tarafından eğitim görüntüleri olarak kullanılmıştır. İkinci 20 görüntü ise test görüntüsü olarak kullanılmıştır. Görüntülerdeki kan damarları piksellerinin toplam pikseller oranı ise %12,7 olarak ölçülmektedir. Şekil 12’de DRIVE veritabanından alınmış örnek bir görüntü verilmektedir.



Şekil 12. DRIVE veritabanından alınmış örnek bir renkli retinal fundus görüntü

1.8.3. ARIA Veritabanı

ARIA (Automated Retinal Image Analyzer) veritabanında [89] Zeiss FF450+ fundus kamerası ile çekilen 24 bit gerçek renk derinliğine sahip 50 derece görüş açısında elde edilmiş 143 adet renkli fundus görüntü bulunmaktadır. Görüntüler 768x576 çözünürlükte ve içerdikleri patolojilere göre üç farklı gruba ayrılmışlardır. Birinci grupta 23 adet yaşa bağlı makula dejenerasyonu (YBMD) hastalığı, ikinci grupta 59 adet

diyabetik retinopati hastalığı içeren görüntüler bulunmaktadır. Sağlıklı olan ve kontrol grubu olarak adlandırılan üçüncü grupta ise 61 adet sağlıklı retinal fundus görüntü bulunmaktadır [Fraz-2012]. Performans değerlendirmesi için bu görüntülerin iki farklı uzman tarafından etiketlenmiş kesin referans olan damar görüntüleri de bulunmaktadır.

1.8.4. HRF Veritabanı

HRF (High-Resolution Fundus) veritabanı [23], Canon CR-1 fundus camera ile 24 bit gerçek renk derinliğinde 45 derece görüş açısında yüksek çözünürlükte (3504x2336 piksel) elde edilen 45 adet görüntü içermektedir. Görüntülerin 15 tanesi sağlıklı kişilere, 15 tanesi diyabetik retinopati hastalığı olan kişilere ve geriye kalan 15 tanesi de glukom içeren hastalara aittir. Performans değerlendirmesi için bu görüntülerin uzman kişiler tarafından etiketlenmiş halleri de veritabanında mevcuttur. Ayrıca veritabanında retina bölgesini seçmek amacıyla yine uzmanlar tarafından oluşturulan maske görüntüleri de yer almaktadır.

1.8.5. CHASE_DB1 Veritabanı

CHASE_DB1 veritabanı, 14 adet çocuk hastadan sağ ve sol gözden olmak üzere toplamda 28 adet renkli görüntü içermektedir. Bu görüntüler 999x960 piksel çözünürlükte ve 30 derece görüş açısında elde edilmiştir. Performans değerlendirmesi için bu görüntülerdeki kan damarları iki uzman tarafından manuel olarak etiketlenmiştir [71].

1.8.6. RetinaCheck Veritabanı

Bu veritabanında 2 ayrı veri seti bulunmaktadır. Bu veri setlerindeki görüntüler EasyScan fundus camerası ile ve SLO (Scanning Laser Ophthalmoscopy) tekniği ile alınan görüntülerdir. IOSTAR veri setinde 30 adet 1024x1024 piksel çözünürlüğünde fundus görüntüler bulunmaktadır [90]. RC-SLO verisetinde ise 40 adet 360x320 piksel boyutunda fundus görüntü parçaları bulunmaktadır. Her iki veri setindeki kan damarları ve kan damarlarının kesişim (öz nitelik) noktaları uzman kişiler tarafından etiketlenmiştir.


Farklı retinal fundus veri tabanları ve bu veri tabanlarında bulunan görüntü sayıları, fundus görüntülerin çözünürlükleri, çekim açıları ve çekim yapılırken kullanılan kameralara özet bir şekilde Tablo 1’de verilmektedir.

Tablo 1. Retinal fundus görüntü veritabanları ve özellikleri

Veritabanı	Görüntü Sayısı	Çözünürlük	Çekim Açısı	Kamera
STARE	20	700x605	35	TopCon TRV-50
DRIVE	40	768x584	45	Canon CR5
ARIA	143	768x576	50	Zeiss FF450+
HRF	45	3504x2336	45	Canon CR-1
CHASE_DB1	28 (14x2)	999x960	30	-
RetinaCheck IOSTAR	30	1024x1024	-	EasyScan
RetinaCheck RC-SLO	40	360x320	-	EasyScan

2. YAPILAN ÇALIŞMALAR

Bu tez çalışmasında renkli retinal görüntülerde kan damarının tespiti edilmesi amaçlanmaktadır. Ayrıca tespit edilen ikili damar görüntüleri kullanılarak damar tanıma ve görüntü çakıştırma gibi amaçlarla kullanılmak üzere öznitelik vektörlerinin çıkarılması hedeflenmektedir. Bu amaçla bu tez çalışmasında iki aşamalı damar çıkarma yöntemi izlenmiştir. İlk olarak bir takım görüntü ön işlemlerinden sonra damar iyileştirme işlemi gerçekleştirilmektedir. Kan damarlarını belirgin hale getirmek amacıyla Gauss, Gabor ve Frangi süzgeçleri kullanılmış ve gri seviye morfolojik top-hat dönüşümü ile nihai iyileştirilmiş damar görüntüleri elde edilmektedir. İkinci olarak iyileştirilmiş kan damarı görüntüleri piksel tabanlı sınıflandırma teknikleri ile ikili damar görüntülerine dönüştürülmektedir. Bunun için kural tabanlı eşikleme, denetimsiz sınıflandırma (kümeleme) ve denetimli sınıflandırma (makine öğrenmesi) yaklaşımları kullanılmaktadır. Makine öğrenmesi aşamasında öznitelik olarak belirginleştirilmiş damar görüntülerinin yanı sıra istatistiksel ve renk kanalları tabanlı öznitelikler de çıkarılmış ve bu öz nitelikler piksel sınıflandırma yöntemlerine sunulmuştur. Piksel sınıflandırma yöntemi olarak denetimsiz sınıflandırma (K-ortalama ve Bulanık C-ortalama) ile denetimli sınıflandırma (Doğrusal Ayırtaç Analizi - DAA, En Yakın K Komşular - EYKK, Naif Bayes Sınıflandırıcı - NBS, Destek Vektör Makineleri - DVM) yöntemleri kullanılmıştır. İkili damar görüntüsü elde edildikten sonra morfolojik inceltme (iskelet çıkarma), öznitelik noktalarının çıkarılması ve daha sonra damar tanıma, görüntü çakıştırma gibi amaçlarla kullanılmak üzere karakteristik öznitelik vektörünün elde edilmesi işlemleri gerçekleştirilmiştir. Şekil 1'de tez çalışmasının akış şeması, Şekil 13'te ise retinal kan damarı bölütleme işleminin genel akış şeması verilmektedir. Sonraki bölümlerde sırasıyla bu işlemlerin ayrıntılarına değinilecektir.



Şekil 13. Retinal kan damarı bölütleme yönteminin genel akış şeması

2.1. Görüntü Ön İşleme Adımları

Renkli retinal fundus görüntü, bu doktora çalışması kapsamında geliştirilen sistem için giriş görüntüsü olarak kullanılmaktadır. Damar bölütme işleminde kullanılmak üzere bu giriş görüntüsündeki verilerin işlenerek hazır hale getirilmesi ve kan damarları ile retina arkaplanının birbirinden daha kolay bir şekilde ayrıştırılması gerekmektedir. Bu nedenle bir dizi ön işlem adımları takip edilmektedir. Bu aşamada sırayla retinal bölge seçimi, retinal bölge büyütme, gri seviye dönüşüm ve damar ışık refleksi eleme ön işlemleri uygulanmaktadır.

2.1.1. Retinal Bölge Seçimi

Retinal fundus görüntüler şekil olarak dikdörtgen biçiminde olmasına karşın, retina bölgesi daire ya da daireye yakın biçimde (elips, basık daire vb.) olmaktadır. Retinal kan

damarlarını tespit ederken gereksiz yapılan işlemleri önlemek ve performans değerlendirmesinin doğru biçimde yapılması amacıyla görüntüdeki retinaya ait olmayan bu bölgelerin elenmesi gerekmektedir. Retinal fundus görüntü veritabanlarının bazılarında (DRIVE, HRF) elle etiketlenmiş maskeler bulunmaktadır. Ancak çoğu veritabanında elle etiketlenmiş maskeler bulunmamaktadır. Maskelerin elle etiketlenmesi zaman gerektiren maliyetli bir iştir. Basit ve Otsu yöntemi ile otomatik eşik uygulayarak maskelerin elde edilmesi durumunda ise yansıtma özelliği düşük olan bazı damarların da eşik altında kaldığı gözlenmektedir. Bu duruma bir örnek Şekil 14’te verilmektedir. Bu çalışmada geliştirilen eşitlik ile retina bölgesine ait olmayan pikseller tespit edilmektedir.

Retina maskesi elde etmek için renk kanalları arasındaki farkların toplamından ve ortalama değerlerinden yararlanılmaktadır. Eşitlik 1’de retina maskesi için kullanılan bağıntı verilmektedir.


$$Maske(x,y) = \begin{cases} 0, & ortalama(K,Y,M) < T_1 \text{ ve } D < T_2 \\ 1, & \text{diger durumlarda} \end{cases} \quad (1)$$

Burada K , Y , M değerleri sırasıyla renkli görüntüde Kırmızı, Yeşil ve Mavi renk bileşenleri olmak üzere, $D = |K - Y| + |K - M| + |Y - M|$ şeklinde hesaplanmaktadır. STARE ve DRIVE veritabanlarında en iyi performansı elde etmek amacıyla T_1 ve T_2 eşik değerleri sırasıyla 40 ve 50 olarak ayarlanmıştır (gri seviye görüntünün 0-255 arasında değerler aldığı kabul edildiğinde).


DRIVE veritabanında daha önce elle uzmanlar tarafından etiketlenmiş maske görüntüleri bulunduğundan retina bölgesi bulmak için önerilen yöntem, bu veritabanındaki görüntülere de uygulanmış ve elde edilen sonuçlar performans açısından elle çıkarılan maske ile karşılaştırılmıştır. Sadece basit eşik değeri kullanarak elde edilen maskeler için hesaplanan doğruluk değeri %99.04 ve doğruluk değerleri arasındaki standart sapma %1.01 iken yukarıda önerilen bağıntı kullanılarak elde edilen doğruluk değeri %99.78 ve doğruluk değerleri arasındaki standart sapma %0.25 olarak elde edilmiştir. STARE veritabanında manuel olarak etiketlenmiş maskeler olmadığından bu veritabanı kullanılarak elde edilen sonuçlar görsel olarak değerlendirilmiştir. Buna göre bulunan retinal maskeler tatmin edici ve yeterli seviyededir.



(a) STARE veritabanından alınan renkli retinal fundus görüntü



(b) Otomatik eşik (OTSU) kullanılarak elde edilen maskesi. Doğruluk %95,10




(c) Basit eşik kullanarak elde edilen maske. Doğruluk %98,48



(d) Önerilen yöntemle elde edilen maske. Doğruluk %99,21

Şekil 14. Retinal maske seçim sonuçları

Retinal maske seçim algoritmasının adım adım akış şeması Şekil 15’te verilmektedir.



Şekil 15. Retinal maske seçim algoritmasının akış şeması

2.1.2. Retinal Bölge Büyütme

Birçok damar iyileştirme yöntemleri simetrik yapısal elemanlar kullanarak evrişim (konvolusyon) işlemi gerçekleştirmektedir. Bunun sonucu olarak retina kenarında dairesel kenar benzeri istenmeyen gürültüler ortaya çıkabilmektedir. Retina bölgesinin dışarı doğru genişletilmesiyle oluşan bu artefaktların dışa doğru itilmesi sağlanabilir. Bu nedenle ilk olarak retinanın dış kenarı elde edilir. Retina kenarında bulunan pikseller merkez kabul edilerek içteki n adet piksel için simetrik yansıma işlemi uygulanır. Bu işlem önce yatayda daha sonra da dikeyde uygulanarak retina bölgesinin n piksel genişlemesi sağlanmış olur. Çalışmada n değeri 3 olarak seçilmiştir.

2.1.3. Gri Seviye Dönüşüm

Maske seçimi ve retina bölgesi genişletme işlemlerinden sonra piksel parlaklıklarını elde etmek için gri seviye dönüşüm gerçekleştirilmektedir. Gri seviye dönüşüm için görüntü işleme, bilgisayarla görme gibi alanlarda kullanılan birkaç farklı yöntem bulunmaktadır. Gri

seviye dönüşüm için genellikle renk kanallarının (Kırmızı (K), Yeşil (Y) ve Mavi (M)) her biri belli bir katsayı ile çarpılıp toplanmaktadır. Eşitlik 2’de kullanılan genelleştirilmiş bağıntı verilmektedir.

$$P = c_k K + c_y Y + c_m M \quad (2)$$

Burada P değeri gri seviye parlaklık, K , Y ve M değerleri sırasıyla Kırmızı, Yeşil ve Mavi renk bileşenlerini, c_k , c_y ve c_m değerleri ise renk kanallarının her birinin çarpılacağı kat sayıları göstermektedir. Burada elde edilen gri seviye değerin normalleştirilmiş olması için renk kanalları kat sayılarının toplam değerinin 1 olması gerekmektedir ($c_k + c_y + c_m = 1$).

Literatürde kullanılan gri seviye dönüşüm yöntemlerinde genellikle yeşil bileşen kullanılmaktadır ($c_k=0$, $c_y=1$ ve $c_m=0$). Çünkü kan damarı ile arkaplan arasında en yüksek karışıklık değerini bu bileşen olduğu ileri sürülmektedir. Benzer şekilde gri seviye dönüşüm için KYM renk kanallarının ortalama değerinin alındığı başka çalışmalar da mevcuttur ($c_k = 1/3$, $c_y = 1/3$, $c_m = 1/3$). Ancak farklı değerlerde renk kanalı kat sayıları uygulanarak daha iyi başarımlar sonuçları elde edilebilir. Bu çalışmada önerilen yöntemde daha yüksek karışıklık sağlamak amacıyla sadece yeşil bileşen yerine Kırmızı (K), Yeşil (Y) ve Mavi (M) bileşenlerin her biri özel kat sayılarla çarpılıp toplanarak elde edilen parlaklık değeri kullanılabilir. En iyi sonucu verdiği gözlenen $c_k=0.1$, $c_y=0.7$ ve $c_m=0.2$ değerleri gri seviye dönüşüm kat sayıları olarak seçilmiştir.

2.1.4. Damar Işık Refleksi Eleme

Retinal kan damarları retinaya göre daha az ışık yansıtma özelliği göstermektedirler. Bu nedenle retinal fundus görüntülerde kan damarları daha koyu görünmektedirler. Buna rağmen bazı retinal kan damarlarının merkez kısmında ışığı yansıtma özelliğinden dolayı 1 ya da 2 piksel kalınlığında uzunlamasına parlak bir şerit oluşmaktadır. Bu duruma damar ışık refleksi denilmektedir. Damar ışık refleksi etkisini elemek için gri görüntü r piksel çaplı disk biçimli bir yapısal eleman kullanılarak gri seviye morfolojik açma işlemi uygulanmaktadır. r değerinin büyük seçilmesi birbirine konumsal olarak yakın kan damarlarının birleşmesi olasılığını doğurmaktadır. Bu nedenle bu değer damar ışık refleksini kaldıracak derecede büyük ve yakın damarları birbirine birleştirmeyecek kadar


minimum seçilmesi en ideal çözüm olmaktadır. Uygulamada r değeri 3 olarak alınmıştır. Şekil 16’da, damar ışık refleksi giderme işlemine bir örnek verilmiştir.



Şekil 16. (solda) Damar ışık refleksi (okla gösterilen) ve (sağda) damar ışık refleksi eleme işleminin sonucu

2.2. Kan Damarı Belirginleştirme

Buraya kadar damar bölütleme performansını arttırmaya yönelik birtakım ön işlemlerin nasıl yapıldığı ele alındı. Bu bölümde retinal kan damarları ile retina arkaplanı arasındaki ayırt edilebilirliği arttırmak için kan damarları ile uyumlu olabilecek birtakım süzgeçler kullanılmaktadır. Kan damarı belirginleştirme adımında giriş görüntüsü olarak ön işlemde geçirilmiş parlaklık görüntüsünün terslenmiş çıktısı kullanılmaktadır. Belirginleştirme aşamasında kan damarlarına uyum gösteren bir süzgeç geliştirmek amacıyla Gauss ve Gabor fonksiyonları kullanılmaktadır. Ek olarak çok ölçekli bir yaklaşım olan ve görüntünün ikinci dereceden türevlerinin öz değerlerini dikkate alan Frangi süzgeci de kan damarı belirginleştirme adımında kullanılmaktadır. Şekil 17’de kan damarı belirginleştirme işlemlerinin genel akış şeması verilmektedir.



Şekil 17. Kan damarı belirginleştirme işleminin akış şeması

2.2.1. İki Boyutlu Gauss Süzgeci

Retinal kan damarları ince uzun şekilde ve kıvrık yapıdadırlar. Damar kesiti incelendiğinde ise ters Gauss fonksiyonuna benzer bir profil ortaya çıkmaktadır. Bu nedenle Gauss fonksiyonu kullanarak kan damarlarına morfolojik olarak uyum gösteren bir süzgeç tasarlanabilmektedir. Bu fikir ilk olarak Chaudhuri ve arkadaşları tarafından [Chaudhuri-1989] kan damarları bölütleme çalışmasında önerilmiştir. Buna göre damar profili ters Gauss eğrisine benzediği için $(n \times n)$ boyutunda iki boyutlu Gauss fonksiyonu kullanarak kat sayıları belirlenen bir yapısal eleman oluşturulmaktadır. Daha sonra bu yapısal eleman (çekirdek fonksiyonu) belli açılarla döndürülerek kan damarına her yönde uyum gösterecek yapısal elemanlar kümesi elde edilmektedir. Eşitlik 3'te kullanılan Gauss fonksiyonunun denklemi verilmektedir.

$$gauss(x, y, \sigma_x, \sigma_y, \theta) = A * \exp\left(-\frac{x'^2}{2\sigma_x^2} - \frac{y'^2}{2\sigma_y^2}\right) \quad (3)$$

$$x' = x \cdot \cos\theta + y \cdot \sin\theta \quad (4)$$


$$y' = -x \cdot \sin\theta + y \cdot \cos\theta \quad (5)$$

Burada yer alan x' ve y' değişkenleri Eşitlik 4-5'te verildiği gibi hesaplanmaktadır. Eşitlik 3'te verilen x ve y piksel koordinatlarını, σ ölçek parametresini ve θ ise dönme açısını göstermektedir. Çalışmada kullanılan farklı yönlerdeki örnek Gauss çekirdekleri Şekil 18'de verilmektedir.



Şekil 18. Farklı ölçeklerde ve farklı yönlerde elde edilen Gauss çekirdekleri ($\sigma_x=1$, $\sigma_y=4$)

Giriş görüntüsü Gauss fonksiyonu kullanılarak farklı yönlerde elde edilen tüm yapısal elemanlarla (uyum süzgeçleriyle) ayrı ayrı katlama işlemine tabi tutulur. Kan damarına en iyi uyum sağladığı kabul edilerek her piksel için karşılık gelen değerlerin maksimumu seçilir ve belirginleştirilmiş damar görüntüsü elde edilir. Bu işleme maksimum süzgeç tepkisi de denilmektedir. Çalışmada açısal çözünürlük $\theta=15$ (yani 15 derece aralıklarla farklı yönlerde 12 farklı uyum süzgeci) seçilmiştir. Kullanılan süzgecin en boy oranını belirleyen $\sigma_x=1$ ve $\sigma_y=4$ olarak seçilmiştir. Parametrelerin bu şekilde seçilmesi ile damara benzeyen tüp benzeri yapılar daha da ön plana çıkarılmıştır. Literatürde iyi sonuç verdiği raporlanan doğru operatörü (line operator) [12] damarın kıvrımlı doğru yapısını gözardı etmektedir. Geliştirilen bu süzgeç ile doğrunun uçları kıvrımlı kan damarlarına daha iyi uyum göstermektedir. Şekil 19'da farklı yönlerde uygulanan Gauss süzgeçlerinin maksimum tepki görüntüsü verilmektedir.



Şekil 19. Fraklı yönlerdeki Gauss süzgeçlerinin maksimum tepki görüntü çıktısı.

2.2.2. İki Boyutlu Gabor Süzgeci

Gabor süzgeci, görüntü işleme, bilgisayarla görme, örüntü tanıma gibi uygulamalarda hedef görüntüdeki bileşenleri ortaya çıkarmak için kullanılan yaygın bir öznelilik çıkarma yöntemidir. Görüntüde aranan bileşen bu süzgeç yardımıyla belirgin hale getirilir ve istenmeyen diğer bileşenler bastırılarak elenir. Harmonik bir fonksiyon olan trigonometrik kosinüs (karmaşık Gabor fonksiyonunun reel bileşeni) ile iki boyutlu Gauss fonksiyonunun çarpılması ile elde edilir. Bu çalışmada, kan damarlarını belirginleştirmek amacıyla uygulanan çekirdek uyum süzgeci elde etmek için kullanılmaktadır. Çekirdek uyum süzgeci çıkarmada kullanılacak temel Gabor çekirdeğinin denklemi Eşitlik 6-8’de verilmektedir.


$$gabor(x, y; \lambda, \theta, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) * \cos(2\pi \cdot \frac{x'}{\lambda}) \quad (6)$$

$$x' = x \cdot \cos\theta + y \cdot \sin\theta \quad (7)$$

$$y' = -x \cdot \sin\theta + y \cdot \cos\theta \quad (8)$$


Burada g gabor çekirdek fonksiyonunu, x ve y değerleri görüntüdeki piksellerin yatay ve dikey koordinatlarını, γ gabor çekirdeğinin en/boy oranını, σ aranan örüntünün ölçeğini

(Gauss zarfının genişliğini), λ ise gabor çekirdeğinin dalga boyunu göstermektedir. Dönme işlemi için x ve y koordinatlarının farklı θ açılarında döndürülmüş halleri Eşitlik 7-8'de verildiği gibi $x' = x \cdot \cos\theta + y \cdot \sin\theta$ ve $y' = -x \cdot \sin\theta + y \cdot \cos\theta$ şeklinde hesaplanmaktadır. Farklı ölçek ve yönlerde elde edilen örnek Gabor çekirdek yapıları Şekil 20'de verilmektedir.



Şekil 20. Farklı ölçeklerde ve farklı yönlerde elde edilen örnek Gabor süzgeçleri ($\sigma=1,2,3$ ve $\gamma=0.5, \lambda=2$)

Elde edilen Gabor çekirdeği Gauss süzgecinin uygulanmasına benzer şekilde 15 derece aralıklarla döndürülerek 12 farklı Gabor süzgeci yapısal elemanı bulunur ve bu yapısal elemanlar kullanılarak ön işlemde geçmiş gri seviye retinal görüntü katlama (konvolusyon) işlemine tabi tutulur. Sonuç olarak farklı yönlerde katlanmış 12 farklı Gabor süzgeç çıktısı elde edilmiş olur. Daha sonra her bir piksel için bu süzgeçlerdeki karşılıklarının maksimum değeri seçilerek çıktı görüntü elde edilmiş olur. Şekil 21'de tez çalışmasında seçilen parametrelerle oluşturulmuş Gabor çekirdek fonksiyonu ve Gabor süzgeci çıktısı verilmektedir.



Şekil 21. ($\sigma=1$ ve $\gamma=0.25$, $\lambda=2\pi\sigma$) parametreleri ile elde edilen Gauss, Kosinüs ve Gabor fonksiyonları (solda) ve retinal görüntünün Gabor süzgeç çıktısı (sağda)

2.2.3. Frangi Süzgeci

Retinal kan damarlarının belirginleştirilmesi için Frangi ve ark. tarafından [29] çalışmasında çok ölçekli bir yaklaşım önerilmiştir. Bu yaklaşım kullanılarak çalışmada kan damarı iyileştirme amacıyla Frangi süzgeci geliştirilmiştir. Yöntemde ilk olarak kan damarı içeren retinal görüntünün kısmi ikinci türev bilgileri kullanılarak Hessian matrisi hesaplanmaktadır. Eşitlik 9’da Hessian matrisin (H) genel denklemi verilmektedir.

$$H = \begin{bmatrix} I_{xx} & I_{xy} \\ I_{yx} & I_{yy} \end{bmatrix} \quad (9)$$

I_{xx} , I_{xy} , I_{yx} ve I_{yy} kısmi türev görüntüleri ön işlemden geçmiş gri seviye görüntünün kısmi ikinci türevlerini göstermektedir. Literatürdeki uygulamalarda bir görüntünün ikinci türevini almak için görüntü, s ölçeğindeki Gauss fonksiyonunun ikinci türevi ile katlama işlemine tabi tutulmaktadır. Bu çalışmada da bu yaklaşım takip edilerek ön işlemden geçirilmiş ve terslenmiş gri seviye görüntünün kısmi ikinci türevleri hesaplanmaktadır.

Kısmi ikinci türev bilgilerinin yer aldığı Hessian matris elde edildikten sonra bu matrisin öz değer analizi yapılmaktadır. Öz değer analizi verinin dağılımındaki değişimleri ifade ettiğinden bu değerler kısmi ikinci türev görüntüsünde kenarlar hakkında bilgiler sunmaktadır. Hessian matris 2×2 boyutlu bir kare matris olduğundan toplamda iki adet öz değere sahip olacaktır. Bu öz değerlere göre bir pikselin kan damarı veya arkaplan üzerinde

olup olmadığı hakkında fikir sahibi olunabilmektedir. Öz değerlerin işaret ve büyüklüklerine göre içerdikleri anlamlar Tablo 2’de verilmektedir.

Tablo 2. Hessian matrisin öz değerlerinin işaret ve büyüklüklerine göre içerdikleri anlamlar

λ_1	λ_2	Yerel Özellik
~ 0	~ 0	Değişim bilgisi yok
K (küçük)	B+ (büyük, pozitif)	damar benzeri (koyu)
K (küçük)	B- (büyük, negatif)	damar benzeri (parlak)
B+ (büyük, pozitif)	B+ (büyük, pozitif)	Köşe (koyu)
B- (büyük, negatif)	B- (büyük, negatif)	Köşe (parlak)

Hessian matrisin öz değerleri bulunduktan sonra bulunan öz değerler $|\lambda_1| < |\lambda_2|$ şeklinde sıralanır ve mutlak değeri büyük olan öz değer λ_2 olarak kabul edilir. Tablo 2’ye göre damar benzeri yapılarda bulunan pikseller için λ_1 küçük ve λ_2 ise negatif yönde büyük değerler almaktadır. Buna göre kan damarların λ_2 ’nin işaretine göre Eşitlik 10’da verilen denklem ile damar olma olasılığını gösteren bir damarlılık değeri $V(s)$ hesaplanmaktadır.

$$V(s) = \begin{cases} 0 & \lambda_2 > 0, \\ \exp\left(-\frac{R_B^2}{2\beta^2}\right)(1 - \exp\left(\frac{S^2}{2c^2}\right)) & \lambda_2 \leq 0, \end{cases} \quad (10)$$


$$R_B = \frac{|\lambda_1|}{|\lambda_2|} \quad (11)$$

$$S = \sqrt{\lambda_1^2 + \lambda_2^2} \quad (12)$$

Burada $V(s)$ değeri, damar olma olasılığını gösteren bir damarlılık değeridir ve s standart sapmasına sahip (ölçek parametresi) Gauss fonksiyonu kullanılarak elde edilmektedir. β ve c değerleri sırasıyla R_B ve S ara değerlerinin hassasiyetlerini ayarlamak için kullanılan parametrelerdir. Uygulamada farklı ölçekler kullanılarak elde edilen tüm $V(s)$ değerlerinin maksimum çıktısı Eşitlik 13’e göre seçilerek belirgin hale getirilmiş damar görüntüsü elde edilmektedir.

$$V = \max_{s_{min} \leq s \leq s_{max}} V(s) \quad (13)$$

Burada ölçek değerleri $s=\{0.5, 0.75, ..., 4\}$ olarak alınmaktadır. Tüm ölçekler için hesaplanan $V(s)$ damarlılık değerlerinin maksimum tepkisi (her piksel için farklı ölçeklerden gelen değerlerin maksimumu) Şekil 22’de verildiği gibi Frangi süzgeç çıktısı olarak elde edilmektedir.



Şekil 22. Frangi süzgeç çıktısı


2.2.4. Gri Seviye Morfolojik Top-hat Dönüşümü

Morfolojik top-hat dönüşümü, bir görüntüde küçük nesneleri ve ayrıntıları ortaya çıkarmak ve görüntü işleme uygulamalarında karışıklık (kontrast) seviyesini arttırmak için kullanılan bir yöntemdir. Orijinal görüntüden gri seviyeli morfolojik açma işlemi uygulanmış görüntünün çıkarılması ile elde edilmektedir. Top-hat dönüşümünün genel denklemi Eşitlik 14’te verilmektedir.

$$TopHat(I) = I - (I \circ nB) \quad (14)$$

Burada I , top-hat dönüşümü uygulanacak görüntüyü, B ise yapısal elemanı göstermektedir. Yapısal elemanın ölçeği olarak kabul edilen n parametresi top-hat dönüşümünün ölçek seviyesini göstermek amacıyla kullanılmaktadır. İkili bir görüntüye n

boyutunda yapısal bir eleman kullanılarak morfolojik açma işlemi (önce aşındırma sonra genişletme) uygulandığında n değerinden küçük ayrıntılar silinecektir. Orijinal görüntüden morfolojik açma işlemi uygulanmış görüntü çıkarıldığında ise geriye sadece morfolojik açma işleminde silinen ayrıntılar kalmaktadır. Bu durum Şekil 23'te verilmektedir.



Şekil 23. Orijinal bir ikili görüntü (solda) ve bu görüntünün $n=5$ çaplı disk biçimli yapısal eleman kullanarak elde edilen top-hat dönüşümü [91].

Top-hat dönüşümü, gri seviye görüntülere uygulandığında seçilen yapısal elemana göre kontrast arttıran bir etki oluşturmaktadır. Kullanılan morfolojik işlemler gri seviye morfolojik işlemlerdir. Uygulanan iki temel morfolojik işlem olan aşındırma (erozyon) ve genişletme (dilasyon) işlemleri ise Eşitlik 15-16'da verilen denkleme göre W penceresinde sırasıyla minimum ve maksimum değerler seçilerek hesaplanmaktadır.

$$\text{aşındırma}(f, W) = \min\{W\{f[x, y]\}\} \quad (15)$$

$$\text{genişletme}(f, W) = \max\{W\{f[x, y]\}\} \quad (16)$$

Morfolojik aşındırma işlemi bir görüntüde nesne olarak ifade edilen alanları azaltır ve varsa görüntüdeki küçük ayrıntıları kaldırır. Morfolojik genişletme işlemi ise aşındırma işleminin tam tersi bir etki oluşturur. Morfolojik açma işlemi önce aşındırma daha sonra da genişletme yaptığından genel olarak nesneler arası bağlantıları koparır ve küçük ayrıntıları kaldırır. Bu çalışmada kullanılan morfolojik top-hat dönüşümü, orijinal görüntüden morfolojik açma uygulanan görüntünün çıkarılmasıyla elde edilmektedir. Böylece açma işleminde elenen ayrıntılar veya küçük nesneler elde edilmektedir.

Seçilecek yapısal elemanın şekil ve büyüklüğüne göre uygulanan Top-hat dönüşümü Gauss, Gabor ya da Frangi süzgeci uygulanarak belirgin hale getirilmiş retinal görüntüdeki

kan damarlarının kontrastını daha da arttırmak için kullanılmaktadır. Burada önemli olan açma işlemi için kullanılacak yapısal elemanın seçim işlemidir. Genellikle yapısal elemanın şekli ve büyüklüğü kullanılacağı probleme göre belirlenmektedir. Medikal görüntülerde dönme işleminden bağımsız olduğu için disk biçimli yapısal elemanlar yaygın olarak kullanıldığından bu çalışmada da disk biçimli yapı elemanları kullanılmaktadır. Seçilmesi gereken bir diğer parametre ise seçilen disk biçimli yapısal elemanın boyutunun ne olması gerektiğidir. Burada ortaya çıkarılması gereken küçük ayrıntılar retinal kan damarlarıdır. Dolayısıyla tüm kan damarlarını kapsayacak şekilde büyük ancak optik disk, makula, arkaplan gibi daha büyük yapısal elemanları kapsamayacak ve kopuk kan damarlarını birleştirmeyecek kadar küçük optimum bir boyut seçilmesi uygun olacaktır. Bu nedenle tez çalışmasında yapısal eleman boyutu olan n değeri 5 olarak ve B ise disk biçimli (yarı çapı 5 piksel) bir yapı elemanı olarak seçilmektedir. Şekil 24'te farklı süzgeçlerden sonra uygulanan morfolojik top-hat dönüşümünün çıktıları verilmektedir.




a) Ön işlenmiş ve terslenmiş görüntü



b) Gauss + Top-hat süzgeç çıktısı



c) Gabor + Top-hat süzgeç çıktısı



d) Frangi + Top-hat süzgeç çıktısı

Şekil 24. Farklı süzgeç çıktılarından sonra uygulanan morfolojik top-hat dönüşüm çıktıları

2.3. Piksel Sınıflandırma Yaklaşımı ile Retinal Kan Damarı Bölütleme

Buraya kadar renkli retinal fundus bir görüntüdeki kan damarlarını bölütleme amacıyla yapılan ön işlemler ve iyileştirme adımları incelenmiştir. Retinal kan damarı bölütleme işlemi, görüntüdeki piksellerin damar ya da retina arkaplanına ait olup olmadığının belirlenmesi işlemidir. Bu karar bir çeşit ikili sınıflandırma problemidir. Örneğin belli bir eşik değeri kullanıldığında, piksel parlaklığı bu eşik değerinin üzerinde kalan pikseller beyaz ve parlaklık değeri küçük olan pikseller ise siyah olarak işaretlenebilmektedir. Basit anlamda ortada bir karar verme işlemi olduğundan ve verilen her karar bir çeşit sınıflandırma

olduğundan bu çalışmada kan damarı bölütleme işlemleri piksel sınıflandırma başlığı altında incelenecektir. Ayrıca ön işlemlerden sonra kan damarı ve arkaplanı ayırt edecek şekilde yapılan damar iyileştirme, dönüşüm vb. işlemler de sınıflandırma probleminin öznelilik çıkarma adımı olarak isimlendirilebilmektedir.


Kan damarı bölütleme işlemleri, bu çalışmada basitçe üç alt başlıkta incelenmektedir:

1) belli bir kurala göre oluşturulan eşik değeri kullanılarak sınıflandırma, 2) herhangi bir gözetmen müdahalesi olmadan (önceki bilgilerden bir gözetmen yardımıyla öğrenme işlemi olmadan) yapılan denetimsiz (gözetimsiz) sınıflandırma işlemi, 3) uzman bir denetçi gözetiminde öğrenme işlemi yapılarak gerçekleştirilen sınıflandırma.

2.4. Kural Tabanlı Piksel Sınıflandırma


2.4.1. Otsu Eşikleme Yöntemi

Önceki bölümlerde ön işlemler ve damar iyileştirme adımları ile kan damarlarının arkaplana göre nasıl daha belirgin hale getirildiği açıklanmıştır. Bu bölümde Otsu ve ark. [14] tarafından önerilen gri seviye bir görüntüde histogram değerleri kullanılarak en uygun dinamik eşik belirleme yöntemi kullanılmaktadır. Otsu eşikleme yönteminde, sınıflararası (bu çalışmada damar ve arkaplan) varyans (değişinti) farkını maksimum ve sınıf içi varyansı minimum yapacak şekilde bir eşik değeri belirlenmektedir. Kan damarı belirginleştirme adımında gri seviye morfolojik top-hat dönüşümü ile kan damarları belirgin hale getirilmişti. Parlaklık histogram grafiği çıkarıldığında arkaplan piksellerinin parlaklık değerleri minimuma ve damar piksellerinin parlaklık değerlerinin maksimuma doğru sıralandığı gözlenmektedir. Morfolojik top-hat dönüşümünden sonra elde edilen kan damarları belirginleştirilmiş retinal görüntünün parlaklık histogram eğrisi Şekil 25'te verilmektedir.



Şekil 25. Belirginleştirilmiş kan damarı görüntüsünün histogram grafiği


Histogram eğrisinin sağ tarafı kan damarlarını ve sol tarafı ise retina arkaplanını gösterdiğinden ideal bir eşik bulunduğu retinal kan damarları çıkarılmış olmaktadır. Olası tüm eşik değerleri teker teker denendiğinde Şekil 26'daki gibi bir ROC eğrisi [92] elde edilmektedir. Buna göre bulunacak en uygun eşik ile hesaplanabilecek maksimum doğruluk değeri %96,49 ve ROC eğrisi altında kalan alan 0,9875 olmaktadır. İkili sınıflandırma problemlerinde ideal olarak elde edilecek maksimum doğruluk %100 ve ROC eğrisi altında kalan alan 1 olmalıdır. İkili sınıflandırmada bu değerlere mümkün olduğunca yaklaşarak uygun çözüm bulunması amaçlanır. Tez çalışmasının bu bölümünde amaç, ideal çözüme yakın uygun eşik değerinin bulunmasıdır. Bu nedenle ideal eşik değeri Otsu yöntemi ile araştırılmaktadır.




Şekil 26. Belirginleştirilmiş kan damarı görüntüsüne olası tüm eşiklerin uygulanması sonucu elde edilen ROC eğrisi

Otsu eşikleme yöntemi retinal kan damarı bölütleme problemine iki farklı şekilde uygulanmaktadır. İlk olarak; histogram grafiği dikkate alındığında kan damarı çıkarma problemi ikili sınıflandırma (damar ya da arkaplan) olarak ele alınmaktadır. Bu durumda Otsu yöntemi ile tek bir eşik belirlenerek bu eşik altında kalan pikseller arkaplan olarak ve bu eşik üstünde kalan alanlar ise kan damarı olarak etiketlenmektedir. İkinci olarak

belirginleştirilmiş kan damarı görüntüsünde çok seviyeli (kalın damarlar, ince damarlar ve arkaplan) Otsu yöntemi uygulanarak retinal kan damarları belirlenmektedir. Bu durumda gri seviye görüntünün histogram grafiği 3 farklı bölgeye (sınıf) ayrılmaktadır ve iki farklı eşik değeri bulunmaktadır. Daha sonra kalın ve ince damar pikselleri birleştirilerek nihai ikili damar görüntüsü elde edilmektedir. Histogram grafiklerinde Otsu yöntemiyle tek eşik seçilerek iki seviyeli kan damarlarının etiketlenmesi işlemi Şekil 27’de ve iki eşik seçilerek üç seviyeli kan damarlarının etiketlenmesi işlemi Şekil 28’de verilmektedir.




Şekil 27. Otsu yöntemi ile tek eşik seçilerek iki seviyeli kan damarı bölütleme



Şekil 28. Otsu yöntemi ile iki eşik seçilerek üç seviyeli kan damarı bölütleme

Literatürde genel olarak histogram grafiği üzerinden tek eşik belirlenerek iki görüntü elde edilmektedir. Uygulamada ise daha yüksek seviyeden (4 seviyeli, 5 seviyeli ...) eşikleme işlemleri de yapılmış ancak seviye sayısı arttıkça daha iyi sonuçlar elde edilememiştir. En iyi ve kullanılabilir sonuçlar üç seviyeli eşikleme yöntemleri ile elde edilmiştir. Bu yöntemlerle elde edilen terslenmiş ikili bir damar görüntüleri Şekil 29’da

verilmektedir. Şekilden de görüldüğü gibi seviye sayısı üç olarak seçildiğinde eşik değerleri daha hassas belirlenmekte ve histogram grafiği üzerindeki kan damarları ile arkaplan arasındaki geçiş ince damarları da dikkate alacak şekilde sonuç elde edilmektedir.



Şekil 29. İki sınıflı Otsu (solda) ve üç sınıflı Otsu yöntemleri ile elde edilen ikili damar görüntüleri


2.4.2. Yüzdeli (p-tile) Eşikleme Yöntemi

Yüzdeli eşikleme (p-tile) yöntemi, verilen bir p değerine göre eşik oluşturma işlemine dayanmaktadır. Bunun için öncelikle görüntünün histogramı çıkarılmaktadır. Histogram eğrisi altında kalan alan öyle bir eşik değeri ile bölünmelidir ki eşik değerinin üzerinde kalan alan, toplam alanın yüzde p 'si kadar olmalıdır. Bu şartları sağlayan T eşik değeri ikili dönüşüm için kullanılmaktadır. Bu durum Şekil 30'da ve Eşitlik 17'de görülmektedir. A ve B değerleri histogram değerlerinin altında kalan alanı göstermek üzere:


$$T = \frac{B}{A+B} \quad (17)$$

Uygulamada retinal kan damarları ortalama olarak tüm görüntünün %8-12 lik bir kısmını oluşturduklarından p değeri %8 ile %12 arasında optimum bir değer olarak seçilmektedir. Tez çalışmasında kullanılan STARE veritabanındanki manuel olarak etiketlenmiş görüntülerdeki kan damarları piksellerinin tüm piksellere oranı dikkate alınarak

$p=0.09$ (%9) olarak alınmış ve bu parametre ile elde edilen ikili damar görüntüsü Şekil 31’de verilmiştir.




Şekil 30. Yüzdeli eşikleme yöntemi için kullanılan parametrelerin gösterimi



Şekil 31. Yüzdeli eşikleme ile elde edilen ikili kan damarı görüntüsü

2.5. Denetimsiz Sınıflandırma

Denetimsiz sınıflandırma yöntemleri literatürde daha çok kümeleme (öbekleme) yöntemleri olarak bilinirler. Sınıflandırma işlemi herhangi bir denetçi tarafından kontrol edilen bir öğrenme işlemi gerektirmez. Kümele yapmak için verinin istatistiksel dağılımı dikkate alınarak denetimsiz bir eğitim işlemi yapılmaktadır. Genel olarak katı kümeleme ve bulanık kümeleme olmak üzere iki kategoride incelenmektedirler. En çok bilinen kümeleme yöntemleri K-ortalama (katı kümeleme) ve Bulanık C-ortalama (esnek kümeleme) gibi yöntemlerdir. Retinal görüntülerde kan damarları iyileştirildikten sonra her bir piksel parlaklık dağılımına göre damar ya da arkaplan olarak sınıflandırılabilir. Şekil 32’de tez çalışmasında kan damarı çıkarmak için uygulanan denetimsiz sınıflandırma (kümeleme) yöntemlerinin genel akış şemasını vermektedir. Şekilde ilk olarak giriş olarak alınan renkli retinal görüntüye önceki bölümde açıklanan ön işlemler uygulanmaktadır. Daha sonra öz nitelik çıkarma adımı kan damarı belirginleştirme süzgeçlerinin (Gauss, Gabor ya da Frangi) ardından gri seviye morfolojik top-hat dönüşümü uygulanmaktadır. Sınıflandırma aşamasında kümeleme yöntemleri (K-ortalama veya Bulanık C-ortalama (BCO)) ile ikili damar görüntüsü elde edildikten sonra son işlemler adımı istenmeyen gürültüler elenerek nihai ikili kan damarı görüntüsü elde edilmektedir.



Şekil 32. Çalışmada uygulanan denetimsiz sınıflandırma (kümeleme) yöntemlerinin genel akış şeması


2.5.1. K-ortalama Kümele Yöntemi

K-ortalama yöntemi ilk olarak kümeleme problemlerinin çözümü için MacQueen tarafından 1967 yılında önerilmiştir [93]. K-ortalama kümeleme algoritması görüntü üzerindeki pikselleri istatistiki olarak sınıflandıran denetimsiz bir sınıflandırma yöntemidir. Bu yöntemde görüntüdeki piksellerin kümeyle ait olma değerleri kesinlik anlamı taşıdığından (kümeyle aittir veya değildir) katı kümeleme olarak kabul edilir. Yönteme adını veren K değeri, giriş görüntüsünde kaç adet bölge (veya sınıf) olduğunu temsil eden parametre değeridir.

K-ortalama yönteminin çalışması aşağıdaki gibidir:

- K adet başlangıç küme merkezi noktası (centroid) oluşturulur. K noktanın seçilmesi için iki yaklaşım kullanılmaktadır. Birinci yaklaşım sınıflandırılacak örneklerin ilk K tanesi küme merkezi noktası olarak seçilir. İkinci yaklaşım ise bu noktaların tamamen rastgele seçilmesidir. Yöntemde varsayılan olarak ilk K örneğin küme merkezi noktası olarak seçilmesi tercih edilmiştir.
- Her bir örnek en yakın merkezi noktaya atanır. Uzaklık ölçütü olarak öklit uzaklığı kullanılmaktadır.
- Her bir kümedeki örneklerin ortalaması yeniden hesaplanır ve küme merkezi noktaları hesaplanan bu yeni noktalara kaydırılır.
- Sistem kararlı hale gelmediyse 2. adıma gidilir (sistemin kararlı hale gelmesi, hata değerinin belli bir eşik değerinin altında olması ile mümkündür). Sistem kararlı hale geldiyse kümeleme işlemi sonlandırılır.


Yukarıda açıklanan K -ortalama kümeleme yönteminin basitçe adım adım nasıl çalıştığını göstermektedir. Bu yöntemin retinal kan damarı bölütleme işlemine uygulanması ise şu şekildedir: Öncelikle retinal fundus görüntüler, kan damarı belirginleştirme işleminden geçirildikten sonra kan damarlarının belirgin hale geldiği bir görüntü elde edilir. Bu aşamada Gauss, Gabor ya da Frengi süzgecinden sonra gri seviye morfolojik top-hat dönüşümü uygulanmaktadır. Dönüşüm sonucu, kan damarı bölütleme amacıyla K -ortalama yöntemine verilir. Küme sayısı olan parametre değeri $K=3$ olarak seçilmektedir. Yani görüntü 3 farklı kümeye ayrılmaktadır. Bu kümeler, damar olma olasılığı yüksek olan bölgeler (1. küme), damar olma olasılığı orta derecede olan bölgeler (damar ile arkaplan arasındaki geçiş bölgeleri, 2. küme) ve arkaplan (3. küme) şeklinde olmaktadır. Şekil 33'te 3 bölgeli K -ortalama yönteminden elde edilen görüntü verilmektedir. Son aşamada damar olma olasılığı bulunan tüm pikseller (1. ve 2. kümeler) damar olarak işaretlenerek ikili damar görüntüsü elde edilmektedir.



Şekil 33. K-ortalama yöntemi uygulanarak elde edilen 3 bölge damar görüntüsü (solda) ve ikili damar görüntüsü (sağda)

2.5.2. Bulanık C-ortalama Kümeleme Yöntemi

K-ortalama algoritması, kümeleme yöntemleri arasında katı-kümeleme (hard clustering) olarak anılmaktadır. Katı-kümeleme yöntemlerinde her bir örnek sadece bir kümeye ait olabilmektedir. Bulanık C-ortalama (BCO) algoritması ise esnek-kümeleme (soft-clustering) olarak kabul edilir ve kümeleme algoritmalarının genelleştirilmiş hali olarak bilinir. Bulanık kümeleme algoritmalarında bir örneğin farklı kümelerle ait olma dereceleri söz konusudur. Örneğin verilen bir örnek %70 bir kümeye ait olabilirken %30 başka bir kümeye üyelik değeri bulunabilmektedir. Son aşamada bir örneğin ait olduğu kümeye karar verirken hangi kümede maksimum üyeliğe sahipse örnek o kümedendir şeklinde karar verilir. Şekil 34'te bu durum 3 farklı kümeye ait üyelik fonksiyonlarını ve son durumda maksimum üyelik değerlerine göre ait oldukları kümelerin gösterimi verilmektedir. Bulanık C-ortalama yöntemindeki C değeri küme sayısını temsil etmektedir.



Şekil 34. 3 farklı kümeye ait üyelik fonksiyonları ve ait oldukları kümelerin gösterimi


BCO algoritmasının genel akışı aşağıdaki şekildedir:

- Başlangıç değerleri ayarlanır.
- Küme sayısı (C) ayarlanır ve n adet örnekler elde edilir, m (üstel ağırlık faktörü) ayarlanır.
- $U(0)$ üyelik matrisi rastgele değerler verilerek ayarlanır. U matrisi C satır, n sütundan oluşan ($C \times n$ boyutlu) bir üyelik matrisidir ve her bir örneğin her bir kümedeki üyelik değerlerini tutmaktadır. u_{ik} ise bu matristeki bir elemanı tutar ve i . kümedeki k . örneğin üyelik değerini temsil etmektedir.
- İterasyon için tutulan sayaç başlangıç değerine ayarlanır ($t=0$).
- Her bir küme için V_t küme merkezleri hesap edilir.
- Bir sonraki üyelik değerleri matrisi hesaplanır ($U(t+1)$).
- Sistemin hata değeri belli bir eşiğin altına düştüğünde sistem kararlı hale gelmiş demektir ve kümeleme işlemi sonlandırılır, aksi durumda 2. adıma gidilir.

$$V_i = \frac{\sum_{k=1}^n u_{ik}^m x_k}{\sum_{k=1}^n u_{ik}^m}, i = 1, 2, 3, \dots, c \quad (18)$$

$$u_{ik} = \frac{\left[\frac{1}{(x_k - v_i)^2} \right]^{\frac{1}{m-1}}}{\sum_{j=1}^c \left[\frac{1}{(x_k - v_j)^2} \right]^{\frac{1}{m-1}}}, i = 1, 2, 3, \dots, c; \text{ ve } k = 1, 2, 3, \dots, n \quad (19)$$

Bulanık C-ortalama yöntemi ile kan damarı bölütleme yöntemi K-ortalama yöntemi ile benzer şekilde gerçekleştirilmektedir. İlk olarak retinal fundus görüntülere ön işlemlerden sonra öznelilik çıkarma amacıyla kan damarı belirginleştirme adımları uygulanmaktadır. Daha sonra gri seviye morfolojik top-hat dönüşüm işlemi ile damar belirginleştirme adımı tamamlanmaktadır. Top-hat dönüşüm sonucunda elde edilen kan damarı görüntüleri Bulanık C-ortalama yöntemi ile kümeleme işlemine tabi tutulur. Kümeleme yönteminde görüntüdeki küme sayısı C değeri 3 olarak ayarlanır. Bu kümeler, damar olma olasılığı yüksek olan bölgeler (1. küme), damar olma olasılığı orta derecede olan bölgeler (damar ile arkaplan arasındaki geçiş bölgeleri, 2. küme) ve arkaplan (3. küme) şeklinde olmaktadır. Şekil 35'te 3 bölgeyi Bulanık C Ortalama yönteminden elde edilen görüntü verilmektedir. Son aşamada damar olma olasılığı bulunan tüm pikseller (1. ve 2. kümeler) damar olarak işaretlenerek ikili damar görüntüsü elde edilmektedir. Şekilden de görüldüğü gibi Bulanık C ortalama yöntemi problemde üyelik değerlerini dikkate alarak kümeleme yaptığından K-ortalama yöntemine göre daha hassas sonuçlar sunmaktadır.




Şekil 35. Bulanık C Ortalama yöntemi uygulanarak elde edilen 3 bölgeyi damar görüntüsü (solda) ve ikili damar görüntüsü (sağda)

2.6. Denetimli Sınıflandırma

Denetimli sınıflandırma yöntemleri genellikle verinin bir kısmını kullanarak bir denetçi gözetiminde eğitim işlemi gerçekleştirmektedir. Eğitim verisinden örüntünün sahip olduğu model öğrenilerek test verisinin sınıflandırılması ilkesine dayanmaktadır. Retinal kan damarlarının bölütlenmesi probleminde bir pikselin daha önceden damar veya arkaplan olduğu bir uzman tarafından etiketlenen veriler kullanılarak ikili sınıflandırma gerçekleştirilmektedir. Literatürde ağırlıklı olarak istatistiksel sınıflandırma yöntemleri kullanılmaktadır ve yöntemler genel olarak makine öğrenmesi olarak da anılmaktadır. Bu çalışmada denetimli sınıflandırma yöntemleri olarak aynı veya farklı öz nitelikleri kullanan Doğrusal Ayraç Analizi Sınıflandırıcı (DAA), En Yakın K Komşu Sınıflandırıcı (EYKK), Naif Bayes Sınıflandırıcı (NBS), Destek Vektör Makineleri (DVM) ve Yapay Sinir Ağları Sınıflandırıcı (YSA) yöntemleri kullanılmaktadır.

Şekil 36'da denetimli sınıflandırma yöntemlerinin genel akış şeması verilmektedir. Buna göre bir uzman tarafından etiketlenmiş ve öğrenilmek için hazır olan eğitim verisi sınıflandırıcıya sunularak eğitim verisinden bir model oluşturulmaktadır. Daha sonra gerçekte sınıflandırılacak olan test verisi sınıflandırıcıya sunularak ve daha önceden öğrenilmiş model kullanılarak verinin hangi sınıftan olduğu belirlenmektedir. Bu işlem tahmin etme (test) adımı olarak isimlendirilmektedir. Uygulamalarda genellikle iki ya da daha çok sınıf olabildiğinden ikili ya da çoklu sınıflandırma işlemleri uygulanabilmektedir. Bu çalışmada ise kan damarı ya da arkaplan olmak üzere ikili sınıflandırma gerçekleştirilmektedir.



Şekil 36. Denetimli sınıflandırma yöntemlerinin genel akış şeması

2.6.1. Öznitelik Çıkarma İşlemi

Öznitelik çıkarma işlemi retinal görüntüde kan damarları ve arkaplanı piksellerini ayırt edecek şekilde ham veriden kullanılabilir sayısal ya da kategorik bilginin çıkarılması işlemidir. Bir başka deyişle çok boyutlu ham verinin boyutunun azaltılarak karmaşık sınıflandırma problemlerinin daha anlaşılır hale getirilmesi işlemidir. Görüntü işleme, makine öğrenimi, örüntü tanıma gibi uygulamalarda sınıflandırma işleminden önce uygulanmaktadır. Bu çalışmada retinal kan damarları çıkarmak amacıyla üç farklı kategoride öznitelik çıkarma işlemi uygulanmaktadır: 1) Renkli görüntünün renk bileşenleri kullanılarak öznitelik çıkarma, 2) Damar belirginleştirilmiş görüntüdeki istatistiksel değerler kullanılarak öznitelik çıkarma, 3) Kan damarı belirginleştirmesine dayalı öznitelik çıkarma. Sonraki bölümlerde bu özniteliklerin nasıl çıkarıldığına değinilmektedir.

2.6.1.1. Renk Bileşenlerine Dayalı Öznitelik Çıkarma

Renk tabanlı öznitelikler bir pikselin kırmızı (K), yeşil (Y) ve mavi (M) renk bileşenleri kullanılarak elde edilen özelliklerdir. Bu kısımda 6 adet renk bileşenlerine dayalı öznitelik kullanılmaktadır. Bunlar:

- K : Pikselin kırmızı renk bileşeni,
- Y : Pikselin yeşil renk bileşeni,
- M : Pikselin mavi renk bileşeni,
- |K-Y| : Pikselin kırmızı ve yeşil renkler arasındaki seviye farkı,
- |K-M| : Pikselin kırmızı ve mavi renkler arasındaki seviye farkı,
- |Y-M| : Pikselin mavi ve yeşil renkler arasındaki seviye farkı

Bu öznitelikler kullanılarak elde edilen bölütlenmiş damar görüntüleri sonuç bölümünde verilmektedir.

2.6.1.2. İstatistiksel Öznitelik Çıkarma

Parlaklık değerine dayalı istatistiksel öznitelikler, renkli görüntünün ön işlemde geçirilmiş halinden elde edilen istatistiksel özniteliklerdir. Görüntü üzerinde belli bir boyutta gezdirilen pencere içerisinde bulunan bölgeden hesap edilen minimum piksel değeri, maksimum piksel değeri, ortalama değeri, bu pencerede bulunan piksellerin standart sapması gibi değerler kullanılmaktadır. Çıkarılan 5 adet öznitelik Eşitlik 20-24'te verilmektedir.

$$f_1(x, y) = P(x, y) - \underset{(s,t) \in S^9_{x,y}}{\text{minimum}}\{P(s, t)\} \quad (20)$$

$$f_2(x, y) = \underset{(s,t) \in S^9_{x,y}}{\text{maksimum}}\{P(s, t)\} - P(x, y) \quad (21)$$

$$f_3(x, y) = P(x, y) - \underset{(s,t) \in S^9_{x,y}}{\text{ortalama}}\{P(x, y)\} \quad (22)$$

$$f_4(x, y) = \underset{(s,t) \in S^9_{x,y}}{\text{ssapma}}\{P(s, t)\} \quad (23)$$

$$f_5(x, y) = P(x, y) \quad (24)$$

Burada S değeri w boyutunda ve x, y noktasında merkezlenen pencere bölgesi anlamındadır. Uygulamada $w=9$ olarak seçilmiştir. Bu öznitelikler kullanılarak elde edilen bölütlenmiş damar görüntüleri sonuç bölümünde verilmektedir.

2.6.1.3. Damar Belirginleştirme Yöntemlerine Dayalı Öznitelik Çıkarma

Retinal kan damarlarını arkaplandan ayırt edecek şekilde görsel olarak iyileştirilmesi adımları önceki bölümde anlatılmıştı. Bu bölümde iyileştirilmiş damar görüntülerinin öznitelik olarak nasıl kullanıldığına değinilecektir.

Gauss, Gabor veya Frangi süzgeçlerinden geçen gri seviye retinal fundus görüntüler damarların daha da belirgin hale gelmesi için gri seviye morfolojik top-hat dönüşümü uygulanmaktadır. Tüm bu işlemlerin sonucunda elde edilen damar görüntüsü gri seviye değerli bir görüntüdür. Öz nitelik olarak bu görüntülerin parlaklık değerleri alınmaktadır.

2.6.2. Sınıflandırma Yöntemleri

2.6.2.1. Doğrusal Ayıraç Analizi Sınıflandırıcı (DAA)

Doğrusal Ayıraç Analizi (DAA) sınıflandırıcı literatürde sınıflandırma problemlerinde ya da sınıflandırma öncesi öz nitelik boyut azaltma gibi problemlerin çözümünde kullanılan bir yöntemdir. Sınıflandırma ya da boyut azaltmada Fisher tarafından 1936 yılında önerilen bir doğrusal ayıraç fonksiyonu kullanır [94]. Örüntülerin (bu problemde damar ve retina arkaplanı) öznitelik uzayında birbirinden doğrusal olarak ayırt edilebilmesi ilkesine göre sınıflandırma yapılır. Problemin çözümü de sınıfları ayıran bu doğrunun ya da hiperdüzlemin bulunmasına karşılık gelmektedir. Bir boyut azaltma yöntemi olan Temel Bileşen analizi yöntemi ile benzerlik göstermesine karşın Doğrusal Ayıraç Analizi Sınıflandırıcı farklı olarak sınıf bilgisini de dikkate almaktadır. Ayıraç tabanlı doğrusal sınıflandırma yönteminde damar ya da retina arkaplanından oluşan iki sınıfı birbirinden ayıran hiperdüzlem, bir denetmenin etiketlediği eğitim verisi kullanarak hesaplanmaktadır. Sınıflandırma yapılırken eğitim verisindeki sınıfların sınıflar arası varyansı maksimum ve sınıflar içi varyansı minimum yapacak şekilde bir hiperdüzlem bulunur. Doğrusal sınıflandırıcı modeli için kullanılan amaç fonksiyon Eşitlik 25'te verilmiştir.


$$A(w) = \frac{w^t S_B w}{w^T S_w w} \quad (25)$$

Burada S_B , sınıflar arası varyansı içeren dağılım matrisini, S_w , sınıf içi varyansı içeren dağılım matrisini ve w ise sınıfları birbirinden ayıran hiperdüzlemin normal vektörünü ifade etmektedir. Dağılım matrisleri Eşitlik 26-27’de verilen denklemler ile hesaplanmaktadır.

$$S_B = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^T \quad (26)$$

$$S_w = \sum_{i=1}^C \sum_{x \in D_i} (x - \mu_i)(x - \mu_i)^T \quad (27)$$


Burada μ_1 ve μ_2 sırasıyla birinci ve ikinci sınıfta bulunan örneklerin ortalama değerlerini C ise sınıf sayısını ($C=2$) göstermektedir. Problemin çözümü Eşitlik 25’te verilen A amaç fonksiyonunu maksimum yapacak şekilde w kat sayılarını bulunmasıdır. Katsayılar bulunduğundan sonra test edilecek x öz nitelik vektörü w katsayıları ile çarpılarak ayrıştırma fonksiyonu oluşturulur. Daha sonra $y = w^T x$ ayrıştırma fonksiyonunun işaretine göre x örneğinin sınıfına karar verilir. Şekil 37’de örnek olarak birbirinden lineer olarak ayrılabilen ve 2 sınıfa ait örnekler temsili olarak verilmektedir.



Şekil 37. Doğrusal Ayırtaç Analizi (DAA) sınıflandırıcı yönteminin temsili gösterimi

2.6.2.2. En Yakın K Komşu Sınıflandırıcı (EYKK)

En yakın k komşu sınıflandırıcı, sınıfı belirlenecek örneklerin eğitim kümesindeki örneklere yakınlıkları hesap edilerek sınıflandırma yapan bir yöntemdir. Burada sınıfı belirlenecek örneğin en yakın k adet komşusuna bakılır. Bu komşulardan her birinin sınıfına göre hangi sınıftan en fazla örnek olduğuna bakılarak aday örneğin sınıfına karar verilir. Bu yöntemde parametre olarak k değerinin kaç olduğu ve nasıl belirlendiği en önemli unsurdur. Ayrıca örneklerin birbirine yakınlıkları hesap edilirken kullanılan uzaklık ölçütü de yöntemin bir diğer parametresidir. Genellikle uzaklık ölçütü olarak öklit uzaklığı kullanıldığından bu çalışmada da öklit uzaklığı tercih edilmiştir. k değeri ikili sınıflandırma (kan damarı veya arkaplan) için tek sayı olarak seçilmelidir. En yakın k komşu yönteminin performansı k değerine ve eğitim kümesindeki örnek sayısına bağlıdır. Burada k değeri belirlenirken 1 ile 19 arası tek sayılar teker teker denenmiş ve en uygun k değerinin 11 olduğu gözlenmiştir. Uzaklık ölçütü olarak öklit uzaklık ölçütü alınmıştır. Şekil 38, En Yakın k Komşular (EYKK) yönteminin temsili çalışmasını anlatmaktadır.



Şekil 38. En Yakın k Komşular (EYKK) yönteminin temsili çalışmasını anlatan grafik

2.6.2.3. Naif Bayes Sınıflandırıcı (NBS)

Naif Bayes Sınıflandırıcı (NBS) yöntemi örüntü tanıma, nesne sınıflandırma, veri madenciliği vb. alanlarda kullanılan yaygın bir sınıflandırma yöntemidir. Algoritma, Bayes teoreminin bağımsızlık ilkesine ve olasılık teorisinde koşullu olasılık bağıntısını kullanarak oluşturulan eşitliğe dayanır. Bu bağıntı Eşitlik 28'de verilmektedir.

$$P(C_k|x) = \frac{P(C_k)*P(x|C_k)}{P(x)} \quad (28)$$

Burada C_k sınıf bilgisini (damar veya retina arkaplanı), x ise eğitim kümesindeki öz nitelikleri (bilinen örnekler) temsil etmektedir. Retinal kan damarı tespiti probleminde 2 sınıf olduğundan $k=1$ ve 2 değerlerini almaktadır. Naif (Basit) Bayes sınıflandırıcıda kullanılan öz niteliklerin bağımsız öz nitelikler olduğu kabul edilmektedir. Sırasıyla eşitlikteki her bir terimin anlamları şu şekildedir:

- **$P(C_k | x)$:** x öz niteliğinin bilinmesi koşulunda C_k sınıfının var olma olasılığıdır. Hesap edilmesi gereken bu olasılıktır. Her bir sınıf için bu olasılık değeri hesap edilerek sınıflandırma problemine çözüm getirilir. Bu olasılıktan söz ederken “ x öz niteliğinin bilinmesi durumunda retinal damar sınıfının olasılığı”, ya da “ x öz niteliğinin bilinmesi durumunda retinal arkaplan sınıfının olasılığı” hesap edilmektedir.
- **$P(x)$:** x öz niteliğinin önsel olasılığıdır. Bir çeşit normalizasyon işlevi görmektedir. Genellikle sınıflandırma işleminde maksimum koşullu olasılık seçileceğinden ve her olasılık hesabında bu değer aynı olacağından kullanılmasına gerek duyulmamaktadır.
- **$P(C_k)$:** C_k sınıfının önsel olasılığıdır. Eğitim kümesindeki örneklerle bakılarak C_k sınıfının önsel olasılığı hesaplanmaktadır.
- **$P(x | C_k)$:** C_k sınıfı bilindiğinde x öz niteliğinin olasılığıdır. Problemde öz niteliklerin birbirinden bağımsız olduğu düşünüldüğünde bu olasılığı hesaplamak için her bir öz niteliğin ayrı ayrı koşullu olasılıklarının çarpılması ile hesap edilebilmektedir.

Retinal kan damarı bölütleme probleminde damar ve arkaplan olarak 2 sınıf olduğundan her biri için Eşitlik 29-31’deki gibi iki ayrı koşullu olasılık değeri hesap edilmektedir. Verilen örneğin hangi sınıfa ait olduğunu her bir sınıf için hesaplanan koşullu olasılıklardan hangisinin maksimum olasılığı verdiğine bakarak karar verilmektedir.

Burada C test örneğinin maksimum olasılığa göre karar verildiği sınıfı, C_1 ve C_2 ise sırasıyla damar ve arkaplan sınıflarını temsil etmektedir.

$$P(C_1|x) = \frac{P(C_1)*P(x|C_1)}{P(x)} \quad (29)$$


$$P(C_2|x) = \frac{P(C_2)*P(x|C_2)}{P(x)} \quad (30)$$

$$Sınıf(C) = \begin{cases} 1, & P(C_1|x) > P(C_2|x) \\ 2, & P(C_2|x) > P(C_1|x) \end{cases} \quad (31)$$

Hesap edilen koşullu olasılık değerlerinden en büyük olanı Eşitlik 31'e göre karar verilir.

2.6.2.4. Destek Vektör Makineleri (DVM)

Destek Vektör Makineleri (DVM) sınıflandırma yöntemi, Vapnik ve ark. tarafından ortaya atılan ve ikili sınıflandırma için kullanılan denetimli bir yöntemdir [95],[96]. Yöntemde eğitim verileri kullanılarak iki sınıfı birbirinden en uygun ayıracak hiperdüzlemin bulunması amaçlanmaktadır. Hiperdüzlemin (öz nitelik sayısına göre doğru da olabilir) bir tarafında pozitif örnekler, diğer tarafında negatif örnekler olacak şekilde sınıflar arasındaki uzaklık mümkün olduğunca maksimum yapılmaya çalışılır. Bir başka deyişle iki sınıfı birbirinden ayıran çok sayıdaki hiperdüzlem arasından sınıflar arasındaki uzaklığı maksimum yapan hiperdüzlem seçilmektedir.



Şekil 39. Destek Vektör Makineleri (DVM) yönteminde örnekleri ayıran hiperdüzlem ve destek vektörleri

Şekilde verilen ayırıcı düzlem $y = w^t x$ denklemi ile ifade edilebilir. Burada w , örnekleri birbirinden ayıran düzlemin normal vektörü, x veri kümesindeki her bir örneği temsil eden bağımsız değişken ve b ise oluşan doğrusal denklemin öteleme değeridir.

Sınıflandırma probleminde eğitim verisi kullanılarak w katsayıları bulunmaya çalışılır, öyle ki pozitif örnekler için $w^t x + b \leq 1$ ve negatif örnekler için $w^t x + b \leq -1$ olması sağlanmalıdır. Burada destek vektörleri, örnekleri birbirinden ayıran hiperdüzlemin örnekler arasındaki uzaklığı maksimum tutmasını garanti etmektedir. Bu durum aşağıdaki Eşitlik 32’de verilmektedir.

$$y_i(w x_i + b) - 1 \geq 0, \quad i = 1, 2, 3, \dots, n \quad \text{ve } x_i \in R^d, y_i \in \{-1, 1\} \quad (32)$$


Burada n değeri eğitim verisindeki örnek sayısı, x_i eğitim verisindeki d boyutlu öz nitelik vektörü y_i , vektörün sınıfını ve b ise bağıl konum değerini göstermektedir.

Eğitim örnekleri kullanılarak w ve b vektörleri bulunduğundan sonra test örnekleri $y = w^t x$ denkleminde yerine yazılır ve $y > 0$ sonucunu doğuran test örnekleri pozitif sınıf olarak, $y < 0$ sonucunu doğuran test örnekleri ise negatif sınıf olarak etiketlenir.

Retinal kan damarı bölütleme probleminde kullanılan öz nitelikler genel olarak doğrusal karakteristikte ve birbirinden doğrusal bir hiperdüzlemle ayırt edilebildiği kabul edildiğinden çekirdek fonksiyonu olarak doğrusal çekirdek fonksiyonu kullanılmıştır.

2.6.2.5. Yapay Sinir Ağları Sınıflandırıcı (YSA)

Yapay Sinir Ağları (YSA), insan beynindeki sinir hücrelerinin (nöron) çalışmasının model alınarak geliştirildiği ve yaygın kullanılan denetimli bir makine öğrenme yöntemidir. Bu çalışmada belirli öz nitelikler çıkarıldıktan sonra retinal fundus görüntülerdeki kan damarları ve arkaplan piksellerini birbirinden ayırt etmek için kullanılmaktadır. İnsan beynindeki bir sinir hücresine benzer şekilde sinir hücreleri arasında bağlantılar mevcuttur. Bu bağlantıların her birinin belirli kat sayıları mevcuttur. Öğrenme işlemi bu kat sayıların belirlenmesi işlemine karşılık gelmektedir. Bir yapay sinir ağı hücresinin genel (perseptron) yapısı Şekil 40’ta verilmektedir. Buna göre bir yapay sinir ağı hücresinde n adet giriş (x_i) ve her bir girişin n adet katsayısı (w_i) bulunmaktadır. Katsayılar ve giriş değerleri çarpılıp toplanarak bir $f(x_i, w_i)$ aktivasyon fonksiyonundan geçirilmektedir. Aktivasyon fonksiyonunun değeri çıktıya verilerek bir sonraki sinir ya da sinirlerin girişi ya da doğrudan yapay sinir ağının çıkışı olabilmektedir.




Şekil 40. Basit bir sinir hücresinin (perseptron) yapısı

Yapay Sinir Ağları genel olarak iki alt kategoride incelenmektedir:

- Tek Katmanlı Yapay Sinir Ağları (TK-YSA): Sadece girdi ve çıktı katmanları bulunan ağlardır. Yapısında bir ya da daha fazla eğitilebilen sinir hücresi (perseptron) bulunabilir. Bir perseptronda ağırlıklandırılmış girdi değerleri aktivasyon fonksiyonuna uygulanır ve çıktı olarak +1 veya -1 değeri üretirler. Amaç giriş değerlerini ikili sınıflandırmaktır. Bu amaçla n boyutlu girdi uzayı doğru ya da düzlem ile iki bölgeye ayrılmaktadır. Günümüzde çok katmanlı yapay sinir ağlarının gelişmesiyle kullanım alanı pek bulunmamaktadır.
- Çok Katmanlı Yapay Sinir Ağları (ÇK-YSA): Giriş ve çıkış katmanlarının dışında arada bir ya da daha fazla gizli katman barındıran ileri beslemeli sinir ağlarıdır. Bu tür ağlarda genelde bir adet girdi katmanı, en az bir adet gizli katman ve bir adet çıkış katmanı bulunur. Girişteki işlenmemiş verilerin öz niteliklerini belirlemek, ağırlıklandırmak ve elde edilen sonuç değerlerini çıktı katmanına iletmek amacıyla gizli katmanlara ihtiyaç duyulmaktadır. Çok Katmanlı Yapay Sinir Ağları ileri ve geri beslemeli olabilmektedirler. İleri beslemeli YSA'da bilgi akışı tek yönlüdür. Geri beslemeli YSA'larda ise girdilerin yanında ara katmanlardaki çıktıların da girdiye etkisi dikkate alınmaktadır. Tez çalışmasında çok katmanlı ileri beslemeli sinir ağları kullanılmaktadır.

Şekil 41, çok katmanlı bir yapay sinir ağının genel yapısını göstermektedir. Şekilden de görüldüğü gibi genel bir yapay sinir ağı girdi katmanı, gizli katman ya da katmanlar ile çıktı katmanından oluşmaktadır. Girdi katmanındaki sinir hücresi sayısı sinir ağına sunulan verilerin (öz niteliklerin) boyutu kadar olmaktadır. Böylece girdi katmanındaki her bir sinir hücresine bir öznitelik karşılık gelmektedir. Gizli katman sayısı ve gizli katmanlardaki sinir

hücreleri sayısını belirlemek için kullanılan özel bir yöntem bulunmamaktadır. Genellikle girdi katmanındaki sinir hücreleri sayısına yakın sinir hücresi seçilmekte ve probleme göre en uygun sinir hücresi sayısı deneme-yanılma yoluyla belirlenebilmektedir. Çıkış katmanındaki sinir hücresi sayısı ise karar verilecek sınıf sayısı ile aynı olmaktadır. Retinal kan damarı probleminde damar ve arkaplan olmak üzere iki sınıf bulunduğundan bu çalışmada çıkıştaki sinir hücresi sayısı iki olarak seçilmektedir.



Şekil 41. Yapay sinir ağlarının genel yapısı

Denetimli bir makine öğrenmesi gerçekleştirmek için kullanılan YSA'nın belirlenmesi gereken üç farklı parametresi bulunmaktadır:

Mimari Yapısı: Kullanılacak YSA'nın tek ya da çok katmanlı, ileri ya da geri beslemeli olması YSA'nın yapısını belirlemektedir. Çalışmada ileri beslemeli çok katmanlı YSA kullanılmaktadır.

Öğrenme Algoritması: YSA'nın her bir katmanında bulunan sinir hücrelerinin kat sayılarının belirlenmesi için kullanılan yöntemdir. Bir başka deyişle bu aşama öğrenme işleminin nasıl gerçekleştirildiğinin belirlendiği aşamadır. Buna göre sinir ağının ağırlık


değerleri belirli bir kurala göre güncelleştirilmekte ve bu ağırlık kat sayıları tutarlı olunca öğrenme işlemi gerçekleştirilmiş olmaktadır. Çalışmada kat sayıların belirlenmesi için “scaled conjugate gradient (scg)” öğrenme algoritması kullanılmıştır.

Aktivasyon Fonksiyonu: Bu fonksiyon katmanlar arasındaki fonksiyonel eşleşmeyi gerçekleştirmektedir. Her bir sinir hücresinin girişindeki değerler ile karşılık gelen ağırlık değerleri çarpılıp toplanarak belirli bir değer elde edilmektedir. Bu değer aktivasyon fonksiyonu sayesinde çıkış ile eşleştirilmektedir. Çalışmada hiperbolik tanjant sigmoid aktivasyon fonksiyonu kullanılmaktadır. Eşitlik 33 ve 34’te sinir hücresinin girdi değerleri ile çarpılıp toplanmasını ifade eden eşitlik ve hiperbolik tanjant sigmoid aktivasyon fonksiyonu verilmektedir.

$$y = \tanh(\sum_{i=1}^n w_i x_i + \theta) \quad (33)$$

$$\tanh(s) = \frac{2}{1+e^{-2s}} - 1 \quad (34)$$

Burada w_i , ağırlık kat sayılarını ve x_i ise sinir hücresinin girdi değerlerini ifade etmektedir. θ değeri de sinir hücresi için baz değeri (sabit terim) temsil etmektedir. Şekilde hiperbolik tanjant sigmoid aktivasyon fonksiyonunun ($\tanh(x)$) grafiği verilmektedir.



Şekil 42. Hiperbolik tanjant sigmoid aktivasyon fonksiyonunun ($\tanh(x)$) grafiği

2.6.3. Retinal Kan Damarı Bölütleme

Retinal kan damarı bölütleme amacıyla önceki bölümlerde anlatılan yöntemlerin hangi sırada ve ne amaçla kullandıkları ve hangi parametrelerin seçildiği bölütleme performansını oldukça etkilemektedir. Sonraki bölümlerde eğitim verisinin hazırlanması ve bu verinin sınıflandırıcıya nasıl sunulduğu ve hangi parametrelerin ne amaçla seçildiği verilmektedir.

2.6.3.1. Eğitim Verisinin Hazırlanması

Retinal kan damarı bölütleme probleminin denetimli sınıflandırma ile çözülmesinde eğitim kümesi olarak m adet öz nitelik ve n adet örnekten oluşan öz nitelik matrisi yapılandırılmaktadır. Bu matris $(n \times m)$ boyutundadır. Aynı zamanda her bir örneğin damar ya da arkaplan olduğunu gösteren $(n \times 1)$ boyutlu etiket matrisi de eğitim kümesindeki manuel olarak etiketlenmiş damar görüntüleri kullanılarak oluşturulmaktadır. Denetimli sınıflandırma yöntemleri kullanılarak retinal kan damarı bölütleme işleminin nasıl yapıldığı Şekil 36'da daha önce verilmişti. Retinal kan damarı bölütleme işleminin yapıldığı bu tez çalışmasında denetimli sınıflandırma yöntemleri şu şekilde uygulanmaktadır. İlk olarak kan damarı ve arkaplan olarak 2 farklı sınıf için eğitim kümesi hazırlanmakta ve daha seçilen sınıflandırıcıya göre pikseller sınıflandırılmaktadır. Eğitim için kullanılacak verinin hazırlanması için uygulanan işlem adımları aşağıda verilmektedir:

Öznitelik Çıkarma Adımı: Yöntemde üç farklı grupta öznitelik çıkarılmaktadır. Birincisi damar iyileştirme süzgeçleri (Gauss, Gabor, Frangi) sonucunda elde edilen görüntünün piksel değerleri, ikinci olarak istatistiksel öznitelikler ve üçüncü olarak renk tabanlı basit öznitelikler.

Eğitim İçin Kullanılacak Piksellerin Seçimi: Bu aşamada her bir görüntüden kan damarları ve arkaplana ait olan belirli sayıda piksel koordinatı seçilmektedir. İstatistiksel olarak kan damarları bir görüntüde daha az sayıda olduğundan yaklaşık olarak 4:1 oranında arkaplan ve kan damarlarına ait piksel koordinatları seçilmektedir.

Bir Görüntü İçin Öznitelik Matrisinin ve Etiket Bilgisinin Oluşturulması: Bu aşamada bir görüntüden çıkarılan tüm özniteliklerden seçilen piksellere denk gelen değerler birleştirilerek bir görüntüyü temsil edecek öznitelik matrisi ve bu değerlere denk gelen etiket vektörü oluşturulmaktadır. Burada bir görüntüden n' adet piksel seçildiğinde (kan damarı ve arkaplan) m adet öznitelik için $(n' \times m)$ boyutunda bir matris ve $(n' \times 1)$ boyutlu etiket

vektörü elde edilmektedir. Seçilen piksellerin sınıfına göre etiket vektörü de uygun bir şekilde yapılandırılmaktadır. Kan damarı sınıflandırmada arkaplan sınıfı için 0 değeri ve kan damarı sınıfı için 1 değeri seçilmektedir.

Öznitelik Matrisinin ve Etiket Vektörünün Oluşturulması: Bu aşamada eğitim için kullanılacak tüm görüntülerin her birinden çıkarılan $(n' \times m)$ boyutlu öznitelik matrisleri ile etiket vektörleri birleştirilerek eğitim için kullanılacak $(n \times m)$ boyutlu eğitim veri seti oluşturulmaktadır. Benzer şekilde $(n \times 1)$ boyutlu etiket vektörü de oluşturulmaktadır. Bu adımın son aşamasında eğitilecek sınıflandırıcıyı hatalı yönlendirmemek için örnekler rastgele şekilde karıştırılmaktadır.

Burada kullanılan n' değeri bir görüntüden seçilecek piksel sayısını (örnek sayısı), n değeri tüm görüntülerden seçilecek örnek sayısını ve m ise öznitelik sayısını temsil etmektedir. n değeri eğitim için kullanılacak görüntü sayısına göre artmaktadır. c görüntü sayısı olmak üzere $n = c * n'$ şeklinde bir denklem yazmak mümkündür. Tablo 3'te tez çalışmasında damar bölütleme amacıyla kullanılan eğitim ve test veri setleri için kullanılan parametreler özet şekilde verilmektedir.

Tablo 3. Tez çalışmasında damar bölütleme amacıyla kullanılan eğitim ve test veri setleri için kullanılan parametreler özeti

Parametre	Açıklama
Eğitim Verisi	
Görüntü Sayısı	STARE veritabanı için 10 görüntü DRIVE veritabanı için 20 görüntü
m	Öznitelik sayısı
n'	Bir görüntüden alınacak örnek sayısı (arkaplan için 4000 piksel, kan damarları için 1000 piksel, toplamda 5000 piksel)
$(n' \times m)$	Bir görüntüden alınan öznitelik matrisinin boyutu
$(n' \times 1)$	Bir görüntüden alınan etiket vektörü boyutu
n	Toplam örnek sayısı (görüntü sayısı * n')
$(n \times m)$	Tüm görüntülerden elde edilen öznitelik matrisi boyutu
$(n \times 1)$	Tüm görüntülerden elde edilen etiket matrisi boyutu
Test Verisi	
Görüntü Sayısı	STARE veritabanı için eğitimde kullanılmayan diğer 10 görüntü DRIVE veritabanı için eğitimde kullanılmayan diğer 20 görüntü
n_2	Test edilecek bir görüntüdeki piksel sayısı
$(n_2 \times m)$	Test verisetindeki bir görüntü için yapılandırılan öznitelik matrisi boyutu
$(n_2 \times 1)$	Test sonucunda elde edilecek sınıf bilgisi içeren vektör

2.6.3.2. Retinal Kan Damarı Sınıflandırma (Test İşlemi)

Eğitim veri setinin aksine test veri seti hazırlanırken damar bölütleme yapılacak renkli retinal görüntüsünün tüm pikselleri kullanılmaktadır. Sırasıyla ön işlemler adımı ve öznitelik çıkarma adımlarından geçirilen test görüntüsünden $(n_2 \times m)$ boyutunda bir öznitelik vektörü yapılandırılmaktadır. Burada n_2 değeri test görüntüsündeki piksel sayısını temsil etmektedir. Bu vektör eğitilmiş sınıflandırıcıya sunulduktan sonra $(n_2 \times 1)$ boyutlu ve her bir pikselin (örneğin) sınıfını içeren sınıf etiket vektörü elde edilmektedir. Daha sonra bu etiket vektörü kullanılarak karşılık gelen pikseller damar ya da arkaplan olarak işaretlenmektedir. İkili sınıflandırmada elde edilen sınıf etiket vektörleri 0 ve 1 değerlerini içerdiğinden 0 değeri için karşılık gelen piksel arkaplan olarak, 1 değeri için karşılık gelen piksel damar olarak ayarlanmaktadır.

2.7. Son İşlemler Adımı

Sınıflandırma işleminden sonra çıkarılan siyah-beyaz damar görüntüsü üzerinde hatalı tespit edilen izole damar pikselleri olabilmektedir. Ayrıca gerçekte damara ait olan bazı pikseller de arkaplan olarak işaretlenmektedir. Bu olumsuz etkileri azaltmak için aşağıda verilen son işlemler uygulanmaktadır.

2.7.1. Uzunluk Süzgeci

Elde edilen ikili görüntüde kan damarları parçalarının birbirine komşuluk durumlarına göre her birinin toplam alanları hesap edilmektedir. Bu işlem için Bağlantılı Bileşen Etiketleme (Connected Component Labeling) yöntemi kullanılmaktadır. Normal şartlarda tüm kan damarı ağı birbirine bitişik ve kökten dallara doğru uzanan ağaç şeklinde elde edilmesi gerekmektedir. Ancak uygulanan damar bölütleme yönteminin ideal olmaması ve hatalı tespit gibi sebeplerden dolayı birbirinden kopuk damar bölütleri elde edilmektedir. İşlem sonucunda elde edilen kan damarı aday bölgelerinin toplam piksel alanı belli bir değerden (çalışmada 10 piksel olarak alınmıştır) az olan bölgeler hatalı tespit edilen bölgeler olarak kabul edilmekte ve bu bölgeler arkaplan olarak yeniden işaretlenmektedir. Bu işlem literatürde uzunluk süzgeci (length filter) olarak anılmaktadır.

2.7.2. Damar Bölütleri Arasındaki Boşlukları Doldurma

Damar bölütleme işleminden sonra bazı damar bölütleri arasında hatalı tespit nedeniyle aslında damar yapısına ait ancak arkalan olarak işaretlenen boşluklar olabilmektedir. Yapılacak bir takım sıralı işlemlerden sonra bu boşluklar doldurulmaktadır. Bu işlemde, arkaplan olarak işaretlenmiş bir pikselin komşu piksel sayısı eğer 4 değerinin üzerindeyse bu piksel damar pikseli olarak kabul edilmektedir. Eşitlik 35’te verilen ifade ile damar bölütleri arasındaki boşlukların doldurulması işlemi gerçekleştirilmektedir. Bu işlemlerden sonra nihai ikili kan damarı görüntüsü elde edilmiş olur.

$$I(x) = \begin{cases} 1, & kps \geq 4 \\ 0, & \text{diğer } d. \end{cases} \quad (35)$$

Burada kps değeri ilgili pikselin komşu piksel sayısını göstermektedir.

2.8. Damar Ölçme ile İlgili Çalışmalar.

Çalışma kapsamında retinal kan damarları tespit edildikten sonra elde edilen ikili damar görüntüsü alınarak kan damarları üzerinde görüntü çakıştırma ve kan damarları üzerinden retinal görüntü tanıma işlemleri gerçekleştirilmektedir. Bu amaçla inceltilmiş kan damarları üzerinde dallanma noktası, uç noktalar ve çapraz geçiş noktaları gibi birtakım öznitelikler çıkarılmaktadır ve bu özniteliklerin birbirine komşu olmalarına göre komşuluk ilişki matrisi çıkarılmaktadır. Daha sonra ikili damar görüntüsünde damar kalınlıkları ve komşuluk ilişki matrisi verileri birleştirilerek ikili damar görüntüsünü temsil edecek karakteristik matris elde edilmektedir. Bu şekilde siyah-beyaz damar görüntülerinin her birini temsil edecek karakteristik matrisler elde edilmekte ve belli kriterlere göre karşılaştırma işlemi gerçekleştirilerek çakışan noktalar eşleştirilmektedir. Ayrıca çıkarılan karakteristik matris kullanılarak retinal görüntü tanıma işlemi gerçekleştirilmektedir.


2.8.1. Öznitelik Noktalarının Çıkarılması

Öznitelik noktaları olarak ikili damar görüntüsü üzerinde damar uç noktaları, dallanma (çatal) noktaları ve çapraz geçiş noktaları ele alınmaktadır. Bu amaçla öznitelik noktalarının

bulunması için ilk olarak morfolojik inceltme işlemi gerçekleştirmektedir. [97]. Daha sonra öznitelik noktaların bulunması amacıyla inceltilmiş damar görüntüsü üzerinde bulunan her bir pikselin (5 x 5) komşulukta dairesel olarak incelenerek 0'dan 1'e geçiş sayılarına bakılır. 0'dan 1'e geçiş sayısına göre öznitelik noktaları şu şekilde sınıflandırılır:

- 0-1 geçiş sayısı 1 ise, uç nokta,
- 0-1 geçiş sayısı 2 ise, damar ortasında sıradan bir nokta,
- 0-1 geçiş sayısı 3 ise, bu nokta dallanma noktası ve
- 0-1 geçiş sayısı 4 ise, bu nokta çapraz geçiş noktası olarak kabul edilir.


3 x 3 ve 5 x 5 komşulukta 3 adet 0-1 geçiş sayısına sahip örnek bir dallanma noktası Şekil 43'te verilmektedir.



Şekil 43. 3x3 ve 5x5 komşulukta dallanma noktasının ikili görüntüde gösterimi

Çapraz geçiş noktaları genellikle kan damarlarının o noktada doğrudan bir bağlantısı olmayıp görüntüde atardamarlar ile toplardamarların iki boyutlu görüntüde birbirini kestiği noktalardır. Bulunan öznitelik noktaları Şekil 44 'te ayrı ayrı gösterilmektedir.

Öznitelik noktaları elde edildikten sonra bazı noktaların aslında aynı öznitelik noktasını temsil etmesine rağmen ayrı bir nokta olarak gözlenmektedir. Bu nedenle birbirine çok yakın olan bu noktalar belli bir uzaklık kriterine göre birleştirilmektedir. Bu tez çalışmasında uygulanan yöntemle göre noktaların birbiri ile aynı nokta olarak işaretlenmesi için aralarında öklit uzaklığı olarak en fazla 5 piksel yakınlıkta olması gerekmektedir.



Şekil 44. İnceltilmiş damar görüntüsünde kenar nokta sayısına (kns) göre öznitelik noktalarının gösterimi


2.8.2. Komşuluk İlişki Matrisinin Çıkarılması

İnceltilmiş kan damarı görüntüsünde öznitelik noktaları elde edildikten sonra bu noktaların birbirleri ile olan komşulukları bir graf modeli ile temsil edilmektedir. Buna göre her bir öznitelik noktası (uç nokta, dallanma noktaları) kan damarlarını temsil eden graf üzerinde bir düğüm noktası olarak düşünülmektedir. Düğümlerin birbirlerine olan bağlantılar ise düğümleri birbirine bağlayan kenar olarak kabul edilmektedir. Bu şekilde inceltilmiş damarları temsil eden graf modeli aşağıdaki şekilde verilen yöntemle çıkarılabilmektedir.

- Öznitelik noktaları genel bir yığına atılır.
- Genel yığından bir öznitelik noktası çekilir ve bu noktaya komşu olan noktaları geçici başka bir yığına atılır.
- Geçici yığından bir nokta çekilir ve iskelet üzerinden takip edilir.
- Takip sırasında başka bir öznitelik noktaya erişilmişse bu iki öznitelik noktası komşu olarak ilişkilidir, bu nedenle bu noktaları komşu olarak işaretlenir.
- Herhangi bir öznitelik noktaya erişilmediyse halen ara bir noktada olduğundan takip işlemine devam etmek için 2.a adımına geri dönülür.
- Eğer geçici yığında eleman kalmadı ise söz konusu öznitelik noktasının komşusuna erişilemediğinden 2. adıma geri dönülür.

- Genel yığılma nokta kalmamış ise tüm öznitelik noktaları değerlendirilmiş olduğundan 4. adıma gidilir, aksi durumda genel yığılma halen eleman var ise 2. adıma geri dönlür.
- Görüntüdeki tüm öznitelik noktaları değerlendirildiğinden işleme son verilir, aksi durumda 2. adıma geri gidilir.

Komşulukları gösteren graf elde edildikten sonra bazı düğüm noktalarının birbiri ile komşulukları karşılıklı olduğundan tekrarlı ilişkiler oluşmaktadır. Bu nedenle komşuluk ilişki grafını gösteren matris analiz edilerek tekrar eden ilişkiler. Düğüm noktalarının birbiri ile olan komşuluk ilişkilerini gösteren graf yapısı renkli görüntüler üzerinde Şekil 45'te verilmektedir




Şekil 45. Sentetik kan damar görüntüsü ve öznitelik noktalarının komşuluk ilişkileri

2.8.3. Retina Görüntüsünün Temsili ve Karakteristik Matris Çıkarma

Bu bölümde siyah-beyaz retinal damar görüntüsünü temsil etmek amacıyla öznitelik noktalarını kullanarak karakteristik matrisin çıkarılması amaçlanmaktadır. Öznitelik noktası olarak komşuluk bilgilerini de içermesi bakımından sadece 3 komşuya sahip dallanma noktaları seçilmektedir. Çıkarılacak karakteristik matris, öznitelik noktalarının her birinin karakteristik özelliklerini içermektedir. Bu amaçla ilk olarak siyah-beyaz (ikili) damar görüntüsü üzerindeki her bir noktada öklit uzaklık dönüşümü kullanılarak damar kalınlık


bilgisi hesap edilmektedir [98]. Buradan elde edilen kalınlık bilgisi ile  znitelik noktaları arasında  nem derecesi y ksek (yani kalınlığı fazla) olan d ğ mler se ilmektedir. Kan damarları retina  zerinde a a  yapısına benzer bir  ekilde yayıldığından ve damar u larına do ru gidildik e kalınlık azalacağından  klit uzaklığından elde edilen kalınlık de eri belli bir e ikten b y k oldu unda o nokta  nem derecesi y ksek olan nokta olarak kabul edilmekte ve o d ğ m noktası i in hesaplanacak bilgiler karakteristik matrise eklenerek i lem ve veri fazlalığı azaltılmaktadır. Tez  alışmasında e ik de eri 2.5 piksel olarak se ilmektedir.



 ekil 46. Bir d ğ m i in hesaplanan karakteristik de erlerin temsili g sterimi

 nem derecesi y ksek d ğ mler belirlendikten sonra her bir d ğ m n kom uları bir listeye alınır. Listedenden sırasıyla her bir d ğ m se ilerek o d ğ m n karakteristik vekt r  hesap edilir. Karakteristik vekt r n yapısı  nem derecesini de i eren $\{W, r_0, w_0, r_1, w_1, \theta_1, r_2, w_2, \theta_2\}$ vekt r   ekilde yapılandırılır. Burada W d ğ m noktasına denk gelen  klit uzaklık d n   m ndeki kalınlık de eridir. Di er de erler o d ğ m noktasına en uzak olan d ğ me  izilen ana eksen se ilerek hesaplanmaktadır. Bu de erler ana eksen  nce olmak ko ulu ile kom u d ğ mlere olan uzaklık, a ı ve kom u d ğ mlerin  nem derecelerini g steren kalınlık bilgileridir.  ekil 46 karakteristik vekt r bile enlerini temsili olarak g stermektedir. W dı ındaki di er de erler sırasıyla (r_0, w_0) ikilisi, ilgili d ğ m i in hesaplanan ana eksen uzunlu u ve en uzak kom u noktanın kalınlık bilgisini, $(r_1, w_1, \theta_1, r_2, w_2, \theta_2)$ de erleri ise sırasıyla o d ğ m n di er kom ularına olan uzaklık, kalınlık ve ana eksene olan a ı de erlerini g stermektedir. Burada $r_0 > r_1 > r_2$ olacak  ekilde bir sıralama olmalıdır. Benzer  ekilde her bir d ğ m noktası i in 9 adet de er kullanılarak o d ğ m  temsil eden karakteristik vekt r elde edilmektedir. Bir retinal g r nt de  nem


derecesi en yüksek 40 adet düğümden elde edilen karakteristik vektörler birleştirilecek karakteristik matris yapılandırılmaktadır. Böylece **(40x9)** boyutunda retinal görüntüyü temsil eden karakteristik öznitelik matrisi elde edilmektedir. Şekil 47’de karakteristik matris eldesi için izlenen akış şeması verilmektedir.



Şekil 47. Karakteristik Matris hesabı için izlenen akış şeması

2.8.4. Retinal Görüntü Çakıştırma

Bu bölümde bir görüntüyü temsil eden karakteristik matrisin çıkarılmasından sonra aynı kişiye ait ve öteleme, dönme ve ölçekleme işlemleri uygulanmış başka bir retinal görüntünün çakıştırılması amaçlanmaktadır. Böylece iki farklı görüntüdeki öznitelik noktalarının eşleştirilmesi sağlanmış olacaktır. Bu nedenle için her iki görüntü için de karakteristik matris hesabı yapılması ve karşılaştırma yaparak eşleşen noktaların bulunması işlemi gerçekleştirilmektedir. Şekil 48, karşılaştırma işlemi için izlenecek akış şemasını göstermektedir.



Şekil 48. Karakteristik matris karşılaştırma işleminin akış şeması

Karşılaştırma işleminde karakteristik matriste bulunan 40 adet karakteristik vektörler arasındaki ortalama hata değerleri hesaplanmaktadır. Hata değerleri açılar (θ) için ayrı uzaklıklar için ayrı (r) ve kalınlık bilgileri için ayrı olmak üzere hesaplanmaktadır. Hesaplanan ortalama hata değerlerine göre belirli eşiklerden küçük olan hata değerlerinde karşılaştırılması yapılan karakteristik vektöre karşılık gelen öznelik noktaları birebir eşleştirilmiş olmaktadır.

3. BULGULAR VE İRDELEME

3.1. Performans Değerlendirme Metrikleri ve Veri Kümesi

Örüntü tanıma ve ikili sınıflandırma gibi problemlerde sonuç olarak elde edilen değerlerin başarımını ölçmek için bir takım performans ölçüm metrikleri kullanılmaktadır. Bu çalışmada da literatürde yaygın olarak kullanılan performans metrikleri kullanılmaktadır. Bu metriklerden başlıca olanları doğru pozitif oranı (duyarlılık, sensitivity), yanlış pozitif oranı (false positive rate), özgüllük (specificity) ve doğruluk (accuracy) metrikleridir.

Retinal kan damarı bölütleme probleminde olduğu gibi ikili sınıflandırma sonucunda kesin referansla (ground truth) karşılaştırmak amacıyla bazı temel değerler ölçülmektedir. Bu temel değerler Hata Matrisi (Confusion Matrix) ile ifade edilmektedir. Daha sonra bu değerler kullanılarak asıl performans metrikleri çeşitli eşitliklere göre hesap edilmektedir. Hata Matrisi bileşenleri Tablo 4’te verilmektedir.

Tablo 4. Performans değerlendirmesinde kullanılan metrikler (hata matrisi)


		Kesin Referans (Gerçekte Olan Sınıf)	
		Pozitif (Kabul) (Damar)	Negatif (Ret) (Arkaplan)
Test Sonuçları (Tahmin Edilen Sınıf)	Pozitif (Damar)	Doğru Pozitif (DP)	Yanlış Pozitif (YP)
	Negatif (Arkaplan)	Yanlış Negatif (YN)	Doğru Negatif (DN)

Hata matrisinde kullanılan temel metriklerin anlamları şu şekildedir:

- Doğru pozitif (DP): Gerçekte damar pikseli olup bölütleme sonucunda da damar olarak sınıflandırılan piksellerin sayısıdır.
- Doğru negatif (DN): Gerçekte arkapana ait bir piksel olup bölütleme sonucunda da arkaplan pikseli olarak sınıflandırılan piksellerin sayısıdır.
- Yanlış Pozitif (YP): Gerçekte arkaplanına ait bir piksel olup bölütleme sonucunda damar olarak sınıflandırılan piksellerin sayısıdır.

- Yanlış Negatif (YN): Gerçekte damar pikseli olup bölütleme sonucunda arkaplan pikseli olarak sınıflandırılan piksellerin sayısı

Ölçülen bu performans metrikleri bölütleme sonucunda elde edilen ayırma çizgisi ile kesin referans görüntüde elde edilen ayırma çizgisi ile ayrıca ifade edilebilmektedir. Bu değerlerin bölgesel karşılıkları Şekil 49'da temsil edilmektedir.



Şekil 49. Performans metriklerinin (DP, DN, YP, YN) bölgesel karşılıkları

Temel metrikler ölçüldükten sonra performans değerlendirmesi için Eşitlik 36-38'de verilen eşitlikler ile performans metrikleri hesaplanmaktadır.

$$DUY = \frac{DP}{DP+YN} \times 100 \quad (36)$$

$$KES = \frac{DN}{DN+YP} \times 100 \quad (37)$$

$$DOG = \frac{DP+DN}{DP+DN+YP+YN} \times 100 = \frac{DKPS}{TPS} \times 100 \quad (38)$$

Burada DKPS değeri damar ya da arkaplan olarak doğru kabul edilen piksel sayısını ve TPS ise değerlendirmeye alınan toplam piksel sayısını ifade etmektedir.

Doğruluk değeri doğru kabul edilen piksel sayısının tüm piksellere oranı olarak hesap edilmektedir. Doğru kabul edilen pikseller damarlar için doğru pozitif (DP) alanlar ve arkaplan için doğru negatif (DN) alanların toplamıdır (DP+DN). Tüm piksellerin sayısı ise tüm ölçümlerin toplamı (DP+DN+YP+YN) olarak ifade edilmektedir. Doğruluk değeri retinal kan damarı bölütleme yönteminin ne kadar doğru çalıştığını ölçen en önemli parametredir. Kesinlik değeri ile duyarlılık değeri sırasıyla arkaplan ve damar için hesaplanan isabet oranlarıdır. Kesinlik değeri hatalı tespitler hakkında bilgi sunar ve ne kadar yüksek ise algoritmanın sınıflandırma hatası o kadar az olur. Duyarlılık değeri ise kan damarı (pozitif örnekler) için isabet oranını verir. Bu değer de ne kadar yüksek ise kan damarları o kadar iyi tespit edilebilmiş demektir. Bunların dışında performans ölçümü için kullanılan ve sonuçlar hakkında fikir veren hatalı tespit oranı diye bir metrik bulunmaktadır. Bu metrik kesinlik metriği ile doğrudan ilişkilidir ve (1-kesinlik) eşitliği ile hesap edilebilmektedir. Bu oran ne kadar az olursa damar sınıflandırma yönteminin hatası da o kadar az olmaktadır.

Sınıflandırma işleminde veri seti olarak internet üzerinde halka açık olarak sunulan STARE ve DRIVE veritabanları kullanılmaktadır. Bu veritabanlarının özellikleri Tablo 5'te verilmektedir. Bu veri setlerinde performans değerlendirmesi için manuel olarak etiketlenmiş görüntüler kesin referans görüntüler olarak kullanılmakta ve performans ölçümler buna göre gerçekleştirilmektedir.

Tablo 5. Tez çalışmasında kullanılan STARE ve DRIVE veritabanları hakkında bilgiler

	STARE	DRIVE
Erişim	Açık	Açık
Görüntü Sayısı	20 görüntü	40 görüntü (20 görüntü eğitim için) (20 görüntü test için)
Manuel Damar Görüntüleri	Var	Var
Hazır Maske Görüntüleri	Yok	Var
Kamera	TopCon TRC-50	Canon CR5
Çözünürlük	605x700, 24 bit	768x584, 24 bit
Çekim Açısı	35 ⁰	45 ⁰

3.2. Retina Bölgesi Seçimi ile İlgili Elde Edilen Sonuçlar

Retinal fundus görüntüler çoğunlukla dairesel ya da elips benzeri bir yapıya sahiptirler, ancak görüntüler fundus kameralar aracılığı ile elde edilirken dikdörtgen biçiminde

olmaktadır. Bu sebeple retinal görüntü köşelerinde gerçekte retinaya ait olmayan koyu bölgeler oluşmaktadır. İkinci bölümde bu bölgelerin tespit edilerek elenmesi ve retina bölgesinin seçilmesi için izlenen yöntemlere değinilmiştir. Bu bölümde retina bölgesi seçim işleminin performans sonuçları değerlendirilmiştir. Çalışmada ağırlıklı olarak STARE ve DRIVE veritabanlarından elde edilen görüntüler kullanılmaktadır. STARE veritabanında performans değerlendirmesinde kullanılmak üzere manuel olarak etiketlenmiş maske görüntüler bulunmamaktadır. Ancak DRIVE veritabanında retina bölgesinin seçimi için kullanılan manuel olarak etiketlenmiş maske görüntüleri bulunduğundan performans ölçümü için DRIVE veritabanındaki maske görüntüleri referans olarak alınmıştır.

DRIVE veritabanında toplamda 40 adet retinal fundus görüntü bulunmaktadır. Her bir görüntünün renkli, manuel kan damarı ve maske görüntüleri ayrı ayrı yer almaktadır. Çalışmada 40 adet retinal fundus görüntünün retina bölgelerini seçecek maske görüntüleri çıkarılmış ve referans maske görüntüleri ile karşılaştırılmıştır. Elde edilen maske görüntüleri için performans metrikleri hesaplanmış ve Tablo 6’da verilmiştir.

Tablo 6. DRIVE veritabanında bulunan 40 görüntü için elde edilen retina bölgesi tespiti başarımları sonuçları

Görüntü	DUY	KES	DOG	Görüntü	DUY	KES	DOG
1	100	97,21	99,11	21	100	98,44	99,51
2	100	97,69	99,27	22	99,81	100	99,87
3	100	98,34	99,47	23	99,83	100	99,88
4	99,78	100	99,85	24	99,80	100	99,86
5	99,80	100	99,86	25	99,74	100	99,82
6	99,79	100	99,86	26	100	98,71	99,59
7	99,82	100	99,88	27	99,82	100	99,87
8	100	98,05	99,38	28	99,80	100	99,86
9	99,81	100	99,87	29	99,76	100	99,84
10	99,75	100	99,82	30	99,74	100	99,82
11	99,79	100	99,86	31	99,82	100	99,88
12	99,82	100	99,88	32	100	97,93	99,34
13	99,80	100	99,86	33	99,81	100	99,87
14	100	97,82	99,34	34	99,96	99,70	99,87
15	99,74	100	99,82	35	99,79	100	99,85
16	99,81	100	99,87	36	99,75	100	99,82
17	100	98,64	99,57	37	99,76	100	99,84
18	99,81	100	99,87	38	99,99	99,33	99,78
19	99,74	100	99,82	39	99,80	100	99,86
20	99,79	100	99,85	40	99,70	100	99,79
Ortalama					99,84	99,55	99,75

Maske çıkarma yönteminde kullanılan T_1 ve T_2 eşik parametreleri sırasıyla 40 ve 50 olarak seçilmiştir (Bir gri seviye görüntünün 0-255 arası değerlerle ifade edildiği durumda). Tablo 6’de hesaplanan performans değerlerine göre maske çıkarımı için ortalama %99,84 lük bir doğru tespit oranı ve %99,75 oranında doğruluk değerleri elde edilmiştir.



Şekil 50. Basit eşik kullanılarak elde edilen maske görüntüsü. Doğruluk değeri: %98,48 (solda) ve önerilen yöntemle elde edilen maske görüntüsü. Doğruluk değeri %99,21 (sağda)


Şekil 50’de basit eşik değeri ve önerilen maske çıkarma yöntemi ile tespit edilen iki farklı maske görüntüsü verilmektedir. Görüldüğü gibi sadece basit eşik kullanıldığından düşük parlaklık seviyesine ait bazı kan damarları da eşik altında kalmakta ve maske olarak algılanabilmektedir. Sadece basit eşik kullanıldığında elde edilen doğruluk değeri %99,04 olarak elde edilmektedir. Tablo 7’de DRIVE veritabanındaki 40 görüntü için her iki yöntemle elde edilen ortalama doğruluk değerleri ve bu değerler için hesaplanan standart sapma değerleri verilmektedir.

Tablo 7. DRIVE veritabanındaki 40 görüntü için iki farklı yöntemle elde edilen ortalama doğruluk ve standart sapma değerleri

Yöntem	Ortalama Doğruluk	Standart Sapma
Basit Eşik Kullanıldığında	%99,04	1,01
Önerilen Yöntem	%99,75	0,25

Tablo 7’ten görüldüğü gibi ortalama doğruluk değeri daha yüksek çıkmaktadır. Elde edilen bu performans sonuçları otomatik retinal maske çıkarımı için yeterlidir. Ayrıca farklı

görüntüler arasında elde edilen standart sapma değeri önerilen yöntemde daha düşük çıktığından yöntemi daha tutarlı olduğu ve elde edilen doğruluk değerlerinin birbirine daha yakın olduğu söylenebilmektedir.



Şekil 51. STARE veritabanından alınan bir görüntüde elde edilen retina bölgesi



Şekil 52. KTÜ Farabi hastanesinden alınan bir görüntüde elde edilen retina bölgesi

Önerilen yöntem başka retinal görüntüler üzerinde de uygulanmış ve elde edilen görsel sonuçlar Şekil 51 ve Şekil 52’de verilmiştir. Bu veritabanlarında manuel olarak etiketlenmiş maske görüntüler olmadığından sadece görsel sonuçlar verilmiştir. Ancak şekillerden de görüleceği gibi bu görsel sonuçlar bile önerilen yöntemin sonuçlarının tahmin edici derecede olduğunu göstermektedir. Önerilen yöntemin bu tez çalışmasında olduğu gibi ileride

yapılacak retinal fundus görüntüler üzerinde işlem yapan diğer yöntemler için bir ön işlem olarak kolaylıkla kullanılabileceği düşünülmektedir.

3.3. Kural Tabanlı Piksel Sınıflandırma Yöntemi ile Elde Edilen Sonuçlar

Çalışmanın temel amaçlarından biri retinal fundus görüntülerde kan damarı çıkarma işlemini gerçekleştirmektir. Bu amaçla belirli ön işlemlerden sonra kan damarları belirgin hale getirilmiş ve kural tabanlı piksel sınıflandırma yöntemleri ile her bir piksel kan damarı veya retina arkaplanı olarak sınıflandırılmaktadır. Bu bölümde damar belirginleştirme süzgeçleri ile retinal fundus görüntülerde kan damarları belirginleştirildikten sonra kural tabanlı piksel sınıflandırma (iki ve üç seviyeli Otsu eşikleme ile yüzdeli eşikleme) yöntemleri ile elde edilen bulgular raporlanmaktadır.

Yöntemler bölümünde anlatıldığı gibi öznetelik çıkarma bölümünde damar belirginleştirme süzgeçleri ile retinal fundus görüntülerde kan damarları belirginleştirilmektedir. Kullanılan damar belirginleştirme süzgeçleri olarak iki boyutlu uyum süzgeci (Gauss ve Gabor süzgeci) ile Frangi süzgeci ayrı ayrı uygulanmıştır. Uygulanan her bir süzgeçten sonra iyileştirilmiş kan damarı görüntüsündeki ayrıntıları ön plana çıkarmak ve bölütleme işleminin performansını arttırmak amacıyla gri seviye morfolojik top-hat dönüşümü uygulanmaktadır. Retinal kan damarı bölütleme aşamasında ise ayrı ayrı iki ve üç seviyeli Otsu eşikleme ile yüzdeli eşikleme yöntemleri uygulanarak her birinden elde edilen sonuçlar rapor edilmektedir.

Yöntemler, internet üzerinde erişime açık olarak sunulan STARE ve DRIVE veri setlerinde uygulanmıştır. STARE veritabanında 20 adet görüntü bulunmaktadır. DRIVE veritabanında ise iki farklı grupta toplamda 40 adet görüntü bulunmaktadır. Bu veritabanı, eğitim için 20 adet ve test için 20 adet olmak üzere iki gruba ayrılmıştır. Bu nedenle veritabanının ilk 20 görüntüsü DRIVE1 ve ikinci 20 görüntüsü ise DRIVE2 olarak isimlendirilmektedir.

Gauss süzgecinin ayarlanabilir 1 adet parametresi bulunmaktadır. Bu parametre olan standart sapma (sigma) değeri σ farklı değerlerde (0.90, 0.95, 1, 2) seçilmiş ve elde edilen en iyi ortalama performans $\sigma=0.95$ değeri ile elde edilmektedir. Buna ilişkin STARE, DRIVE1 ve DRIVE2 veritabanlarındaki 20'şer görüntüden elde edilen ortalama bulgular Tablo 8'de verilmiştir.

Tablo 8. Gauss süzgeci kullanılarak elde edilen performans sonuçları

Veritabanı	Yöntem ve Parametreler	DUY	KES	DOG
STARE	Yüzdeli Eşikleme	79.64	95.92	94.45
	Otsu	55.81	98.93	94.69
	3 seviyeli Otsu	76.37	96.33	94.83
DRIVE1	Yüzdeli Eşikleme	78.79	96.55	94.97
	Otsu	47.30	99.53	94.94
	3 seviyeli Otsu	67.97	98.13	95.48
DRIVE2	Yüzdeli Eşikleme	77.59	96.25	94.59
	Otsu	41.86	99.56	94.61
	3 seviyeli Otsu	67.28	97.98	95.32

Tablo 8'den görüldüğü gibi Gauss süzgeci ile damar belirginleştirdikten sonra uygulanan eşikleme yöntemleri ile veritabanı değıştikçe sonuçlara ulaşılmaktadır. Bunun sebebi görüntülerin alınma şartları ve görüntüleri alınan kişilerin bölgesel ve/veya etnik olarak farklı popülasyona ait olmasıdır. Ayrıca 3 seviyeli Otsu yöntemi, beklenildiği gibi 2 seviyeli geleneksel Otsu eşikleme yönteminden daha iyi sonuç vermektedir. Bunun sebebi damar çıkarma amacıyla uygulanan eşikleme yöntemlerinde kalın ve ince damarların başlangıçta tek bir küme yerine ayrı ayrı dikkate alınmasıdır. Bunun yanında yüzdeli eşikleme yöntemi uygulaması basit bir yöntemdir ve bu yöntemle elde edilen doğruluk değeri görece 3 seviyeli eşikleme yöntemine göre daha düşüktür. Ancak sunduğu yüksek duyarlılık değeri ile dikkat çekmektedir.

Gabor süzgeci, standart sapma (σ) ve dalga boyu (λ), dönme açısı (θ), en boy oranı (γ) gibi farklı parametrelerle kontrol edilmektedir. Gabor çekirdeği 15 derece aralıklarla tüm yönlerde döndürülerek farklı yönlerde gabor çekirdeği elde edilmektedir. Dolayısıyla $\theta=\{0, 15, 30, 15, \dots, 165\}$ şeklinde değeri almaktadır. $\lambda=3*\sigma$ ve $\gamma=0.25$ seçilerek farklı ölçeklerde uygulanan Gabor süzgeci kullanarak STARE, DRIVE1 ve DRIVE2 veritabanınlardaki 20'şer görüntüden elde edilen ortalama performans değeri Tablo 9'da verilmektedir. Bu süzgeç için seçilen standart sapma (sigma) değeri $\sigma=\{0.25, 0.50, 0.75, 1\}$ olarak seçilmiş ve elde edilen en iyi ortalama performans $\sigma=0.50$ değeri ile elde edilmiştir.

Tablo 9. Gabor süzgeci ve kural tabanlı piksel sınıflandırma yöntemleri kullanılarak farklı veritabanlarından elde edilen performans sonuçları

Veritabanı	Yöntem ve Parametreler	DUY	KES	DOG
STARE	Yüzdeli Eşikleme	76.56	96.74	95.19
	Otsu	57.27	98.84	93.70
	3 seviyeli Otsu	80.48	94.73	93.76
DRIVE1	Yüzdeli Eşikleme	74.21	97.68	95.60
	Otsu	48.27	99.55	95.05
	3 seviyeli Otsu	68.86	97.95	95.40
DRIVE2	Yüzdeli Eşikleme	72.40	97.44	95.24
	Otsu	42.53	99.57	94.68
	3 seviyeli Otsu	62.26	98.59	95.45

Tablo 9’den görüldüğü gibi Gabor süzgeci ile kan damarı belirginleştirildikten sonra uygulanan eşikleme yöntemleri arasında 3 seviyeli Otsu eşikleme yönteminin geleneksel Otsu eşikleme yöntemine göre daha yüksek başarı elde etmektedir. Ayrıca yüzdeli eşikleme yöntemi ile daha yüksek duyarlılık değeri elde edildiği ve bazı görüntülerde buna ek olarak daha yüksek doğruluk değeri elde edildiği gözlenmektedir.

Benzer şekilde Frangi damar iyileştirme süzgecinin de kontrol edilen σ , β ve c parametreleri bulunmaktadır. Bu parametreler $\sigma = \{0.5, 0.75, 1, \dots, 4\}$ olacak şekilde, $\beta = 0.5$, ve $c = 4$ olarak seçilmiştir. STARE, DRIVE1 ve DRIVE2 veritabanınlardaki 20’şer görüntüden elde edilen ortalama performans sonuçları Tablo 10’da verilmektedir.

Tablo 10. Frangi süzgeci ve kural tabanlı sınıflandırma yöntemleri kullanılarak farklı veritabanlarından elde edilen performans sonuçları

Veritabanı	Yöntem ve Parametreler	DUY	KES	DOG
STARE	Yüzdeli Eşikleme	78.07	96.35	94.96
	Otsu	46.42	99.17	95.24
	3 seviyeli Otsu	61.52	98.26	95.54
DRIVE1	Yüzdeli Eşikleme	75.75	97.22	95.23
	Otsu	40.83	99.49	94.34
	3 seviyeli Otsu	57.41	98.87	95.23
DRIVE2	Yüzdeli Eşikleme	73.26	96.91	94.82
	Otsu	40.81	99.30	94.24
	3 seviyeli Otsu	58.04	98.38	94.88

Yine benzer şekilde Frangi süzgecinden sonra eşikleme yöntemleri ile kan damarlarının çıkarılması sonucunda beklenildiği üzere 3 seviyeli Otsu yönteminin

geleneksel Otsu yöntemine göre daha yüksek başarı sunduğu görülmektedir. Ayrıca yüzdeli eşikleme yönteminin de diğer eşikleme yöntemlerine göre daha iyi sonuçlar verdiği gözlenmektedir.

Tablolardan da görüldüğü gibi Yüzdeli eşikleme yöntemi ile yüksek duyarlılık değeri elde edilmekte ve 3 seviyeli Otsu eşikleme yöntemi de 2 seviyeli eşiklemeye göre daha yüksek doğruluk sonuçları ortaya çıkarmaktadır. Kural tabanlı eşikleme yöntemleri hız açısından denetimli ve denetimsiz sınıflandırma yöntemlerine göre daha avantajlıdır. Elde edilen performans değerleri denetimli ve denetimsiz sınıflandırma yöntemleri kadar yüksek olmasalar bile literatürle karşılaştırılabilir düzeydedirler ve hız gerektiren gerçek zamanlı uygulamalarda tercih edilebilmektedirler.

3.4. Denetimsiz Sınıflandırma Yöntemlerinden Elde Edilen Sonuçlar

Denetimsiz sınıflandırma yöntemlerinde de ilk olarak kan damarları belirginleştirilmektedir. Bu aşamada ayrı ayrı Gauss, Gabor ve Frangi süzgeç çıktıları elde edilmektedir. Denetimsiz sınıflandırma işlemine damar belirginleştirme süzgeç çıktılarının parlaklık değerleri öznitelik olarak sunulmaktadır. Gauss, Gabor ve Frangi süzgeçleri için STARE ve DRIVE veritabanındaki görüntüler için ortalamada en iyi sonucu verecek şekilde seçilen parametreler Tablo 11’de verilmektedir.

Tablo 11. Gauss, Gabor ve Frangi süzgeçleri için seçilen parametreler

Parametre	Açıklama	Seçilen Değer
Gauss Süzgeci		
σ	Standart sapma	STARE için $\sigma=1$ DRIVE için $\sigma=3$
σ_x/σ_y	Gauss çekirdek süzgecinin en-boy oranı	0.25
θ	Gauss çekirdek süzgecinin dönem açısı	$\theta=\{0, 15, 30, 15, \dots, 165\}$
Gabor Süzgeci		
σ	Standart sapma	$\sigma=2$
λ	Trigonometrik kosinüs fonksiyonunun dalga boyu	$\lambda=3*\sigma = 6$
γ	Gabor çekirdek süzgecinin en-boy oranı	0.25
θ	Gabor çekirdek süzgecinin dönem açısı	$\theta=\{0, 15, 30, 15, \dots, 165\}$
Frangi Süzgeci		
σ	Ölçek parametresi	$\sigma=\{0.5, 1.0, 1.5, \dots, 5.0\}$
β	-	4
c	-	15

Denetimsiz sınıflandırma aşamasında kümeleme parametreleri olarak K-ortalama ve Bulanık C-ortalama yöntemlerinde küme sayısını gösteren parametreler ayrı ayrı 2, 3 ve 4 olarak seçilmektedir. Buna göre farklı küme sayılarına göre elde edilen performans sonuçları Tablo 12’de verilmektedir. Tabloya göre hem K-ortalama kümeleme yönteminde hem de Bulanık C-ortalama kümeleme yönteminde en iyi performansın Gabor süzgecinden sonra küme sayısının 3 olarak alındığı durumda elde edildiği görülmektedir.

Tablo 12. Gabor süzgecinden sonra katı ve bulanık kümeleme yöntemlerinin farklı küme sayısına göre elde edilen ortalama performans sonuçları

STARE VERİTABANI			
	DUY	KES	DOG
Gabor + Bulanık C-ortalama (c=2)	51.59	99.34	95.74
Gabor + Bulanık C-ortalama (c=3)	75.38	96.83	95.18
Gabor + Bulanık C-ortalama (c=4)	87.06	89.79	89.53
Gabor + K-ortalama (c=2)	50.37	99.39	95.70
Gabor + K-ortalama (c=3)	68.69	98.16	95.94
Gabor + K-ortalama (c=4)	84.30	92.05	91.44
DRIVE VERİTABANI			
	DUY	KES	DOG
Gabor + Bulanık C-ortalama (c=2)	54.60	99.01	93.34
Gabor + Bulanık C-ortalama (c=3)	67.76	98.59	95.87
Gabor + Bulanık C-ortalama (c=4)	54.50	99.02	93.34
Gabor + K-ortalama (c=2)	54.51	99.01	93.33
Gabor + K-ortalama (c=3)	61.02	99.05	95.71
Gabor + K-ortalama (c=4)	54.44	99.02	93.33

Denetimsiz piksel sınıflandırma yöntemleri ile STARE ve DRIVE veritabanlarında bulunan tüm görüntüler için farklı süzgeçler kullanılarak elde edilen ortalama başarımlar sonuçları Tablo 13’te verilmektedir. Sonuçlardan da görüldüğü gibi DRIVE veritabanından Gabor filtresinden sonra 3 küme sayısı ile uygulanan Bulanık C-ortalama yöntemi en iyi sonucu vermektedir. STARE veritabanında ise yine Gabor filtresinden sonra 3 küme sayısı ile uygulanan K-ortalama yöntemi en iyi performans sonucunu vermektedir.

Tablo 13. STARE ve DRIVE veritabanlarındaki görüntüler için elde edilen ortalama performans sonuçları (küme sayısı 3 olarak seçilmiştir)

STARE VERİTABANI			
	DUY	KES	DOG
Gabor filter + FCM	75,38	96,83	95,18
Gauss filter + FCM	59,20	97,07	94,16
Frangi filter + FCM	57,62	98,79	95,71
Gabor filter + K-means	68,69	98,16	95,94
Gauss filter + K-means	70,24	97,09	95,16
Frangi filter + K-means	58,98	98,63	95,67
DRIVE VERİTABANI			
	DUY	KES	DOG
Gabor filter + FCM	67,76	98,59	95,87
Gauss filter + FCM	74,29	97,02	95,00
Frangi filter + FCM	69,27	98,39	95,82
Gabor filter + K-means	61,02	99,05	95,71
Gauss filter + K-means	61,79	98,75	95,50
Frangi filter + K-means	68,83	98,43	95,83

Burada elde edilen sonuçlara küme sayısının 3 olarak seçilmesi ideal durum olmakta, küme sayısının 2 olması zayıf bölütleme (under-segmentation) ve küme sayısının 4 olması ise kuvvetli bölütleme (over-segmentation) durumunu ortaya çıkarmaktadır. Literatürde kümeleme yaklaşımlarının kan damarı bölütleme çalışmalarında kullanılmasında genellikle damar ve arkaplan olarak 2 küme sayısı kullanılmaktadır. Ancak bu çalışmada küme sayısının 3 olarak seçilmesi sonuç üzerinde olumlu etki yaratmasına karşın küme sayısının 4 olarak seçilmesi performansı düşüren bir etki oluşturmuştur. Buradan da anlıyoruz ki küme sayısı seçilen bu süzgeçlere göre ideal olarak 3 olmalıdır.

3.5. Denetimli Sınıflandırma Yöntemlerinden Elde Edilen Bulgular

Bu bölümde denetimli sınıflandırma yöntemleri kullanılarak elde edilen performans bulguları ve değerlendirilmesi verilmektedir. Kullanılan görüntüler diğer kan damarı bölütleme yöntemlerine benzer şekilde STARE ve DRIVE veritabanlarından elde edilen görüntülerdir. Öznitelik olarak 2. bölümde verilen ve süzgeç çıktılarına dayanan öznitelikler ile istatistiksel ve renk bileşenlerine dayalı çıkarılan toplamda 16 adet öznitelik kullanılmaktadır. Sınıflandırıcının eğitiminde kullanılacak eğitim verisi, veritabanlarında eğitim için ayrılan görüntülerden damar ve arkaplan üzerinde olan belli sayıda piksel seçilerek elde edilmektedir. Her bir görüntüdeki piksel sayısı çok fazla olduğundan

görüntüden damar üzerinde ve retina üzerinde olacak şekilde rastgele damar ve arkaplana ait pikseller seçilmiştir. Benzer şekilde eğitim kümesindeki tüm görüntülerden belli miktarlarda damar ve arkaplana ait pikseller seçilerek sınıflandırıcı için gerekli eğitim verisi yapılandırılmaktadır. Daha sonra sınıflandırıcıyı eğitim esnasında yönlendirmemek için eğitim verisi rasgele olarak karıştırılmaktadır. Çalışmada sınıflandırma için (arkaplan ve kan damarı) her bir görüntüden damar üzerinde olan 1000 adet ve retina arkaplanı üzerinden 4000 adet piksel olmak üzere toplamda 5000 adet piksel seçilmektedir. STARE veritabanından toplamda 20 adet görüntüden 10 tanesi eğitim için ve eğitimde kullanılmayan diğer 10 adet görüntü ise test için ayrılmaktadır. Böylece STARE veritabanı için toplamda 50000 adet piksel içeren eğitim veriseti yapılandırılmaktadır. Benzer şekilde DRIVE veritabanında toplamda 40 adet görüntüden 20 adet görüntü eğitim için ve eğitimde kullanılmayan diğer 20 adet görüntü ise test için kullanılacak şekilde ayrılmaktadır. Bu veritabanında da STARE veritabanından eğitim veriseti hazırlama işlemine benzer şekilde her bir görüntüden belli sayıda örnek pikseller alınarak 100 bin adet piksel seçilerek yapılandırılmaktadır. Son aşamada her bir veritabanında test için ayrılan görüntülerin her biri teker teker eğitim veriseti kullanılarak eğitilen sınıflandırıcı kullanılarak ikili damar görüntüsüne çevrilmektedir. Veritabanlarına göre seçilen piksel miktarları Tablo 14'te verilmektedir.

Tablo 14. Veritabanı ve seçilen sınıf sayısına göre kullanılan piksel sayıları

	STARE	DRIVE
Görüntü Başına Kan Damarı Piksel Sayısı	1000	1000
Görüntü Başına Arkaplan Piksel Sayısı	4000	4000
Görüntü Başına Toplam Piksel Sayısı	5000	5000
Eğitim Verisetinde Kullanılan Görüntü Sayısı	10	20
Eğitim Verisetinde Kullanılan Piksel Sayısı	50000	100000

Sınıflandırıcı performansını değerlendirmek amacıyla çıkarılan öznitelikler arasında farklı öznitelik grupları oluşturulmuş ve kullanılmıştır. Oluşturulan temel öznitelikler aşağıda verilmektedir:

- F₁: Kontrast sınırlı adaptif histogram eşitleme çıktısı
- F₂: Standart sapma süzgeç çıktısı
- F₃: Gauss süzgeç çıktısı
- F₄: Gabor süzgeç çıktısı
- F₅: Frangi süzgeç çıktısı
- F₆: İstatistiksel öznitelikler (5 adet)
- F₇: Renk bileşenlerine dayalı öznitelikler (6 adet)

Sınıflandırma için kullanılan 7 adet öznitelik gruplarından farklı kombinasyonlarda kullanılarak eğitim ve test işlemi gerçekleştirilmektedir. 7 adet öznitelik grupları için yapılandırılan toplam öznitelik sayısı 16 adet olduğundan bu özniteliklerin tümü ve oluşturulan belirli kombinasyonları denetimli sınıflandırıcılara sunulmuştur. Bunların dışında, 16 adet öznitelik için literatürde yaygın olarak bilinen boyut indirgeme yöntemlerinden Temel Bileşen Analizi (TBA) [99] de uygulanmıştır. 16 adet öznitelik, TBA yöntemine sunulduktan sonra 16 adet öznitelik barındıran yeni bir boyuta geçilmiştir. Burada iki farklı şekilde yeni öznitelik grubu oluşturulmuştur. 1) yeni boyut uzayında tüm özniteliklerin önem derecesine göre sıralandıktan sonra en önemli %95'i alınarak (16 öznitelik 5 öznitelik boyutuna indirgenmiştir) ve 2) yeni boyut uzayında tüm öznitelikler (16 öznitelik) alınarak sınıflandırıcılara sunulmuştur. Elde edilen sınıflandırma bulguları tablolarda verilmektedir.

İlk olarak Doğrusal (Fisher) Ayırtaç Sınıflandırıcı uygulanmış ve STARE ve DRIVE veritabanlarında elde edilen bulgular Tablo 15'te verilmiştir.

Tablo 15. Doğrusal (Fisher) Ayırtaç Sınıflandırıcı ile elde edilen performans bulguları

Öznitelikler	STARE			DRIVE		
	DUY	KES	DOG	DUY	KES	DOG
F1	55.17	99.16	95.97	58.48	98.50	95.03
F3	48.17	99.15	95.45	38.74	99.57	94.34
F4	46.57	99.33	95.52	45.23	99.29	94.64
F5	37.61	99.73	95.10	38.27	99.43	94.15
F6	54.17	99.08	95.83	57.45	97.88	94.47
F1+F2+F3	54.77	98.98	95.80	56.87	98.65	95.04
F1+F2+F4	54.61	99.02	95.83	58.57	98.25	94.82
F1+F2+F5	54.65	98.97	95.78	59.98	98.18	94.88
F3+F4+F5	45.99	99.46	95.56	42.96	99.52	94.65
Tümü (16)	59.73	98.89	96.13	60.46	98.42	95.13
F1+F2	54.94	98.94	95.78	58.17	98.41	94.93
F1+F2+F6	55.10	99.01	95.85	59.18	98.31	94.93
F1+F2+F3+F6	54.94	99.03	95.86	57.96	98.54	95.03
F1+F2+F4+F6	54.69	99.05	95.86	59.50	98.19	94.84
F1+F2+F5+F6	54.75	99.04	95.85	60.70	98.10	94.87
F1+F3+F4+F5+F6	56.13	99.08	95.99	58.22	98.43	94.95
F1+F2+F3+F4+F5+F6	56.32	98.92	95.87	58.81	98.33	94.92
TBA (%95, 5 öznitelik)	47.70	99.58	95.80	47.60	99.34	94.86
TBA (%100, 16 öznitelik)	60.00	98.93	96.18	57.87	98.64	95.09

Tablo 15'ten görüldüğü gibi Doğrusal Ayırtaç Analizi tabanlı sınıflandırıcı ile en tutarlı ve yüksek sınıflandırma sonuçları tüm özniteliklerin kullanıldığı durumda ortaya çıkmaktadır. Kullanılan 16 adet özneliğin TBA yöntemi ile farklı bir boyuta dönüşümünde elde edilen sonuçlar dönüşümden önceki sonuçlar ile birbirine çok yakın çıkmaktadır. STARE veritabanı için TBA yöntemi ile boyut dönüşümü görece daha yüksek başarı ortaya çıkarabilirken DRIVE veritabanı için orijinal öznitelikler daha yüksek başarı ortaya çıkarmaktadır.

En yakın K komşu sınıflandırıcı ile elde edilen performans bulguları Tablo 16'da verilmektedir. K değeri (araştırılacak komşu değeri) 11 olarak ayarlanmıştır.

Tablo 16. En Yakın K Komşu Sınıflandırıcı ile elde edilen performans bulguları (k=11)

Öznitelikler	STARE			DRIVE		
	DUY	KES	DOG	DUY	KES	DOG
F1	66.39	98.62	96.26	70.67	96.77	94.51
F3	68.02	97.06	95.02	65.65	97.79	95.03
F4	62.89	97.87	95.42	64.70	97.57	94.74
F5	66.49	98.21	96.02	68.28	97.29	94.77
F6	58.71	98.78	95.94	69.25	96.89	94.51
F1+F2+F3	69.30	97.82	95.80	71.04	97.45	95.17
F1+F2+F4	65.37	98.21	95.88	71.29	96.91	94.69
F1+F2+F5	64.24	98.54	96.10	72.65	97.06	94.94
F3+F4+F5	68.63	98.16	96.05	71.38	97.66	95.38
Tümü (16)	62.64	98.34	95.90	70.01	98.10	95.66
F1+F2	63.05	98.53	95.98	71.01	96.86	94.63
F1+F2+F6	62.67	98.57	96.05	73.76	96.92	94.92
F1+F2+F3+F6	67.04	98.47	96.22	72.88	97.39	95.27
F1+F2+F4+F6	63.87	98.64	96.16	73.91	97,00	95,00
F1+F2+F5+F6	65.06	98.64	96.26	75.12	97.06	95.16
F1+F3+F4+F5+F6	67.27	98.67	96.40	73.12	97.51	95.39
F1+F2+F3+F4+F5+F6	67.65	98.62	96.39	74.14	97.39	95.37
TBA (%95, 5 öznitelik)	63.87	98.31	95.90	70.48	97.69	95.33
TBA (%100, 16 öznitelik)	62.71	98.38	95.93	69.08	98.23	95.69

Tablo 16'ye göre STARE veritabanında (F1+F2+F3+F4+F5+F6) öznitelik grubu kullanılarak en iyi performans sonucu elde edilmiştir. DRIVE veritabanında ise renk tabanlı öznitelikleri de içeren tüm öznitelikler ile en yüksek doğruluk değerine ulaşılmıştır, ancak duyarlılık değeri bir miktar daha düşük elde edilmiştir. Veritabanı ve görüntüler değişikçe aynı öznitelik grupları ve aynı parametreler ile doğal olarak birbirinden farklı sonuçlar elde edilmektedir. En Yakın K Komşu sınıflandırıcı özniteliklerin uzayda birbirine göre konumsal durumlarını dikkate aldığından TBA yöntemi ile boyut dönüşümü daha iyi sonuç vermektedir.

Naif Bayes Sınıflandırıcı ile elde edilen performans sonuçları Tablo 17'de verilmektedir.

Tablo 17. Naif Bayes Sınıflandırıcı ile elde edilen performans bulguları

	STARE			DRIVE		
Öznitelikler	DUY	KES	DOG	DUY	KES	DOG
F1	61.45	98.80	96.11	65.57	97.75	94.96
F3	61.48	98.13	95.52	55.51	98.89	95.16
F4	56.59	98.73	95.75	55.81	98.70	95.01
F5	48.56	99.43	95.70	51.27	98.91	94.78
F6	64.72	98.52	96.11	68.45	97.12	94.63
F1+F2+F3	67.81	97.21	95.18	69.84	96.81	94.49
F1+F2+F4	65.44	97.51	95.3	69.84	96.63	94.31
F1+F2+F5	60.13	98.08	95.39	66.37	96.98	94.33
F3+F4+F5	62.48	98.39	95.85	62.71	98.37	95.29
Tümü (16)	68.21	97.79	95.72	74.02	96.49	94.54
F1+F2	62.34	97.34	94.90	69.51	96.21	93.91
F1+F2+F6	67.11	98,00	95.83	72.30	96.27	94.20
F1+F2+F3+F6	69.20	97.77	95.77	72.29	96.63	94.52
F1+F2+F4+F6	67.69	97.97	95.86	72.11	96.53	94.42
F1+F2+F5+F6	64.96	98.29	95.94	70.21	96.72	94.43
F1+F3+F4+F5+F6	67.25	98.23	96.05	69.98	97.35	94.98
F1+F2+F3+F4+F5+F6	68.45	98.25	96.06	70.78	97.02	94.75
TBA (%95, 5 öznitelik)	47.31	96.25	92.73	52.94	98.98	94.98
TBA (%100, 16 öznitelik)	58.83	96.40	93.78	61.78	92.23	89.55

Naif Bayes Sınıflandırıcı ile elde edilen sonuçlarda öznitelik gruplarındaki sayı arttıkça performans beklenenden daha düşük çıkmaktadır. STARE veritabanı için %96,11 ve DRIVE veritabanı için %95,29 oranında doğruluk değeri elde edilmiştir. Naif Bayes sınıflandırıcı özniteliklerin dağılımına göre karar vermektedir ve tez çalışmasında Naif Bayes uygulanırken normal dağılım dikkate alınmaktadır. Ayrıca Naif Bayes sınıflandırıcı özniteliklerin birbirinden bağımsız olduğu ön kabulüne dayanır. Sayıları arttıkça özniteliklerin birbirine olan bağımlılıkları artmakta ve dolayısıyla sınıflandırıcı performansı düşmektedir. TBA yöntemi ile boyut dönüşümünde de elde edilen yeni boyut uzayında verinin dağılımındaki varyans maksimum olacak şekilde seçilmektedir ve bu durum Naif Bayes sınıflandırıcısında kullanılan normal dağılım fonksiyonundan uzaklaşılmasına neden olmaktadır. Tablo 17’de elde edilen sonuçlar bunu göstermektedir.

Destek Vektör Makineleri (DVM) Sınıflandırıcı ile elde edilen performans bulguları Tablo 18’de verilmektedir.

Tablo 18. Destek Vektör Makineleri Sınıflandırıcı ile elde edilen performans bulguları

Öznitelikler	STARE			DRIVE		
	DUY	KES	DOG	DUY	KES	DOG
F1	56.26	99.13	96.02	65.55	97.76	94.96
F3	61.65	98.11	95.52	59.33	98.62	95.25
F4	56.24	98.77	95.76	58.88	98.45	95.05
F5	51.90	99.31	95.85	58.11	98.48	94.98
F6	55.54	99.07	95.92	63.79	97.27	94.37
F1+F2+F3	63.25	98.36	95.87	65.63	98.23	95.42
F1+F2+F4	59.96	98.75	96.00	65.97	97.74	95.00
F1+F2+F5	54.81	99.22	96.00	65.00	97.95	95.10
F3+F4+F5	58.57	98.84	95.95	62.82	98.54	95.45
Tümü (16)	64.54	98.61	96.25	68.63	98.13	95.57
F1+F2	58.72	98.79	95.92	65.69	97.61	94.85
F1+F2+F6	59.48	98.88	96.05	68.56	97.50	94.99
F1+F2+F3+F6	63.08	98.55	96.02	67.68	98.03	95.40
F1+F2+F4+F6	60.69	98.80	96.09	68.72	97.61	95.10
F1+F2+F5+F6	56.68	99.14	96.08	67.95	97.80	95.21
F1+F3+F4+F5+F6	60.29	98.89	96.12	66.46	98.16	95.41
F1+F2+F3+F4+F5+F6	60.53	98.82	96.08	67.44	98.10	95.44
TBA (%95, 5 öznitelik)	57.30	99.20	96.22	62.42	98.49	95.36
TBA (%100, 16 öznitelik)	64.76	98.69	96.33	66.13	98.42	95.61

Destek Vektör Makineleri Sınıflandırıcı ile de her iki veritabanındaki görüntüler için en yüksek başarımlar tüm özniteliklerin kullanıldığı durumda elde edilmektedir ve tabloda koyu olarak gösterilmektedir. Destek Vektör Makineleri Sınıflandırıcı birbirinden doğrusal olarak bir hiperdüzlem ile ayrılabilen iki sınıflı bir problemi çözmektedir. Çözüm bulurken olası tüm hiperdüzlemlerden en iyi olanı seçmektedir ve yapısal olarak doğrusal sınıflandırıcı ile benzer karakteristiğe sahiptir. TBA yöntemi ile özniteliklerin varyansının maksimum olduğu uzaya dönüşüm işlemi, DVM sınıflandırıcı için başarıyı beklenildiği gibi daha da arttırmaktadır.

Yapay Sinir Ağları Sınıflandırıcı için elde edilen performans bulguları Tablo 19’da verilmektedir. Yapay Sinir Ağı oluşturulurken nöron sayısının ve gizli katman sayısının en uygun ne olacağı ile tutarlı bir yöntem bulunmamaktadır. Ebetteki giriş katmanındaki nöron sayısı öznitelik sayısı kadar ve çıkış katmanındaki nöron sayısı ise sınıf sayısı kadar olmaktadır. Uygulamalara bakıldığında gizli katman sayısı ve gizli katmanlardaki nöron sayısı 20 olacak şeklinde seçilmesinin uygun olduğu gözlenmiştir. Bu nedenle 2 adet gizli katmana sahip ve her katmanda 20 nöron bulunan ileri beslemeli bir yapay sinir ağı

yapılandırılmış ve eğitilmiştir. Test verisetindeki görüntüler için Tablo 19'daki performans bulguları elde edilmiştir.

Tablo 19. Yapay Sinir Ağları Sınıflandırıcı ile elde edilen performans bulguları

	STARE			DRIVE		
Öznitelikler	DUY	KES	DOG	DUY	KES	DOG
F1	67.20	98.29	96.07	65.58	97.75	94.96
F3	72.02	96.62	94.90	66.52	97.92	95.22
F4	66.69	97.67	95.52	65.42	97.66	94.89
F5	67.82	98.37	96.19	67.98	97.51	94.94
F6	62.08	98.67	96.06	68.55	96.92	94.46
F1+F2+F3	70.32	97.62	95.71	71.77	97.57	95.34
F1+F2+F4	66.10	98.27	96.02	71.65	97,00	94.81
F1+F2+F5	66.02	98.50	96.21	73.09	96.86	94.80
F3+F4+F5	71.16	97.57	95.72	72.09	97.41	95.21
Tümü (16)	70.35	97.83	95.98	74.08	97.46	95.44
F1+F2	63.43	98.48	96,00	71.55	96.95	94.75
F1+F2+F6	64.79	98.53	96.15	73.43	96.40	94.41
F1+F2+F3+F6	70.19	98.17	96.20	72.02	97.34	95.15
F1+F2+F4+F6	67.81	98.28	96.13	72.09	97.15	94.98
F1+F2+F5+F6	64.97	98.52	96.15	73.97	97.07	95.07
F1+F3+F4+F5+F6	68.96	98.51	96.38	72.96	97.36	95.24
F1+F2+F3+F4+F5+F6	67.93	98.27	96.11	71.74	97.60	95.35
TBA (%95, 5 öznitelik)	63.92	98.81	96.37	71.23	97.67	95.38
TBA (%100, 16 öznitelik)	69.78	98.26	96.31	72.87	97.93	95.74

Yapay Sinir Ağları Sınıflandırıcıda elde edilen en yüksek doğruluk değeri STARE veritabanı için %96.38 ve DRIVE veritabanı için %95.74 olarak elde edilmektedir. Bu sonuçlar neredeyse tüm özniteliklerin kullanıldığı durumda elde edilmektedir. YSA ile sınıflandırma yönteminde, veriler doğrusal olmayan bir şekilde (özellikle gizli katman veya katmanlar bulunduğu durumda) birbirinden ayırt edilmektedir. Bu nedenle genel olarak öznitelik sayısının fazla olması daha iyi sonuç beklentisini doğurmaktadır. Tablo 19'da elde edilen en yüksek sonuçların neredeyse tüm özniteliklerin kullanıldığı durumlarda elde edilmesi bu durumu açıklamaktadır. Ancak bu durum bazı durumlarda YSA'nın aşırı öğrenmesine (ezberlemesine) neden olmakta ve yeni gelen test görüntülerinde görece daha düşük sonuçları ortaya çıkarmaktadır. TBA yöntemi ile boyut dönüştürme ve boyut indirgeme sonucunda YSA ile elde edilen performans sonuçları boyut dönüşümünden önceki yüksek başarımlarına yakındır. Çünkü TBA ile verilerin boyutları doğrusal olarak başka bir boyuta dönüştürülmektedir. Ek olarak TBA yöntemi ile boyut indirgeme

yapıldığında öznitelik sayısı değiştiği için kullanılan YSA'nın giriş katmanındaki sinir sayısını değiştirmektedir. Ayrıca yapılandırılan sinir ağının farklı parametrelerle (farklı katman sayısı ve katmanlardaki nöron sayısı ile) eğitimi yapılmış ve test görüntülerinin test edilmesi de gerçekleştirilmiş ancak katman sayısı arttıkça elde edilen performans değerlerinin düştüğü gözlenmiştir.

Tez çalışmasında beş farklı sınıflandırıcı ile denetimli sınıflandırma gerçekleştirilmiştir. Ayrıca daha önceki bölümlerde verildiği gibi kural tabanlı ve denetimsiz sınıflandırma yöntemleri kullanılarak da retinal kan damarları çıkarılmıştır. Her bir yöntemden STARE ve DRIVE veritabanlarında bulunan tüm görüntülerden elde edilen ortalama başarımlar sonuçları tablolar halinde verilmiştir. Tablo 20'de tez çalışmasında uygulanan tüm yöntemlerden elde edilen en iyi sonuçlar özet halinde verilmektedir.

Tablo 20. Tez çalışmasında uygulanan tüm yöntemlerden elde edilen en iyi sonuçların özeti

	STARE			DRIVE		
Yöntem	DUY	KES	DOG	DUY	KES	DOG
Yüzdeli Eşikleme	76.56	96.74	95.19	74.21	97.68	95.60
Otsu	46.42	99.17	95.24	48.27	99.55	95.05
3 Seviyeli Otsu	61.52	98.26	95.54	67.97	98.13	95.48
K-ortalama	68.69	98.16	95.94	68.83	98.43	95.83
BCO	57.62	98.79	95.71	67.76	98.59	95.87
DAA	60.00	98.93	96.18	60.46	98.42	95.13
EYKK	67.27	98.67	96.40	70.01	98.10	95.66
Naif Bayes	64.72	98.52	96.11	62.71	98.37	95.29
DVM	64.76	98.69	96.33	66.13	98.42	95.61
YSA	68.96	98.51	96.38	72.87	97.93	95.74

Tablo 21'de tez çalışmasında uygulanan yöntemin diğer çalışmalarla karşılaştırılması verilmektedir. Tez çalışmasında elde edilen bulgulara göre en yüksek iki sonucu veren yöntem koyu yazılı olarak verilmektedir.

Tablo 21. STARE ve DRIVE veritabanlarındaki görüntülerden elde edilen performans sonuçları ile literatür çalışmalarında elde edilen performans sonuçlarının karşılaştırılması

STARE VERİTABANI			
	DUY	KES	DOG
Önerilen Yöntem (EYKK)	67.27	98.67	96.40
Önerilen Yöntem (YSA)	68.96	98.51	96.38
Hoover ve ark. [15]	67.51	95.67	92.67
Jiang ve ark. [17]	-	-	93.37
Staal ve ark. [64]	-	-	95.16
Nguyen ark. [13]	-	-	93.24
Budai ve ark. [100]	58.00	98.20	93.86
Oliveira ve ark. [101]	80.49	95.92	94.46
Bao ve ark. [102]	78.12	96.12	96.24
Mapayi ve ark. [103]	76.26	96.57	95.10
Roychowdhury ve ark. [79]	77.20	97.30	95.10
Rani ve ark. [104]	74.19	97.47	95.01
Ricci ve ark. [12]	-	-	95.84
Soares ve ark. [65]	-	-	94.80
Marin ve ark. [4]	69.44	98.19	95.26
Sudeshna ve ark. (normal cases) [105]	75.77	97.88	97.30
Sudeshna ve ark. (abnormal cases) [105]	75.49	97.92	97.41
DRIVE VERİTABANI			
	DUY	KES	DOG
Önerilen Yöntem (K-ortalama)	68.83	98.43	95.83
Önerilen Yöntem (BCO)	67.76	98.59	95.87
Chaudhuri ve ark. [3]	-	-	87.73
Lili Xu ve ark. [67]	77.60	-	93.28
Staal ve ark. [64]	-	-	94.42
Nguyen ve ark. [13]	-	-	94.07
Budai ve ark. [100]	64.40	98.70	95.72
Oliveira ve ark. [101]	91.06	94.31	94.02
Mapayi ve ark. [103]	73.13	97.24	95.11
Roychowdhury ve ark. [79]	72.50	98.30	95.20
Rani ve ark. [104]	72.60	96.86	93.70
Shah ve ark. [106]	72.05	98.14	94.79
Ricci ve ark. [12]	-	-	95.63
Lupascu ve ark. [68]	72.00	-	95.97
Soares ve ark. [65]	-	-	94.66
Marin ve ark. [4]	70.67	98.01	94.52
Al-Rawi ve ark. [18]	-	-	95.35
Sudeshna ve ark. [105]	75.48	97.92	96.16

Tablo 21'e göre yöntemde STARE veritabanı için elde edilen en yüksek ortalama doğruluk değeri denetimli sınıflandırma yöntemlerinden olan En Yakın K Komşu (EYKK)

sınıflandırıcı ile %96.40 olarak ve DRIVE veritabanı için elde edilen ortalama doğruluk değeri denetimsiz sınıflandırma (kümeleme) yöntemlerinden olan Bulanık C-ortalama yöntemi ile %95.87 olarak elde edilmiştir. Bu sonuçlar diğer çalışmaların birçoğuna göre daha yüksek olmaktadır. Ayrıca Tablo 21’de performans ölçütü olarak kesinlik değeri verilmiştir. Yüksek kesinlik değeri daha az gürültü yani daha az hatalı tespit demektir. Kesinlik değeri olarak önerilen yöntem diğer çalışmalara göre daha yüksek bir kesinlik değerine sahiptir. Kullanılan STARE ve DRIVE veritabanlarında sırasıyla elde edilen kesinlik değerleri sırasıyla %98.67 ve %98.59 olarak elde edilmiştir. Ayrıca önerilen yöntemin verisetleri üzerinde elde edilen duyarlılık değeri diğer yöntemler ile karşılaştırılabilir düzeydedir. Yüksek duyarlılık değeri tespit edilen kan damarı piksel sayının fazla olması anlamına gelmekle beraber fazladan gürültü de getirmektedir. Bu durum aşırı bölütleme (over-segmentation) durumunu ortaya çıkarmaktadır. Bu durumda sonuç olarak elde edilen doğruluk değeri ve kesinlik değeri azalmaktadır.

3.6. Damar Ölçme Çalışmalarından Elde Edilen Sonuçlar

Bu bölümde kan damarlarının morfolojik özelliklerini ölçüme dayalı görüntü eşleştirme bulguları verilmektedir. Yöntemde DRIVE veritabanından alınan ikili bir damar görüntüsü ve bu görüntünün dönme öteleme ve ölçeklemeye uğratılmış görüntüsü kullanılmıştır. Dönüştürme işlemi olarak görüntünün %20 oranında büyütme ve 15 derece döndürme işlemleri uygulanmıştır ve test görüntüsü elde edilmiştir. Döndürme ve ölçekleme esnasında piksel koordinatlarının konumları değiştiğinden ayrıca bir ölçekleme yapılmamıştır. Referans görüntü için toplamda 291 adet ve test görüntüsü için toplamda 507 adet öznitelik noktası bulunmuştur. Test görüntüsünde öznitelik nokta sayısının fazla olmasının nedeni dönüşüm esnasında oluşan gürültülerdir. Daha sonra asına karşın test görüntüsünde bu sayı 507 olarak elde edilmiştir. Bu fazlalığın nedeni dönüşüm esnasında oluşan artefaklardır.

Karşılaştırma işlemi için belli bir önem derecesine sahip noktalar seçildikten sonra referans görüntüde toplamda 129 adet öznitelik noktası elde edilirken test görüntüsünde 151 adet öznitelik noktası elde edilmiştir. Yine de test görüntüsündeki öznitelik nokta sayısındaki kısmi bir fazlalık oluşabilmektedir. Karşılaştırma işleminde kullanılacak karakteristik matris yapılandırmasında 34 düğüm noktasının birbiri ile aynı olduğu gözlenmiştir. Eşleşen bu öznitelik noktalarından 6 tanesi eşleşme durumu mümkün olmayan düğümler olduğu tespit

edilmiştir. Diğer 28 adet düğüm noktasının 24 tanesi gerçekte birebir eşleşen noktalar olduğu sonucuna ulaşılmıştır. Tez çalışmasında, uzaklık karşılaştırması için kullanılan ortalama açısal hata eşiği radyan cinsinden 0.187 randyan ve ortalama uzaklık hata eşiği 5 piksel olarak seçilmiştir.

3.7. Koşma Süresi ve Algoritma Karmaşıklığı ile ilgili Değerlendirme

Tez kapsamında gerçekleştirilen uygulamalar ve yöntemler Matlab 2014a aracı kullanılarak kodlanmıştır. Kodların çalıştığı makinede Microsoft® Windows 10 (64bit) işletim sistemi ve 3.3 Ghz hızında 2 çekirdekli bir işlemci ve 4GB rastgele erişimli bellek (RAM) bulunmaktadır. Uygulamada önışlemden başlayarak görüntüdeki kan damarları Gauss, Gabor ve Frangi süzgeçleri ile iyileştirilmektedir. Bu süzgeçlerin farklı veritabanlarındaki görüntüler için elde edilen koşma zamanları Tablo 22’de verilmektedir.

Tablo 22. Damar iyileştirme süzgeçlerinin farklı veritabanlarındaki görüntüler için elde edilen koşma süreleri

Süzgeç	STARE (700x605)	DRIVE (768x584)
Gauss Süzgeci	2.10 sn	1.63 sn
Gabor Süzgeci	2.02 sn	1.57 sn
Frangi Süzgeci	4.95 sn	3.93 sn

Kan damarları iyileştirildikten sonra her bir görüntü pikselinin damar ya da arkaplan olarak sınıflandırılması işlemleri gerçekleştirilmektedir. Kural tabanlı piksel sınıflandırma ile denetimsiz piksel sınıflandırma işlemleri (kümeleme, öbekleme) herhangi bir eğitim gerektirmediğinden bir görüntü doğrudan damar bölütleme işlemine tabi tutulabilmektedir. Bir görüntüde bu işlemler için geçen yaklaşık süre de Tablo 23’te verilmektedir.

Tablo 23. Kural tabanlı ve denetimsiz piksel sınıflandırma yöntemlerinin farklı veritabanlarındaki görüntüler için elde edilen koşma süreleri

Yöntem	STARE (700x605)	DRIVE (768x584)
Yüzdeli Eşikleme	2.05 sn	1.49 sn
Otsu	2.18 sn	1.51 sn
Çok Seviyeli Otsu	2.22 sn	1.53 sn
K-ortalama	9.36 sn	5.88 sn
Bulanık C-ortalama	6.77 sn	5.52 sn

Denetimli sınıflandırma yöntemlerinde piksel sınıflandırmak için önce eğitim sonra da eğitilmiş sınıflandırıcı kullanarak test görüntüsünü bölütleme aşaması gerçekleştirilmektedir. Dolayısıyla eğitim için ayrı test için ayrı bir süre gerektirmektedir. Denetimli sınıflandırma yöntemleri için elde edilen koşma süreleri Tablo 24'te verilmektedir. Koşma sürelerinin ölçülmesinde tüm özniteliklerin kullanıldığı durum dikkate alınmaktadır. Eğitim için gereken süreye öznitelik çıkarma işlemi dahil edilmemiştir. Ancak test için ölçülen süreye öznitelik çıkarma işlemi dahil edilmiştir.

Tablo 24. Denetimli piksel sınıflandırma yöntemleri için elde edilen koşma süreleri

Yöntem	Eğitim İşlemi		Test İşlemi	
	STARE	DRIVE	STARE	DRIVE
Doğrusal Ayırtaç Analizi – DAA	<1sn	<1sn	~30sn	~23sn
En Yakın K Komşu (EYKK)	-	-	~450sn	~620sn
Naif Bayes	<1sn	<1sn	~30sn	~24sn
Destek Vektör Makinaları (DVM)	~25sn	~70sn	~48sn	~60sn
Yapay Sinir Ağları (YSA)	~27sn	~34sn	~30sn	~23sn

Son olarak koşma süresi verilen diğer yöntemlerle önerilen çalışmadaki kural tabanlı, denetimsiz ve denetimli sınıflandırma yöntemlerinden elde edilen koşma zamanları Tablo 25'te verilmektedir.

Tablo 25. Koşma Sürelerinin diğer yöntemlerle karşılaştırılması

	Koşma Süreleri		SİSTEM
	STARE	DRIVE	
Önerilen Yöntem (Kural Tabanlı)	2.5 sn	1.9 sn	3.3 GHz CPU, 4GB RAM
Önerilen Yöntem (Denetimsiz Sınıflandırma)	9.1 sn	8.6 sn	3.3 GHz CPU, 4GB RAM
Önerilen Yöntem (Denetimli Sınıflandırma)	30sn – 7dk	30sn – 10dk	3.3 GHz CPU, 4GB RAM
Hoover et al. [2]	5 dk	-	Sun SPARC
Jiang et al. [14]	8-36 sn	8-36 sn	600 MHz PC
Staal et al. [8]	15 dk	15 dk	1 GHz CPU, 1GB RAM
Nguyen et. al. [20]	2.5 sn	2.5 sn	2.4 GHz CPU, 2 GB RAM
Budai et. al. [22]	1.31 sn	1.04 sn	2.3 GHz CPU, 4 GB RAM
Roychowdhury et. al. [26]	6.7 sn	3.11 sn	2.6 GHz CPU, 2 GB RAM
Rani et. al. [27]	3.26 sn	2.58 sn	3.4 GHz CPU, 4GB RAM

Görüldüğü gibi denetimli sınıflandırma kullanan yöntemlerin eğitim için ve test için ayrı ayrı kořma zamanlarına ihtiyaç duyulmaktadır. Bir kere denetimli bir sınıflandırıcı eğitildikten sonra defalarca kullanılabilir, Ancak her test işlemi için test edilecek görüntüye ait öznitelikler çıkarılması gerekmektedir.



4. SONUÇLAR

Medikal görüntülerin bilgisayar destekli teşhis ve tanı sistemlerinde kullanımı son yıllarda çalışılan popüler konulardandır. Bu çalışmada renkli retinal fundus görüntüler kullanılarak kan damarı tespiti işlemi gerçekleştirilmektedir. Elde edilen ikili damar görüntüsünde görüntüyü temsil edecek öznelik noktaları çıkarılarak görüntü çakıştırma işlemi gerçekleştirilmiştir.

Renkli fundus görüntüler bu tez çalışmasında önerilen yöntemlere giriş görüntüsü olarak alınmaktadır. İlk olarak görüntüdeki retina bölgesinin seçilmesi işlemi gerçekleştirilmiş ve kan damarı belirginleştirme adımından önce damar tespit işlemlerinin performansını arttırmak amacıyla bir takım ön işlem adımları uygulanmıştır. Ön işlem olarak retina bölgesi seçme, retina bölgesi genişletme, renk kanallarının (Kırmızı, Yeşil, Mavi) farklı katsayılarla çarpılarak gri seviyeye dönüştürülmesi ve damar ortasında oluşan ışık yansımalarının elenmesi işlemleri gerçekleştirilmiştir. Daha sonra kan damarı belirginleştirme için üç farklı süzgeç geliştirilmiş ve ayrı ayrı uygulanmıştır. Damar iyileştirme süzgeci olarak, iki boyutlu Gauss fonksiyonuna dayanan ve kan damarlarının profiline en uygun olan Gauss süzgeci, Gauss fonksiyonu ve trigonometrik fonksiyonların çarpılması ile elde edilen Gabor süzgeci ile görüntünün ikinci türev bilgisi kullanılarak hesaplanan damarlılık değerine dayalı çok ölçekli Frangi süzgeci geliştirilmiştir. Damar iyileştirme süzgeçlerinin hemen ardından görüntüdeki ayrıntıları daha belirgin hale getirecek bir seviye morfolojik top-hat dönüşümü uygulanmıştır.

Damar iyileştirme süzgeçlerine dayanan öznelikler piksel sınıflandırma yaklaşımı ile sınıflandırılarak ikili kan damarı görüntüsü elde edilmiştir. Piksel sınıflandırma işlemi üç farklı yaklaşımla uygulanmış ve bu yaklaşımlar ile elde edilen bulgular 3. bölümde raporlanmıştır. Piksel sınıflandırma yaklaşımlarından ilki belli bir kurala dayanan ve bu kurala göre oluşturulan bir eşik değeriyle ikili damar görüntüsü elde edilen kural tabanlı piksel sınıflandırma yöntemidir. Bu aşamada uygulaması ve koşma zamanı basit olan yüzdeli eşikleme ile iki ve 3 seviyeli Otsu yöntemleri uygulanmıştır. Buradan elde edilen sonuçlar raporlanmış ve elde edilen sonuçların literatürle karşılaştırılabilir düzeyde ve koşma süresinin gerçek zamanlı uygulamalar için uygun olduğu sonucuna varılmıştır.

Piksel sınıflandırma yaklaşımlarından ikincisi ise herhangi bir şekilde denetimli eğitim işlemi gerektirmeyen ve görüntüden çıkarılan özneliklerin dağılımlarına denetimsiz eğitim

gerçekleştirerek sınıflandırma yapan denetimsiz sınıflandırma (kümeleme, öbekleme) yöntemleridir. Tez çalışmasında denetimsiz sınıflandırma olarak katı kümeleme örneği olan K-ortalama ile esnek kümeleme örneği olan Bulanık C-ortalama yöntemi uygulanmıştır. Burada daha önceki çalışmaların aksine kan damarı ve retina arkaplanı şeklinde iki sınıflı bir kümelemenin yanında ince damar, kalın damar ve arkaplan olarak 3 sınıflı bir kümeleme yaklaşımı uygulanmıştır. Burada küme sayısının 2, 3 ve 4 olarak farklı seçenekler uygulanmış ve en uygun küme sayısının 3 olduğu sonucuna varılmıştır. Bu yaklaşımla elde edilen sonuçların birçok literatür çalışmasından daha iyi seviyede olduğu gözlenmiştir.

Piksel sınıflandırma yaklaşımlarından üçüncüsü denetimli sınıflandırma yöntemleridir. Bu aşamada makine öğrenmesi kullanan bir sınıflandırıcı yapılandırılarak eğitilmekte ve daha sonra da eğitilen sınıflandırıcı modeli kullanılarak test görüntüsündeki pikselleri test edilmektedir. Denetimli sınıflandırıcı olarak burada Doğrusal (Fisher) Ayırtaç Analizi Sınıflandırıcı, Naive Bayes, En Yakın K Komşu, Destek Vektör Makinaları ve Yapay Sinir Ağları sınıflandırıcıları kullanılmıştır. Farklı öznitelik grupları oluşturulmuş ve bu gruplarla eğitim ve test işlemleri gerçekleştirilmiştir. Ayrıca çıkarılan 16 adet öznitelik Temel Bileşen Analizi (TBA) yöntemi ile verilerin dağılımındaki varyansı maksimum yapacak yeni bir boyuta dönüşüm gerçekleştirilmiştir. Bu aşamada ayrıca boyut azaltma işlemi de uygulanmış ve elde edilen bulgular verilerek irdelenmiştir. Performans değerleri olarak STARE veritabanındaki test görüntüleri için en iyi sonuç En Yakın K Koşu sınıflandırıcı ile elde edilmektedir. DRIVE veritabanındaki test görüntüleri için ise en iyi performans sonucu denetimsiz sınıflandırma yöntemleri (Bulanık C-ortalama) ile

Kan damarı bölütleme işleminin ardından ikili damar görüntülerinin ölçülmesi işlemi gerçekleştirilmiştir. Bu amaçla ilk olarak kan damarları inceltirilmiş ve damar öznitelik noktaları bulunmuştur. Daha sonra bu öznitelik noktalarına dayalı retina görüntüsünü temsil eden karakteristik matris elde edilmiştir. Bu karakteristik matris, farklı dönüşümlere uğramış ve aynı kişiye ait retina görüntülerinin karşılaştırılması amacıyla kullanılmıştır. Bu amaçla alınan bir retina görüntüsü için çıkarılan 129 öznitelik noktasından 34 tanesi çıkıştırma işlemi için karakteristik matrise alınmış ve bu noktalardan 26 tanesinin birebir eşleştirilmiş olduğu görülmüştür.

Buna göre tez çalışmasında aşağıda sıralanan maddeler önerilmiştir:

- Damar çıkarma performansını arttıracak şekilde birtakım ön işlemler önerilmiştir.
 - Gri seviye dönüşüm için sadece yeşil bileşen yerine renk kanallarının farklı katsayılarla çarpılması önerilmiştir.

- Retina kenarındaki artefaktları elemek için retina bölgesi genişletme yöntemi önerilmiştir.
- Retina bölgesi seçme için kullanılacak maske denklemi önerilmiştir.
- Kan damarları belirginleştirmek için literatürde farklı çalışmalarda tek başına kullanılan uyum süzgeçleme, çok ölçekli Frangi süzgeci gibi süzgeçler ile morfolojik top-hat dönüşümünün birlikte kullanımı önerilmiştir.
- Kan damarı sınıflandırırken literatürde çoğunlukla damar ya da arkaplan olarak ikili sınıflandırma yaklaşımı takip edilmektedir. Burada iki sınıflı sınıflandırma yerine 3 sınıflı sınıflandırma yaklaşımı önerilmektedir.
- Damar tanıma ve/veya damar çakıştırma için kullanılabilecek bir karakteristik matris yapısı önerilmiştir.
- Kan damarı bölütleme yöntemlerinin performansları, kullanılan görüntülere göre farklılık göstermektedir. Denetimli sınıflandırma yöntemlerinin eğitim veriseti hazırlanırken büyük uğraşlar gerektirmektedir. Bu nedenle herhangi bir denetçi gerektirmeyen bir uygulama yapılmak istendiğinde denetimsiz sınıflandırma yöntemlerinin tezde bahsedilen damar belirginleştirme süzgeçlerinden sonra uygulanması önerilmektedir.
- Hız gerektiren ve görece yüksek başarı gerektirmeyen uygulamalarda kural tabanlı sınıflandırma yöntemlerinin kullanımı önerilmektedir.

Çalışmanın temel katkılarından biri literatürdeki diğer çalışmaların birçoğuna göre daha yüksek başarımlar elde edilmesidir. Bu başarımlar STARE veritabanındaki test görüntüleri için denetimli sınıflandırma yöntemleri ile, DRIVE veritabanındaki test görüntüleri için denetimsiz sınıflandırma ile elde edilmektedir. Bu nedenle farklı sınıflandırıcılar bir arada kullanılmış ve elde edilen performans değerleri karşılaştırmalı olarak verilmiştir.

Çalışmanın katkılarından bir diğeri denetimsiz sınıflandırma yöntemlerinde geleneksel kan damarı bölütleme problemlerinde ikili sınıflandırma yapmak yerine ince damar, kalın damar ve arkaplan olarak üç sınıf içeren sınıflandırma yaparak daha yüksek performans sonuçları elde edilebildiğidir. 3. bölümde de görüldüğü gibi küme sayısının iki yerine 3 olarak alınması performansı arttırırken daha çok küme sayılı kümele işlemlerinde performans yine daha düşük seviyelere inmektedir.

Çalışmanın bir diğeri katkısı retina bölgesi bulmak için uygulanan yöntemdir. Geleneksel yöntemlerde basit eşikleme ile ya da manuel olarak elde edilen maske görüntüleri kullanılmakta iken bu çalışmada geliştirilen retina bölgesi bulma yöntemi ile bu süreç

otomatik bir şekilde gerçekleştirilebilmektedir. Böylece tam otomatik bir sistem mümkün olabilmektedir.

Tez çalışmasında piksel sınıflandırması için üç farklı yaklaşım kullanılmaktadır. Literatüre ve elde edilen sonuçlara bakıldığında denetimli ve denetimsiz sınıflandırma yöntemlerinin diğerlerine göre daha yüksek performans sonuçları verdiği gözlenmektedir. Eğitim içeren sınıflandırma yöntemlerinde test görüntüsünün performansı doğal olarak eğitim kümesindeki örneklerle bağlıdır. Eğitim kümesinin oluşturulması süreci her bir pikselin teker teker damar ya da arkaplan olarak etiketlenmesini gerektirdiğinden çok yorucu ve başlangıç olarak zaman ve maliyet gerektiren bir iştir. Bu nedenle uygulanabilir sistemler için yine bir makine öğrenmesi olan denetimsiz sınıflandırma yöntemlerinin kullanımda daha elverişli olduğu düşünülmektedir. Elbette ki denetimli sınıflandırma yöntemleri ortalamada daha yüksek başarımlı sonucu vermekte ancak getirdiği ekstra maliyetler nedeniyle alternatif yöntemler tercih edilebilmektedir. Bu nedenle herhangi bir eğitim verisetine ihtiyaç duymadan ve denetimli sınıflandırma yöntemlerine yakın başarımlı sonucuna ulaşan yöntemler daha kullanışlı olmaktadır. Bu tez çalışmasında denetimli sınıflandırma yöntemlerine alternatif olarak önerilen ve makine öğrenmesi gerektirmeyen diğer yöntemler çalışmanın bir başka katkısıdır.

Çalışmada getirilen bir diğer yenilik ise kan damarı bölütleme işleminden sonra görüntü tanıma veya çakıştırma için yapılandırılan karakteristik matristir. Oluşturulan bu matris, kan damarlarına dayalı çakıştırma ve görüntü tanıma gibi uygulamalarda görüntünün karakteristiğini temsil edecek benzersiz bir kimlik bilgisi yapılandırmada temel bileşen olarak kullanılabilmektedir.

Diğer taraftan damar iyileştirme süzgeçlerinden sonra gri seviye morfolojik top-hat dönüşümünün uygulanması kan damarlarını oldukça belirgin duruma getirmiş ve bölütlenme aşamasında kolaylık sağlamıştır. Ayrıca deneysel bulgular göstermiştir ki farklı veritabanlarındaki görüntüler için farklı parametreler seçilmesi gerekmektedir. Çünkü farklı veritabanlarındaki görüntülerin elde edilme biçimleri (görüntü alma açısı ve kullanılan kamera) değişiklik göstermektedir.

5. ÖNERİLER

Bu tez çalışmasında renkli retinal fundus görüntülerden kan damarları çıkarma ve daha sonra da görüntü çakıştırma ve görüntü tanıma gibi uygulamalarda kullanılmak üzere retina görüntülerini temsil edecek karakteristik matris yapılandırılması işlemleri gerçekleştirilmektedir.

Retinal görüntülerde kan damarı tespitinde hastalık ve benzeri sebepler kan damarı tespitini zorlaştırmaktadır. Bu çalışmanın devamı olarak bu hastalıklı bölgelerin tespiti yöntemleri ile retinal kan damarı çıkarma yöntemleri birleştirilerek performans artırılabilir.

Bu çalışmada retinal kan damarları tespiti için piksel tabanlı sınıflandırma yöntemleri uygulanmıştır. Ancak piksel tabanlı yaklaşım yerine bölge tabanlı yaklaşımla elde edilen mikro bölgelerin kan damarına ait olup olmadıkları tespiti üzerinde durulması performansı arttıran bir etken olabilir. Gelecek çalışmalarda bölge tabanlı sınıflandırma yöntemleri geliştirilebilir. Seçilecek mikro bölgelerin derin öğrenme vb. algoritmaları ile öğrenilerek damar ya da arkaplana ait olup olmadıkları çıkarılabilir.

Yapılabilecek bir diğer çalışma ise kan damarı tespiti için öznelilik çıkararak ikili veya ince damar, kalın damar, arkaplan şeklinde üç sınıf içeren sınıflandırma yapmak yerine retina üzerinde lezyonlar, optik disk makula, kan damarı, retina arkaplanı şeklinde daha çok sınıf kullanarak eğitim ve sonrasında sınıflandırma işlemi gerçekleştirilebilir. Bu işlem için eğitim kümesinde kullanılmak üzere çok sayıda manuel etiketlenmiş verisetine ihtiyaç duyulmaktadır. Böyle bir veriseti grubu hazırlanabilir.

Bu tez çalışmasında damar iyileştirme ve öznelilik çıkarma olarak kullanılan süzgeçler görüntü başına ortalama 2-3 saniyelik bir süre almaktadır. Bu süzgeçlerin görüntüye uygulanma biçimleri paralel hesaplamaya uygun olduğundan gelecek çalışmalarda öznelilik çıkarma aşamasında paralel hesaplama yöntemleri kullanılabilir.

6. KAYNAKLAR

1. Vyborny, C.J. ve Giger, M.L., Computer Vision and Artificial Intelligence in Mammography, AJR. American Journal of Roentgenology, 162,3 (1994) 699-708.
2. Shen, L., Rangayyan, R.M. ve Desautels, J.L., Detection and Classification of Mammographic Calcifications, International Journal of Pattern Recognition and Artificial Intelligence, 7,06 (1993) 1403-1416.
3. Chaudhuri, S., Chatterjee, S., Katz, N., Nelson, M. ve Goldbaum, M., Detection of Blood Vessels in Retinal Images Using Two-Dimensional Matched Filters, IEEE Transactions on Medical Imaging, 8,3 (1989) 263-269.
4. Marín, D., Aquino, A., Gegúndez-Arias, M.E. ve Bravo, J.M., A New Supervised Method for Blood Vessel Segmentation in Retinal Images by Using Gray-Level and Moment Invariants-Based Features, IEEE Transactions on Medical Imaging, 30,1 (2011) 146-158.
5. Fraz, M.M., Remagnino, P., Hoppe, A., Uyyanonvara, B., Rudnicka, A.R., Owen, C.G. ve Barman, S.A., Blood Vessel Segmentation Methodologies in Retinal Images – a Survey, Computer Methods and Programs in Biomedicine, 108,1 (2012) 407-433.
6. <http://www.worldaroundus.org.uk> The World Around Us. 28 Eylül 2017.
7. www.topcon-medical.eu Topcon Medical. 28 Eylül 2017.
8. www.opsweb.org Ophthalmic Photographers' Society. 28 Eylül 2017.
9. Martinez-Perez, M.E., Hughes, A.D., Thom, S.A., Bharath, A.A. ve Parker, K.H., Segmentation of Blood Vessels from Red-Free and Fluorescein Retinal Images, Medical Image Analysis, 11,1 (2007) 47-61.
10. <http://www.ces.clemson.edu/~ahoover/stare/> Structured Analysis of the Retina Stare. 28 Eylül 2017.
11. www.jamanetwork.com The Jama Network. 28 Eylül 2017.
12. Ricci, E. ve Perfetti, R., Retinal Blood Vessel Segmentation Using Line Operators and Support Vector Classification, IEEE Transactions on Medical Imaging, 26,10 (2007) 1357-1365.
13. Nguyen, U.T., Bhuiyan, A., Park, L.A. ve Ramamohanarao, K., An Effective Retinal Blood Vessel Segmentation Method Using Multi-Scale Line Detection, Pattern Recognition, 46,3 (2013) 703-715.
14. Otsu, N., A Threshold Selection Method from Gray-Level Histograms, IEEE Transactions on Systems, Man, and Cybernetics, 9,1 (1979) 62-66.

15. Hoover, A., Kouznetsova, V. ve Goldbaum, M., Locating Blood Vessels in Retinal Images by Piecewise Threshold Probing of a Matched Filter Response, IEEE Transactions on Medical Imaging, 19,3 (2000) 203-210.
16. Gang, L., Chutatape, O. ve Krishnan, S.M., Detection and Measurement of Retinal Vessels in Fundus Images Using Amplitude Modified Second-Order Gaussian Filter, IEEE Transactions on Biomedical Engineering, 49,2 (2002) 168-172.
17. Jiang, X. ve Mojon, D., Adaptive Local Thresholding by Verification-Based Multithreshold Probing with Application to Vessel Detection in Retinal Images, IEEE Transactions on Pattern Analysis and Machine Intelligence, 25,1 (2003) 131-137.
18. Al-Rawi, M., Qutaishat, M. ve Arrar, M., An Improved Matched Filter for Blood Vessel Detection of Digital Retinal Images, Computers in Biology and Medicine, 37,2 (2007) 262-267.
19. Cinsdikici, M.G. ve Aydın, D., Detection of Blood Vessels in Ophthalmoscope Images Using Mf/Ant (Matched Filter/Ant Colony) Algorithm, Computer Methods and Programs in Biomedicine, 96,2 (2009) 85-95.
20. Zhang, B., Zhang, L., Zhang, L. ve Karray, F., Retinal Vessel Extraction by Matched Filter with First-Order Derivative of Gaussian, Computers in Biology and Medicine, 40,4 (2010) 438-445.
21. Wang, Y., Ji, G., Lin, P. ve Trucco, E., Retinal Vessel Segmentation Using Multiwavelet Kernels and Multiscale Hierarchical Decomposition, Pattern Recognition, 46,8 (2013) 2117-2133.
22. Odstrcilik, J., Kolar, R., Budai, A., Horneegger, J., Jan, J., Gazarek, J., Kubena, T., Cernosek, P., Svoboda, O. ve Angelopoulou, E., Retinal Vessel Segmentation by Improved Matched Filtering: Evaluation on a New High-Resolution Fundus Image Database, IET Image Processing, 7,4 (2013) 373-383.
23. <https://www5.cs.fau.de/research/data/fundus-images/> Hrf Database. 28 Eylül 2017.
24. Akram, M.U. ve Khan, S.A., Multilayered Thresholding-Based Blood Vessel Segmentation for Screening of Diabetic Retinopathy, Engineering with Computers, 29,2 (2013) 165-173.
25. Liu, I. ve Sun, Y., Recursive Tracking of Vascular Networks in Angiograms Based on the Detection-Deletion Scheme, IEEE Transactions on Medical Imaging, 12,2 (1993) 334-341.
26. Zhou, L., Rzeszotarski, M.S., Singerman, L.J. ve Chokreff, J.M., The Detection and Quantification of Retinopathy Using Digital Angiograms, IEEE Transactions on Medical Imaging, 13,4 (1994) 619-626.

27. Chutatape, O., Zheng, L. ve Krishnan, S.M., Retinal Blood Vessel Detection and Tracking by Matched Gaussian and Kalman Filters, Engineering in Medicine and Biology Society, Proceedings of the 20th Annual International Conference of the IEEE, 1998, 6, 3144-3149.
28. Poon, K., Hamarneh, G. ve Abugharbieh, R., Live-Vessel: Extending Livewire for Simultaneous Extraction of Optimal Medial and Boundary Paths in Vascular Images, International Conference on Medical Image Computing and Computer-Assisted Intervention, 2007, 444-451.
29. Frangi, A.F., Niessen, W.J., Vincken, K.L. ve Viergever, M.A., Multiscale Vessel Enhancement Filtering, International Conference on Medical Image Computing and Computer-Assisted Intervention, 1998, 130-137.
30. Barrett, W.A. ve Mortensen, E.N., Interactive Live-Wire Boundary Extraction, Medical Image Analysis, 1,4 (1997) 331-341.
31. Delibasis, K.K., Kechriniotis, A.I., Tsonos, C. ve Assimakis, N., Automatic Model-Based Tracing Algorithm for Vessel Segmentation and Diameter Estimation, Computer Methods and Programs in Biomedicine, 100,2 (2010) 108-122.
32. Yin, Y., Adel, M. ve Bourennane, S., Retinal Vessel Segmentation Using a Probabilistic Tracking Method, Pattern Recognition, 45,4 (2012) 1235-1244.
33. Zana, F. ve Klein, J.-C., Segmentation of Vessel-Like Patterns Using Mathematical Morphology and Curvature Evaluation, IEEE Transactions on Image Processing, 10,7 (2001) 1010-1019.
34. Mendonca, A.M. ve Campilho, A., Segmentation of Retinal Blood Vessels by Combining the Detection of Centerlines and Morphological Reconstruction, IEEE Transactions on Medical Imaging, 25,9 (2006) 1200-1213.
35. Yang, Y., Huang, S. ve Rao, N., An Automatic Hybrid Method for Retinal Blood Vessel Extraction, International Journal of Applied Mathematics and Computer Science, 18,3 (2008) 399-407.
36. Sun, K., Chen, Z., Jiang, S. ve Wang, Y., Morphological Multiscale Enhancement, Fuzzy Filter and Watershed for Vascular Tree Extraction in Angiogram, Journal of Medical Systems, 35,5 (2011) 811-824.
37. Fraz, M.M., Barman, S.A., Remagnino, P., Hoppe, A., Basit, A., Uyyanonvara, B., Rudnicka, A.R. ve Owen, C.G., An Approach to Localize the Retinal Blood Vessels Using Bit Planes and Centerline Detection, Computer Methods and Programs in Biomedicine, 108,2 (2012) 600-616.
38. Martínez-Pérez, M.E., Hughes, A.D., Stanton, A.V., Thom, S.A., Bharath, A.A. ve Parker, K.H., Retinal Blood Vessel Segmentation by Means of Scale-Space Analysis and Region Growing, International Conference on Medical Image Computing and Computer-Assisted Intervention, 1999, 90-97.

39. Martinez-Perez, M.E., Hughes, A.D., Thom, S.A. ve Parker, K.H., Improvement of a Retinal Blood Vessel Segmentation Method Using the Insight Segmentation and Registration Toolkit (Itk), Engineering in Medicine and Biology Society (EMBS), 29th Annual International Conference of the IEEE, 2007, 892-895.
40. Wink, O., Niessen, W.J. ve Viergever, M.A., Multiscale Vessel Tracking, IEEE Transactions on Medical Imaging, 23,1 (2004) 130-133.
41. Sofka, M. ve Stewart, C.V., Retinal Vessel Centerline Extraction Using Multiscale Matched Filters, Confidence and Edge Measures, IEEE Transactions on Medical Imaging, 25,12 (2006) 1531-1546.
42. Farnell, D.J., Hatfield, F., Knox, P., Reakes, M., Spencer, S., Parry, D. ve Harding, S., Enhancement of Blood Vessels in Digital Fundus Photographs Via the Application of Multiscale Line Operators, Journal of the Franklin Institute, 345,7 (2008) 748-765.
43. Moghimirad, E., Rezatofighi, S.H. ve Soltanian-Zadeh, H., Retinal Vessel Segmentation Using a Multi-Scale Medialness Function, Computers in Biology and Medicine, 42,1 (2012) 50-60.
44. Fathi, A. ve Naghsh-Nilchi, A.R., Automatic Wavelet-Based Retinal Blood Vessels Segmentation and Vessel Diameter Estimation, Biomedical Signal Processing and Control, 8,1 (2013) 71-80.
45. Vermeer, K.A., Vos, F.M., Lemij, H.G. ve Vossepoel, A.M., A Model Based Method for Retinal Blood Vessel Detection, Computers in Biology and Medicine, 34,3 (2004) 209-219.
46. Lam, B.S.Y. ve Yan, H., A Novel Vessel Segmentation Algorithm for Pathological Retina Images Based on the Divergence of Vector Fields, IEEE Transactions on Medical Imaging, 27,2 (2008) 237-246.
47. Lam, B.S., Gao, Y. ve Liew, A.W.-C., General Retinal Vessel Segmentation Using Regularization-Based Multiconcavity Modeling, IEEE Transactions on Medical Imaging, 29,7 (2010) 1369-1381.
48. Espona, L., Carreira, M.J., Ortega, M. ve Penedo, M.G., A Snake for Retinal Vessel Segmentation, Iberian Conference on Pattern Recognition and Image Analysis, 2007, 178-185.
49. Al-Diri, B. ve Hunter, A., A Ribbon of Twins for Extracting Vessel Boundaries, The 3rd European Medical and Biological Engineering Conference EMBEC'05, 2005.
50. Al-Diri, B., Hunter, A. ve Steel, D., An Active Contour Model for Segmenting and Measuring Retinal Vessels, IEEE Transactions on Medical Imaging, 28,9 (2009) 1488-1497.

51. Zhao, Y., Rada, L., Chen, K., Harding, S.P. ve Zheng, Y., Automated Vessel Segmentation Using Infinite Perimeter Active Contour Model with Hybrid Region Information with Application to Retinal Images, IEEE Transactions on Medical Imaging, 34,9 (2015) 1797-1807.
52. Chan, T.F. ve Vese, L.A., Active Contours without Edges, IEEE Transactions on Image Processing, 10,2 (2001) 266-277.
53. Sum, K. ve Cheung, P.Y., Vessel Extraction under Non-Uniform Illumination: A Level Set Approach, IEEE Transactions on Biomedical Engineering, 55,1 (2008) 358-360.
54. Dizdaroğlu, B., Ataer-Cansizoglu, E., Kalpathy-Cramer, J., Keck, K., Chiang, M.F. ve Erdogmus, D., Structure-Based Level Set Method for Automatic Retinal Vasculature Segmentation, EURASIP Journal on Image and Video Processing, 2014,1 (2014) 39.
55. Roska, T. ve Chua, L.O., The Cnn Universal Machine: An Analogic Array Computer, IEEE Transactions on Circuits and Systems II: Analog and Digital Signal Processing, 40,3 (1993) 163-173.
56. Ibanez, L., Schroeder, W., Ng, L. ve Cates, J., The ITK Software Guide, 2005.
57. Alonso-Montes, C., Vilarino, D. ve Penedo, M., Cnn-Based Automatic Retinal Vascular Tree Extraction, Cellular Neural Networks and Their Applications, 9th International Workshop, 2005, 61-64.
58. Alonso-Montes, C., Vilarino, D., Dudek, P. ve Penedo, M., Fast Retinal Vessel Tree Extraction: A Pixel Parallel Approach, International Journal of Circuit Theory and Applications, 36,5-6 (2008) 641-651.
59. Vilariño, D.L. ve Rekeczky, C., Pixel-Level Snakes on the Cnnum: Algorithm Design, on-Chip Implementation and Applications, International Journal of Circuit Theory and Applications, 33,1 (2005) 17-51.
60. Vilariño, D.L. ve Rekeczky, C., Implementation of a Pixel-Level Snake Algorithm on a Cnnum-Based Chip Set Architecture, IEEE Transactions on Circuits and Systems I: Regular Papers, 51,5 (2004) 885-891.
61. Nekovei, R. ve Sun, Y., Back-Propagation Network and Its Configuration for Blood Vessel Detection in Angiograms, IEEE Transactions on Neural Networks, 6,1 (1995) 64-72.
62. Sinthanayothin, C., Boyce, J.F., Cook, H.L. ve Williamson, T.H., Automated Localisation of the Optic Disc, Fovea, and Retinal Blood Vessels from Digital Colour Fundus Images, British Journal of Ophthalmology, 83,8 (1999) 902-910.
63. Niemeijer, M., Staal, J., van Ginneken, B., Loog, M. ve Abramoff, M.D., Comparative Study of Retinal Vessel Segmentation Methods on a New Publicly Available Database, Medical Imaging: Image Processing, 2004, 5370, 648-657.

64. Staal, J., Abràmoff, M.D., Niemeijer, M., Viergever, M.A. ve Van Ginneken, B., Ridge-Based Vessel Segmentation in Color Images of the Retina, IEEE Transactions on Medical Imaging, 23,4 (2004) 501-509.
65. Soares, J.V., Leandro, J.J., Cesar, R.M., Jelinek, H.F. ve Cree, M.J., Retinal Vessel Segmentation Using the 2-D Gabor Wavelet and Supervised Classification, IEEE Transactions on Medical Imaging, 25,9 (2006) 1214-1222.
66. Osareh, A. ve Shadgar, B., Automatic Blood Vessel Segmentation in Color Images of Retina, Iranian Journal of Science and Technology, 33,B2 (2009) 191-206.
67. Xu, L. ve Luo, S., A Novel Method for Blood Vessel Detection from Retinal Images, Biomedical Engineering Online, 9,14 (2010) 1-10.
68. Lupascu, C.A., Tegolo, D. ve Trucco, E., Fabc: Retinal Vessel Segmentation Using Adaboost, IEEE Transactions on Information Technology in Biomedicine, 14,5 (2010) 1267-1274.
69. You, X., Peng, Q., Yuan, Y., Cheung, Y.-m. ve Lei, J., Segmentation of Retinal Blood Vessels Using the Radial Projection and Semi-Supervised Approach, Pattern Recognition, 44,10-11 (2011) 2314-2324.
70. Fraz, M.M., Remagnino, P., Hoppe, A., Uyyanonvara, B., Rudnicka, A.R., Owen, C.G. ve Barman, S.A., An Ensemble Classification-Based Approach Applied to Retinal Blood Vessel Segmentation, IEEE Transactions on Biomedical Engineering, 59,9 (2012) 2538-2548.
71. <https://blogs.kingston.ac.uk/retinal/chasedb1/> Chase_Db1 - Retinal Image Database | Retinal Image Analysis. 28 Eylül 2017.
72. Kharghanian, R. ve Ahmadyfard, A., Retinal Blood Vessel Segmentation Using Gabor Wavelet and Line Operator, International Journal of Machine Learning and Computing, 2,5 (2012) 593-597.
73. Cheng, E., Du, L., Wu, Y., Zhu, Y.J., Megalooikonomou, V. ve Ling, H., Discriminative Vessel Segmentation in Retinal Images by Fusing Context-Aware Hybrid Features, Machine Vision and Applications, 25,7 (2014) 1779-1792.
74. Franklin, S.W. ve Rajan, S.E., Computerized Screening of Diabetic Retinopathy Employing Blood Vessel Segmentation in Retinal Images, Biocybernetics and Biomedical Engineering, 34,2 (2014) 117-124.
75. Melinščak, M., Prentašić, P. ve Lončarić, S., Retinal Vessel Segmentation Using Deep Neural Networks, 10th International Conference on Computer Vision Theory and Applications(VISAPP), 2015.
76. Wang, S., Yin, Y., Cao, G., Wei, B., Zheng, Y. ve Yang, G., Hierarchical Retinal Blood Vessel Segmentation Based on Feature and Ensemble Learning, Neurocomputing, 149 (2015) 708-717.

77. Li, Q., Feng, B., Xie, L., Liang, P., Zhang, H. ve Wang, T., A Cross-Modality Learning Approach for Vessel Segmentation in Retinal Images, IEEE Transactions on Medical Imaging, 35,1 (2016) 109-118.
78. Fu, H., Xu, Y., Wong, D.W.K. ve Liu, J., Retinal Vessel Segmentation Via Deep Learning Network and Fully-Connected Conditional Random Fields, , IEEE 13th International Symposium on Biomedical Imaging (ISBI), 2016, 698-701.
79. Roychowdhury, S., Koozekanani, D.D. ve Parhi, K.K., Blood Vessel Segmentation of Fundus Images by Major Vessel Extraction and Subimage Classification, IEEE Journal of Biomedical and Health Informatics, 19,3 (2015) 1118-1128.
80. Zhu, C., Zou, B., Zhao, R., Cui, J., Duan, X., Chen, Z. ve Liang, Y., Retinal Vessel Segmentation in Colour Fundus Images Using Extreme Learning Machine, Computerized Medical Imaging and Graphics, 55 (2017) 68-77.
81. Toliaş, Y.A. ve Panas, S.M., A Fuzzy Vessel Tracking Algorithm for Retinal Images Based on Fuzzy Clustering, IEEE Transactions on Medical Imaging, 17,2 (1998) 263-273.
82. Salem, S.A., Salem, N.M. ve Nandi, A.K., Segmentation of Retinal Blood Vessels Using a Novel Clustering Algorithm (Racal) with a Partial Supervision Strategy, Medical & Biological Engineering & Computing, 45,3 (2007) 261-273.
83. Kande, G.B., Subbaiah, P.V. ve Savithri, T.S., Unsupervised Fuzzy Based Vessel Segmentation in Pathological Digital Fundus Images, Journal of Medical Systems, 34,5 (2010) 849-858.
84. Dey, N., Roy, A.B., Pal, M. ve Das, A., Fcm Based Blood Vessel Segmentation Method for Retinal Images, International Journal of Computer Science and Network, 1,3 (2012) 1-5.
85. Emary, E., Zawbaa, H.M., Hassanien, A.E., Schaefer, G. ve Azar, A.T., Retinal Vessel Segmentation Based on Possibilistic Fuzzy C-Means Clustering Optimised with Cuckoo Search, International Joint Conference on Neural Networks (IJCNN), 2014, 1792-1796.
86. Saffarzadeh, V.M., Osareh, A. ve Shadgar, B., Vessel Segmentation in Retinal Images Using Multi-Scale Line Operator and K-Means Clustering, Journal of Medical Signals and Sensors, 4,2 (2014) 122-129.
87. Yavuz, Z. ve Köse, C., Blood Vessel Extraction in Color Retinal Fundus Images with Enhancement Filtering and Unsupervised Classification, Journal of Healthcare Engineering, 2017.
88. Niemeijer, M., Staal, J., Ginneken, B., Loog, M. ve Abramoff, M., Drive: Digital Retinal Images for Vessel Extraction, Methods for Evaluating Segmentation and Indexing Techniques Dedicated to Retinal Ophthalmology, 2004.
89. http://www.eyecharity.com/aria_online/ Aria Online, Retinal Image Archive. 28 Eylül 2017.

90. <http://www.retinacheck.org/datasets> Retinacheck. 28 Eylül 2017.
91. https://en.wikipedia.org/wiki/Top-hat_transform Morphological Top-Hat Transform. 28 Eylül 2017.
92. Fawcett, T., An Introduction to Roc Analysis, Pattern Recognition Letters, 27,8 (2006) 861-874.
93. MacQueen, J., Some Methods for Classification and Analysis of Multivariate Observations, Proceedings of the Fifth Berkeley Symposium on Mathematical Statistics and Probability, 1967, 1, 281-297.
94. Fisher, R.A., The Use of Multiple Measurements in Taxonomic Problems, Annals of human genetics, 7,2 (1936) 179-188.
95. Cortes, C. ve Vapnik, V., Support-Vector Networks, Machine learning, 20,3 (1995) 273-297.
96. Vapnik, V., The Nature of Statistical Learning Theory, Springer Science & Business Media, 2013.
97. Guo, Z. ve Hall, R.W., Parallel Thinning with Two-Subiteration Algorithms, Communications of the ACM, 32,3 (1989) 359-373.
98. Maurer, C.R., Qi, R. ve Raghavan, V., A Linear Time Algorithm for Computing Exact Euclidean Distance Transforms of Binary Images in Arbitrary Dimensions, IEEE Transactions on Pattern Analysis and Machine Intelligence, 25,2 (2003) 265-270.
99. Krzanowski, W., Principles of Multivariate Analysis, 23, OUP Oxford, 2000.
100. Budai, A., Bock, R., Maier, A., Hornegger, J. ve Michelson, G., Robust Vessel Vегmentation in Fundus Images, International journal of biomedical imaging, 2013.
101. Oliveira, W.S., Teixeira, J.V., Ren, T.I., Cavalcanti, G.D. ve Sijbers, J., Unsupervised Retinal Vessel Segmentation Using Combined Filters, PloS one, 11,2 (2016) e0149943.
102. Bao, X.-R., Ge, X., She, L.-H. ve Zhang, S., Segmentation of Retinal Blood Vessels Based on Cake Filter, BioMed research international, 2015.
103. Mapayi, T., Viriri, S. ve Tapamo, J.-R., Adaptive Thresholding Technique for Retinal Vessel Segmentation Based on Glcm-Energy Information, Computational and mathematical methods in medicine, 2015.
104. Rani, P., Priyadarshini, N., Rajkumar, E. ve Rajamani, K., Retinal Vessel Segmentation under Pathological Conditions Using Supervised Machine Learning, International Conference on Systems in Medicine and Biology (ICSMB) 2016, 62-66.

105. Kar, S.S. ve Maity, S.P., Blood Vessel Extraction and Optic Disc Removal Using Curvelet Transform and Kernel Fuzzy C-Means, Computers in Biology and Medicine, 70 (2016) 174-189.
106. Shah, S.A.A., Tang, T.B., Faye, I. ve Laude, A., Blood Vessel Segmentation in Color Fundus Images Based on Regional and Hessian Features, Graefe's Archive for Clinical and Experimental Ophthalmology, 255,8 (2017) 1525-1533.



ÖZGEÇMİŞ

Zafer YAVUZ, 1981'de Trabzon'un Maçka ilçesinde doğdu. İlkokulu Trabzon 24 Şubat İlkokulunda, ortaokulu Trabzon Cumhuriyet Ortaokulunda ve liseyi Trabzon Fatih Lisesinin Yabancı Dil Ağırlıklı bölümünde tamamladı. 1999 yılında Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümüne başladı ve bu bölümden 2004 yılında mezun oldu. Aynı yıl Karadeniz Teknik Üniversitesi Bilgisayar Mühendisliği Bölümünde yüksek lisansa başladı ve 2007 yılında Yüksek Lisans eğitimini tamamladı. Daha sonra 2008 yılında KTÜ Bilgisayar Mühendisliği bölümünde doktora eğitimine başladı. 2005 yılından günümüze kadar KTÜ Bilgisayar Mühendisliği bölümde sırasıyla Arş. Gör., Uzman ve Öğr. Gör. olarak görev aldı. Doktora çalışmaları boyunca çeşitli ulusal ve uluslararası makale ve bildiriler yapan Zafer YAVUZ, halen KTÜ Bilgisayar Mühendisliği Bölümde Öğr. Gör. olarak çalışmakta ve evli olup iyi derecede İngilizce bilmektedir.

SCI/SCI-E indekslerine giren dergilerde yayınlanan makaleler

Yavuz Z., Köse C., "Blood Vessel Extraction in Color Retinal Fundus Images with Enhancement Filtering and Unsupervised Classification", JOURNAL OF HEALTHCARE ENGINEERING, 2017.

Hakemli konferans/sempozyumların bildiri kitaplarında yer alan bazı yayınlar

Yavuz Z., Köse C., "A Retinal Image Identification Method using Blood Vessel Topological Information", 2017 Tıp Teknolojileri Kongresi, TIPTEKNO'17, TRABZON, TÜRKİYE, 12-14 Ekim 2017, cilt.1, no.1, ss.104-108.

Yavuz Z., Köse C., "Retinal fundus image registration using bifurcation and crossover points", Signal Processing and Communication Application Conference (SIU), 2016 24th, ZONGULDAK, TÜRKİYE, 16-19 Mayıs 2016, vol.3, pp.1485-1488.

Yavuz Z., Köse C., "A Novel Method for Selecting Region of Interest in Color Retinal Fundus Images", XX. Biyomedikal Mühendisliği Ulusal Toplantısı (Uluslararası Katılımlı), İZMİR, TÜRKİYE, 3-5 Kasım 2016, vol.1, pp.96-99.

Yavuz Z., Köse C., "Vessel Segmentation In Retinal Images Using Multiscale Image Enhancement And Clustering", IEEE 23. Sinyal İşleme ve İletişim Uygulamaları Kurultayı, MALATYA, TÜRKİYE, 16-19 Mayıs 2015, cilt.1, ss.581-584.

Yavuz Z., Köse C., "Retinal Blood Vessel Extraction using image enhancement and Fuzzy C-means Clustering", The 4th International Fuzzy Systems Symposium, İSTANBUL, TÜRKİYE, 5-6 Kasım 2015, vol.1, no.1, pp.255-259.

Yavuz Z., Köse C., "Blood Vessel Segmentation From Retinal Images Based On Enhancement Methods", Signal Processing and Communications Applications Conference (SIU), 2014 22nd, TRABZON, TÜRKİYE, 23-25 Nisan 2014, cilt.1, ss.907-910.

Yavuz Z., Köse C., "Retinal Blood Vessel Segmentation Using Gabor Filter And Top-Hat Transform", Signal Processing and Communications Applications (SIU), 2011 IEEE 19th Conference on, ANTALYA, TÜRKİYE, 20-22 Nisan 2011, cilt.1, ss.546-549.

Yavuz Z., Köse C., "Retinal Blood Vessels for the Segmentation Two-Dimensional Comparison of Filter Response and Gabor Filter Method", Electrical-Electronics and Computer Engineering Symposium, BURSA, TÜRKİYE, 2-5 Kasım 2010, vol.1, no.1, pp.1-4.

Yavuz Z., İkibas C., Köse C., "A Simple Analytic Approach For Tracking Retinal Vessels And Measuring Their Diameters", First International Conference on Bioinformatics (BIOINFORMATICS 2010), Valencia, İSPANYA, 20-23 Ocak 2010, vol.1, pp.13-18.

Yavuz Z., İkibas C., Şevik U., Köse C., "Retinal Görüntülerde Optik Diskin Otomatik Olarak Çıkartılması İçin Bir Yöntem ", 5th International Advanced Technologies Symposium, KARABÜK, TÜRKİYE, 13-15 Mayıs 2009, pp.8-8.