



**GÖRÜNTÜ İŞLEME VE MAKİNE ÖĞRENMESİNE DAYALI
DİYABETİK RETİNOPATİ HASTALIĞI
TEŞHİSİ VE SINIFLANDIRILMASI
Kemal ADEM**

**Doktora Tezi
Mekatronik Mühendisliği Anabilim Dalı
Doç. Dr. Mahmut HEKİM
2017
Her hakkı saklıdır**

T.C.
GAZİOSMANPAŞA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK ANABİLİM DALI

DOKTORA TEZİ

GÖRÜNTÜ İŞLEME VE MAKİNE ÖĞRENMESİNE DAYALI
DİYABETİK RETİNOPATİ HASTALIĞI
TEŞHİSİ VE SINIFLANDIRILMASI

Kemal ADEM

TOKAT

2017

Her hakkı saklıdır

Kemal ADEM tarafından hazırlanan “Görüntü İşleme ve Makine Öğrenmesine Dayalı Diyabetik Retinopati Hastalığı Teşhisi ve Sınıflandırılması” adlı tez çalışmasının savunma sınavı 4 TEMMUZ 2017 tarihinde yapılmış olup aşağıda verilen Jüri tarafından Oy Birliği / Oy Çokluğu ile Gaziosmanpaşa Üniversitesi Fen Bilimleri Enstitüsü MEKATRONİK MÜHENDİSLİĞİ ANA BİLİM DALI 'nda DOKTORA TEZİ olarak kabul edilmiştir.

Jüri Üyeleri

Danışman
Doç. Dr. Mahmut HEKİM
Gaziosmanpaşa Üniversitesi
Üye
Prof. Dr. Ali KARCI
İnönü Üniversitesi
Üye
Doç. Dr. Selim DEMİR
Gaziosmanpaşa Üniversitesi
Üye
Yrd. Doç. Dr. Cem EMEKSİZ
Gaziosmanpaşa Üniversitesi
Üye
Yrd. Doç. Dr. Erdiç AVAROĞLU
Mersin Üniversitesi

İmza


.....

.....

.....

.....

.....

ONAY

Prof. Dr. Eubekir ALTUNTAS
Fen Bilimleri Enstitüsü Müdürü
04/07/2017

TEZ BEYANI

Tez yazım kurallarına uygun olarak hazırlanan bu tezin yazılmasında bilimsel ahlak kurallarına uyulduğunu, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezin içerdği yenilik ve sonuçların başka bir yerden alınmadığını, kullanılan verilerde herhangi bir tahrifat yapılmadığını, tezin herhangi bir kısmının bu üniversite veya başka bir üniversitedeki başka bir tez çalışması olarak sunulmadığını beyan ederim.

Kemal ADEM

04.07.2017

ÖZET

DOKTORA TEZİ

GÖRÜNTÜ İŞLEME VE MAKİNE ÖĞRENMESİNE DAYALI DİYABETİK RETİNOPATİ HASTALIĞI TEŞHİSİ VE SINIFLANDIRILMASI

KEMAL ADEM

GAZİOSMANPAŞA ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK ANABİLİM DALI

TEZ DANIŞMANI: Doç. Dr. Mahmut HEKİM

Bu tezde, oftalmologların teşhis işlerini kolaylaştırma ve zaman kaybının önlenmesi için diyabetik retinopati hastalığının otomatik teşhisi ve sınıflandırılmasına odaklanılmıştır. Bu amaç için, retina görüntülerindeki anatomik yapılar olan optik disk ve damar bölgelerinin tespit edilerek görüntüden göz ardı edilmesi sağlanmıştır. Optik disk tespiti için sırasıyla HSV renk uzayı, adaptif histogram eşitleme, Gama dönüşümü, Canny kenar bulma algoritması ve çembersel Hough dönüşümü, damar bölütlemesi için ise sırasıyla RGB renk uzayı, adaptif histogram eşitleme, Gabor ve Top-hat dönüşümü yöntemleri uygulanmıştır. Anatomik bölgelerin tespit edilerek retina görüntüsünden göz ardı edilmesinden sonra eksuda ve hemoraji lezyonlarının tespit edilmesi için manüel eşikleme ve ateşböceği / parçacık sürü optimizasyonu temelli iteratif eşikleme yöntemleri kullanılmıştır. Eşikleme yöntemleri sonucu eksudalı toplam piksel sayısı, eksudalı bölge sayısı, hemorajili toplam piksel sayısı ve hemorajili bölge sayısından oluşan öznitelik veri seti doğrusal regresyon, çok katmanlı algılayıcı, çapsal tabanlı fonksiyon sinir ağı ve destek vektör makinesi temelli sınıflayıcılara giriş olarak kullanılarak diyabetik retinopati teşhisi ve sınıflandırılması gerçekleştirilmiştir. Sınıflandırma doğruluğu açısından sınıflayıcı performanslarını değerlendirmek için farklı kombinasyonlar kullanılarak farklı deneyler yapılmıştır. Gerçekleştirilen deneyler parçacık sürü optimizasyonu temelli destek vektör makinesi yaklaşımının ateşböceği temelli olan yaklaşımlardan daha yüksek toplam doğru sınıflandırma başarı oranlarına ulaştığını göstermiştir. Sonuç olarak, hasta yoğunluğundan dolayı yaşanabilecek muhtemel karışıklıkların önüne geçerek oftalmologlara ön-tanı imkanı veren teşhis destek sisteminin gerçekleştirilmesi sağlanmıştır.

2017, 119 sayfa

ANAHTAR KELİMELER: Diyabetik Retinopati, Eksuda, Hemoraji, Parçacık Sürü Optimizasyonu, Ateşböceği algoritması, Doğrusal Regresyon, Destek Vektör Makinesi.

ABSTRACT

Ph. D. Thesis

THE DIAGNOSIS AND CLASSIFICATION OF DIABETIC RETINOPATHY DISEASE BASED ON IMAGE PROCESSING AND MACHINE LEARNING

KEMAL ADEM

GAZIOSMANPASA UNIVERSITY INSTITUTE OF SCIENCE
DEPARTMENT OF MECHATRONIC ENGINEERING

Supervisor: Assoc. Prof. Dr. Mahmut HEKİM

In this study, we focus on the automatic diagnosis and classification of diabetic retinopathy disease in order to facilitate diagnostic work of ophthalmologists and prevent time loss. For this aim, the optic disc and vein areas which are the anatomical structures of the retinal images are detected and removed from the image. For optic disk detection, HSV color space, adaptive histogram equalization, Gamma transformation, Canny edge detection algorithm and the circle Hough transform were used respectively. Then, RGB color space, adaptive histogram equalization, Gabor and Top-Hat transformations are applied for vein segmentation, respectively. After anatomic regions are detected and then removed from the retinal image, manual thresholding and iterative thresholding methods based on firefly/particle swarm optimization are used for the detection of exudate and hemorrhagic lesions. Then, the diagnosis and classification of diabetic retinopathy are implemented by using the feature dataset which consists of the total pixel counts of exudate and hemorrhage, and the numbers of exudate and hemorrhagic regions as inputs into the linear regression, multilayer perceptron, radial basis function and support vector machine based classifiers. In order to evaluate their performances in terms of classification accuracy, different experiments are implemented using different combinations of the total pixel counts of exudate and hemorrhage, and the numbers of exudate and hemorrhagic regions. The experiments show that the support vector machine-based approach with particle swarm optimization achieves higher total correct classification success rates than the firefly and support vector machine-based approaches for all used classifier models. Finally, this thesis offers a diagnostic support system to be used by ophthalmologists, which avoids potential confusions occurring due to patient overcrowding.

2017, 119 page

KEYWORDS: Diabetic Retinopathy, Exudate, Hemorrhage, Particle swarm optimization, Firefly algorithm, Linear regression, Support vector machine.

ÖNSÖZ

Doktora çalışmam boyunca, her türlü konuda yardımlarını esirgemeyen, değerli fikirleriyle çalışmama yön veren kıymetli hocam Sayın Doç. Dr. Mahmut HEKİM'e sonsuz teşekkürler.

Çalışmalarımda kullandığım materyalin elde edilmesini sağlayan ve DR hastalığıyla ilgili bilgi veren Gaziosmanpaşa Üniversitesi Tıp Fakültesi Göz Hastalıkları A.B.D.'dan Doç. Dr. Selim DEMİR'e ve lisans döneminden itibaren aynı yolda beraberce ilerlediğimiz Öğr. Gör. Onur CÖMERT'e teşekkürlerimi sunarım.

Bugünlere gelmemde maddi, manevi desteği olan babam Muhsin ADEM ve annem Sevinç ADEM'e, tez çalışmalarım sırasında manevi desteğini bir an olsun esirgemeyen her zaman yanımda olan eşim Elif İnci ADEM ve ailemize yeni katılan kızım Belis Defne ADEM'e teşekkürlerimi bir borç bilirim.

Kemal ADEM
Temmuz, 2017

İÇİNDEKİLER

	<u>Sayfa</u>
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER	3
2.1. Diyabet	3
2.2. Diyabetik retinopati.....	4
2.2.1. Diyabetik retinopati evreleri	5
2.2.2. Diyabetik retinopatinin izlenmesi ve tedavisi	6
2.3. Kaynak özetleri	9
2.3.1. Optik disk tespiti	10
2.3.2. Damar segmentasyonu	11
2.3.3. Eksuda tespiti	12
2.3.4. Hemoraji tespiti.....	14
2.3.5. Diyabetik retinopati sınıflandırılması.....	17
2.4. Sayısal görüntü işleme tanımları	18
3. MATERYAL VE YÖNTEM.....	20
3.1. Materyal	20
3.2. Görüntü işleme yöntemleri	21
3.2.1. Renk uzayları	21
3.2.2. Parlaklık ayarlama	27
3.2.3. Karşıtlık ayarlama	28
3.2.4. Gama düzeltmesi.....	29
3.2.5. Histogram temelli görüntü iyileştirme	30
3.2.6. Filtre temelli görüntü iyileştirme	33
3.2.7. Kenar tespit algoritması temelli görüntü bölütleme	34
3.2.8. Çembersel Hough dönüşümü	35
3.2.9. Gabor dönüşümü.....	37
3.2.10. Morfolojik işlemler.....	39
3.2.11. Eşikleme	42
3.2.11.1. Manüel eşikleme	42
3.2.11.2. Ateş böceği algoritması (FFA) ile iteratif eşikleme	44
3.2.11.3. Parçacık sürü optimizasyonu algoritması (PSOA) ile iteratif eşikleme	46
3.3. Sınıflandırma	48
3.3.1. Doğrusal regresyon	48
3.3.2. Çok katmanlı sinir ağı	49
3.3.3. Destek vektör makinesi	51
3.3.4. RBF sinir ağı	53
4. BULGULAR ve TARTIŞMA.....	55
4.1. Optik disk tespiti	56
4.2. Damar bölütlemesi	61

4.3. Eksuda tespiti	65
4.4. Hemoraji tespiti	76
4.5. DR sınıflandırması	87
5. SONUÇ	103
6. KAYNAKLAR	105
EKLER	116
ÖZGEÇMİŞ	119



SİMGE VE KISALTMALAR DİZİNİ

Simgeler

Açıklama

Θ	Aşındırma işlemi
$\oplus$	Yayma işlemi
ϕ	Aktivasyon fonksiyonu
w	Ağırlık katsayısı
$\emptyset$	Haritalama fonksiyonu

Kısaltmalar

Açıklama

DR	Diyabetik Retinopati
NPDR	Nonproliferatif Diyabetik Retinopati
PDR	Proliferatif Diyabetik Retinopati
OD	Optik Disk
FfA	Fundus Floresein Anjiyografi
RGB	Red Green Blue
HSV	Hue Saturation Value
CMY	Cyan Magenta Yellow
FFA	Ateşböceği Algoritması (Firefly Algorithm)
PSOA	Parçacık Sürü Optimizasyonu Algoritması
LR	Doğrusal Regresyon (Linear Regression)
ANN	Yapay Sinir Ağı (Artificial Neural Network)
MLPNN	Çok Katmanlı Sinir Ağı(Multi Layer Perceptron Neural Network)
SVM	Destek Vektör Makinesi (Support Vector Machine)
RBF	Çapsal Tabanlı Fonksiyon (Radial Basis Function)
TCC	Toplam Doğru Sınıflandırma (Total Correct Classification)
TP	Doğru Pozitif (True Positive)
TN	Doğru Negatif (True Negative)
FP	Yanlış Pozitif (False Positive)
FN	Yanlış Negatif (False Negative)
DTPS	Doğru Tespit edilmiş Piksel Sayısı
TPS	Toplam Piksel Sayısı

ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 2. 1. Sağlam ve DR hastalıklı örnek retina görüntüsü	5
Şekil 2. 2. Göz dibi muayenesi	6
Şekil 2. 3. Örnek fundus kameralar	7
Şekil 2. 4. Retina görüntüsüne FfA uygulanması	8
Şekil 2. 5. DR hastalıklı retinaya lazer tedavisi uygulanması	8
Şekil 2. 6. Lazer tedavisi uygulanmış retina görüntüsü	9
Şekil 3. 1. Görüntü işleme temel adımları	21
Şekil 3. 2. Renk uzaylarının sınıflandırılması	22
Şekil 3. 3. RGB renk uzayı	22
Şekil 3. 4. RGB renk uzayı için retina görüntüsünün R, G ve B kanalı	23
Şekil 3. 5. HSV renk uzayı	23
Şekil 3. 6. HSV renk uzayı için retina görüntüsünün H, S ve V kanalı	24
Şekil 3. 7. CMY renk uzayı	25
Şekil 3. 8. CMY renk uzayı için retina görüntüsünün C, M ve Y kanalları	25
Şekil 3. 9. YUV renk uzayının U-V bileşeni	26
Şekil 3. 10. YUV renk uzayı için retina görüntüsünün Y, U ve V kanalları	26
Şekil 3. 11. YIQ renk uzayı I ve Q bileşenleri	27
Şekil 3. 12. YIQ renk uzayı için örnek retina görüntüsünün Y, I ve Q kanalları	27
Şekil 3. 13. Retina görüntüsünde parlaklık ayarlama örneği	28
Şekil 3. 14. Retina görüntüsünde kontrast ayarlama örneği	28
Şekil 3. 15. Retina görüntüsü ve Gri seviyeye 0.8-0.6-0.4 eşik değerinde gama düzeltmesi	29
Şekil 3. 16. Retina görüntüsü ve histogramı	30
Şekil 3. 17. Histogram eşitlemesi ve eşitleme sonrası görüntünün histogramı	32
Şekil 3. 18. Adaptif histogram eşitlemesi uygulaması	33
Şekil 3. 19. Medyan filtresi uygulaması	34
Şekil 3. 20. Canny kenar tespit algoritmasının uygulaması	35
Şekil 3. 21. Çembersel Hough dönüşümü parametre uzayı	36
Şekil 3. 22. Retina görüntüsünde çembersel Hough dönüşümü uygulaması	37
Şekil 3. 23. Örnek Gabor çekirdeği ($\theta=0^\circ$)	38
Şekil 3. 24. Gabor dönüşümü ile elde edilen retina görüntüsü	39
Şekil 3. 25. Aşındırma işlemi uygulanmış görüntü	40
Şekil 3. 26. Yayma işlemi uygulanmış görüntü	41
Şekil 3. 27. Top-hat dönüşümü uygulanmış görüntü	42
Şekil 3. 28. Manüel eşikleme örneği (Eşik değeri = 115)	43
Şekil 3. 29. Damarları göz ardı edilen retina görüntüsüne FFA ile iteratif eşikleme	46
Şekil 3. 30. Damar bölgesi çıkartılan retina görüntüsüne PSOA ile iteratif eşikleme	48
Şekil 3. 31. MLPNN'de kullanılan nöron şekli	50
Şekil 3. 32. Optimum düzlem ve destek vektörleri	52
Şekil 3. 33. RBF sinir ağının genel yapısı	54
Şekil 4. 1. DR hastalık teşhisi yazılımının çalışma adımları	55
Şekil 4. 2. Retina görüntüsü ve G kanalı retina görüntüsü	56
Şekil 4. 3. Adaptif histogram eşitleme uygulanması	57
Şekil 4. 4. Canny kenar tespit algoritması uygulanması	57
Şekil 4. 5. Çembersel Hough dönüşümünün uygulanması	58
Şekil 4. 6. Retina görüntüsü ve V kanalı retina görüntüsü	58
Şekil 4. 7. Adaptif histogram eşitleme ve gama dönüşümü uygulanması	59
Şekil 4. 8. Canny kenar tespit algoritması uygulanması	59
Şekil 4. 9. Çembersel Hough dönüşümünün uygulanması	60
Şekil 4. 10. Retina görüntüsü ve RGB renk uzayının yeşil kanalı görüntüsü	62
Şekil 4. 11. Adaptif histogram eşitleme uygulanması	62
Şekil 4. 12. Örnek Gabor çekirdeği ($\theta=0^\circ$)	63

Şekil 4. 13. Gabor dönüşümü ile elde edilen retina görüntüsü	63
Şekil 4. 14. Top-hat dönüşümü uygulanması ve damarların bölütlenmesi	64
Şekil 4. 15. OD bölgesi çıkartılan retina görüntüsüne FFA ile iteratif eşikleme	66
Şekil 4. 16. OD bölgesi çıkartılan retina görüntüsüne PSOA ile iteratif eşikleme.....	67
Şekil 4. 17. ImageRet veri tabanında FFA temelli iteratif eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi	72
Şekil 4. 18. ImageRet veri tabanında PSOA temelli iteratif eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi	73
Şekil 4. 19. GopRetina veri tabanında FFA temelli eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi	73
Şekil 4. 20. GopRetina veri tabanında PSOA temelli eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi	74
Şekil 4. 21. Eşikleme yöntemlerinin doğru sınıflandırma oranları ve zaman performansları	76
Şekil 4. 22. Damar bölgesi çıkartılan retina görüntüsüne FFA ile iteratif eşikleme	78
Şekil 4. 23. Damar bölgesi çıkartılan retina görüntüsüne PSOA ile iteratif eşikleme	78
Şekil 4. 24. ImageRet veri tabanında FFA temelli iteratif eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi	83
Şekil 4. 25. ImageRet veri tabanında PSOA temelli iteratif eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi	84
Şekil 4. 26. GopRetina veri tabanında FFA temelli eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi	84
Şekil 4. 27. GopRetina veri tabanında PSOA temelli eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi	85
Şekil 4. 28. Eşikleme yöntemlerinin doğru sınıflandırma oranları ve zaman performansları.....	87

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 2. 1. Retina görüntülerinden optik disk tespiti yaklaşımları ve başarı oranları.....	11
Çizelge 2. 2. Retina görüntülerinden damar segmentasyonu yaklaşımları ve başarı oranları	12
Çizelge 2. 3. Retina görüntülerinde eksuda tespiti ile ilgili yaklaşımlar ve başarı oranları	14
Çizelge 2. 4. Retina görüntülerinde hemoraji tespiti ile ilgili yaklaşımlar ve başarı oranları	16
Çizelge 2. 5. Retina görüntülerinde DR tespiti ile ilgili yaklaşımlar ve başarı oranları.....	18
Çizelge 3. 1. Çalışmada kullanılan retina görüntüsü veri tabanları.....	20
Çizelge 4. 1. OD bölgesi tespiti için gerçekleştirilen deneysel çalışmaların karşılaştırılması	60
Çizelge 4. 2. OD tespiti için önerilen yöntem ve literatür karşılaştırılması	61
Çizelge 4. 3. Damar bölütlemesi için önerilen yöntem ve literatür karşılaştırılması	65
Çizelge 4. 4. ImageRet veri tabanından alınan görüntülere FFA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri	69
Çizelge 4. 5. ImageRet veri tabanından alınan görüntülere PSOA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri	69
Çizelge 4. 6. GopRetina görüntülerine FFA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri	70
Çizelge 4. 7. GopRetina görüntülerine PSOA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri	70
Çizelge 4. 8. Eksuda tespiti için kullanılan yöntemlerin duyarlılık, özgüllük ve TCC oranları.....	71
Çizelge 4. 9. Eksuda tespiti ile ilgili çalışmalarda kullanılan yöntemler ve başarı oranları	75
Çizelge 4. 10. FFA ve PSOA ile eşikleme yöntemlerinin zaman performansları	75
Çizelge 4. 11. ImageRet veri tabanından alınan görüntülere FFA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri	80
Çizelge 4. 12. ImageRet veri tabanından alınan görüntülere PSOA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri	80
Çizelge 4. 13. GopRetina veri tabanından alınan görüntülere FFA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri	81
Çizelge 4. 14. GopRetina veri tabanından alınan görüntülere PSOA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri	81
Çizelge 4. 15. Hemoraji tespiti için kullanılan yöntemlerin duyarlılık, özgüllük ve TCC oranları	82
Çizelge 4. 16. Hemoraji tespiti ile ilgili çalışmalarda kullanılan yöntemler ve başarı oranları	85
Çizelge 4. 17. FFA ve PSOA ile eşikleme yöntemlerinin zaman performansları	86
Çizelge 4. 18. ImageRet veri tabanında Model-1 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi	88
Çizelge 4. 19. ImageRet veri tabanında Model-1 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi	88
Çizelge 4. 20. ImageRet veri tabanında Model-1 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi	89
Çizelge 4. 21. ImageRet veri tabanında Model-1 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi	89
Çizelge 4. 22. ImageRet veri tabanında Model-2 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi	89
Çizelge 4. 23. ImageRet veri tabanında Model-2 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi	90
Çizelge 4. 24. ImageRet veri tabanında Model-2 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi	90
Çizelge 4. 25. ImageRet veri tabanında Model-2 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi	90
Çizelge 4. 26. ImageRet veri tabanında Model-3 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi	91

Çizelge 4. 27. ImageRet veri tabanında Model-3 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi	91
Çizelge 4. 28. ImageRet veri tabanında Model-3 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi	91
Çizelge 4. 29. ImageRet veri tabanında Model-3 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi	91
Çizelge 4. 30. ImageRet veri tabanında Model-4 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi	92
Çizelge 4. 31. ImageRet veri tabanında Model-4 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi	92
Çizelge 4. 32. ImageRet veri tabanında Model-4 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi	92
Çizelge 4. 33. ImageRet veri tabanında Model-4 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi	93
Çizelge 4. 34. ImageRet veri tabanında gerçekleştirilen deneylerin başarı oranları	94
Çizelge 4. 35. GopRetina veri tabanında Model-1 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi	95
Çizelge 4. 36. GopRetina veri tabanında Model-1 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi	95
Çizelge 4. 37. GopRetina veri tabanında Model-1 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi	95
Çizelge 4. 38. GopRetina veri tabanında Model-1 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi	96
Çizelge 4. 39. GopRetina veri tabanında Model-2 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi	96
Çizelge 4. 40. GopRetina veri tabanında Model-2 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi	96
Çizelge 4. 41. GopRetina veri tabanında Model-2 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi	97
Çizelge 4. 42. GopRetina veri tabanında Model-2 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi	97
Çizelge 4. 43. GopRetina veri tabanında Model-3 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi	97
Çizelge 4. 44. GopRetina veri tabanında Model-3 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi	98
Çizelge 4. 45. GopRetina veri tabanında Model-3 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi	98
Çizelge 4. 46. GopRetina veri tabanında Model-3 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi	98
Çizelge 4. 47. GopRetina veri tabanında Model-4 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi	99
Çizelge 4. 48. GopRetina veri tabanında Model-4 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi	99
Çizelge 4. 49. GopRetina veri tabanında Model-4 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi	99
Çizelge 4. 50. GopRetina veri tabanında Model-4 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi	99
Çizelge 4. 51. GopRetina veri tabanında gerçekleştirilen deneylerin başarı oranları	101



1. GİRİŞ

Diyabet hem kendisi hem de neden olduğu komplikasyonlardan dolayı önemli bir sağlık problemidir (Klein ve ark., 1984). İnsanların yaşam kalitesini düşüren bu kronik hastalık ile mücadelede sağlık harcamaları önemli ölçüde yüksektir. Hastalığın erken teşhisi ve komplikasyonları ortaya çıkmadan önce yönetimi bu hastalıkla mücadelede çok önemlidir (Yau ve ark., 2012). Ülkemizde 2002 yılında yapılan TURDEP-1 çalışması sonucuna göre %7.1 olan diyabet insidansı çok kısa bir süre içinde önemli bir oranda artış göstermiş ve 2011 yılında yine aynı çalışma grubuna göre hastalığın insidansı %13.7 olarak rapor edilmiştir (Satman ve ark., 2002; Satman ve ark., 2011). Bu yüzden, diyabet hastalığı ve bu hastalığın neden olduğu problemlerin tedavi ve yönetimi ülkemiz için önemli bir sorun teşkil etmektedir.

Diyabet hastalığı yüzünden meydana gelen Diyabetik Retinopati (DR) dünya genelinde görme keskinliğinde azalmanın ve körlüğün en önde gelen nedenidir (Klein ve ark., 1984). Hastaların retinasında erken dönemde mikrovasküler baloncuklaşmalar (mikro anevrizma) ve damar geçirgenliğindeki artış nedeni ile retina içi sıvı ve lipid birikimi oluşmaktadır (Hiller ve ark., 1988). Fundus muayenesi ve dijital fundus kameralar ile tespit edilebilen mikro anevrizma ve eksuda bulguları hastalığın seyri ile orantılıdır ve takip/tedavi kriteri olarak kullanılmaktadır. Erken ve zamanında müdahale ile tedavi süreci başarılı olurken, hastalığın tedavisinin geçikmesi geri dönüşü olmayan görme kayıplarına neden olmaktadır. Bu yüzden diyabet hastalarının düzenli olarak oftalmologlar (göz doktorları) tarafından alınan fundus kameralarla retina görüntülerine göre erken teşhis ve tedavi yöntemlerinin uygulanması gerekmektedir (Gönül ve Kadioğlu, 2013). Diyabet hastalığının oldukça artış göstermesi nedeniyle DR hastalarının yoğunluğu artmakta ve bu yüzden hastaların düzenli olarak takip edilmesi zorlaşmaktadır. Bu tezde oftalmologların teşhis işlerinin kolaylaştırılmasına ve zaman kaybının önlenmesine yardımcı olmak için DR hastalığının otomatik teşhisi amaçlanmaktadır.

Çalışmada analiz amacıyla kullanılan görüntüler Cumhuriyet Üniversitesi Klinik Araştırmalar Etik Kurul’undan etik kurul raporu alınan Gaziosmanpaşa Üniversitesi Tıp

Fakültesi Göz Hastalıkları Anabilim Dalı'na gelen hastalardan ve bilimsel araştırmalara açık olan ImageRet veri tabanından elde edilmiştir.

Tez çalışmasının 4 temel amacı vardır: (1) Gaziosmanpaşa Üniversitesi, Tıp Fakültesi, Göz Hastalıkları Anabilim Dalı'na gelen hastalardan alınan görüntülerin kullanılması ve bu görüntülerdeki DR lezyonlarının ilgili Anabilim Dalı'ndaki öğretim üyesiyle tespit edilerek retina görüntü veri tabanı oluşturmaktır. (2) Retinadaki anatomik yapılar olan optik disk ve kan damarlarının otomatik tespiti ile bu yapılara benzer DR lezyonlarının karıştırılmamasıdır. (3) Her bir DR lezyonunun görüntü işleme algoritmalarıyla özneteliğinin çıkartılarak makine öğrenmesi yöntemleriyle tespit edilmesi ve sınıflandırılmasıdır. (4) Oftalmologların fundus kameralarla elde ettikleri retina görüntüleri kullanılarak DR hastalığının lezyonlarının tespiti konusunda karar destek sistemi oluşturmaktır.

Bu tez beş bölümden oluşmaktadır. Birinci bölüm "Giriş" bölümüdür ve burada teze genel bir bakış açısı kazandırmaya yönelik olarak temel bilgiler verilerek tez çalışmasının amacı ve içeriğinden bahsedilmiştir. İkinci bölümde retinanın anatomik bölgeleri ve diyabetik retinopati lezyonlarının tespiti ile ilgili kaynak araştırmasına değinilmiştir. Bu bölümde ayrıca diyabet, diyabetik retinopati, evreleri ve tedavileri ile ilgili genel bilgilere yer verilmiştir. Üçüncü bölüm "Materyal ve Yöntem" bölümüdür. Bu bölümde kullanılan veri kümeleri ve DR lezyonlarının tespiti için kullanılan görüntü işleme teknikleri anlatılmıştır. Dördüncü bölüm "Bulgular ve Tartışma" bölümüdür. Bu bölümde anatomik bölgeler ve DR lezyonlarının tespiti için elde edilen veri kümelerine görüntü işleme teknikleri ve farklı sınıflandırma yöntemleri uygulanarak doğru sınıflandırma oranları elde edilmiştir. Kullanılan sınıflandırma yöntemlerinin sonuçları karşılaştırılarak grafiklerle gösterilmiş ve çıkan sonuçlar tartışılmıştır. Beşinci bölüm olan sonuç bölümünde ise çalışma süresince elde edilen kazanımlar verilmiş ve öneriler sunulmuştur.

2. KURAMSAL TEMELLER

2.1. Diyabet

Diyabet (Diabetes mellitus), vücuttaki insülin miktarının yetersizliği veya insülin direnci sonucu oluşan, kan şekeri yüksekliği (hiperglisemi) nedeniyle gelişen bir metabolizma hastalığıdır (Büyükdevrim, 1992). Dünya Sağlık Örgütü (WHO) tarafından evrensel bir sağlık sorunu olarak kabul edilen diyabet hastalığı iki tipte incelenmektedir.

- Tip I Diyabet (İnsülin-bağımlı): Pankreas hücrelerinin zedelenmesine bağlı olarak gelişen insülin eksikliği ile ortaya çıkan ve insüline bağımlı olarak gelişen diyabet türüdür. Genellikle 10-20 yaşları arasında görülmektedir. Bu diyabet türü ani başlayan kilo kayıpları ve çok su tüketme gibi belirtiler ile ortaya çıkmaktadır.
- Tip II Diyabet (İnsülin-bağımsız): Daha sık görülen ve başlangıçta insüline ihtiyaç olmadan da kontrol edilebilen diyabet türüdür. 50-70 yaşları arasında daha sık görülmektedir.

Uluslararası Diyabet Federasyonu'nun (IDF) 2015 yılında yaptığı araştırmalara göre; 415 milyon diyabet hastası (11 yetişkinden 1'i) bulunmakta ve 2 diyabetli yetişkinden yaklaşık 1'i henüz diyabetli olduğunu bilmemektedir. Dünya genelinde diyabete yapılan harcama sağlık harcamalarının %12'si olup 673 milyar ABD Doları'dır. Diyabet hastalarının %75'e yakını düşük ve orta gelir düzeyindeki ülkelerde yaşamaktadır. Ayrıca diyabet hastalığı kaynaklı her 6 saniyede 1 kişi (toplamda 5 milyon) hayatını kaybetmektedir (Yau ve ark., 2012). Ülkemizde 2002 yılında yapılan TURDEP-1 çalışması sonucuna göre %7.1 olan diyabet yoğunluğu (insidansı) çok kısa bir süre içinde önemli bir oranda artış göstermiş ve 2011 yılında yine aynı çalışma grubunun gerçekleştirdiği TURDEP-2 çalışma sonucuna göre ise hastalığın insidansı %13.7 olarak rapor edilmiştir (Satman ve ark., 2002; Satman ve ark., 2011). TURDEP-1'de 45-49 yaş aralığında %10'un üzerinde diyabet sıklığı başlamaktadır. TURDEP-2 çalışmasına göre ise 40-44 yaş grubundan itibaren nüfusun en az %10'unda diyabetle karşılaşmaktadır. Buna göre Türkiye'de diyabetin 1998-2000 yılına göre yaklaşık olarak 5 yaş daha erken başladığı düşünülebilir (Satman ve ark., 2011). Sonuçlar,

lkemizde diyabetin en nemli toplum saęlıęı sorunlarından biri olduęunu gstermektedir. Bu yzden, diyabet hastalıęı ve bu hastalıęın neden olduęu problemlerin tedavi ve ynetimi lkemiz iin nemli bir sorun teřkil etmektedir.

2.2. Diyabetik retinopati

Diyabet hastalıęına baęlı oluřan ve gzn retina tabakasında karřılařılan bozulmalara Diyabetik retinopati (DR) denir (Klein ve ark., 1984; zetin, 2000). Dnya genelinde yaklařık 93 milyon insanda DR olduęu ve bu nedenle yaklařık 28 milyon insanın grme kaybı yařadıęı tahmin edilmektedir (Yau ve ark., 2012). Birok faktr DR oluřumunda etkin olmasına raęmen en nemli faktr artmıř kan glikozu nedenli oluřan ilerlemiř glikasyon son rnleridir. Damar duvarında oluřan bu bozulma neticesinde damarlarda baloncuklařma, tıkanıklıklar, damar dıřına sızıntılar oluřmaktadır. Diyabete baęlı mikrovaskler ve makrovaskler komplikasyonlar gz damarları ile birlikte tm vcut damarlarında da grlmektedir (Hiller ve ark., 1988). Bbrek yetmezlięi, koroner arter tıkanıklıkları, beyin damarlarındaki tıkanıklıęa baęlı inme diyabete baęlı hayati risk tařıyan bařlıca sistemik vaskler etkilenim yerleridir. Retinal vaskler dolařımının invaziv bir giriřime gerek duymadan grlebilmesi sistemik hastalıkların monitrizasyonu aısından olduka nemlidir. Bu aıdan retina muayenesi ile elde edilen veriler diyabetin davranıřını gstermektedir. Amerika’da yapılan geniř kapsamlı bir alıřma sonularına gre DR varlıęı %34’ten %89’a kadar deęiřen lm (mortalite) riski tařımaktadır (Klein ve ark., 1999).

Diyabet nedeniyle kılcal kan damarları eperinde bazal membran kalınlařması perisit¹-endotel² hcre harabiyeti ve trombositlerin fonksiyonlarında bozulma nedeniyle trombosit agregasyonunda artıř meydana gelmektedir. Bununla birlikte pıhtılařmada rol oynayan fibrinojen³ seviyesindeki artıř damar tıkanıklıęına neden olmaktadır. Bylece kapiller ve arteriyollerde meydana gelen tıkanmalar retinanın yeterli oksijenlenememesine ve anjiojenik⁴ faktrler aracılıęıyla yeni damarların oluřumuna yol amaktadır (Klein ve ark., 1994). Oluřan yeni damarlar anormal yapıda olduęu iin


¹ Kılcal damarlarda bulunan ve makrofajlara dnřebilen hcre olarak da bilinen baę doku kkenli hcre.

² Kalp ve damarların i yzeyini evreleyen tek katlı yassı epitel.

³ Fibrinojen kanın pıhtılařmasında nemli bir role sahip olan kan proteiniidir.

⁴ Kılcal damar geirgenlięinin artması sonucu oluřan faktrler.

kolay kanayabilen özelliğe sahiptir. Retina bölgesindeki kan damarlarının çeperinde meydana gelen hücresel kayıplar mikroanevrizmalara, geçirgenliğin artması ile oluşan yeni damarlardaki kanamalar hemorajilere ve kan retina bariyerinde oluşan hasar sonucu damar duvar dışına çıkan kan lipidlerinin retinada birikimi ise eksudalara neden olmaktadır (Klein ve ark., 1999). Sağlam ve hastalıklı retina görüntüsü Şekil 2.1’de verilmektedir.



a) Sağlam retina görüntüsü

b) DR hastalıklı retina görüntüsü

Şekil 2. 1. Sağlam ve DR hastalıklı örnek retina görüntüsü

Şekil 2.1’de görüldüğü gibi, sağlam retina görüntüsü ve kırmızı renkte bulunan hemorajiler ile sarımsı renkte bulunan eksudaları barındıran DR hastalıklı retina görüntüsü arasındaki farklılıklar gözle saptanabilmektedir.

2.2.1. Diyabetik retinopati evreleri

Diyabetik retinopati; nonproliferatif DR (NPDR) ve proliferatif DR (PDR) olmak üzere iki grupta değerlendirilmektedir (İnan, 2011).

- NPDR evresi DR’nin ilk aşamasıdır. Bu evre hafif, orta ve ağır olmak üzere 3 grupta incelenmektedir.
 1. Hafif NPDR aşamasında en az 1 mikroanevrizma veya hemorajiye rastlanmaktadır.
 2. Orta NPDR aşamasında birden fazla sayıda hemoraji, sert eksuda ve makula ödemi lezyonları oluşmaktadır.

3. Ağır NPDR aşamasında ise 4 kadranda hemoraji, 2 kadranda venöz ve 1 kadranda da intra retinal mikrovasküler anomali bulguları saptanmaktadır (İnan, 2011).

- DR hastalığının ilerlemiş evresi olan PDR oluşumunun en önemli nedeni retina kan damarlarının tıkanması ve ilgili damarların yeterince beslenememesidir. Bu durumun sonucu olarak retina ve optik disk bölgesinde anormal yapıda damar oluşumları (neovaskülarizasyon) gözlemlenmektedir. Ancak yeni oluşan anormal yapıda olan damarların geçirgenliği düşük olduğu için normal kan akışı esnasında çok kolay bir şekilde sızıntı ve kanamalar oluşmaktadır. Kanamaların retina yüzeyi ve saydam vitreus jeline doğru büyümesi ciddi görme kayıplarına sebep olabilmektedir (İnan, 2014).

2.2.2. Diyabetik retinopatinin izlenmesi ve tedavisi

DR hastalığı erken safhalarında belirti oluşturmeyen ve hastaların şikayetine sebebiyet vermeyen sinsi bir hastalıktır. Bu sebeple diyabet hastalığı bulunan bireylerin herhangi bir belirti beklemeden düzenli olarak göz kontrollerini yılda en az bir kere olacak şekilde göz bebeği genişletilerek detaylı göz dibi muayenesi yaptırması gerekmektedir (Apaydın ve Bilgin, 2010). Örnek muayenelerden çekilen resimler Şekil 2.2’de verilmektedir.




Şekil 2. 2. Göz dibi muayenesi (Anonim, 2017a)

Şekil 2.2’de görüldüğü üzere DR hastalığının izlenmesinde ve muayene edilmesinde en çok kullanılan tarama yöntemi, fundus kameralar aracılığıyla alınan göz dibi retina görüntüleridir. Kliniklerde kullanılan bazı fundus kameralara örnekler Şekil 2.3’te verilmektedir.



Şekil 2. 3. Örnek fundus kameralar (Anonim, 2017b)

Şekil 2.3’te görüldüğü gibi kliniklerde en çok kullanılan fundus kamera markaları Canon, Topcon ve Kowa Medicals firmalarının ürünleridir. Özellikle diyabetli hastaların ne kadar uzun süredir bu hastalıkla uğraşıyorlarsa o oranda DR göz hastalığına yakalanma ve hastalığın gelişme riski artmaktadır. Göz dibi muayenesinde DR bulguları saptanan bir hastaya hastalığın ilerlememesi için oftalmolog tarafından tedavi önerilmektedir. Tedavi ne kadar erken yapılır ve DR tanısı erken konulursa tedavinin başarılı olma ihtimali de o oranda artmaktadır. DR bulgularının daha net bir şekilde ön plana çıkarılmasını sağlayan yöntem Fundus Floresein Anjiyografi (FfA) ‘dır. Bu yöntemde hastanın kolundan damara özel bir boya (kontrast) maddesi enjekte edilir. Bu özel madde retinanın kan damarlarından geçerken retinanın göz dibi görüntüleri çekilir (Apaydın ve Bilgin, 2010). Şekil 2.4’te normal ve DR hastalığı bulunan FfA görüntüleri verilmektedir.




a) Normal FfA görüntüsü b) DR hastalıklı FfA görüntüsü

Şekil 2. 4. Retina görüntüsüne FfA uygulanması


Şekil 2.4.a’de görüldüğü üzere sağlıklı bir gözün FfA görüntüsünde damarlarda veya makulada herhangi bir sızıntıya ait parlak renkte beyazlık görülmemektedir. Şekil 2.4.b’deki DR hastalıklı FfA görüntüsünde ise siyah ok ile gösterilen parlak renkteki beyazlıklar, damarlardan sızıntı olduğunu göstermektedir. Bu tetkik yöntemi sayesinde sızdıran damarların daha rahat bir şekilde tespit edilmesi ve tedavi edilmesi sağlanmaktadır.

DR hastalığının gerçekleştirilen muayeneler sonucunda görme merkezinin etkilenmesi ve yeni damar oluşumu gibi bulgularla karşılaşıldığı durumlarda hastalığın evresine göre diyet değişiklikleri, spor, sıkı kan şekeri regülasyonu, lazer fotokoagülasyonu, göz içi enjeksiyonu ve vitrektomi yöntemleriyle tedavi edilir (Tunç, 2010). Bu yöntemlerden Lazer tedavisinin uygulaması Şekil 2.5’de verilmektedir.



Şekil 2. 5. DR hastalıklı retina lazer tedavisi uygulanması (Anonim, 2017c)

Şekil 2.5’de görülen lazer tedavisi uygulaması DR hastalığının oluşturduğu hasarları onarmak için en sık uygulanan yöntemdir. Diyabet hastalığı bulunan kişiler oftalmologlara ne kadar erken başvurlarsa lazer ile tedavi yönteminin başarısı da o oran da artmaktadır. Bu tedavi yöntemi ile göz içerisinde kanama, kanama ihtimali olan yeni damarların oluşumu ve görme merkezindeki ödem oluşumu gibi sorunların gelişimi ve ilerlemesi engellenmektedir. Lazer tedavisi uygulanmış retina görüntüsü Şekil 2.6’da gösterilmektedir.



Şekil 2. 6. Lazer tedavisi uygulanmış retina görüntüsü

Şekil 2.6’da görüldüğü gibi DR’li hastanın retinasında yeni damarların oluşumunu engellemek için lazer tedavisi gerçekleştirilmiştir. Bu tedavi sayesinde oksijene ihtiyacı olan ve yeni damar oluşumunun tetiklendiği yerlerdeki retina dokusu yok edilir ve komşu dokulardan oksijensiz bölgelere oksijen geçişi sağlanmaktadır. DR hastalarına uygulanacak olan lazer tedavileri zamanında yapılmadığı takdirde kalıcı görme kaybı ve gözün için kanama meydana getirebilirler. Bu durumda da cerrahi müdahale gerekmektedir (Polat ve Batioğlu, 2007).

2.3. Kaynak özetleri

Dijital görüntülemadaki gelişmeler ve bilgisayar sistemleri yardımıyla hesaplama gücünün artması son yıllarda DR’nin otomatik teşhisi konusunda uzmanların ilgisini oldukça çekmektedir (Gardner ve ark., 1996). DR lezyonlarının tespit edilmesi ile ilgili birçok çalışma yapılmış ve karşılaştırılmıştır. Literatürdeki çalışmalar optik disk tespiti,

damar segmentasyonu, eksuda, hemoraji tespiti ve DR sınıflandırılması olmak üzere beş alt başlıkta yayınlandığı yıl, görüntü sayısı, görüntü işleme yöntemleri ve doğru sınıflandırma oranları bakımından incelenmektedir.

2.3.1. Optik disk tespiti

Retinanın anatomik yapılarından olan optik disk bölgesinin otomatik tespiti ile ilgili çalışmalar incelendiğinde piksellerin parlaklık değerleri ile görüntü bölütleme, dairesel Hough dönüşümü ve diğer görüntü işleme teknikleri (uyumlu filtre ve istatistiksel özellikler) olmak üzere 3 alt başlıkta kullanıldığı görülmüştür.

Parlaklık değerleri ile görüntü bölütleme yaklaşımına dayanan optik disk tespiti çalışmalarında retina görüntülerine kontrast ayarlama, parlaklık ayarlama ve histogram eşitleme gibi ön işlemler uygulandıktan sonra parlaklık değeri ile yapılan eşiklemede 112 görüntü üzerinde %99.1 doğru sınıflandırma başarısına ulaşılmıştır (Sinthanayothin ve ark., 1999). Diğer bir çalışmada ise optik disk tespitinde, parlaklık değeri eşiklemesi ile birlikte Öklid ve Mahalanobis uzaklık ölçütlerini de hesaba katarak 30 görüntü üzerinde %90 doğru sınıflandırma başarısı sağlanmıştır (Walter ve Klein, 1999).

Dairesel Hough dönüşümü temelli yaklaşımlara dayanan adaptif histogram eşitleme, Canny kenar tespit algoritması, morfolojik işlemler ve dairesel Hough dönüşümü gibi görüntü işleme yöntemlerini sırasıyla uygulayarak gerçekleştirilen çalışmalarda, 1056 görüntü üzerinde %98.4 (Fleming ve ark., 2007); 54 görüntü üzerinde %98 (Treigys ve ark., 2008); 40 görüntü üzerinde %87.5 (Nergiz ve ark., 2014) ve 89 görüntü üzerinde %98.87 (Adem ve ark., 2016) doğru sınıflandırma başarısı ile optik disk tespiti gerçekleştirilmiştir.

Diğer görüntü işleme teknikleri olan uyumlu filtre ve istatistiksel özellik temelli yaklaşımlara dayanan optik disk tespiti çalışmalarının birinde, retina görüntülerine uyumlu filtre ve morfolojik işlemler uygulayarak 81 görüntüde %98.77 (Abdel-Razik ve ark., 2008), diğerinde ise görüntüye ön işlemler uygulandıktan sonra istatistiksel özellikleri çıkartılarak yapılan sınıflandırmada 40 görüntü üzerinde %100 (Çetiner ve

Çetisli, 2014) doğru sınıflandırma başarısına ulaşılmıştır. Çizelge 2.1’de optik disk bölgesinin otomatik tespiti ile ilgili çalışmalar ve başarı oranları özetlenmektedir.

Çizelge 2. 1. Retina görüntülerinden optik disk tespiti yaklaşımları ve başarı oranları

Yazarlar	Yıl	Veri Tabanı	Görüntü Sayısı	Yöntemler	Duy.	Özg.	TCC
Sinthanayothin ve ark.	1999	-	112	Piksel bazlı görüntü bölütleme	99.1	99.1	-
Walter ve Klein	1999	-	30	Parlaklık değerleri, Uzaklık ölçümleri	-	-	90
Li ve Chutatape	2004	-	889	PCA	-	-	99
Fleming ve ark.	2007	-	1056	Görüntü gradyanı, Hough dönüşümü	-	-	98.4
Treigys ve ark.	2008	-	54	Canny kenar tespiti, Hough dönüşümü	-	-	98
Abdel-Razik ve ark.	2008	Stare	81	2D Gauss uyumlu filtre, Morfolojik işlemler	-	-	98.77
Çetiner ve Çetisli	2014	Drive	40	Kontrast iyileştirme, İstatistiksel özellik ve Eşikleme	-	-	100
Nergiz ve ark.	2014	Drive	40	Adaptif Histogram Eşitleme, Morfolojik İşlem, Canny, Dairesel Hough Dönüşümü	-	-	87.5
Adem ve ark.	2016	ImageRet	89	Renk Uzayları, Canny Kenar Bulma, Dairesel Hough Dönüşümü	-	-	98.87

2.3.2. Damar segmentasyonu

Retinanın anatomik yapılarından olan damar segmentasyonu ile ilgili çalışmalar piksellerin parlaklık değerleri ile görüntü bölütleme, Gabor dönüşümü ve diğer görüntü işleme teknikleri (gauss filtre ve uyumlu filtre) olmak üzere 3 alt başlıkta toplanmıştır.

Parlaklık değerleri ile görüntü bölütleme yaklaşımı çalışmalarının ilkinde retina görüntülerine kontrast ayarlama, parlaklık ayarlama histogram eşitleme gibi ön işlemler uygulandıktan sonra Watershed algoritması ile birlikte parlaklık değeri kullanılarak yapılan eşiklemede 109 görüntü üzerinde %85.05 doğruluk ile damar segmentasyonu gerçekleştirilmiştir (Goatman ve ark., 2011). Diğer çalışmada ise Top-hat dönüşümünün uygulanması sonucu elde edilen görüntüde parlaklık değeri eşiklemesi uygulanarak 40 görüntü üzerinde %94.33 doğruluk oranı ile damar segmentasyonu gerçekleştirilmiştir (Rossant ve ark., 2011).

Gabor dönüşümü temelli yaklaşımlara dayanan çalışmalarda renk uzayı dönüşümü, adaptif histogram eşitleme, Gabor dalgacığı dönüşümü ve morfolojik işlemler gibi görüntü işleme yöntemlerini sırasıyla uygulayarak 60 görüntü üzerinde %96.14 (Soares ve ark., 2006) ve 20 görüntü üzerinde %84.3 (Wu ve ark., 2006) başarı oranları ile damar segmentasyonu gerçekleştirilmiştir.

Diğer görüntü işleme tekniklerine dayanan çalışmalarda retina görüntülerine Gauss filtre ve morfolojik işlemler uygulayarak 48 görüntüde %85.5 (Gang ve ark., 2002) başarı oranı yakalanmıştır. Uyumlu filtre temelli çalışmaların ilkinde 40 görüntü üzerinde %94.22 (Al-rawi ve ark., 2007), ikincisinde ise 20 görüntü üzerinde %96.1 (Oloumi ve ark., 2014) doğruluk oranı ile damar segmentasyonu gerçekleştirilmiştir. Çizelge 2.2’de damar segmentasyonu ile ilgili çalışmalar ve başarı oranları özetlenmektedir.

Çizelge 2. 2. Retina görüntülerinden damar segmentasyonu yaklaşımları ve başarı oranları

Yazarlar	Yıl	Veri tabanı	Görüntü Sayısı	Yöntemler	Duy.	Özg.	TCC
Gang ve ark.	2002	-	48	Gauss filtresi	-	-	85.5
Wu ve ark.	2006	Stare	20	Gabor filtresi	-	-	84.3
Al-rawi ve ark.	2007	Drive	40	Uyumlu filtre, Genetik Algoritma	-	-	94.22
Goatman ve ark.	2011	-	109	Eşikleme, Watershed	84.2	85.9	-
Rossant ve ark.	2011	Drive	40	Top-hat dönüşümü, Eşikleme	70.3	97.88	94.33
Oloumi ve ark.	2014	Drive	20	Uyumlu filtre, Çizgi operatörü	-	-	95.1

2.3.3. Eksuda tespiti

Retinanın parlak lezyonu olan eksudaların otomatik tespiti ile ilgili çalışmalar incelendiğinde piksellerin parlaklık değerine dayalı bölütlenmesi, istatistiksel özellikler ve diğer görüntü işleme teknikleri (Renk uzayı dönüşümleri, Gabor, Top-hat dönüşümü ve matematiksel morfolojik işlemler) olmak üzere 3 farklı yöntemin kullanıldığı görülmüştür.

Parlaklık değeri ile görüntü bölütme temelli çalışmalarda retina görüntülerine kontrast ayarlama, parlaklık ayarlama ve histogram eşitleme gibi ön işlemler uygulandıktan

sonra parlaklık değeri ile yapılan eşiklemede 301 görüntü üzerinde %93.1 (Gardner ve ark., 1996); 30 görüntü üzerinde %92.8 (Walter ve ark., 2002); 300 görüntü üzerinde %95 (Niemeijer ve ark., 2007); 58 görüntü üzerinde %100 (Sanchez ve ark., 2008); 372 görüntü üzerinde %98.08 (Zeljko ve ark., 2015) doğru sınıflandırma başarısına ulaşılmıştır. Diğer bir çalışmada ise parlaklık değeri eşiklemesi olarak dinamik eşikleme algoritması kullanılarak 80 görüntü üzerinde %100 (Sanchez ve ark., 2009) doğru sınıflandırma başarısı ile eksuda tespiti gerçekleştirilmiştir.

İstatistiksel özellikler temelli çalışmalarda retina görüntülerine renk uzayı dönüşümleri, kontrast, parlaklık ayarlama ve adaptif histogram eşitleme ön işlemleri uygulandıktan sonra elde edilen görüntülerin ortalama, standart sapma, varyans, karışıklık ve çarpıklık gibi istatistiksel özellikleri değerlendirilerek gerçekleştirilen çalışmalarda 301 görüntü üzerinde %93.1 (Gardner ve ark., 1996); 20 görüntü üzerinde %79.62 (Sanchez ve ark., 2004); 39 görüntü üzerinde %98.05 (Sophorak ve ark., 2008); 300 görüntü üzerinde %96 (Osareh ve ark., 2009); 122 görüntü üzerinde %97.61 (Ponnibala ve Vijayachitra, 2014); 1410 görüntü üzerinde %97.56 (Akram ve ark., 2014) ve 200 görüntü üzerinde %93 (Jaya ve ark., 2015) doğru sınıflandırma başarısı ile eksuda tespiti gerçekleştirilmiştir.

Diğer görüntü işleme tekniklerine dayanan eksuda tespiti çalışmalarında retina görüntülerine renk uzayı dönüşümleri uygulayarak 200 görüntü üzerinde %93 (Jaya ve ark., 2015), Gabor dönüşümleri uygulayarak 20 görüntü üzerinde %94.73 (Akram ve Khan, 2012), Top-hat dönüşümleri uygulayarak 60 görüntü üzerinde %80 (Sophorak ve ark., 2008); 56 görüntü üzerinde %91.07 (Tjandrasa ve ark., 2015) ve matematiksel morfolojik işlemler uygulanarak 88 görüntü üzerinde %70.48 (Welfer ve ark., 2010) doğru sınıflandırma başarısı ile eksuda tespiti gerçekleştirilmiştir. Çizelge 2.3' te eksuda bölgesinin otomatik tespiti ile ilgili çalışmalar ve başarı oranları özetlenmektedir.

Çizelge 2. 3. Retina görüntülerinde eksuda tespiti ile ilgili yaklaşımlar ve başarı oranları

Yazarlar	Yıl	Veri Tabanı	Görüntü Sayısı	Yöntemler	Duy.	Özg.	TCC
Gardner ve ark.	1996	-	301	İstatistiksel özellikler, Eşikleme, ANN	93.1	93.1	-
Walter ve ark.	2002	-	30	Piksel parlaklık değişimleri	92.8	80	-
Sanchez ve ark.	2004	-	20	Renk Değerleri, İstatistiksel Sınıflandırma	79.62	-	-
Niemeijer ve ark.	2007	-	300	Piksel bazlı görüntü bölütleme, Eşikleme	95	86	-
Sophorak ve ark.	2008	-	60	Morfolojik İşlemler	80	99.5	-
Sophorak ve ark.	2008	-	39	İstatistiksel Değerler, Naive Bayes	93.38	98.14	98.05
Osareh ve ark.	2009	-	300	Şekilsel özellikler, ANN	96	94.6	-
Sanchez ve ark.	2009	-	80	Histogram eşitleme, Dinamik Eşikleme	100	90	-
Welfer ve ark.	2010	Image Ret	88	Matematiksel morfolojik işlemler	70.48	98.84	-
Akram ve Khan	2012	Stare, Drive	20	HSI renk uzayı, Gabor, Eşikleme	-	-	94.73
Ponnibala ve Vijayachitra	2014	-	122	Renk uzayı, Adaptif Histogram Eşitleme, Morfolojik İşlemler, İstatistiksel Özellikler, ANN	97.05	100	97.61
Akram ve ark.	2014	Drive, Stare, Messidor	1410	Kontrast iyileştirme, Gabor, İstatistiksel Özellikler, Bayes	97.39	98.02	97.56
Zhang ve ark.	2014	Messidor	1200	Medyan Filtresi, Morfolojik İşlemler, İstatistiksel Özellikler.	-	-	93
Tjandrasa ve ark.	2015	Messidor	56	Kontrast iyileştirme, Top-hat dönüşümü, Kmeans, ANN	-	-	91.07
Jaya ve ark.	2015	-	200	Renk uzayı, Hough dönüşümü, Fuzzy-SVM	94.1	90	93
Zeljko ve ark.	2015	-	372	Medyan Filtresi, Morfolojik İşlemler, Eşikleme	98.08	96.31	-

2.3.4. Hemoraji tespiti

Retinanın koyu lezyonu olan hemorajilerin otomatik tespiti ile ilgili çalışmalar incelendiğinde uyumlu filtre, morfolojik işlemler (Top-hat, Bottomhat), gabor dönüşümü, istatistiksel özellikler ve diğer görüntü işleme teknikleri (Gauss filtresi ve HSV renk uzayı dönüşümü ile eşikleme) olmak üzere 5 farklı yöntem kullanılmıştır.

Uyumlu filtre temelli çalışmalarda retina görüntülerine renk uzayı dönüşümleri ve adaptif histogram eşitleme ön işlemlerinin ardından uyumlu filtre uygulanarak 89 görüntü üzerinde %82.4 (Spencer ve ark., 1996); 41 görüntü üzerinde %95.3 (Hansgen ve ark.,1998); 68 görüntü üzerinde %84 (Frame ve ark.,1998); 20 görüntü üzerinde %56

(Streeter ve Cree, 2003) ve 89 görüntü üzerinde %100 (Kande ve ark., 2010) doğru sınıflandırma başarısı ile hemoraji tespiti gerçekleştirilmiştir.

Morfolojik işlem temelli çalışmaların ilkinde retina görüntülerine açma, kapama, yayma, erozyon gibi temel morfolojik işlemler uygulanarak gerçekleştirilen çalışmalarda 30 görüntü üzerinde %84.1 (Zhang ve Fan, 2006); 10846 görüntü üzerinde %98.6 (Fleming ve ark., 2008) ve 15 görüntü üzerinde %84.49 (Shivaram ve ark., 2009) başarı oranları, ikincisinde retina görüntülerinin hatlarını ön plana çıkararak hemorajilerin daha rahat bir şekilde tespit edilmesi için top-hat dönüşümü uygulanmasıyla 94 görüntü üzerinde %88.5 (Walter ve ark., 2007) ve 20 görüntü üzerinde %99.12 (Kleawsirikul ve ark., 2013) başarı oranları, üçüncüsünde ise bottom-hat dönüşümünün uygulanması sonucu ise 89 görüntü üzerinde %92.19 (Romero ve ark., 2015) başarı oranları ile hemorajilerin tespiti gerçekleştirilmiştir.

Gabor dönüşümü temelli çalışmalarda renk uzayı dönüşümü, adaptif histogram eşitleme, Gabor dalgacığı dönüşümü gibi görüntü işleme yöntemlerini sırasıyla uygulayarak 120 görüntü üzerinde %90.24 (Quelleg ve ark., 2008); 20 görüntü üzerinde %93.71 (Akram ve Khan, 2012); 130 görüntü üzerinde %99.4 (Akram ve ark., 2013); 1410 görüntü üzerinde %98.12 (Akram ve ark., 2014) ve 89 görüntü üzerinde %94.76 (Raja ve Vasuki, 2015) doğru sınıflandırma başarısı ile hemoraji tespiti gerçekleştirilmiştir.

İstatistiksel özellik temelli çalışmalarda retina görüntülerine renk uzayı dönüşümleri, kontrast, parlaklık ayarlama ve adaptif histogram eşitleme ön işlemleri uygulandıktan sonra elde edilen görüntülerin ortalama, standart sapma, varyans, karışıklık ve çarpıklık gibi istatistiksel özellikleri değerlendirilerek gerçekleştirilen çalışmalarda 80 görüntü üzerinde %99.99 (Sopharak ve ark., 2013); 1410 görüntü üzerinde %98.12 (Akram ve ark., 2014) ve 301 görüntü üzerinde %73.8 (Gardner ve ark., 1996) doğru sınıflandırma başarı oranlarına ulaşılmıştır.

Diğer görüntü işleme tekniklerine dayanan hemoraji tespiti çalışmalarında HSV renk uzayı dönüşümleri uygulayarak 125 görüntü üzerinde %88 (Hatanaka ve ark., 2008),

Gauss filtresi uygulayarak 140 görüntü üzerinde %87 (Niemeijer ve ark., 2005); 1441 görüntü üzerinde %85.4 (Fleming ve ark., 2006) doğru sınıflandırma başarıları ile hemoraji tespiti gerçekleştirilmiştir. Çizelge 2.4'te hemoraji bölgesinin otomatik tespiti ile ilgili çalışmalar ve başarı oranları özetlenmektedir.

Çizelge 2. 4. Retina görüntülerinde hemoraji tespiti ile ilgili yaklaşımlar ve başarı oranları

Yazarlar	Yıl	Görüntü Sayısı	Yöntemler	Duy.	Özg.	TCC
Spencer ve ark.	1996	89	Uyumlu filtre, Top-hat dönüşümü, Gaussian filtresi	82.4	85.6	-
Gardner ve ark.	1996	301	İstatistiksel Özellikler, ANN	73.8	73.8	-
Hansgen ve ark.	1998	41	Uyumlu Filtre, Bölge büyütme, Ayrık Dalgacık	95.3	-	-
Frame ve ark.	1998	68	Uyumlu filtre, Bölge büyütme	84	85	-
Streeter ve Cree	2003	20	Top-hat dönüşümü, Uyumlu filtre, Bölge büyütme	56	-	-
Niemeijer ve ark.	2005	140	Gaussian filtresi, Piksel bazlı bölütleme	100	87	-
Fleming ve ark.	2006	1441	Kontrast ayarlama, Watershed Bölge büyütme, Medyan, Gaussian filtresi	85.4	83.1	-
Zhang ve Fan	2006	30	Çok boyutlu morfolojik işlemler	-	-	84.1
Walter ve ark.	2007	94	Kontrast zenginleştirme, Top-hat dönüşümü, Global eşikleme	88.5	-	-
Fleming ve ark.	2008	10846	Histogram ayarlama, Medyan filtresi, Morfolojik İşlemler, SVM	98.6	95.5	-
Hatanaka ve ark.	2008	125	HSV renk uzayı, Parlaklık değişimi, Eşikleme	80	88	-
Quelleg ve ark.	2008	120	Dalgacık dönüşümü, Eşikleme	90.24	89.75	-
Shivaram ve ark.	2009	15	Kontrast iyileştirme, Medyan filtresi, Eşikleme,	89.49	99.89	-
Kande ve ark.	2010	89	Piksel bazlı bölütleme, Uyumlu filtre, Top-hat dönüşümü	100	91	-
Akram ve Khan	2012	20	HSI renk uzayı, Gabor, Eşikleme	-	-	93.71
Kleawsirikul ve ark.	2013	20	Renk dönüşüm uzayları, Top-hat dönüşümü, Kural Bazlı sınıflandırma	80.37	99.53	99.12
Akram ve ark.	2013	130	Kontrast iyileştirme, Gabor, İstatistiksel özellikler, SVM	98.64	99.69	99.4
Sophorak ve ark.	2013	80	Medyan Filtre, Adaptif Histogram Eşitleme, İstatistiksel Özellikler, Naive Bayes	85.68	99.99	99.99
Akram ve ark.	2014	1410	Kontrast iyileştirme, Gabor, İstatistiksel Özellikler, Bayes	97.83	98.36	98.12
Romero ve ark.	2015	89	Medyan Filtre, Bottom-hat, Radon dönüşümü, PCA	88.06	97.47	92.19
Raja ve Vasuki	2015	89	Histogram Eşitleme, LAB renk uzayı, Gabor, Eşikleme, SVM	94.76	99.85	-

2.3.5. Diyabetik retinopati sınıflandırılması

DR sınıflandırılması ile ilgili çalışmalar incelendiğinde parlaklık değeri ile görüntü bölütleme, istatistiksel özellikler ve diğer görüntü işleme teknikleri (morfolojik özellikler, dalgacık dönüşümü, HSV renk uzayı ve uzaklık algoritması) olmak üzere 3 farklı yöntemin kullanıldığı görülmüştür.

Parlaklık değerleri ile görüntü bölütleme temelli çalışmalarda retina görüntülerine kontrast ayarlama, parlaklık ayarlama ve histogram eşitleme gibi ön işlemler uygulandıktan sonra parlaklık değeri ile yapılan eşikleme kullanılarak 301 görüntü üzerinde %88.4 (Gardner ve ark., 1996); 83 görüntü üzerinde %97 başarı oranı gerçekleştirilmiştir (Hansen ve ark., 2004). Dinamik eşikleme kullanılarak gerçekleştirilen çalışmada ise 260 görüntü üzerinde %93.1 (Larsen ve ark., 2003) doğru sınıflandırma başarısı ile DR teşhisi gerçekleştirilmiştir.

İstatistiksel özellik temelli çalışmalarda retina görüntülerine renk uzayı dönüşümleri, kontrast, parlaklık ayarlama ve adaptif histogram eşitleme ön işlemleri uygulandıktan sonra elde edilen görüntülerin ortalama, standart sapma, varyans, karışıklık ve çarpıklık gibi istatistiksel özellikleri değerlendirilerek gerçekleştirilen çalışmalarda 767 görüntü üzerinde %80.21 (Sinthanayothin ve ark., 2003); 143 görüntü üzerinde %100 (Kahai ve ark., 2006); 14406 görüntü üzerinde %86.5 (Philip ve ark., 2007); 158 görüntü üzerinde %82 (Aptel ve ark., 2008); 340 görüntü üzerinde %99.38 (Ganesan ve ark., 2014) ve 60 görüntü üzerinde %98.33 (Welikala ve ark., 2015) doğru sınıflandırma başarısı ile DR teşhisi gerçekleştirilmiştir.

Diğer görüntü işleme tekniklerine dayanan DR sınıflandırması çalışmalarında morfolojik dönüşümler uygulayarak 140 görüntü üzerinde %93 (Nayak ve ark., 2008); 124 görüntü üzerinde %84 (Yun ve ark., 2008), wavalet dönüşümü uygulayarak 240 görüntü üzerinde %99.17 (Noronha ve ark., 2013), HSV renk uzayı dönüşümleri uygulayarak 40 görüntü üzerinde %96.2 (Latha ve Durga, 2014), Öklid ve Mahalanobis uzaklık ölçütlerini de hesaba katarak 376 görüntü üzerinde %98 (Agurto ve ark., 2010) doğru sınıflandırma başarısı ile DR teşhisi gerçekleştirilmiştir. Çizelge 2.5’de otomatik DR sınıflandırılması ile ilgili çalışmalar ve başarı oranları özetlenmektedir.

Çizelge 2. 5. Retina görüntülerinde DR tespiti ile ilgili yaklaşımlar ve başarı oranları

Yazarlar	Yıl	Görüntü Sayısı	Yöntemler	Duy.	Özg.	TCC
Gardner ve ark.	1996	301	Piksel bazlı bölütleme, ANN	88.4	83.5	-
Larsen ve ark.	2003	260	Dinamik eşikleme	93.1	71.6	-
Sinthanayothin ve ark.	2003	767	İstatistiksel özellikler, ANN	80.21	70.66	-
Hansen ve ark.	2004	83	Eşikleme	97	75	-
Kahai ve ark.	2006	143	İstatistiksel özellikler ve öğrenme	100	67	-
Philip ve ark.	2007	14406	Wilson skoru ve Kappa istatistiği	86.5	95.3	-
Aptel ve ark.	2008	158	Kappa analizi	76.92	99.16	82
Nayak ve ark.	2008	140	Morfolojik özellikler, ANN	90	100	93
Yun ve ark.	2008	124	Morfolojik özellikler, ANN	90	100	84
Agurto ve ark.	2010	376	Uzaklık algoritmaları	-	-	98
Noronha ve ark.	2013	240	Dalgacık dönüşümü, SVM	99.17	99.17	99.17
Ganesan ve ark.	2014	340	İstatistiksel Özellikler, SVM, Olaslısal ANN	99.03	99.73	99.38
Latha ve Durga	2014	40	Medyan Filtre, HSV renk uzayı, İstatistiksel Özellikler, PSO.	97.2	94	96.2
Welikala ve ark.	2015	60	İstatistiksel Özellikler, Genetik Algoritmalar	100	97.5	98.33

2.4. Sayısal görüntü işleme tanımları

Gerçek yaşamdaki üç boyutlu nesnelerden oluşan bir sahnenin basit iki değişkenli bir fonksiyon olarak tanımlanmasına görüntü denir. Tanımlanan $f(x, y)$ fonksiyonunda ifade edilen bir görüntüde f parlaklık, karşıtlık gibi bir birim iken x ve y değişkenleri ise görüntünün koordinatlarıdır (Gonzalez ve Woods, 2002). Görüntü oluşturan temel parametreler piksel, parlaklık, çözünürlük ve karşıtlıktır.

Piksel, optik bir algılayıcı tarafından görüntülenen resmin sayısal ortamdaki her satır ve sütunun kesiştiği noktaya piksel adı verilir. Bir piksel kırmızı, mavi ve yeşil renklerden oluşur. Piksel yoğunluğu ile sayısal görüntünün kalitesi doğru orantılıdır. Örneğin, günlük hayatta kullanılan akıllı telefonlar, bilgisayarlar, televizyonlar vb. teknoloji cihazlarında piksel değerlerinin yüksek olması görüntü kalitesinin daha net olmasını sağlamaktadır. (Gonzalez ve Woods, 2002).

Parlaklık, sayısal ortama aktarılan bir görüntü farklı piksel değeriyle ifade edilebilmektedir. Görüntüdeki her pikselin parlaklık değeri ortamdaki ışık yoğunluğu ile doğru orantılıdır. Ortamın ışık yoğunluğu ile görüntünün parlaklık değeri doğru orantılıdır.

özünürlük, sayısal ortama aktarılan görüntüdeki resmin toplam piksel sayısıdır. Günlük hayatımızda kullandığımız akıllı telefonlar, bilgisayarlar ve televizyonlar belirli bir özünürlüğe sahiptir. Bir görüntüde piksel sayısına baėlı olarak özünürlük artar ve görüntü netleşir (ayırılı, 2006).



3. MATERYAL VE YÖNTEM

3.1. Materyal

Tez çalışmasında her DR lezyonunun teşhis ve sınıflandırılması için Çizelge 3.1’de verilen görüntü veri tabanlarından alınan retina görüntüleri kullanılmıştır.

Çizelge 3. 1. Çalışmada kullanılan retina görüntüsü veri tabanları

Veritabanı	Görüntü sayısı	Çözünürlük	Görüntü formatı
DRIVE	40	565 X 584	.tif
ImageRet	70	1500 X 1152	.png
GOPRetina	88	3008 X 1960	.jpg

Çalışmada kullanılan retina görüntüleri için internet üzerinde halka açık olarak sunulan DRIVE, ImageRet ve GOPRetina veri tabanlarından alınan retina görüntüleri kullanılmıştır.

DRIVE veri tabanında, yedisi DR hastalıklı olan toplam 40 adet görüntü bulunmaktadır. Bu görüntüler Canon CR5 3CCD kamerası ile 45° görüş açısı ile alınmış 768x584 çözünürlükte 24 bitlik renkli görüntülerdir. Kan damarı bölütlemesinin performansını ölçmek için her iki veri tabanında da bulunan görüntülerin manüel olarak bölütlenmiş halleri de bulunmaktadır (Hoover ve ark., 2000; Staal ve ark., 2004).


ImageRet veri tabanında, dijital fundus kamerası 50° görüş açısı ile alınmış 1500x1152 çözünürlükte ve 24 bitlik renkli görüntülerdir. Bu veri tabanında 70 adet retinal fundus görüntü bulunmaktadır. Bu görüntülerin 17’si sağlıklı ve geri kalan 53’ü de DR belirtili (eksuda ve hemoraji) görüntülerden oluşmaktadır (Kauppi ve ark., 2007).

GOPRetina veri tabanında, dijital fundus kamerası 50° görüş açısı ile alınmış 3008x1960 çözünürlükte ve 24 bitlik renkli görüntüler Gaziosmanpaşa Üniversitesi Sağlık Araştırma ve Uygulama Merkezi Göz Hastalıkları Polikliniği’nde muayene olan hastalardan alınmıştır. Görüntülerin kullanılması için Cumhuriyet Üniversitesi Klinik

Araştırmalar Etik Kurul’undan etik kurul raporu alınmış olup ilgili rapor Ek-1’de verilmektedir. Bu veritabanında 88 adet retinal fundus görüntü bulunmaktadır. Bu görüntülerin 16’sı eksudalı, 23’ü hemorajili, 24’ü eksudalı ve hemorajili, 25’i ise sağlıklı bireylerden alınmıştır.

3.2. Görüntü işleme yöntemleri

Kamera, fotoğraf makinesi ve sensörler yardımıyla algılanan herhangi bir nesne veya obje görüntüsünün analog ortamdan sayısal ortama aktarılması ve aktarılan bu nesne üzerinde gerçekleştirilen analizlere görüntü işleme denir (Gonzalez ve Woods, 2004). Şekil 3.1’de görüntü işleme sisteminin genel yapısı gösterilmektedir.




Şekil 3. 1. Görüntü işleme temel adımları (Gonzalez ve Woods, 2004)

Şekil 3.1’de gösterilen görüntü işlemenin temel adımları renk uzayları arası dönüşüm, parlaklık ayarlama, karşıtlık ayarlama, Gamma düzeltmesi, histogram temelli görüntü iyileştirme, filtre temelli görüntü iyileştirme, kenar tespit algoritmaları, dairesel Hough dönüşümü, Gabor dönüşümü, eşikleme ve morfolojik işlemlerden oluşur.

3.2.1. Renk uzayları

Renk uzayları, renkleri tanımlamak için kullanılan matematiksel modellerdir. Renkli görüntüyü elde edebilmek için, saklamaya ve uygulamaya en uygun olan renk uzayı kullanılmaktadır (Taşkın, 2007). Görüntüde elde etmek istediğimiz sonuca göre renk

uzayının seçilmesi gerekir. Renk uzayları genellikle cihaz bağımlı ve cihaz bağımsız olmak üzere iki grupta incelenmektedir. Şekil 3.2’de renk uzaylarının sınıflara ayrılmış şeması verilmektedir.




Şekil 3. 2. Renk uzaylarının sınıflandırılması (Taşkın, 2007)

Bu tezde, Şekil 3.2’de verilen RGB, HSV, CMY, YUV ve YIQ renk uzayları kullanılmıştır.


RGB Renk Uzayı

RGB (R: Kırmızı (Red), G: Yeşil (Green), B: Mavi (Blue)) renk uzayı televizyon, monitör ve kameralarda renkli görüntüyü elde etmek için geliştirilmiştir. RGB renk uzayı toplamalı renk karışımı yöntemiyle bir küpün içine renklerin yerleştirilmesi ile elde edilmektedir. Şekil 3.3 renklerin bir küpün x, y, z koordinat düzlemine 0 ile 1 arasında oluşan değerlerin yerleştirilmesini göstermektedir.



Şekil 3. 3. RGB renk uzayı (Yılmaz, 2007)


Şekil 3.3'te görüldüğü gibi, her ana rengin küpün koordinat noktasında 1 değerini alacak şekilde yerleştirilir. Örneğin (0,0,0) noktası siyaha, (1,1,1) noktası beyaza karşılık gelirken, köşegen her renk değerinden eşit miktarda içerdiği için gri seviye karşılık gelir. RGB renk uzayında bir renk tonu için üç değer içermektedir. (Yılmaz, 2007). Şekil 3.4'te çalışmadan alınan örnek bir retina görüntüsünün R, G ve B kanallarına ayrılarak hastalıklı bölgelerin tespiti için uygun renk uzayı ve kanalı seçimi işlemlerine karar verilmektedir.



Şekil 3. 4. RGB renk uzayı için retina görüntüsünün R, G ve B kanalı


HSV Renk Uzayı

HSV renk uzayında üç değişken vardır: renk özü (H : Hue), doygunluk (S : Saturation) ve parlaklık değeri (V : Value) parametresidir. Renk özü her renk için ayırt edici nitelikler ve belli bir açı ile ifade edilir. Doymunluk bir rengin aynı ton değeri için ayırt edici nitelikler. En son değeri ise bir rengin açıklık koyuluk derecesidir. HSV renk uzayının daha anlaşılır bir şekilde ifade edilmesi için Şekil 3.5'de verilmektedir.



Şekil 3. 5. HSV renk uzayı (Sural ve ark., 2002)


Şekil 3.5'de görüldüğü gibi, S yatay düzlemde $[0\ 1]$ arasında değer almaktadır. Altıgen huninin tabanı ile tepesi arasındaki doğrusal eksen 0, altıgen dilimlerin çevresi 1, V düşey düzlemde 0 veya 1, altıgen huninin tabanı 0 ve tepesi 1 değerini almaktadır. H değeri ise altıgen huninin daire dilimlerinde açısal değere sahiptir. Kırmızı 0 dereceden başlamak üzere ana renkler 120 derecelik açılarla, ara renkler ise sarı 60 dereceden başlayarak yine 120 derecelik açılarla yerleştirilmiştir. $S=0$ ve $V=0$ siyah rengi, $S=0$ ve $V=1$ beyaz rengi tanımlamaktadır. $S=0$ iken H 'nin bir anlam ifade etmediği şekillerde görülmektedir. $V=1$, $S=1$ iken tonlar en yüksek değerini almaktadır (Sural ve ark., 2002). Şekil 3.6'da çalışmadan alınan örnek bir retina görüntüsü H , S ve V kanallarına ayrılarak hastalıklı bölgelerin tespiti için uygun renk uzayı ve kanalı seçimi işlemlerine karar verilmektedir.



Şekil 3. 6. HSV renk uzayı için retina görüntüsünün H , S ve V kanalı


CMY Renk Uzayı

Renk pigmentlerini kağıt üzerine baskılayan cihazlar (örneğin, renkli yazıcı ve fotokopi makinesi vb.) için geliştirilmiştir. Bir yazıcı RGB veri girişine sahip olsa bile RGB veri girişini CMY 'e çevirmek zorundadır. CMY renk uzayının yazıcılarda kullanılmasının nedeni beyaz kâğıdın renkleri emmesi ile ilgilidir. Örneğin mor sarı karışımında morun emilmesi ile sarı yeşili yansıtır. Sarının emilmesi ile mor maviyi yansıtır. Böylece emilme olmayan bölgede kırmızı kalır. Böylece kağıt üzerine istenilen renk basılmış olur. CMY renk uzayının kartezyen koordinat sistemine yerleştirilmesi Şekil 3.7'de gösterilmektedir.



Şekil 3. 7. CMY renk uzayı (Yılmaz ve ark., 2002)


Şekil 3.7’de görüldüğü gibi, ara renkler 1 değerini almaktadır. Ayrıca (0,0,0) ton değeri beyaz, (1,1,1) ton değeri ise siyahtır. CMY renk uzayında da RGB renk uzayındaki gibi bir rengin 3 ton değeri bulunmaktadır (Yılmaz ve ark., 2002). Şekil 3.8’de çalışmadan alınan örnek bir retina görüntüsü C, M ve Y kanallarına ayrılarak hastalıklı bölgelerin tespitinde kullanılan uygun renk uzayını ve kanal seçimini göstermektedir.



Şekil 3. 8. CMY renk uzayı için retina görüntüsünün C, M ve Y kanalları


YUV Renk Uzayı

YUV renk uzayı PAL, NTSC ve SECAM bileşik ve renkli video standartlarında kullanılır. Görüntüyü kaydetme ilk zamanlarda siyah beyaz olarak yapılmıştır. Daha sonra renkli görüntüye geçilmesi YUV renk uzayını zorunlu kılmıştır. YUV renk uzayının amacı renkli görüntüyü siyah beyaza dönüştürmesidir. Renkli cihazlarda ise renk seçeneği olarak kullanılmaktadır (Buğday, 2010). Şekil 3.9’da YUV renk uzayının U ve V bileşeni görülmektedir.



Şekil 3. 9. YUV renk uzayının U-V bileşeni (Buğday, 2010)


Şekil 3.9’da görüldüğü üzere Y siyah-beyaz sistemin parlaklık bilgisini, U ve V ise renk bilgisini tutmaktadır. Şekil 3.10’da çalışmadan alınan örnek bir retina görüntüsü Y, U ve V kanallarına ayrılarak hastalıklı bölgelerin tespitinde kullanılan uygun renk uzayını ve kanalı seçimini göstermektedir.



Şekil 3. 10. YUV renk uzayı için retina görüntüsünün Y, U ve V kanalları


YIQ Renk Uzayı

YIQ renk uzayı, YUV renk uzayından türetilmiştir. NTSC bileşik video standardında görüntü seçeneği olarak kullanılan bir renk uzayıdır. YIQ renk uzayını YUV renk uzayından ayıran en önemli özellik I ve Q renk seçeneğidir. Şekil 3.11’de YIQ renk uzayının farklılığı sağlayan I ve Q bileşeni görülmektedir (Buğday, 2010).



Şekil 3. 11. YIQ renk uzayı I ve Q bileşenleri (Buğday, 2010)

Şekil 3.11’de görüldüğü gibi Y yine siyah-beyaz sistemin parlaklık değerini göstermekte, I ve Q değerleri ise renk bilgisini transfer etmek için kullanılmaktadır. Şekil 3.12’de çalışmadan alınan örnek bir retina görüntüsü Y, I ve Q kanallarına ayrılarak hastalıklı bölgelerin tespitinde kullanılan uygun renk uzayını ve kanal seçimini göstermektedir.




Şekil 3. 12. YIQ renk uzayı için örnek retina görüntüsünün Y, I ve Q kanalları

3.2.2. Parlaklık ayarlama

Parlaklık ayarlama, görüntülerin gri değerlerinin ağırlıklı ortalamasına dayalı olarak gerçekleştirilir. Bu amaç için, görüntüdeki piksellerin hesaplanan ağırlıklı ortalama gri ton değerine sabit bir c sayısı eklenir. Bu yaklaşım için kullanılan dönüşüm fonksiyonu Eşitlik 3.1’de verilmektedir.

$$s = T(r) = r + c \quad (3.1)$$

Görüntünün parlaklığı $c < 0$ için artar ve $c > 0$ için azalır (Bellanger, 2000). Şekil 3.13'te çalışmadan alınan retina görüntüsünün parlaklığı ayarlanarak hastalıklı bölgelerin daha kolay bir şekilde ortaya çıkması sağlanmaktadır.




(a) Renkli retina görüntüsü (b) Parlaklığı artırılmış retina görüntüsü

Şekil 3. 13. Retina görüntüsünde parlaklık ayarlama örneği

3.2.3. Karşıtlık ayarlama

Görüntüdeki en parlak bölüm ile en karanlık bölüm arasındaki farka karşıtlık denir. Görüntüdeki siyah ve beyaz arasındaki karşıtlık aralığı artıktıkça iki uç arasındaki gri tonlar daha net ortaya çıkar. Aradaki değer ne kadar fazla olursa görüntü o kadar canlı ve net olmaktadır. Resimlerin renk tonlarını ayarlamak amacıyla karşıtlık ayarlaması yapılmaktadır (Bellanger, 2000). Şekil 3.14'te çalışmadan alınan gri seviye retina görüntüsünün karşıtlığı ayarlanarak hastalıklı bölgelerin daha kolay bir şekilde ortaya çıkması sağlanmaktadır.



(a) Gri seviye retina görüntüsü (b) Karşıtlığı artırılmış retina görüntüsü


Şekil 3. 14. Retina görüntüsünde karşıtlık ayarlama örneği

3.2.4. Gama düzeltmesi

Görüntünün gri seviye tonlarını aydınlatmak veya karartmak için Eşitlik 3.2 ile verilen Gama düzeltmesi dönüşüm formülü kullanılır.

$$s = cr^\gamma \quad (3.2)$$

Eşitlik 3.2’de verilen γ değerindeki değişimle görüntü tonları ayarlanmaktadır. Şekil 3.15’de çalışmadan alınan retina görüntüsüne farklı γ değerleri ile Gama düzeltmesi yapılarak hastalıklı bölgelerin daha kolay bir şekilde ortaya çıkması sağlanmaktadır (Farid, 2001).




Şekil 3. 15. Retina görüntüsü ve Gri seviyeye 0.8-0.6-0.4 eşik değerinde gama düzeltmesi

Şekil 3.15’de görüldüğü gibi gama eşik değeri azaltılırsa görüntüdeki gürültülerin azaldığı görülmektedir. Retina görüntüsü içerisinde optik disk ve retina damarlarının tespiti için kullanılmaktadır.

3.2.5. Histogram temelli görüntü iyileştirme

Görüntü içerisindeki her bir renk değerinden ne kadar bulunduğunu koordinat sistemi şeklinde veren ve bu sayede görüntüdeki parlaklık yoğunluklarının analiz edilmesini sağlayan grafik sistemine histogram denir. Bir görüntünün histogramı alınırken öncelikle görüntü renkli bir görüntü ise bu görüntü gri renk uzayına çevrilir ve görüntünün histogramında siyah ve beyaz renk tonlarından oluşan bir grafik elde edilir. Gri renk uzayında her bir piksel 0-255 arası bir değer alır. Ton değeri 0' a yaklaşması görüntünün siyaha yakın renk tonlarında olduğunu 255'e yaklaşması da beyaza yakın renk tonlarında olduğunu göstermektedir. Parlaklığın 0 değeri siyah rengi 1 değeri ise beyaz rengi temsil etmektedir (Gonzalez ve Woods, 2002). Çalışmada kullanılan retina görüntüsünün histogramı Şekil 3.16'da verilmektedir.



Şekil 3. 16. Retina görüntüsü ve histogramı

Görüntünün histogramında renk değerleri bir bölgede yoğunluk göstermiş ise bu görüntünün karışıklığı yüksektir. Renk değerleri dağılmış ise görüntünün karışıklığı düşüktür denir. Karışıklığı düşük olan görüntüleri iyileştirmek ve daha iyi bir görüntü elde etmek için histogram üzerinde bazı değişiklikler yapılması gerekmektedir. Bu yapılan değişiklikler bütün görüntüye etki etmektedir. Görüntü iyileştirme işlemi için genel histogram eşitleme ve adaptif histogram eşitleme teknikleri kullanılmaktadır.

Genel histogram eşitleme

Histogram eşitleme yöntemi gri ton değerlerinin aralığını tekrar düzenlemeyi hedefleyen bir yöntemdir. Histogram eşitleme yönteminde gri ton değerlerinin yoğun olduğu yere daha geniş bir aralık, yoğunluğun az olduğu yere daha dar bir aralık ayrılır

(Gonzalez ve Woods, 2002). Genel histogram eşitleme algoritmasının çalışma adımları şu şekilde sıralanabilir:

Adım 1: Histogramı oluşturulan görüntüdeki pikseller r ton değeri ile ifade edilsin. Piksel değerlerinin alabileceği en yüksek ton değerinin bir fazlası L ile gösterilsin.

$$0 \leq r \leq L - 1 \quad (3.3)$$

Adım 2: Histogram eşitleme formülünü elde etmek için $p(r_k)$ fonksiyonu tanımlandığında oluşturulan formül;

$$p(r_k) = \frac{n_k}{n} \quad (3.4)$$

n_k : Parlaklığı k olan piksel sayısı

n : Toplam piksel sayısı

r_k : Parlaklığı k olan pikselin görüntüde bulunma oranı

Adım 3: s_k histogram eşitlemesi formülü için kullanılan kümülatif olasılık fonksiyonudur.

$$s_k = \sum_{i=0}^k \frac{n_i}{n} = \sum_{i=0}^k p(r_i) \quad (3.5)$$

s_k : Parlaklığı k olan pikselin kümülatif olasılık değeri

Adım 4: Bu denklemden sonra ters dönüşüm uygulandığında;

$$r_k = T^{-1}(s_k) \quad (3.6)$$

eşitliği elde edilir.


$$0 \leq s_k \leq 1$$

$$T^{-1}(s_k) = (L - 1)T(r_k) \quad (3.7)$$

formülü kullanılarak histogram eşitlemesi tamamlanmış olur.

Histogram eşitleme yöntemi tüm görüntüleri iyileştirmez. Görüntü içerisindeki tüm piksellerin belli aralıkta renk değerine sahip olduğu resimlerde etkilidir. Resim gri ve tonlarından oluşuyorsa histogram eşitleme işe yarar. Eğer renkli bir resimde histogram eşitleme yapılacaksa renkleri ayrıştırıp örneğin kırmızı, yeşil ve mavi renk kanalları için

ayrı ayrı histogram eşitleme yapılmalıdır (Çayırılı, 2006). Çalışmadan alınan retina görüntüsünün histogramının eşitlenmesiyle elde edilen sonuç ve eşitleme yapılmış görüntünün histogramı Şekil 3.17’de gösterilmektedir.




Şekil 3. 17. Histogram eşitlemesi ve eşitleme sonrası görüntünün histogramı

Adaptif histogram eşitleme

Adaptif histogram eşitleme, dar bir bölgede yoğun dağılıma sahip görüntülerde gürültü oluşması problemini çözmek için kullanılan yerel histogram eşitleme algoritmasıdır. Bu algorithmada temel görüntü dikdörtgensel alt bölgelere bölünür ve her bölgeye histogram eşitleme uygulandıktan sonra bi-lineer interpolasyon yöntemi ile alt bölgeler birleştirilerek temel görüntü yeniden elde edilir (Teo, 2003). Adaptif histogram eşitleme algoritması aşağıdaki adımlardan oluşmaktadır.

- Adım 1:* Görüntünün boyutuna göre bir çerçeve belirle. (Örnek 36 piksellik bir kare)
- Adım 2:* Çerçeveyi görüntünün sol üst köşesine konumla.
- Adım 3:* Her çerçeve için genel histogram eşitleme algoritması uygula.
- Adım 4:* Alt bölgeleri birleştir.

Çalışmada kullanılan retina görüntüsüne adaptif histogram eşitleme algoritmasının uygulanması sonucu elde edilen görüntü ve histogram grafiği Şekil 3.18’de gösterilmektedir.



Şekil 3. 18. Adaptif histogram eşitlemesi uygulaması


3.2.6. Filtre temelli görüntü iyileştirme

Bozulma görüntünün makineden geçiş aşamasında işlenip betimlenirken oluşan hatalardır (Gonzalez ve Woods, 2002). Görüntülerde en çok meydana gelen bozulma radyal bozulmadır. Görüntü bozulmaları genellikle lens kaynaklıdır, lenslerin karakteristiği görüntünün kalitesini belirler. Görüntülerde bu duruma ek olarak piksel bozulması da olabilir (Gonzalez ve Woods, 2004). Bu bozulmaları gidermek için çalışmada Medyan filtresi kullanılmaktadır.

Medyan filtresi

İstatistiksel olarak kullanılan bir filtredir. Komşu piksellerin medyan değeri alınarak kullanılır. Her çıkış pikseli giriş pikselinin 3x3, 5x5 gibi komşuluğunda medyan değeri içermelidir. Medyan filtresi hatalı piksel değerini değiştirerek girdiğimiz medyan değeri ile değiştirilir. Medyan filtresi genellikle düşük gürültülerde etkilidir (Gonzalez ve Woods, 2002). Medyan filtresi küçük boyutlara uygulandığında gürültü seviyesine yetersiz kalmakta, büyük boyutlara uygulandığında görüntüde bulanıklık meydana gelmektedir. %50 ve üzeri orandaki gürültülerde görüntü detayını koruyamamaktadır

(Lukac, 2003). Tuz-biber gürültüsü eklenen retina görüntüsüne Medyan filtresi uygulanması sonucu elde edilen görüntü Şekil 3.19’da verilmektedir.



Şekil 3. 19. Medyan filtresi uygulaması

Şekil 3.19’da verilen retina görüntüsündeki belirgin tuz-biber gürültüsünün Medyan filtresi ile temizlendiği görülmektedir. Özellikle fundus kameradan görüntü alma aşamasında hasta veya cihaz kaynaklı oluşabilecek hataları gidermede Medyan filtre kullanılmaktadır (Niemeijer ve ark., 2007).

3.2.7. Kenar tespit algoritması temelli görüntü bölütleme

Kenar bulma görüntü işlemede en önemli işlem olarak nitelendirilir. Renkli görüntülerin çoğunda kenar bulma işlemi, görüntüleri gri seviyeye dönüştürerek yapılmaktadır. Gri görüntülerdeki kenarlar, iki bölgenin parlaklık seviyelerinin açık bir şekilde birbirinden farklı olduğu sınırlar olarak tanımlanabilir. Kenarlar görüntü içindeki en önemli bilgidir (Balcı, 2008). Kenar bölgeleri görüntülerde piksel değerlerindeki ani değişimlerin gerçekleştiği yerler olarak da tanımlanır. Görüntülerde ani değişim gösteren yerleri bulan ve kenar olup olmadıklarını inceleyen en başarılı yöntemlerden biri Canny kenar tespit algoritmasıdır (Ding ve Goshtasby, 2001).

Canny kenar tespit algoritması

Kenar bulmada son derece etkin bir algoritmadır. Bu algoritmanın çalışma adımları şu şekildedir (Canny, 1986).

Adım 1: Öncelikle görüntü gri seviyeye dönüştür.

Adım 2: Gri seviyeye dönüştürülen görüntüye Gaussian filtresi uygulayarak görüntüleri temizle (σ :Yumuşatma katsayısı).

$$F(x, y) = I(x, y) * G(x, y, \sigma) \quad (3.8)$$


Adım 3: Filtreleme sonucu oluşturulan görüntünün kısmi türevlerini hesapla ve her bir noktanın eğim değerlerini bul.

$$M(x, y) = |\nabla I(x, y)| = \sqrt{\left(\frac{\partial F(x, y)}{\partial x}\right)^2 + \left(\frac{\partial F(x, y)}{\partial y}\right)^2} \quad (3.9)$$

Adım 4: Görüntünün eğim değerlerinde maksimum olmayan noktaları bastır.

Adım 5: Hatalı bulunan kenar noktalarını azaltmak için algoritmanın son adımında $M(x, y)$ 'e bir eşik değeri uygulayarak eşik değerinin altında kalan bütün noktalar arka plan olarak ayarla.

Canny kenar bulma algoritması uygulanan retina görüntüsü Şekil 3.20'de gösterilmektedir.



Şekil 3. 20. Canny kenar tespit algoritmasının uygulaması

3.2.8. Çembersel Hough dönüşümü

Hough dönüşümünün özel bir hali olan çembersel Hough dönüşümünde öncelikle kenarlar bulunur. Bulunan kenarlar üzerinden herhangi bir eşikleme yöntemi ile siyah-beyaz yeni bir görüntü ortaya çıkarılır. Bir akümülatör matris ile kenar pikselleri için

noktanın kendisinde bulunma olasılığı olan geometrik cisimlerin polar düzlemdeki değerleri arttırılır. Bütün pikseller için bu şekilde değerlerin atanması sağlanır ve oluşması muhtemel şekiller belirlenir. Akümülatör matrisi, r yarıçaplı ve $[a,b]$ merkezli çemberde üç boyutlu olarak oluşmaktadır. Yarıçap aralığı belirlendikten sonra çember denklemi kullanılarak çember merkezi tespiti yapılır (Abdelazeem, 2002). Eşitlik 3.10'da merkez noktasının koordinatı (a,b) ve yarıçapı r olan çemberin analitik düzlemdeki denklemi verilmektedir.


$$(x - a)^2 + (y - b)^2 = r^2 \quad (3.10)$$

Analitik düzlemdeki denklemi verilen çemberin parametrik gösterimi ise Eşitlik 3.11'de gösterilmektedir.

$$x = a + r \sin \theta \quad (3.11)$$

$$y = b + r \cos \theta$$

Eşitlik 3.11'de verilen açı $0 < \theta < 2\pi$ aralığında değişim yapılarak belirli bir yarıçapı olan çember üzerinde, noktanın bulunup bulunmadığının kontrolü gerçekleştirilir. Çembersel Hough dönüşümü için kullanılacak parametre uzayı ise Şekil 3.21'de gösterilmiştir.



Şekil 3. 21. Çembersel Hough dönüşümü parametre uzayı (Rizon ve ark. 2005)

Şekil 3.21'de verilen çembersel Hough dönüşümünde kullanılacak parametre uzayında iki boyutlu akümülatör matris ile çemberin merkezi olan $[a,b]$ noktalarının saklanması

sağlanır. Bu saklama işlemi için gereken koşul yarıçap değerinin verilmiş olmasıdır. Bu algoritmanın adımları şu şekildedir (Rizon ve ark. 2005).


Adım 1: Görüntüyü gri renk uzayına çevir.

Adım 2: Gri renk uzayına çevrilen görüntüye Canny kenar bulma algoritması uygula.

Adım 3: Kenar bulma algoritması uygulanmış siyah-beyaz görüntünün tüm piksellerinde belirlenen yarıçap değerine göre çember taraması yap.

Adım 4: Bulunan çemberleri gri renk uzayındaki görüntüde çizerek belirle.

Çembersel Hough dönüşümünün uygulanması sonucu retinadaki optik disk bölgesinin tespiti Şekil 3.22’de gösterilmektedir.



Şekil 3. 22. Retina görüntüsünde çembersel Hough dönüşümü uygulaması

3.2.9. Gabor dönüşümü

Gabor dönüşümü görüntü üzerindeki belirli yönlerde uzanan ayrıtları tespit etmek ve özellik çıkarmak için kullanılan bir görüntü işleme algoritmasıdır. Bu dönüşüm yöntemi genel yapısı itibariyle yön temelli bir filtre olduğundan plaka tanıma işlemlerinde, karakter tanımda ve yüz tanıma gibi sistemlerde çok sık kullanılmaktadır. Bu algoritmanın çalışma adımları şu şekildedir (Petkov ve Wieling, 2004).

Adım 1: Görüntüyü $I(x,y)$ şeklinde iki boyutlu bir matrise dönüştür.

Adım 2: Gabor dönüşümü için gerekli parametrelere $(\tau, \theta, \sigma, \gamma)$ değer ata. Burada, τ görüntüdeki ilgili örüntünün dalga boyunu, θ ilgili örüntünün

açısını, σ ilgili örüntünün ölçeğini, γ ise Gabor çekirdeğinin en/boy oranını göstermektedir.

Adım 3: Gabor dönüşümü eşitliğinde gerekli (x', y') değerlerini Eşitlik 3.12 ile hesapla.

$$x' = x \cos \theta + y \sin \theta \quad (3.12)$$


$$y' = y \cos \theta - x \sin \theta$$

Adım 4: Gabor dönüşümünde kullanılan dalgacık çekirdeğini Eşitlik 3.13 ile hesapla.

$$g(x, y, \tau, \theta, \sigma, \gamma) = \exp\left(-\frac{x'^2 + \gamma^2 y'^2}{2\sigma^2}\right) \cos\left(2\pi \frac{x'}{\tau}\right) \quad (3.13)$$


Adım 5: Görüntüye elde edilen Gabor filtresini uygula (Gabor çekirdeği ile görüntüyü konvüle et).

Şekil 3.23 çalışmada kullanılan örnek bir Gabor çekirdeğinin görüntüsünü göstermektedir.



Şekil 3. 23. Örnek Gabor çekirdeği ($\theta=0^\circ$)

Şekil 3.23'te görüldüğü gibi oluşturulan Gabor çekirdeği 30° aralıklarla döndürülerek 6 farklı Gabor çekirdeği elde edilir. Elde edilen 6 farklı Gabor çekirdeği önışlemden geçirilmiş son görüntü ile konvolüsyon işlemine tabi tutularak 6 farklı görüntü elde edilir. Her bir piksel için bu görüntülerden maksimum parlaklık değeri üreten pikseller kan damarı olarak belirlenmektedir. Şekil 3.24 Gabor dönüşümü ile elde edilen retina görüntüsünü göstermektedir.



Şekil 3. 24. Gabor dönüşümü ile elde edilen retina görüntüsü

Şekil 3.24'te görüldüğü gibi, Gabor dönüşümü uygulanması sonucu görüntüde damarların daha belirgin, damar olmayan bölgelerin ise arka planda kalması sağlanmıştır.

3.2.10. Morfolojik işlemler

Morfolojik işlemler görüntülerin biçimsel yapısı ile ilgilenerek cisimlerin ayırt edilmesine ve sınıflandırılmasına imkan sağlar. Bu işlem gri seviye görüntüler üzerinde de kullanılabilir ama çoğunlukla siyah-beyaz (ikili) görüntülerde kullanılır. Gürültülerin azaltılarak sonuca ulaşılmasına yardımcı olur. Genellikle harf tanıma, plaka tanıma, parmak izi okuyucu gibi işlemlerde kullanılır (Wang ve ark. 1995). Çalışmada morfolojik işlemlerden aşındırma (erosion) ve yayma (dilation) yöntemleri kullanılmıştır.

Aşındırma İşlemi

İkili görüntüdeki nesneyi inceltmeyi ya da küçültmeyi gerçekleştiren morfolojik işlemdir. Bu işlemle görüntüdeki nesneler küçülür, delikler genişler, birbirine bağlı olan nesnelere ayrılır. Cebirsel olarak aşındırma işlemi, kesişim işlemine denk olur. Aşındırma uygulanan görüntüler bir nevi erozyona uğratılmaktadır. Görüntüdeki sınır bölgelerinin erozyona uğratılması ile işlem gerçekleştirilir. İkili görüntüdeki 0 ve 1 değerleri üzerinde yapısal elemanın işlem yapmasıyla aşındırma işlemi gerçekleştirilir. İkili görüntüdeki 0'a komşu olan 1'lerin, 0'a çevrilmesi ile aşındırılmış görüntü elde edilmektedir (Dougherty ve Lotufo, 2003).

Z^2 uzayında bulunan X ve Y kümeleri için aşındırma işlemi şu şekildedir;

$$X \ominus Y = \{z | (Y)_z \subseteq X\} \quad (3.14)$$



a) Aşındırma işleminden önce

b) Aşındırma işleminden sonra

Şekil 3. 25. Aşındırma işlemi uygulanmış görüntü

Şekil 3.25'te görüldüğü gibi ikili görüntüye aşındırma işlemi uygulandıktan sonra görüntüde bölütlenmesi istenmeyen bölgeler olan gürültülerin giderilmesi sağlanmıştır.

Yayma işlemi

İkili görüntüdeki nesneleri kalınlaştırmaya ya da büyütmeye yarayan morfolojik işlemdir. Nesne belirlenen yapısal eleman ile kesiştiği bölgeler kadar büyüme işlemi gösterir. Görüntüdeki her bir piksel yapısal elemanın merkezine oturtturularak yayma işlemi yapılmaktadır. İşlem sonunda görüntüdeki nesneler büyür, delik varsa kapanır ve sivri köşelerin yumuşadığı görülmektedir. Cebirsel olarak birleşim işlemine denk olmaktadır. İşlem esnasında ikili görüntüde bulunan 0 ve 1 değerleri üzerinde değişiklikler yapılmaktadır. İşlem 1 değerinin komşuluğunda bulunan 0 değerlerinin 1'e çevrilmesi ile gerçekleşir (Dougherty ve Lotufo, 2003).

Z^2 uzayında bulunan X ve Y kümeleri için yayma işlemi şu şekildedir;

$$X \oplus Y = \{z | (Y^-)_z \cap X \neq \emptyset\} \quad (3.15)$$



a) Yayma işleminden önce

b) Yayma işleminden sonra

Şekil 3. 26. Yayma işlemi uygulanmış görüntü

Şekil 3.26’da görüldüğü gibi ikili görüntüye yayma işlemi uygulandıktan sonra görüntüde bölütlenmesi istenen bölgelerin görüntüden çıkartılmasının önüne geçilmiştir.

Top-Hat işlemi

Bu işlem görüntüdeki parlaklık seviyeleri arasında bulunan karşıtlığı arttırmak ve görüntü içerisindeki parlak noktaları bulmak için kullanılan bir yöntemdir. Çukur veya tepe bölgelerini belirginleştirmeye yaramaktadır (Yavuz ve Köse, 2015). Top-hat işleminin genel ifadesi Eşitlik 3.16’daki gibidir.

$$top(x) = x - (x \circ (n \times Y)) \quad (3.16)$$

Eşitlik 3.17’de x görüntüyü, Y yapı elemanını ve n Top-hat dönüşümü ölçek katsayısını göstermektedir. Bu dönüşüm sonucu oluşacak görüntü orijinal görüntüden Y ve n katsayılarının kullanılmasıyla morfolojik olarak açılmış görüntünün çıkarılması ile elde edilmektedir. Top-hat dönüşümü uygulanması sonucu elde edilen görüntü Şekil 3.27’de gösterilmektedir.



Şekil 3. 27. Top-hat dönüşümü uygulanmış görüntü

Şekil 3.27’de görüldüğü üzere retina görüntüsüne Top-hat dönüşümünün uygulanmasıyla damarların belirginleştiği görülmektedir.

3.2.11. Eşikleme

Görüntülerdeki nesneyi arka plandan ayırmak için kullanılan en basit ve en sık kullanılan tekniklerden biridir (Kittler ve Illingworth, 1986; Bin ve Jain, 1997). Eşikleme yöntemi için öncelikle veri setine uygun eşik değerinin belirlenmesi gerekmektedir. Eşik değerinin belirlenmesi için genellikle görüntü histogramından faydalanılır. Bu yöntemin başarısı daha sonra uygulanacak tekniklerin başarı oranını etkileyeceğinden eşik değerinin doğru seçilmesi oldukça önemlidir. Bu değer doğru seçilmesiyle eşikleme yöntemi görüntülerin farklı özelliklerini birlikte kullanan diğer yöntemlere göre daha hızlı sonuç verir. Bu yöntem endüstriyel ortamlarda ürün kalite kontrolü gibi görüntü işleme uygulamalarında kullanılmaktadır (Adem ve ark., 2015).

3.2.11.1. Manüel eşikleme

Manüel eşikleme, görüntü içerisindeki istenilen nesneleri ön plana çıkartmak için en sık kullanılan eşikleme yöntemlerindendir. Manüel eşiklemenin çalışma adımları şu şekilde sıralanabilir:

Adım 1: Görüntüyü gri seviye formatına dönüştür.


Adım 2: Gri seviyeye dönüştürülen görüntünün histogramını elde et.

Adım 3: Görüntü histogramının incelenmesi sonucu deneyerek bir eşik değeri belirle.

Manüel eşikleme yönteminde eşik değeri belirlenirken histogramın şekli, entropisi veya nesne özellikleri göz önüne alınarak belirlenir (Ridler ve Calvard, 1978; Otsu, 1979; Yasuda ve ark., 1980).

Adım 4: Seçilen eşik değerinden büyük olan pikseller 1, küçük olan pikseller 0 yapılarak görüntü ikili resme dönüştürülür. Bu ikili resmin 1 olduğu yerler görüntüde ön plana çıkarılmak istenen nesnenin yerlerini gösterirken, 0 olan yerler ise arka planı göstermektedir.

Şekil 3.28’de Manüel eşikleme kullanılarak yapılan görüntü bölütleme işleminin sonucu gösterilmektedir.



Şekil 3. 28. Manüel eşikleme örneği (Eşik değeri = 115)

Şekil 3.28’de görüldüğü üzere eşik değeri olarak görüntünün histogramı göz önüne alınarak deneme yanılma yöntemiyle elde edilen 115 değeri belirlenmiştir. Bu şekilde retina görüntüsündeki eksudalı bölgelerin tespit edilmesi gerçekleştirilmiştir. Bu eşikleme türünün dezavantajı tüm retina görüntülerinde saptanan manüel eşik değerinin doğru sonuç üretememesidir. Bu dezavantajı ortadan kaldırmak için her görüntüde yeniden eşik değeri ayarlanmalıdır.

3.2.11.2. Ateş böceği algoritması (FFA) ile iteratif eşikleme

FFA, doğadaki ateşböceklerinin parlaklık davranışlarının benzetimini ortaya çıkaran sürü zekasına dayalı bir algoritmadır (Yang, 2008). Bu çalışmada FFA, iteratif eşikleme algoritması olarak önemli DR bulgularından olan hemorajilerin tespiti için kullanılan FFA algoritması aşağıdaki 3 kurala dayalı uygulanmaktadır:

1. Tüm ateş böcekleri için cinsiyet farkı önemli değildir ve cinsiyete bakılmaksızın birbirlerini etkileyebilirler.
2. Ateş böceklerinin etkileyciliği parlaklık oranlarına bağlıdır. Parlaklığı düşük olan ateş böcekleri yüksek olanlara doğru hareket edecektir. Eğer daha parlak bir ateş böceği yoksa rastgele hareket edecektir.
3. Ateş böceklerinin parlaklığı problemde kullanılan amaca göre belirlenir.

Ateş böceği algoritmasının parlaklık yoğunluğu farkı ve etkileycilik oranının formüle edilmesi gibi iki problemi bulunmaktadır. Bir ateş böceğinin etkileyciliği amaç fonksiyonuna bağlı olarak oluşturduğu parlaklık değeri ile belirlenir. Bir ateş böceğinin parlaklık yoğunluğunu gösteren I değeri Eşitlik 3.17 ile hesaplanır:

$$I = I_0 e^{-\gamma r} \quad (3.17)$$

Eşitlik 3.18’de verilen I_0 değeri başlangıç parlaklık yoğunluğunu, γ sabit parlaklık soğurma katsayısını ve r ise iki ateş böceği arasındaki uzaklığı göstermektedir. Ateş böceklerinin etkileyciliği parlaklık ve uzaklık gibi iki etkene bağlıdır ve β etkileycilik değeri Eşitlik 3.18 ile hesaplanır:

$$\beta = \beta_0 e^{-\gamma r^2} \quad (3.18)$$

Eşitlik 3.18’de verilen β_0 değeri iki ateş böceği arasındaki uzaklığın 0 olduğundaki etkileycilik değerini gösterir ve bu değer 0 ile 1 arasında değer alabilmektedir. i ve j gibi iki ateş böceği arasındaki uzaklık değeri Eşitlik 3.19 ile hesaplanır:

$$r_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (3.19)$$

Burada i ateş böceğinin kendisinden daha güçlü etkileyiciliğe sahip j ateş böceğine hareketi Eşitlik 3.20 ile hesaplanır:

$$x_i^{t+1} = x_i + \beta_0 e^{(-\gamma r_{ij}^2)} (x_j - x_i) + \alpha \left(r - \frac{1}{2} \right) \quad (3.20)$$

Eşitlik 3.20'deki ikinci terim etkileyicilik oranını gösterir, üçüncü terimde α ve r [0-1] arasında homojen dağılıma sahip rastgele değer alabilen parametrelerdir. Uygulamalarda α , β_0 ve γ değerleri [0,1] arasında seçilmektedir. Bu değerler uygulama sonuçlarına bağlıdır ve deneme yanılma yöntemi sonucu saptanan parametreler Çizelge 3.2'de gösterilmektedir.

Çizelge 3.2. FFA'nın çalışmada kullanılan parametre değerleri

Parametre	Değer
İterasyon sayısı (t)	50
Ateş böceği sayısı (K)	500
Soğurma katsayısı (γ)	0.05
$r=0$ da etkileyicilik değeri (β_0)	0.95
Adım boyutu kontrolü (α)	0.5

Çizelge 3.2'de verilen parametre değerlerine göre ateş böceği ile iteratif eşikleme algoritması aşağıdaki adımlardan oluşmaktadır:

Adım 1: Ateş böceği algoritmasının başlangıç parametrelerini Tablo 1'e göre ata.

Adım 2: Damarları gözardı edilen G kanal retina görüntüsüne rastgele yerleştirilen 500 ateş böceğinin parlaklık, etkileyicilik değerlerini ve aralarındaki uzaklıkları Eşitlik 16, 17 ve 18'e göre hesapla.


Adım 3: Ateş böceklerinin *etkileyicilik* değerlerini karşılaştır. Ateş böceklerinin konumunu daha etkileyici olanlara doğru Eşitlik 19'u kullanarak güncelle.

Adım 4: İterasyon sayısı sonlandı mı?

Adım 5: İterasyon sayısı sonlanmadıysa Adım 2'ye git.

Adım 6: İterasyon sayısı sonlandıysa ateş böceklerinin son konumlarındaki parlaklık değerlerinin ortalamalarını hesapla ve bu yeni değeri iteratif eşik değeri olarak seç.

Bu algoritmanın çalışma adımlarına göre öncelikle görüntüde rastgele piksellere gelecek şekilde 500 ateş böceği dağıtılmıştır. Görüntüde dağıtıldığı piksellerin parlaklık değerleri ateş böceklerinin parlaklık değeri olarak belirlenmiştir. Önerilen algoritmada ateş böcekleri arasında parlaklık bakımından kıyaslama yapıldığı için parlaklığı düşük olan ateş böceklerine doğru Eşitlik 19'da gösterildiği gibi hareket gerçekleştirilmiştir ve bu işlem 50 defa tekrarlanmıştır. Ateş böceklerinin konumlarının parlaklık ortalaması eşik değeri olarak belirlenmiştir. Şekil 3.29 FFA ile elde edilen görüntüleri göstermektedir.



Şekil 3. 29. Damarları göz ardı edilen retina görüntüsüne FFA ile iteratif eşikleme

Şekil 3.29'de görüldüğü gibi, retinadaki hemoraji içeren bölgelerin tespit edilmesi için FFA ile iteratif eşik değeri üretilmiştir. Bu sayede her görüntüde farklı bir eşik değeri oluşturulmuştur.

3.2.11.3.Parçacık sürü optimizasyonu algoritması (PSOA) ile iteratif eşikleme

PSOA, 1995 yılında Kenedy ve Eberhart tarafından önerilen doğadaki sürü halinde hareket eden kuş ve balık hareketlerinin benzetimini yapan sürü zekasına dayalı bir

algoritmadır. PSOA bireyler arasındaki sosyal davranışlarının bilgi paylaşımını esas almaktadır. Her bireye parçacık adı verilir ve parçacıklardan oluşan topluluğa da sürü denir. Her bir parçacık pozisyonunu önceki pozisyon tecrübelerinden yararlanarak en iyi konuma doğru ayarlamaktadır. Bu süreç iterasyon sayısı gibi durdurma ölçütüne ulaşıncaya kadar devam etmektedir (Kennedy ve Eberhart, 1995). PSOA ile iteratif eşikleme algoritmasının çalışma adımları şu şekildedir.

- Adım 1:* Damarları gözardı edilen G kanal retina görüntüsünde rastgele üretilen parçacıkların başlangıç pozisyonları ve hızları ile başlangıç sürüsü oluştur.
- Adım 2:* Sürü içerisindeki tüm parçacıkların uygunluk değerlerini hesapla.
- Adım 3:* Her bir parçacık için mevcut iterasyondaki yerel en iyiyi ($pbest$) bul. (Sürü içerisinde en iyilerin sayısı parçacık sayısı kadardır.)
- Adım 4:* Mevcut iterasyondaki yerel en iyiler içerisinde global en iyiyi ($gbest$) seç.
- Adım 5:* Parçacıkların pozisyonunu ve hız değerini aşağıdaki Eşitlik 3.21'e göre güncelle.


$$\begin{aligned} v_i^{k+1} &= v_i^k + c_1^k rand_1(pbest_i^k - x_i^k) + c_2^k rand_2(gbest_i^k - x_i^k) \\ x_i^{k+1} &= x_i^k + v_i^{k+1} \end{aligned} \quad (3.21)$$

Burada, x_i^k pozisyonu ve v_i^k hız değerini, c_1^k ve c_2^k her parçacığı $pbest$ ve $gbest$ pozisyonlarına doğru çeken, hızlanmayı ifade eden sabitlerdir. c_1^k , parçacığın kendi tecrübelerine göre hareket etmesini, c_2^k ise sürüdeki diğer parçacıkların tecrübelerine göre hareket etmesini sağlar. $rand_1$ ve $rand_2$ $[0,1]$ arasında düzgün dağılımlı rastgele sayılardır.

- Adım 6:* İterasyon sayısı sonlandı mı?
- Adım 7:* İterasyon sayısı sonlanmadıysa Adım 2'ye git.
- Adım 8:* İterasyon sayısı sonlandıysa parçacıkların son konumlarındaki parlaklık değerlerinin ortalamalarını hesapla ve yeni değeri iteratif eşik değeri olarak seç.

Algoritmadaki çalışma adımlarına göre, öncelikle görüntüde rastgele piksellere gelecek şekilde 500 parçacık dağıtılmıştır. Görüntüde dağıtıldığı piksellerin parlaklık değerleri parçacıkların parlaklık değeri olarak belirlenmiştir. Önerilen algoritmada parçacıklar arasında parlaklık bakımından kıyaslama yapılarak parlaklığı düşük olan parçacıklara

doğru Eşitlik 8’de gösterildiği gibi hareket gerçekleştirilmiştir. Bu algoritma 50 kez tekrarlanmış ve parçacıkların konumlarının parlaklık ortalaması eşik değeri olarak seçilmiştir. Şekil 3.30 PSOA ile elde edilen görüntüleri göstermektedir.



Şekil 3. 30. Damar bölgesi çıkartılan retina görüntüsüne PSOA ile iteratif eşikleme

Şekil 3.30’da görüldüğü gibi, retinadaki hemoraji içeren bölgelerin tespit edilmesi için PSOA ile iteratif eşik değeri üretilerek her görüntüde farklı bir eşik değeri oluşturulmuştur. Her iki algoritma ile üretilen eşik değerlerinin doğru sınıflandırma oranları ve zaman performansları karşılaştırılmıştır.

3.3. Sınıflandırma

Sınıflandırma, nedeni ve sonucu bilinen örneklerden yararlanarak yeni karşılaşılan bir örnek hakkında yorum yapabilmeyi sağlayan bir işlemdir. Sınıflandırma işleminin amacı, veri gruplarını oluşturan sınıf özellikleri ve bu sınıfların çıkış karakterleri arasındaki ilişkileri keşfetmek ve bu sayede yeni bir veri örneğinin sınıf etiketini tahmin etmektir (Telcioğlu, 2007).

3.3.1. Doğrusal regresyon

Giriş-çıkış arasında doğrusal bir eşitlik bulmayı sağlayan regresyon analizi en temel ve hesaplama karmaşıklığı en düşük olan sınıflandırma yöntemlerindendir (Chapra ve

Canale, 2003). Sınıflandırma yönteminde kullanılan tek değişkenli doğrusal regresyon denklemi Eşitlik 3.22’de verilmektedir.

$$\begin{aligned} y &= f(x, w) = w_0 + w_1x_1 + \dots + w_dx_d \\ &= w_0 + x^T w_1 \end{aligned} \quad (3.22)$$


Burada, w_0 ve w_1 terimlerinin değerini bulmak için en sık kullanılan yöntem en küçük kareler (LMS) yöntemidir (Chapra ve Canale, 2003). Bu katsayıların hesaplanmasında hata minimizasyonu sağlayan Eşitlik 3.23 kullanılmaktadır.

$$w_i = \frac{1}{n} \sum_{i=1}^n (y_i - f(x_i, w))^2 \quad (3.23)$$

Eşitlik 3.23’te regresyon fonksiyonunun katsayıları belirlendikten sonra, test veri setine Eşitlik 3.22 uygulanır. Elde edilen değerler deneysel çalışmalar sonucunda belirlenen 0.5 eşik değeri ile karşılaştırılarak hastalık teşhisi gerçekleştirilmiştir. Sınıflandırıcı olarak kullanılan doğrusal regresyonun en büyük dezavantajı karar verme aşamasında bir eşik değerine ihtiyaç duymasıdır. Doğrusal, tek değişkenli ve hesaplama karmaşıklığı yönünden düşük maliyete sahip olması sebebiyle önerilen çalışmada sınıflandırıcı olarak öncelikle en küçük karelere dayalı doğrusal regresyon modeli kullanılmıştır.

3.3.2. Çok katmanlı sinir ağı

Çok katmanlı sinir ağı (MLPNN) doğrusal olmayan aktivasyon fonksiyonu içeren nöronlardan oluşan yapay sinir ağı modelidir. Şekil 3.31’de MLPNN’de kullanılan nöronların genel görünümü verilmektedir.



Şekil 3. 31. MLPNN’de kullanılan nöron şekli (Bellanger, 2000)

Şekil 3.31’deki nöronun dört girişi ve tek çıkışı mevcuttur. Verinin her boyutu (i_1, i_2, i_3, i_4) ayrı bir ağırlıkla (w_1, w_2, w_3, w_4) çarpılarak nörona ulaşmakta ve girişler nöronda işlem gördükten sonra üretilen değer y adıyla çıkışa verilmektedir. Nöronun içerisinde iki adet işlem birimi bulunmaktadır. Bunlardan ilki gelen bilgileri toplayan doğrusal birimdir ve toplama sonucunu ikinci birime göndermektedir. İkinci birime giriş olarak hazırlanan n değeri Eşitlik 3.24’te verilmektedir (Bellanger, 2000).

$$n = \sum_k i_k w_k \quad (3.24)$$

İkinci birim, nöronun doğrusal olmayan fonksiyonunu içeren birimdir. Gelen toplam, bu aktivasyon fonksiyonundan geçtikten sonra elde ettiği değeri nöronun çıkışına vermektedir. Nöron çıkışındaki değeri temsil eden y değeri Eşitlik 3.25’de verildiği gibi hesaplanmaktadır.

$$y_{\text{out}} = f(n) \quad (3.25)$$

Eşitlik 3.25’deki f ifadesi tercih edilen aktivasyon fonksiyonunu temsil etmektedir. En sık kullanılan aktivasyon fonksiyonları sigmoid, hiperbolik tanjant ve basamak fonksiyonlarıdır. Her zaman olmasa da her bir aktivasyon fonksiyonunun diğerlerine göre daha başarılı olduğu problemler de mevcuttur.

MLPNN’de eğitim algoritması olarak genelde geriye yayılım algoritması türevleri kullanılmaktadır. Eğitim algoritması yardımıyla nöronlar arasındaki bağlantıların ağırlıkları ayarlanarak ağın çıkışı optimize edilir. Veride bulunan çıkış değerinin y

değeri ile temsil edildiğini kabul edelim. Ağın çıkışında elde edilen y^* değerinin y değerinden farkı yardımıyla ağdaki tüm bağlantıların ağırlıkları güncellenir ve bu güncelleme yapılırken genellikle hedefe yakınsayarak yaklaşan eğim azaltma yöntemi kullanılır. Eşitlik 3.26'da verilen denklemlerin uygulanmasıyla bir MLPNN üzerinde geri yayılım algoritmasını kullanarak katsayıların güncellenmesi sağlanmaktadır.

$$e = y^* - y$$


$$\varepsilon = \frac{1}{2} e^2 \quad (3.26)$$

$$\Delta w = -\eta \frac{\partial \varepsilon}{\partial w}$$

Eşitlik 3.26'da üç adet birbirinin devamı niteliğinde denklem verilmiştir. Bunlardan ilki daha önce bahsedildiği gibi ağı hesapladığı değerin verideki çıkış değerine göre ne kadar saptığını gösteren e değerinin bulunmasını sağlamaktadır. İkinci denklemde ise üzerinde hesaplama yapılan nörona ilişkin ani hata enerjisi (ε) değeri hesaplanmaktadır. Son olarak ani hata enerjisinin ilgili nörona gelen tüm bağlantı ağırlıklarına mevcut ağırlıkların (w) tersi oranında dağıtılması yardımıyla her ağırlığın güncellenme miktarı (Δw) hesaplanmaktadır. Her ağırlığın güncelleme miktarı bir öğrenme oranı parametresiyle (η) orantılı şekilde küçültülmektedir. Bu işlem verinin her noktası için tekrarlanmakta ve η parametresi sayesinde bir anlamda bulunan çözümlerin ortalaması hesaplanmaktadır (Bellanger, 2000).

3.3.3. Destek vektör makinesi

Destek vektör makinesi (SVM) istatistiksel öğrenme teorisine dayalı bir sınıflandırıcıdır. SVM'nin çalışma amacı, iki sınıfı birbirinden ayırabilen en uygun karar fonksiyonunun tahmin edilmesi işlemidir (Vapnik, 1995; Vapnik, 2000). Bu karar fonksiyonunun bulunmasıyla Şekil 3.32'de gösterildiği gibi eğitim veri setini ayırabilecek en uygun hiper düzlem tespit edilmektedir.



Şekil 3. 32. Optimum düzlem ve destek vektörleri (Vapnik, 2000)

Doğrusal olarak ayrılabilen iki sınıflı bir sınıflandırma probleminde SVM' deki destek vektörlerinin denklemleri Eşitlik 3.27'de verilmektedir.

$$\begin{aligned} wx + b &= +1 & y = +1 \text{ sınıfı için} \\ wx + b &= -1 & y = -1 \text{ sınıfı için} \end{aligned} \quad (3.27)$$

Burada y sınıf etiketlerini, w ağırlık vektörünü ve b ise yaklaşımlarını göstermektedir. Optimum düzlem aralığını arttırmak için Eşitlik 3.28'de görüldüğü gibi w değerinin minimum değerde tutulması gerekmektedir.

$$m = \frac{2}{\sqrt{ww}} \quad f_{min}(w) = \frac{ww}{2} \quad (3.28)$$

Eşitlik 3.28'a bağlı olarak,

$$y_i(wx_i + b) - 1 \geq 0 \quad (3.29)$$

elde edilir. Eşitlik 3.29 Lagrange denklemleriyle çözülerek Eşitlik 3.30'de gösterilmektedir.

$$L(w, b, a) = \frac{w^2}{2} - \sum_{i=1}^k a_i y_i (w x_i + b) + \sum_{i=1}^k a_i \quad (3.30)$$

İki sınıflı bir problem için destek vektör makinesinin vereceği karar fonksiyonu Eşitlik 3.31’de verilmektedir (Osuna ve ark., 1997).


$$f(x) = \text{sign}(\sum_{i=1}^k a_i y_i(x_i) + b) \quad (3.31)$$

3.3.4. RBF sinir ağı

RBF (Çapsal Tabanlı Fonksiyon), doğrusal olarak ayırlamayan sınıfları, bir haritalama işlemi yardımıyla doğrusal olarak ayrılabilen farklı bir uzaya taşımayı amaçlayan basit bir sinir ağı modelidir. Haritalama işlemi x veri seti üzerinde $\phi(x)$ ile gösterilen bir fonksiyonla yapılmaktadır.

$$\begin{aligned} \phi(x) &= \exp\left(-\frac{\|c_j - x_i\|^2}{2r^2}\right) \\ y(x) &= \sum_{i=1}^N (W_i \phi(x)) \end{aligned} \quad (3.32)$$

Eşitlik 3.32’deki haritalama fonksiyonu ile merkezi noktalarla (c_j) giriş veri noktaları (x_i) arasındaki farklar genellikle öklid uzaklığı kullanılarak hesaplanmaktadır. Burada r değeri prototipin çapını (yayılma katsayısı) ifade etmektedir ve bu değer giriş verisinin dağılımına göre rastgele seçilmektedir. N değeri gizli katmandaki nöron sayısını ve W_i gizli katman ile çıkış katmanı arasındaki ağırlıkları göstermek üzere, x giriş verisine göre çıkıştan elde edilecek y değerleri hesaplanmaktadır. RBF ağının genel yapısı Şekil 3.33’te gösterilmektedir.



Şekil 3. 33. RBF sinir ağının genel yapısı (Press ve ark., 2007)

Şekil 3.33'te görüldüğü gibi RBF sinir ağlarında genellikle bir giriş katmanı, her biri RBF fonksiyonu içeren bir gizli katman ve bir çıkış katmanı bulunmaktadır (Hardy, 1971; Press ve ark., 2007).

4. BULGULAR ve TARTIŞMA

Bu bölümde önerilen görüntü işleme yazılımının çalışmasını ayrıntılı bir şekilde incelemek için GopRetina, ImageRet ve DRIVE veritabanlarındaki retina görüntüleri kullanılmıştır. DRIVE veritabanı içerisinde damarların el ile çizilmiş görüntüleri bulunduğundan dolayı retina damarlarının bölütlenmesinde kullanılan yöntemlerin başarı oranlarının değerlendirilmesi için kullanılmıştır. GopRetina ve ImageRet veritabanları da optik disk, eksuda, hemoraji tespiti ve DR sınıflandırması için kullanılmıştır. En iyi sonucu elde etmek amacıyla farklı veritabanlarından alınan görüntüler üzerinde Matlab ortamında optik disk ve kan damarlarının otomatik tespiti gerçekleştirilmiştir. Optik disk ve kan damarlarının görüntüden tespit edilerek gözardı edilmesinden sonra eksuda, hemoraji lezyonlarının tespiti ve DR sınıflandırması için eğitim aşamasında doğrusal regresyon, SVM, MLPNN ve RBF sinir ağı modelleri kullanılmıştır. Sınıflandırma sonuçları grafikler ve çizelgeler halinde sunulmuş ve yorumlanmıştır. Geliştirilen bu görüntü işleme yazılımının çalışma adımları Şekil 4.1’de gösterilmektedir.



Şekil 4. 1. DR hastalık teşhisi yazılımının çalışma adımları

Şekil 4.1’de gösterilen önişlem adımında, RGB / HSV renk uzayı dönüşümü ve adaptif histogram eşitleme, optik disk bölgesinin tespit edilmesi adımında Canny kenar bulma algoritması ve çembersel Hough dönüşümü, retina damarlarının bölütlenmesi adımında

Gabor ve Top-hat dönüşümü ve lezyonlu bölgelerin tespit edilmesi için de PSOA / FFA temelli iteratif eşikleme yöntemi ile her bir görüntü için “eksudalı toplam piksel sayısı” “eksudalı bölge sayısı”, “hemorajili toplam piksel sayısı” ve “hemorajili bölge sayısı” öznitelikleri hesaplanmıştır.

4.1. Optik disk tespiti

Retinanın anatomik bölgelerinden olan Optik Disk (OD) bölgesinin tespit edilerek retinada benzer parlaklık seviyesinde bulunan eksuda lezyonları ile karıştırılmaması amaçlanmıştır. Bu çalışmalarda 80 retina görüntüsü bulunduran ImageRet veri tabanı ve 100 retina görüntüsü bulunduran GopRetina veri tabanı kullanılmıştır. Retina görüntülerinde OD bölgesinin tespiti için RGB ve HSV renk uzaylarını kullanarak 2 farklı deneysel çalışma gerçekleştirilmiştir. Bu çalışmaların ilkinde kullanılan algoritmanın adımları aşağıdaki gibidir:


Adım 1: Retina görüntüsünü RGB renk uzayının G (Yeşil) kanalına taşı.

Adım 2: OD bölgesinin belirgin hale getirilmesi için G kanalına taşınan görüntüye adaptif histogram eşitleme uygula.

Adım 3: Görüntünün ikili görüntü (siyah-beyaz) formatına dönüşmesi için Canny kenar tespiti algoritmasını uygula.


Adım 4: Elde edilen ikili görüntüde OD bölgesinin tespiti için çembersel Hough dönüşümü uygula.

Bu algorithmada öncelikle retina görüntüsü RGB renk uzayının G kanalına taşınmıştır. Şekil 4.2 retina görüntüsü ve G kanalı retina görüntülerini göstermektedir.




Şekil 4. 2. Retina görüntüsü ve G kanalı retina görüntüsü

Şekil 4.2’de görüldüğü gibi RGB renk uzayında bulunan retina görüntüsü G kanalına indirgenerek görüntünün incelenmesi kolaylaştırılmıştır. Yeşil kanalda bulunan retina görüntüsüne adaptif histogram eşitleme işleminin uygulanması Şekil 4.3’te gösterilmektedir.



Şekil 4. 3. Adaptif histogram eşitleme uygulanması

Şekil 4.3’te görüldüğü gibi görüntüye adaptif histogram eşitleme uygulanarak OD bölgesinin belirgin hale getirilmesi sağlanmıştır. Şekil 4.4 Canny kenar tespit uygulanması sonucu elde edilen görüntüyü göstermektedir.



Şekil 4. 4. Canny kenar tespit algoritması uygulanması

Şekil 4.4’te görüldüğü gibi görüntüye Canny kenar tespit algoritması uygulanarak OD bölgesinin ve damarların ön plana çıktığı görülmüştür. Bu görüntüye çembersel Hough dönüşümünün uygulanması Şekil 4.5’de gösterilmektedir.



Şekil 4. 5. Çembersel Hough dönüşümünün uygulanması

Şekil 4.5’de görüldüğü gibi OD bölgesinin çap uzunluğunun çembersel Hough dönüşümüne girdi verilip uygulanmasıyla OD tespiti işlemi gerçekleştirilmiştir. OD bölgesinin tespit başarısını arttırmak için ikinci deneysel çalışmanın algoritma adımları aşağıdaki gibidir:

Adım 1: Retina görüntüsünü HSV renk uzayının V (Value) kanalına taşı.


Adım 2: OD bölgesinin belirgin hale getirilmesi için yeşil kanala taşınan görüntüye adaptif histogram eşitleme ve gama dönüşümünü uygula.

Adım 3: Görüntünün ikili görüntü (siyah-beyaz) formatına dönüşmesi için Canny kenar tespiti algoritmasını uygula.

Adım 4: Elde edilen ikili görüntüde OD bölgesinin tespiti için çembersel Hough dönüşümü uygula.


Bu algoritmada öncelikle retina görüntüsü HSV renk uzayının V kanalına taşınmıştır.

Şekil 4.6 retina görüntüsü ve Value kanalı retina görüntülerini göstermektedir.




Şekil 4. 6. Retina görüntüsü ve V kanalı retina görüntüsü

Şekil 4.6’da görüldüğü gibi retina görüntüsü HSV renk uzayına taşındıktan sonra V kanalına indirgenerek görüntünün incelenmesi kolaylaştırılmıştır. V kanalında bulunan retina görüntüsüne adaptif histogram eşitleme ve gama dönüşümünün birlikte uygulanması sonucu Şekil 4.7’de gösterilmektedir.



Şekil 4. 7. Adaptif histogram eşitleme ve gama dönüşümü uygulanması

Şekil 4.7’de görüldüğü gibi görüntüye adaptif histogram eşitleme ve gama dönüşümü uygulanarak OD bölgesinin belirgin hale getirilmesi sağlanmıştır. Şekil 4.8 Canny kenar tespit uygulanması sonucu elde edilen görüntüyü göstermektedir.



Şekil 4. 8. Canny kenar tespit algoritması uygulanması

Şekil 4.8’de görüldüğü gibi görüntüye Canny kenar tespit algoritması uygulanarak OD bölgesinin ve damarların ön plana çıktığı görülmüştür. Bu görüntüye çembersel Hough dönüşümünün uygulandığında oluşan görüntü Şekil 4.9’da gösterilmektedir.



Şekil 4. 9. Çembersel Hough dönüşümünün uygulanması

Şekil 4.9’da görüldüğü gibi OD bölgesinin retina görüntülerinde deneysel çalışmalar sonucunda tespit ettiğimiz çap uzunluğunun (çap uzunluğu=95 piksel) çembersel Hough dönüşümüne girdi verilip uygulanmasıyla OD tespiti işlemi gerçekleştirilmiştir. ImageRet ve GopRetina veri tabanlarındaki retina görüntülerine iki algoritmanın uygulanmasıyla sonuçlar karşılaştırılmıştır. Sonuçlar karşılaştırılırken doğru sınıflandırma performansı olarak K-parçalı çapraz geçerlilik yöntemi ile analiz edilmiştir. K-parçalı çapraz geçerlik yöntemi eldeki veri üzerinde yöntemlerin tarafsız olarak testine imkan veren bir geçerlik yöntemidir. Çalışmada 5-parçalı çapraz geçerlilik yöntemi kullanılmış ve eldeki veri seti beş parçaya ayrılmıştır. Bu parçaların üçü birleştirilip eğitim verisi ve diğer iki parça da test verisi olarak kullanılmıştır. Her seferinde farklı iki parça test için kullanılmak üzere bu işlem beş kez tekrarlanmış, sonuçta beş ayrı test sonucu elde edilmiştir. Bu değerlerin ortalaması olan toplam doğru sınıflandırma (TCC) oranı genel başarı ölçütü olarak değerlendirilmiştir. ImageRet ve GopRetina veri tabanlarındaki retina görüntülerine deneysel çalışmaların uygulanması sonucu oluşan doğru sınıflandırma performansları Çizelge 4.1’de gösterilmektedir.

Çizelge 4. 1. OD bölgesi tespiti için gerçekleştirilen deneysel çalışmaların karşılaştırılması

Veri tabanı	Görüntü sayısı	Görüntü İşleme Yöntemleri	TCC (%)
ImageRet	70	RGB (G) - Adaptif Histogram Eşitleme - Canny - Çembersel Hough Dönüşümü	92.85
		HSV (V) - Adaptif Histogram Eşitleme - Gama dönüşümü - Canny - Çembersel Hough Dönüşümü	95.72
GopRetina	88	RGB (G) - Adaptif Histogram Eşitleme - Canny - Çembersel Hough Dönüşümü	96.59
		HSV (V) - Adaptif Histogram Eşitleme - Gama dönüşümü - Canny - Çembersel Hough Dönüşümü	98.86

Çizelge 4.1’de görüldüğü üzere HSV renk uzayı ve gama dönüşümü eklenerek gerçekleştirilen çözüm önerisinin daha başarılı olduğu görülmektedir. Ayrıca GopRetina veri tabanında bulunan retina görüntülerinde daha başarılı bir şekilde OD bölgesinin tespiti gerçekleştirilmiştir. Bu durum GopRetina da bulunan retina görüntülerinin daha kaliteli olduğu sonucunu ortaya çıkarmıştır. Deneysel çalışmalar sonucunda başarılı olan yöntemin literatürdeki çalışmalar ile karşılaştırılması sonuçları Çizelge 4.2’de verilmiştir.

Çizelge 4. 2. OD tespiti için önerilen yöntem ve literatür karşılaştırılması

Yazarlar	Yıl	Görüntü Sayısı	TCC (%)
Walter ve Klein	1999	30	90
Abdel-Razik ve ark.	2008	81	98.77
Nergiz ve ark.	2014	40	87.5
Kaur ve Mittal	2015	128	91
Yu ve ark.	2016	66	94.63
Adem ve ark.	2016	89	98.87
Önerilen yöntem	2017	70	95.72
Önerilen yöntem	2017	88	98.86

Çizelge 4.2’de görüldüğü gibi önerilen çalışmanın literatürdeki diğer çalışmalardan daha başarılı sonuçlar verdiği görülmüştür. Bu sayede retina hastalıklarının bilgisayar destekli tanısında optik disk bölgesi ile aynı özelliğe sahip hastalıklı bölgelerin karıştırılmasının önüne geçilmesi sağlanmıştır.

4.2. Damar bölütlemesi

Retinanın anatomik bölgelerinden olan damar bölgesinin tespit edilerek retinada benzer parlaklık seviyesinde bulunan hemoraji lezyonları ile karıştırılmaması amaçlanmıştır. Bu çalışmalarda bölütlemenin doğruluğunu hesaplamak için gerekli el ile çizilmiş damar görüntülerini de bulunduran DRIVE veri tabanı kullanılmıştır. Bu veri tabanında 40 adet retina görüntüsü bulunmaktadır. Retina görüntülerinde damar bölgesinin tespiti için kullanılan algoritmanın adımları aşağıdaki gibidir:

Adım 1: Retina görüntüsüne RGB renk uzayının G kanalını uygula.

Adım 2: Damarların belirgin hale getirilmesi için G kanalına taşınan görüntüye adaptif histogram eşitleme uygula.

Adım 3: Damar bölütlenmesi için Gabor dönüşümünü uygula.

Adım 4: Gürültülerin giderilmesi için morfolojik işlemlerden Top-hat dönüşümünü uygula.

Bu algorithmada öncelikle retina görüntüsü RGB renk uzayının G kanalına taşınmıştır.

Şekil 4.10 retina görüntüsü ve yeşil kanal retina görüntüsünü göstermektedir.



Şekil 4. 10. Retina görüntüsü ve RGB renk uzayının yeşil kanalı görüntüsü


Şekil 4.10’da görüldüğü gibi, retina görüntüsü RGB renk uzayının G kanalına taşınarak görüntüdeki damarların ön plana çıkarılması sağlanmıştır. İkinci aşamada, G kanalı görüntüsünün parlaklık ve kontrastını iyileştirmek için adaptif histogram eşitleme yöntemi uygulanmıştır. Şekil 4.11 G kanalında bulunan retina görüntüsüne adaptif histogram eşitleme işleminin uygulanmasını göstermektedir.



Şekil 4. 11. Adaptif histogram eşitleme uygulanması


Şekil 4.11’de görüldüğü gibi görüntüye adaptif histogram eşitleme uygulanarak damarların belirgin hale getirilmesi sağlanmıştır. Retinadaki damarların belirgin hale

getirilerek bölütlenmesi ve benzer yapıda olan hemorajili bölgeler ile karışıklığın önüne geçilmesi için Gabor dönüşümü kullanılmıştır. Şekil 4.12 çalışmada kullanılan örnek bir Gabor çekirdeğinin görüntüsünü göstermektedir.



Şekil 4. 12. Örnek Gabor çekirdeği ($\theta=0^\circ$)


Şekil 4.12’de görülen Gabor çekirdeğinin 30° aralıklarla döndürülerek elde edilen 6 farklı Gabor çekirdeği önceki adımda iyileştirilen görüntü ile konvüle edilerek 6 farklı görüntü oluşturulmuştur. Bu görüntülerden parlaklık değeri yüksek olan görüntü çıkış görüntüsü olarak elde edilmiştir. Şekil 4.13 Gabor dönüşümü ile elde edilen retina görüntüsünü göstermektedir.



Şekil 4. 13. Gabor dönüşümü ile elde edilen retina görüntüsü

Şekil 4.13’de görüldüğü gibi, Gabor dönüşümü uygulanması sonucu görüntüde damarların daha belirgin, damar olmayan bölgelerin ise arka planda kalması sağlanmıştır. Görüntüdeki parlaklık seviyeleri arasında bulunan karışıklığı arttırmak ve görüntü içerisindeki parlak noktaları saptamak için Top-hat dönüşümü kullanılmıştır.

Şekil 4.14 Top-hat dönüşümü uygulanması sonucu elde edilen görüntüyü göstermektedir.



Şekil 4. 14. Top-hat dönüşümü uygulanması ve damarların bölütlenmesi

Şekil 4.14’te görüldüğü üzere Gabor dönüşümü uygulanan retina görüntüsüne Top-hat dönüşümünün uygulanmasıyla damarların ön plana çıktığı görülmektedir. Top-hat dönüşümü ile elde edilen damar haritası daha önce oluşturulan G kanalı retina görüntüsü üzerine bindirilerek hemoraji içeren bölgelerin tespiti kolaylaşmaktadır.

DRIVE veri tabanlarındaki retina görüntülerine damar bölütlenmesi algoritmasının uygulanması sonucu siyah-beyaz damar görüntüsü elde edilmiştir. Performans değerlendirmesi için doğruluk değerinin hesaplanması gerekmektedir. Bu işlem için kullanılan veri tabanında el ile çizilmiş damar görüntüleri hedef görüntü olarak kabul edilmiştir. Doğruluk değeri, doğru tespit edilmiş piksellerin tüm tespit edilen piksellere oranı olarak hesaplanmış ve Eşitlik 4.1’de verilmiştir.

$$\text{Doğruluk} = \frac{DTPS}{TPS} \quad (4.1)$$

Eşitlik 4.1’de verilen *DTPS* doğru tespit edilmiş piksel sayısını, *TPS* ise tespit edilen toplam piksel sayısını göstermektedir. Performans değerlendirmesi yapılırken DRIVE veri tabanında bulunan 40 retina görüntüsüne önerilen algoritmanın uygulanması ile elde edilen 40 doğruluk değerinin ortalaması %95.24 olarak hesaplanmıştır. Deneysel çalışmalar sonucunda başarılı olan yöntemin literatürdeki çalışmalar ile karşılaştırma sonuçları Çizelge 4.3’te verilmiştir.

Çizelge 4. 3. Damar bölütlemesi için önerilen yöntem ve literatür karşılaştırılması

Yazarlar	Yıl	Görüntü Sayısı	Doğruluk (%)
Gang ve ark.	2002	48	85.5
Wu ve ark.	2006	20	84.3
Al-rawi ve Karajeh	2007	40	94.22
Goatman ve ark.	2011	109	84.8
Rossant ve ark.	2011	40	94.33
Oloumi ve ark.	2014	20	95.1
Yavuz ve Köse	2015	40	94.02
Önerilen yöntem	2017	40	95.24

Çizelge 4.3'te görüldüğü gibi önerilen çalışmanın literatürdeki diğer çalışmalardan daha başarılı sonuçlar verdiği görülmüştür. Bu sayede retina hastalıklarının bilgisayar destekli tanısında damar bölgeleri ile aynı özelliğe sahip hastalıklı bölgelerin karıştırılmasının önüne geçilmesi sağlanmıştır.

4.3. Eksuda tespiti

ImageRet ve GopRetina veri tabanındaki retina görüntülerinin her birinden öncelikle benzer parlaklık seviyesinde olan OD bölgesi göz ardı edilmiştir. Retinanın parlak lezyonu olan eksudaların tespitinde elde edilen bu retina görüntülerine iteratif eşikleme yöntemleri uygulanarak eksudaların tespiti gerçekleştirilmiştir. ImageRet veri tabanında 70 retina görüntüsünün 34'ü eksuda lezyonu içermekte, 36'sı eksuda lezyonu içermemektedir. GopRetina veri tabanında ise 88 retina görüntüsünün 40'ı eksuda lezyonu içermekte, 48'i eksuda lezyonu içermemektedir. Eksuda içeren bölgeler tespit edilirken her bir retina görüntüsünde farklı eşik değeri üretebilmek için FFA temelli iteratif eşikleme yaklaşımı ve Doğrusal Regresyon (LR) temelli sınıflayıcıyı içeren algoritma adımları aşağıdaki gibidir:

Adım 1: Retina görüntüsüne (1) renk uzayı seçimi, (2) parlaklık-kontrast iyileştirme, (3) adaptif histogram eşitleme ön-işleme yöntemlerini sırasıyla uygula.


Adım 2: OD bölgesinin tespit edilmesi ve retina görüntüsünden göz ardı edilmesi için (1) Canny kenar bulma algoritması, (2) Çembersel Hough dönüşümü yöntemlerini sırasıyla uygula.

Adım 3: OD bölgesi göz ardı edilen retina görüntüsünde FFA temelli iteratif eşikleme algoritması ile ikili görüntüye çevir.

Adım 4: İkili görüntüde toplam eksudalı piksel sayısını ve eksudalı bölge sayısını bul.

Adım 5: Toplam eksudalı piksel sayısını ve eksudalı bölge sayısını LR temelli sınıflayıcıya giriş olarak kullanarak eksuda lezyonlarını tespit et.

Bu algorithmada eşikleme yöntemi olarak PSOA temelli iteratif eşikleme ve sınıflayıcı olarak ise MLPNN, RBF ve SVM'nin uygulanmasıyla oluşacak 8 farklı varyasyondan en başarılı olanı çözüm seçilmiştir. Algorithmada verilen ön-işleme yöntemleri ve OD bölgesinin tespit edilerek görüntünden göz ardı edilmesi işlemi önceki bölümde anlatılmıştır. Bu bölümde ise eksudaların tespiti için FFA ve PSOA temelli iteratif eşikleme yöntemleri uygulanmıştır. FFA'nın çalışma adımlarına göre öncelikle görüntüde rastgele piksellere gelecek şekilde 500 ateş böceği dağıtılmıştır. Görüntüde dağıtıldığı piksellerin parlaklık değerleri ateş böceklerinin parlaklık değeri olarak belirlenmiştir. Önerilen algorithmada ateş böcekleri arasında parlaklık bakımından kıyaslama yapıldığı için parlaklığı yüksek olan ateş böceklerine doğru FFA algoritmasındaki yer değiştirme mesafesinde hareket gerçekleştirilmiştir ve bu işlem 50 defa tekrarlanmıştır. Ateş böceklerinin konumlarının parlaklık ortalaması eşik değeri olarak belirlenmiştir. Şekil 4.15 FFA ile elde edilen görüntüleri göstermektedir.



a) Ateşböceklerinin görüntüde dağılımı


b) Eşikleme sonucu eksuda tespiti

c) Retinada eksuda içeren bölgeler

Şekil 4. 15. OD bölgesi çıkartılan retina görüntüsüne FFA ile iteratif eşikleme

Şekil 4.15'de görüldüğü gibi, retinadaki eksuda içeren bölgelerin tespit edilmesi için FFA ile iteratif eşik değeri üretilmiştir. Bu sayede her görüntüde farklı bir eşik değeri oluşturulmuştur. PSOA çalışma adımlarına göre ise öncelikle görüntüde rastgele piksellere gelecek şekilde 500 parçacık dağıtılmıştır. Görüntüde dağıtıldığı piksellerin parlaklık değerleri parçacıkların parlaklık değeri olarak belirlenmiştir. Önerilen

algoritmada parçacıklar arasında parlaklık bakımından kıyaslama yapılarak parlaklığı yüksek olan parçacıklara doğru PSOA algoritmasındaki yer değiştirme mesafesinde hareket gerçekleştirilmiştir. Bu algoritma 50 kez tekrarlanmış ve parçacıkların konumlarının parlaklık ortalaması eşik değeri olarak seçilmiştir. Şekil 4.16'da PSOA ile elde edilen görüntüler gösterilmektedir.



Şekil 4. 16. OD bölgesi çıkartılan retina görüntüsüne PSOA ile iteratif eşikleme

Şekil 4.16'da görüldüğü gibi, retinadaki eksuda içeren bölgelerin tespit edilmesi için PSOA ile iteratif eşik değeri üretilerek her görüntüde farklı bir eşik değeri oluşturulmuştur. Eşik değeri uygulanarak elde edilen ikili görüntüde öznelik olarak eksuda içeren “piksel ve bölge sayısı değerleri” hesaplanmıştır. Öznelik veri setinin LR, MLPNN, RBF ve SVM sınıflayıcılarına giriş olarak verilmesiyle doğru sınıflandırma oranları ve zaman performansları karşılaştırılmıştır. Doğru sınıflandırma performansı *K*-parçalı çapraz geçerlilik yöntemi ile analiz edilmiştir. *K*-parçalı çapraz geçerlilik yöntemi eldeki veri üzerinde yöntemlerin tarafsız olarak testine imkan veren bir geçerlilik yöntemidir. LR yönteminde, 5-parçalı çapraz geçerlilik yöntemi kullanılmış ve eldeki veri seti beş parçaya ayrılmıştır. Bu parçaların üçü birleştirilip eğitim verisi ve diğer iki parça da test verisi olarak kullanılmıştır. Her seferinde farklı iki parça test için kullanılmak üzere bu işlem beş kez tekrarlanmış, sonuçta beş ayrı test sonucu elde edilmiştir. Bu değerlerin ortalaması olan doğru sınıflandırma oranı genel başarı ölçütü olarak değerlendirilmiştir. MLPNN modelinde gizli katmanda 10 adet nöron, aktivasyon için sigmoid fonksiyonu ve eğitim için de geri yayılım algoritması kullanılmıştır. Bu yöntemde modelin tarafsız olarak testine imkan veren rasgele seçimli çapraz geçerlilik

yöntemi kullanılmıştır. Çalışmada eldeki veri kümeleri %40 eğitim, %20 geçerlilik ve %40'ı da test verisi olarak dağıtılarak ortalama başarı oranı tespit edilmiştir. RBF modelinde ağırlık yayılma katsayısı 10 olarak alınmış ve gizli katmanda 10 adet nöron ve çıkış katmanında 1 adet nöron kullanılmıştır. SVM ile yapılan sınıflandırmada çekirdek fonksiyonu olarak doğrusal fonksiyon kullanılmıştır. Çalışmada kullanılan LR, MLPNN, RBF ve SVM modellerinin genel bir başarıya sahip olduğunu anlamak için aşağıdaki istatistiksel ölçütler kullanılmaktadır:

Doğru Pozitif (TP): Doğru sınıflandırılan eksudalı bireylerin sayısı

Doğru Negatif (TN): Doğru sınıflandırılan eksudalı olmayan bireylerin sayısı

Yanlış Pozitif (FP): Yanlış olarak eksudalı tespit edilen ancak eksudalı olmayan bireylerin sayısı

Yanlış Negatif (FN): Yanlış olarak eksudalı olmadığı tespit edilen ancak eksudalı olan bireylerin sayısını gösterir.

Bu ölçütler kullanılarak duyarlılık, özgüllük ve TCC oranları aşağıdaki Eşitlik 4.1, 4.2 ve 4.3 ile hesaplanmaktadır:

$$Duyarlılık = \frac{DP}{DP+YN} \quad (4.2)$$

$$Özgüllük = \frac{DN}{DN+YP} \quad (4.3)$$

$$TCC = \frac{DP+DN}{DP+YP+DN+YN} \quad (4.4)$$

Eşitlik 4.2'deki duyarlılık oranı, gerçek hastalar içinden hastaları ayırma olasılığıdır. Eşitlik 4.3'teki özgüllük oranı ise gerçek sağlamlar içinden sağlamları ayırma olasılığıdır. Duyarlılık ve özgüllük birleştirilerek tek bir ölçü elde edilmek istendiğinde kullanılan ölçütlerden biri olan Eşitlik 4.4'deki toplam doğru sınıflandırma oranı da gerçekte testin hasta ve sağlam olanların toplam doğru tanı oranına bölünmesiyle bulunmaktadır. Başarının yüksek olması durumunda genel değerlendirme yapmak için karışıklık matrisi ve ROC eğrisi analizi kullanılmaktadır (Bishop, 1995).

ImageRet veri tabanındaki retina görüntülerine FFA ve PSOA iteratif eşikleme sonucu oluşan özniteliklerin LR, MLPNN, RBF ve SVM sınıflayıcılarının uygulanmasıyla oluşan modellerden elde edilen başarıların karışıklık matrisleri Çizelge 4.4 ve 4.5’de gösterilmektedir. Karışıklık matrislerinde eksuda içeren görüntüler 1, eksuda içermeyen görüntüler 0 olarak isimlendirilmiştir.

Çizelge 4. 4. ImageRet veri tabanından alınan görüntülere FFA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri

ImageRet								
FFA								
	LR		MLPNN		RBF		SVM	
Sınıf	0	1	0	1	0	1	0	1
0	36	1	36	1	36	1	36	1
1	23	10	12	21	11	22	6	27

Çizelge 4. 5. ImageRet veri tabanından alınan görüntülere PSOA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri

ImageRet								
PSOA								
	LR		MLPNN		RBF		SVM	
Sınıf	0	1	0	1	0	1	0	1
0	36	1	37	0	37	0	37	0
1	21	12	11	22	10	23	5	28

Çizelge 4.4’te görüldüğü gibi ImageRet veri tabanında FFA temelli iteratif eşikleme uygulanması sonucu 70 retina görüntüsü için LR ile 24, MLPNN ile 13, RBF ile 12 ve SVM ile de 7 yanlış sınıflandırma gerçekleştirilmiştir. Yanlış sınıflandırmalar incelendiğinde ise eksuda içermeyen ancak eksudalı olarak sınıflandırılan görüntü sayısının toplamda 4 olmasına rağmen diğer durumda yanlış sınıflandırma sayısının toplamda 52 olduğu gözlemlenmiştir. Çizelge 4.5’de ise ImageRet veri tabanında PSOA temelli iteratif eşikleme uygulanması sonucu 70 retina görüntüsü için LR ile 21,

MLPNN ile 11, RBF ile 10 ve SVM ile de 5 yanlış sınıflandırma gerçekleştirilmiştir. Yanlış sınıflandırmalar incelendiğinde ise eksuda içermeyen ancak eksudalı olarak sınıflandırılan görüntü sayısının toplamda 1 olmasına rağmen diğer durumda yanlış sınıflandırma sayısının toplamda 47 olduğu gözlemlenmiştir. Çizelge 4.4 ve 4.5’de görülen yanlış sınıflandırma sonuçları incelendiğinde MLPNN ve SVM’nin diğer yöntemlere göre daha başarılı olduğu görülmüştür.

GopRetina veri tabanındaki retina görüntülerine FFA ve PSOA iteratif eşikleme sonucu oluşan özneteliklerin LR, MLPNN, RBF ve SVM sınıflayıcılarının uygulanmasıyla oluşan modellerden elde edilen başarıların karışıklık matrisleri Çizelge 4.6 ve 4.7’de gösterilmektedir.

Çizelge 4. 6. GopRetina görüntülerine FFA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri

GopRetina								
FFA								
	LR		MLPNN		RBF		SVM	
Sınıf	0	1	0	1	0	1	0	1
0	47	1	47	1	47	1	47	1
1	35	5	7	33	5	35	2	38

Çizelge 4. 7. GopRetina görüntülerine PSOA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri

GopRetina								
PSOA								
	LR		MLPNN		RBF		SVM	
Sınıf	0	1	0	1	0	1	0	1
0	47	1	48	0	48	0	48	0
1	33	7	4	36	3	37	1	39

Çizelge 4.6’da görüldüğü gibi GopRetina veri tabanında FFA temelli iteratif eşikleme uygulanması sonucu 88 retina görüntüsü için LR ile 36, MLPNN ile 8, RBF ile 6 ve SVM ile de 3 yanlış sınıflandırma gerçekleştirilmiştir. Yanlış sınıflandırmalar

incelendiğinde ise eksuda içermeyen ancak eksudalı olarak sınıflandırılan görüntü sayısının toplamda 4 olmasına rağmen diğer durumda yanlış sınıflandırma sayısının toplamda 49 olduğu gözlemlenmiştir. Çizelge 4.7’de ise GopRetina veri tabanında PSOA temelli iteratif eşikleme uygulanması sonucu 88 retina görüntüsü için LR ile 34, MLPNN ile 4, RBF ile 3 ve SVM ile de 1 yanlış sınıflandırma gerçekleştirilmiştir. Yanlış sınıflandırmalar incelendiğinde ise eksuda içermeyen ancak eksudalı olarak sınıflandırılan görüntü sayısının toplamda 1 olmasına rağmen diğer durumda yanlış sınıflandırma sayısının toplamda 41 olduğu gözlemlenmiştir. Çizelge 4.6 ve 4.7’de görülen yanlış sınıflandırma sonuçları incelendiğinde MLPNN ve SVM’nin diğer yöntemlere göre daha başarılı olduğu görülmüştür. ImageRet ve GopRetina veri tabanlarından alınan retina görüntülerinin OD bölgeleri çıkartılarak FFA ve PSOA temelli iteratif eşikleme uygulanması sonucu eksudalı piksel ve bölge sayıları hesaplanarak öznitelik veri seti oluşturulmuştur. Öznitelik veri setinin LR, MLPNN, RBF ve SVM sınıflandırıcılarına girdi verilmesiyle oluşan modellerin geçerlilik sonuçları Çizelge 4.8’de gösterilmektedir.


Çizelge 4. 8. Eksuda tespiti için kullanılan yöntemlerin duyarlılık, özgüllük ve TCC oranları

Hastalık Tipi	Veritabanı	Eşikleme	Sınıflayıcı	Duy.	Özg.	TCC
Eksuda	ImageRet (70)	FFA	LR	30.3	97.3	65.72
			MLPNN	63.6	97.3	81.4
			RBF	66.7	97.3	82.9
			SVM	81.8	97.3	90
		PSOA	LR	36.4	100	70
			MLPNN	66.7	100	84.3
			RBF	69.7	100	85.7
			SVM	84.9	100	92.9
	GopRetina (88)	FFA	LR	12.5	97.9	59.1
			MLPNN	82.5	97.9	90.1
			RBF	87.5	97.9	93.2
			SVM	95	97.9	96.6
		PSOA	LR	17.5	97.9	61.4


Çizelge 4. 8. devamı Eksuda tespiti için kullanılan yöntemlerin duyarlılık, özgüllük ve TCC oranları

Hastalık Tipi	Veritabanı	Eşikleme	Sınıflayıcı	Duy.	Özg.	TCC
Eksuda	GopRetina (88)	PSOA	MLPNN	90	100	95.46
			RBF	92.5	100	96.59
			SVM	97.5	100	98.9


Çizelge 4.8’de görüldüğü gibi, eksuda tespiti için her iki veri tabanında da PSOA temelli iteratif eşikleme algoritmasının FFA’ya göre daha başarılı olduğu görülmüştür. Bu durumun nedeni FFA temelli eşiklemede, ateş böcekleri yer değiştirirken sadece iki ateş böceğinin parlaklık değerlerine bakılırken, PSOA temelli eşiklemede ise tüm parçacıkların parlaklık değerleri göz önüne alınmasıdır. PSOA temelli iteratif eşikleme algoritması ile ImageRet veri tabanında SVM kullanarak doğru sınıflandırma oranı %92.9 iken, GopRetina veri tabanında SVM ile doğru sınıflandırma oranı %98.9 olmuştur. Görüntü işleme yöntemleri ve sınıflayıcının aynı olmasına rağmen doğru sınıflandırma oranındaki farklılık ImageRet veri tabanındaki retina görüntülerinin kalitesinin düşüklüğünden kaynaklanmıştır. Şekil 4.17, 4.18, 4.19 ve 4.20 bu modeller için hesaplanan duyarlılık ve özgüllük değerlerini kullanarak elde edilen ROC eğrilerini göstermektedir.




Şekil 4. 17. ImageRet veri tabanında FFA temelli iteratif eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi



Şekil 4. 18. ImageRet veri tabanında PSOA temelli iteratif eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi



Şekil 4. 19. GopRetina veri tabanında FFA temelli eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi



Şekil 4. 20. GopRetina veri tabanında PSOA temelli eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi

Şekil 4.17, 4.18, 4.19 ve 4.20'deki ROC eğrilerinin altındaki alanlar incelendiğinde, hem ImageRet veri tabanında hem de GopRetina veri tabanında eksudalı hastaların tespiti için PSOA temelli eşiklemedeki doğru sınıflandırma oranının FFA temelli eşiklemeye göre daha yüksek olduğu görülmektedir. Bununla birlikte sınıflayıcı modellerin doğru sınıflandırma oranlarına göre performansları karşılaştırıldığında sırasıyla SVM, RBF, MLPNN ve LR olarak gözlemlenmiştir. Eksudaların tespiti üzerine literatürde yapılan çalışmalar ile önerilen çalışmaların görüntü sayısı, özellik çıkarma için kullanılan yöntemler ve başarı oranlarının karşılaştırılması Çizelge 4.9'da verilmiştir.

Çizelge 4. 9. Eksuda tespiti ile ilgili çalışmalarda kullanılan yöntemler ve başarı oranları

Yazarlar	Yıl	Veri Tabanı	Görüntü Sayısı	Yöntemler	Duy.	Özg.	TCC
Ponnibala ve Vijayachitra	2014	-	122	Renk uzayı, Adaptif Histogram Eşitleme, Morfolojik İşlemler, İstatistiksel Özellikler, ANN	97.05	98	97.61
Akram ve ark.	2014	Drive, Stare, Messidor	1410	Kontrast iyileştirme, Gabor, İstatistiksel Özellikler, Bayes	97.39	98.02	97.56
Zhang ve ark.	2014	Messidor	1200	Ortalama Filtre, Morfolojik İşlemler, İstatistiksel Özellikler	91.24	94.05	93
Tjandrasa ve ark.	2015	Messidor	56	Kontrast iyileştirme, Hough dönüşümü, Kmeans, ANN	88.07	92.25	91.07
Jaya ve ark.	2015	-	200	Renk uzayı dönüşümü, Hough, Fuzzy-SVM	94.1	90	93
Zeljko ve ark.	2015	-	372	Medyan Filtre, Morfolojik İşlemler, Eşikleme	98.08	96.31	97.25
Önerilen Çalışma	2017	ImageRet	70	Canny kenar tespit, Çembersel Hough, PSOA temelli iteratif eşikleme, SVM	84.9	100	92.9
Önerilen Çalışma	2017	GopRetina	88	Canny kenar tespit, Çembersel Hough, PSOA temelli iteratif eşikleme, SVM	97.5	100	98.9


Çizelge 4.9’da görüldüğü üzere eksudaların tespiti için GopRetina veri tabanı üzerinde PSOA temelli iteratif eşikleme ve SVM sınıflayıcısını kullanarak %98.9 doğru sınıflandırma oranı elde edilerek literatürdeki diğer çalışmalar ile kıyaslandığında daha yüksek bir başarı oranı yakalanmıştır. Doğru sınıflandırma oranının yüksek olması kadar önemli diğer bir parametre de bu iki algoritmanın zaman performanslarıdır. FFA ve PSOA temelli eşikleme algoritmalarının SVM sınıflayıcısı ile oluşturulan gerçekleştirme zamanları Çizelge 4.10’da verilmiştir.

Çizelge 4. 10. FFA ve PSOA ile eşikleme yöntemlerinin zaman performansları

Yöntem	Zaman Performansı (sn)
FFA ile eşikleme, SVM	5.91
PSOA ile eşikleme, SVM	0.63

Çizelge 4.10’da görüldüğü gibi, eşikleme yöntemlerinin zaman performansları karşılaştırıldığında PSOA ile eşiklemenin diğer eşikleme yöntemine göre yaklaşık 9 kat

daha hızlı çalıştığı gözükmemektedir. Bu durumun nedeni PSOA temelli iteratif eşiklemede kullanılan parçacıkların yer değiştirme fonksiyonunun daha etkili olduğu düşünülmektedir. Şekil 4.21 FFA ve PSOA temelli iteratif eşikleme algoritması ile başarılı sınıflayıcı modellerin doğru sınıflandırma oranlarını ve zaman performanslarını göstermektedir.



Şekil 4. 21. Eşikleme yöntemlerinin doğru sınıflandırma oranları ve zaman performansları

Şekil 4.21’de görüldüğü üzere PSOA temelli eşikleme yöntemi FFA temelli eşikleme yöntemine göre hem doğru sınıflandırma oranı hem de zaman performansı açısından daha başarılıdır. Bu nedenle çalışmada eşikleme yöntemi olarak PSOA temelli iteratif eşikleme kullanılmıştır. İteratif eşikleme algoritması sonucu çıkartılan öznetelik kümesinin de daha başarılı sınıflayıcı model olan SVM ile sınıflandırılmasıyla retina görüntülerinde eksuda teşhisi gerçekleştirilmiştir.

4.4. Hemoraji tespiti

ImageRet ve GopRetina veri tabanındaki retina görüntülerinin her birinden öncelikle benzer parlaklık seviyesinde olan damar bölgeleri göz ardı edilmiştir. Retinanın koyu lezyonu olan hemorajilerin tespitinde elde edilen bu retina görüntülerine iteratif eşikleme yöntemleri uygulanarak hemoraji tespiti gerçekleştirilmiştir. ImageRet veri

tabanında 70 retina görüntüsünün 39'u hemoraji lezyonu içermekte, 31'i hemoraji lezyonu içermemektedir. GopRetina veri tabanında ise 88 retina görüntüsünün 47'si hemoraji lezyonu içermekte, 41'i hemoraji lezyonu içermemektedir. Hemoraji içeren bölgeler tespit edilirken her bir retina görüntüsünde farklı eşik değeri üretebilmek için FFA temelli iteratif eşikleme yaklaşımı ve Doğrusal Regresyon (LR) temelli sınıflayıcıyı içeren algoritma adımları aşağıdaki gibidir:

Adım 1: Retina görüntüsüne (1) renk uzayı seçimi, (2) parlaklık-kontrast iyileştirme, (3) adaptif histogram eşitleme ön-işleme yöntemlerini sırasıyla uygula.


Adım 2: Kan damarlarının bölütlenmesi ve retina görüntüsünden göz ardı edilmesi için (1) Gabor dönüşümü, (2) Top-hat dönüşümü yöntemlerini sırasıyla uygula.

Adım 3: Damar bölgesi göz ardı edilen retina görüntüsünde FFA temelli iteratif eşikleme algoritması ile ikili görüntüye çevir.

Adım 4: İkili görüntüde hemoraji içeren piksel ve bölge değerlerini saydır.

Adım 5: Hemorajili piksel değerlerini ve bölge sayısını LR temelli sınıflayıcıya giriş olarak kullanarak hemoraji lezyonlarını tespit et.


Bu algoritmada eşikleme yöntemi olarak PSOA temelli iteratif eşikleme ve sınıflayıcı olarak ise LR, MLPNN, RBF ve SVM'nin uygulanmasıyla oluşacak 8 farklı varyasyondan en başarılı olanı çözüm seçilmiştir. Algoritmada verilen ön-işleme yöntemleri ve damar bölgesinin tespit edilerek görüntüden göz ardı edilmesi işlemi önceki bölümde anlatılmıştır. Bu bölümde ise hemorajilerin tespiti için FFA ve PSOA temelli iteratif eşikleme yöntemleri uygulanmıştır. FFA'nın çalışma adımlarına göre öncelikle görüntüde rastgele piksellere gelecek şekilde 500 ateş böceği dağıtılmıştır. Görüntüde dağıtıldığı piksellerin parlaklık değerleri ateş böceklerinin parlaklık değeri olarak belirlenmiştir. Önerilen algoritmada ateş böcekleri arasında parlaklık bakımından kıyaslama yapıldığı için hemorajinin koyu lezyon olmasından dolayı parlaklığı düşük olan ateş böceklerine doğru FFA algoritmasındaki yer değiştirme mesafesinde hareket gerçekleştirilmiştir ve bu işlem 50 defa tekrarlanmıştır. Ateş böceklerinin konumlarının parlaklık ortalaması eşik değeri olarak belirlenmiştir. Şekil 4.22 FFA ile elde edilen görüntüleri göstermektedir.



a) Ateşböceklerinin görüntüde dağılımı




b) Eşikleme sonucu hemoraji tespiti



c) Retinada hemoraji içeren bölgeler

Şekil 4. 22. Damar bölgesi çıkartılan retina görüntüsüne FFA ile iteratif eşikleme


Şekil 4.22’de görüldüğü gibi, retinadaki hemoraji içeren bölgelerin tespit edilmesi için FFA ile iteratif eşik değeri üretilmiştir. Bu sayede her görüntüde farklı bir eşik değeri oluşturulmuştur. PSOA çalışma adımlarına göre ise öncelikle görüntüde rastgele piksellere gelecek şekilde 500 parçacık dağıtılmıştır. Görüntüde dağıtıldığı piksellerin parlaklık değerleri parçacıkların parlaklık değeri olarak belirlenmiştir. Önerilen algoritmada parçacıklar arasında parlaklık bakımından kıyaslama yapılarak parlaklığı düşük olan parçacıklara doğru PSOA algoritmasındaki yer değiştirme mesafesinde hareket gerçekleştirilmiştir. Bu algoritma 50 kez tekrarlanmış ve parçacıkların konumlarının parlaklık ortalaması eşik değeri olarak seçilmiştir. Şekil 4.23’te PSOA ile elde edilen görüntüler gösterilmektedir.



a) Parçacıkların görüntüde dağılımı



b) Eşikleme sonucu hemoraji tespiti



c) Retinada hemoraji içeren bölgeler

Şekil 4. 23. Damar bölgesi çıkartılan retina görüntüsüne PSOA ile iteratif eşikleme

Şekil 4.23'te görüldüğü gibi, retinadaki hemoraji içeren bölgelerin tespit edilmesi için PSOA ile iteratif eşik değeri üretilerek her görüntüde farklı bir eşik değeri oluşturulmuştur. Eşik değeri uygulanarak elde edilen ikili görüntüde öznitelik olarak hemoraji içeren toplam piksel sayısı ve bölge sayısı hesaplanmıştır. Öznitelik veri setinin LR, MLPNN, RBF ve SVM sınıflayıcılarına giriş olarak verilmesiyle doğru sınıflandırma oranları ve zaman performansları karşılaştırılmıştır. Doğru sınıflandırma performansı *K*-parçalı çapraz geçerlilik yöntemi ile analiz edilmiştir. *K*-parçalı çapraz geçerlilik yöntemi eldeki veri üzerinde yöntemlerin tarafsız olarak testine imkan veren bir geçerlilik yöntemidir. LR yönteminde, 5-parçalı çapraz geçerlilik yöntemi kullanılmış ve eldeki veri seti beş parçaya ayrılmıştır. Bu parçaların üçü birleştirilip eğitim verisi ve diğer iki parça da test verisi olarak kullanılmıştır. Her seferinde farklı iki parça test için kullanılmak üzere bu işlem beş kez tekrarlanmış, sonuçta beş ayrı test sonucu elde edilmiştir. Bu değerlerin ortalaması olan doğru sınıflandırma oranı genel başarı ölçütü olarak değerlendirilmiştir. MLPNN modelinde gizli katmanda 10 adet nöron, aktivasyon için sigmoid fonksiyonu ve eğitim için de geri yayılım algoritması kullanılmıştır. Bu yöntemde modelin tarafsız olarak testine imkan veren rasgele seçimli çapraz geçerlilik yöntemi kullanılmıştır. Çalışmada eldeki veri kümeleri %40 eğitim, %20 geçerlilik ve %40'ı da test verisi olarak dağıtılarak ortalama başarı oranı tespit edilmiştir. RBF modelinde ağırlık yayılma katsayısı 10 olarak alınmış ve gizli katmanda 10 adet nöron ve çıkış katmanında 1 adet nöron kullanılmıştır. SVM ile yapılan sınıflandırmada çekirdek fonksiyonu olarak doğrusal fonksiyon kullanılmıştır. Çalışmada kullanılan LR, MLPNN, RBF ve SVM modellerinin genel bir başarıya sahip olduğunu anlamak için aşağıdaki istatistiksel ölçütler kullanılmaktadır:

Doğru Pozitif (TP): Doğru sınıflandırılan hemorajili bireylerin sayısı

Doğru Negatif (TN): Doğru sınıflandırılan hemoraji olmayan bireylerin sayısı

Yanlış Pozitif (FP): Yanlış olarak hemorajili tespit edilen ancak hemoraji olmayan bireylerin sayısı

Yanlış Negatif (FN): Yanlış olarak hemorajili olmadığı tespit edilen ancak hemorajili olan bireylerin sayısını gösterir.

Bu ölçütler kullanılarak duyarlılık, özgüllük ve toplam TCC oranları hesaplanmaktadır. Başarının yüksek olması durumunda genel değerlendirme yapmak için karışıklık matrisi

ve ROC eğrisi analizi kullanılmaktadır (Bishop, 1995). ImageRet ve GopRetina veri tabanlarındaki retina görüntülerine FFA ve PSOA iteratif eşikleme sonucu oluşan özneliliklerin LR, MLPNN, RBF ve SVM sınıflayıcılarının uygulanmasıyla oluşan modellerden elde edilen başarıların karışıklık matrisleri Çizelge 4.11, 4.12, 4.13 ve 4.14'te gösterilmektedir. Karışıklık matrislerinde hemoraji içeren görüntüler 1, hemoraji içermeyen görüntüler 0 olarak isimlendirilmiştir.

Çizelge 4. 11. ImageRet veri tabanından alınan görüntülere FFA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri

ImageRet								
FFA								
	LR		MLPNN		RBF		SVM	
Sınıf	0	1	0	1	0	1	0	1
0	29	2	29	2	30	1	30	1
1	21	18	14	25	12	27	8	31

Çizelge 4. 12. ImageRet veri tabanından alınan görüntülere PSOA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri

ImageRet								
PSOA								
	LR		MLPNN		RBF		SVM	
Sınıf	0	1	0	1	0	1	0	1
0	30	1	30	1	30	1	31	0
1	18	21	12	27	10	29	7	32

Çizelge 4.11'de görüldüğü gibi ImageRet veri tabanında FFA temelli iteratif eşikleme uygulanması sonucu 70 retina görüntüsü için LR ile 23, MLPNN ile 16, RBF ile 13 ve SVM ile de 9 yanlış sınıflandırma gerçekleştirilmiştir. Yanlış sınıflandırmalar incelendiğinde ise hemoraji içermeyen ancak hemorajili olarak sınıflandırılan görüntü sayısının toplamda 6 olmasına rağmen diğer durumda yanlış sınıflandırma sayısının toplamda 55 olduğu gözlemlenmiştir. Çizelge 4.12'de ise ImageRet veri tabanında

PSOA temelli iteratif eşikleme uygulanması sonucu 70 retina görüntüsü için LR ile 19, MLPNN ile 13, RBF ile 11 ve SVM ile de 7 yanlış sınıflandırma gerçekleştirilmiştir. Yanlış sınıflandırmalar incelendiğinde ise hemoraji içermeyen ancak hemorajili olarak sınıflandırılan görüntü sayısının toplamda 3 olmasına rağmen diğer durumda yanlış sınıflandırma sayısının toplamda 47 olduğu gözlemlenmiştir. Çizelge 4.11 ve 4.12’de görülen yanlış sınıflandırma sonuçları incelendiğinde SVM ve RBF’nin diğer yöntemlere göre daha başarılı olduğu görülmüştür.

Çizelge 4. 13. GopRetina veri tabanından alınan görüntülere FFA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri

GopRetina								
FFA								
	LR		MLPNN		RBF		SVM	
Sınıf	0	1	0	1	0	1	0	1
0	39	2	40	1	40	1	41	0
1	28	19	8	39	4	43	2	45

Çizelge 4. 14. GopRetina veri tabanından alınan görüntülere PSOA iteratif eşikleme ile LR, MLPNN, RBF ve SVM kullanılması sonucu karışıklık matrisleri

GopRetina								
PSOA								
	LR		MLPNN		RBF		SVM	
Sınıf	0	1	0	1	0	1	0	1
0	40	1	41	0	41	0	41	0
1	26	21	6	41	5	42	1	46


Çizelge 4.13’te görüldüğü gibi GopRetina veri tabanında FFA temelli iteratif eşikleme uygulanması sonucu 88 retina görüntüsü için LR ile 30, MLPNN ile 9, RBF ile 5 ve SVM ile de 2 yanlış sınıflandırma gerçekleştirilmiştir. Yanlış sınıflandırmalar incelendiğinde ise hemoraji içermeyen ancak hemorajili olarak sınıflandırılan görüntü sayısının toplamda 4 olmasına rağmen diğer durumda yanlış sınıflandırma sayısının toplamda 42 olduğu gözlemlenmiştir. Çizelge 4.14’te ise GopRetina veri tabanında

PSOA temelli iteratif eşikleme uygulanması sonucu 88 retina görüntüsü için LR ile 27, MLPNN ile 6, RBF ile 5 ve SVM ile de 1 yanlış sınıflandırma gerçekleştirilmiştir. Yanlış sınıflandırmalar incelendiğinde ise hemoraji içermeyen ancak hemorajili olarak sınıflandırılan görüntü sayısının toplamda 1 olmasına rağmen diğer durumda yanlış sınıflandırma sayısının toplamda 38 olduğu gözlemlenmiştir. Çizelge 4.13 ve 4.14’te görülen yanlış sınıflandırma sonuçları incelendiğinde SVM ve RBF’nin diğer yöntemlere göre daha başarılı olduğu görülmüştür. ImageRet ve GopRetina veri tabanlarından alınan retina görüntülerinin damar bölgeleri çıkartılarak FFA ve PSOA temelli iteratif eşikleme uygulanması sonucu hemorajili piksel ve bölge sayıları hesaplanarak öznelik veri seti oluşturulmuştur. Öznelik veri setinin LR, MLPNN, RBF ve SVM sınıflandırıcılarına girdi verilmesiyle oluşan modellerin geçerlilik sonuçları Çizelge 4.15’te gösterilmektedir.


Çizelge 4. 15. Hemoraji tespiti için kullanılan yöntemlerin duyarlılık, özgüllük ve TCC oranları

Hata Tipi	Veritabanı	Eşikleme	Sınıflayıcı	Duy.	Özg.	TCC
Hemoraji	ImageRet (70)	FFA	LR	46.15	93.55	67.15
			MLPNN	64.1	93.55	77.15
			RBF	69.2	96.77	81.4
			SVM	79.5	96.77	87.15
		PSOA	LR	53.8	96.77	72.86
			MLPNN	69.23	96.77	81.43
			RBF	74.36	96.77	84.28
			SVM	82.05	100	90
	GopRetina (88)	FFA	LR	40.4	95.1	65.9
			MLPNN	82.9	97.6	89.8
			RBF	91.5	97.6	94.3
			SVM	95.7	100	97.7
		PSOA	LR	44.68	97.56	69.3
			MLPNN	87.23	100	93.18
			RBF	89.36	100	94.31
			SVM	97.88	100	98.9


Çizelge 4.15’te görüldüğü gibi, hemoraji tespiti için her iki veri tabanında da PSOA temelli iteratif eşikleme algoritmasının FFA’ya göre daha başarılı olduğu görülmüştür. Bu durumun nedeni FFA temelli eşiklemede, ateş böcekleri yer değiştirirken sadece iki ateş böceğinin parlaklık değerlerine bakılırken, PSOA temelli eşiklemede ise tüm parçacıkların parlaklık değerleri göz önüne alınmasıdır. PSOA temelli iteratif eşikleme algoritması ile ImageRet veri tabanında SVM kullanarak doğru sınıflandırma oranı %90 iken, GopRetina veri tabanında SVM ile doğru sınıflandırma oranı %98.9 olmuştur. Görüntü işleme yöntemleri ve sınıflayıcının aynı olmasına rağmen doğru sınıflandırma oranındaki farklılık ImageRet veri tabanındaki retina görüntülerinin kalitesinin düşüklüğünden kaynaklanmıştır. Şekil 4.24, 4.25, 4.26 ve 4.27 bu modeller için hesaplanan duyarlılık ve özgüllük değerlerini kullanarak elde edilen ROC eğrilerini göstermektedir.




Şekil 4. 24. ImageRet veri tabanında FFA temelli iteratif eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi



Şekil 4. 25. ImageRet veri tabanında PSOA temelli iteratif eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi



Şekil 4. 26. GopRetina veri tabanında FFA temelli eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi



Şekil 4. 27. GopRetina veri tabanında PSOA temelli eşikleme yönteminin sınıflayıcı modeller sonucu oluşan deneysel çalışmalarının ROC eğrisi

Şekil 4.24, 4.25, 4.26 ve 4.27'deki ROC eğrilerinin altındaki alanlar incelendiğinde, hem ImageRet veri tabanında hem de GopRetina veri tabanında hemorajili hastaların tespiti için PSOA temelli eşiklemedeki doğru sınıflandırma oranının FFA temelli eşiklemeye göre daha yüksek olduğu görülmektedir. Bununla birlikte sınıflayıcı modellerin doğru sınıflandırma oranlarına göre performansları karşılaştırıldığında sırasıyla SVM, RBF, MLPNN ve LR olarak gözlemlenmiştir. Hemorajilerin tespiti üzerine literatürde yapılan çalışmalar ile önerilen çalışmaların görüntü sayısı, özellik çıkarma için kullanılan yöntemler ve başarı oranlarının karşılaştırılması Çizelge 4.16'da verilmiştir.

Çizelge 4. 16. Hemoraji tespiti ile ilgili çalışmalarda kullanılan yöntemler ve başarı oranları

Yazarlar	Yıl	Görüntü Sayısı	Yöntemler	Duy.	Özg.	TCC
Zhang ve Fan	2006	30	Çok boyutlu morfolojik işlemler	-	-	84.1
Walter ve ark.	2007	94	Kontrast zenginleştirme, Top-hat dönüşümü, Global eşikleme	-	-	86.5
Hatanaka ve ark.	2008	125	HSV renk uzayı, Parlaklık değişimi, Eşikleme	80	88	83.7
Quelleg ve ark.	2008	120	Dalgacık, Eşikleme	90.24	89.75	89.92
Akram ve Khan	2012	20	HSI renk uzayı, Gabor, Eşikleme	-	-	93.71
Kleawsirikul ve ark.	2013	20	Renk dönüşüm uzayları, Top-hat dönüşümü, Kural Bazlı sınıflandırma	80.37	99.53	99.12

Çizelge 4. 16. devamı Hemoraji tespiti ile ilgili çalışmalarda kullanılan yöntemler ve başarı oranları


Yazarlar	Yıl	Görüntü Sayısı	Yöntemler	Duy.	Özg.	TCC
Akram ve ark.	2014	1410	Kontrast iyileştirme, Gabor, İstatistiksel Özellikler, Bayes	97.83	98.36	98.12
Romero ve ark.	2015	89	Medyan Filtresi, Bottom-hat, Radon dönüşümü, PCA	88.06	97.47	92.19
Raja ve Vasuki	2015	89	Histogram Eşitleme, Lab renk uzayı, Gabor, Eşikleme, SVM	94.76	99.85	96.48
Önerilen Çalışma	2017	70	Gabor, Top-hat, PSOA temelli iteratif eşikleme, SVM	82.05	100	90
Önerilen Çalışma	2017	88	Gabor, Top-hat, PSOA temelli iteratif eşikleme, SVM	97.88	100	98.9

Çizelge 4.16’da görüldüğü üzere hemorajilerin tespiti için GopRetina veri tabanı üzerinde PSOA temelli iteratif eşikleme ve SVM sınıflayıcısını kullanarak %98.9 doğru sınıflandırma oranı elde edilerek literatürdeki diğer çalışmalar ile kıyaslandığında daha yüksek başarı oranı yakalanmıştır. Doğru sınıflandırma oranının yüksek olması kadar önemli diğer bir parametre de bu iki algoritmanın zaman performanslarıdır. FFA ve PSOA temelli eşikleme algoritmalarının SVM sınıflayıcısı ile oluşturulan gerçekleştirme zamanları Çizelge 4.17’de verilmiştir.

Çizelge 4. 17. FFA ve PSOA ile eşikleme yöntemlerinin zaman performansları

Yöntem	Zaman Performansı (sn)
FFA ile eşikleme, SVM	7.26
PSOA ile eşikleme, SVM	0.93

Çizelge 4.17’de görüldüğü gibi, eşikleme yöntemlerinin zaman performansları karşılaştırıldığında PSOA ile eşiklemenin diğer eşikleme yöntemine göre yaklaşık 8 kat daha hızlı çalıştığı gözükmemektedir. Bu durumun nedeni PSOA temelli iteratif eşiklemede kullanılan parçacıkların yer değiştirme fonksiyonunun daha etkili olduğu düşünülmektedir. Şekil 4.28 FFA ve PSOA temelli iteratif eşikleme algoritması ile başarılı sınıflayıcı modellerin TCC oranlarını ve zaman performanslarını göstermektedir.



Şekil 4. 28. Eşikleme yöntemlerinin TCC oranlarını ve zaman performansları

Şekil 4.28’de görüldüğü üzere PSOA temelli eşikleme yöntemi FFA temelli eşikleme yöntemine göre hem doğru sınıflandırma oranı hem de zaman performansı açısından daha başarılıdır. Bu nedenle çalışmada eşikleme yöntemi olarak PSOA temelli iteratif eşikleme kullanılmıştır. İteratif eşikleme algoritması sonucu çıkartılan öznetelik kümesinin de daha başarılı sınıflayıcı model olan SVM ile sınıflandırılmasıyla retina görüntülerinde hemoraji teşhisi gerçekleştirilmiştir.

4.5.DR sınıflandırması

Retina görüntülerinde DR hastalığı teşhisi için eksuda ve hemorajilerin tespit edilmesiyle eksudalı piksel, bölge sayısı ve hemorajili piksel, bölge sayısı olmak üzere her bir görüntüden 4 adet öznetelik hesaplanarak veri seti oluşturulmuştur. DR hastalık teşhisi sınıflandırmasında dört farklı model kullanılmıştır. Model-1, HE (hemoraji ve eksudayı birlikte içeren DR hastalar) sınıfı ve NonDR (sağlıklı bireyler) sınıfı olmak üzere 2 sınıftan oluşmaktadır. Model-2, HE+E+H (hemorajili DR, eksudalı DR, hemorajili ve eksudalı DR hastalar) sınıfı ve NonDR (sağlıklı bireyler) sınıfı olmak üzere 2 sınıftan oluşmaktadır. Model-3, E (eksudalı DR hastalar) sınıfı, H (hemorajili DR hastalar) sınıfı ve NonDR (sağlıklı bireyler) sınıfı olmak üzere 3 sınıftan oluşmaktadır. Model-4, HE (hemoraji ve eksudayı birlikte içeren DR hastalar) sınıfı, E (eksudalı DR hastalar) sınıfı, H (hemorajili DR hastalar) sınıfı ve NonDR (sağlıklı bireyler) sınıfı olmak üzere 4 sınıftan oluşmaktadır. Oluşturulan veri setinin her bir

model için LR, MLPNN, RBF ve SVM sınıflayıcılarına giriş olarak verilmesiyle duyarlılık, özgülük ve TCC oranları karşılaştırılmıştır. LR yönteminde, 5-parçalı çapraz geçerlilik yöntemi kullanılmış ve eldeki veri seti beş parçaya ayrılmıştır. Bu parçaların üçü birleştirilip eğitim verisi ve diğer iki parça da test verisi olarak kullanılmıştır. Her seferinde farklı iki parça test için kullanılmak üzere bu işlem beş kez tekrarlanmış, sonuçta beş ayrı test sonucu elde edilmiştir. Bu değerlerin ortalaması olan doğru sınıflandırma oranı genel başarı ölçütü olarak değerlendirilmiştir. MLPNN modelinde gizli katmanda 10 adet nöron, aktivasyon için sigmoid fonksiyonu ve eğitim için de geri yayılım algoritması kullanılmıştır. Bu yöntemde modelin tarafsız olarak testine imkan veren rasgele seçimli çapraz geçerlilik yöntemi kullanılmıştır. Çalışmada eldeki veri kümeleri %40 eğitim, %20 geçerlilik ve %40'ı da test verisi olarak dağıtılarak ortalama başarı oranı tespit edilmiştir. RBF modelinde ağırlık yayılma katsayısı 10 olarak alınmış ve gizli katmanda 10 adet nöron ve çıkış katmanında 1 adet nöron kullanılmıştır. SVM ile yapılan sınıflandırmada çekirdek fonksiyonu olarak doğrusal fonksiyon kullanılmıştır.

ImageRet veri tabanındaki retina görüntülerine kullanılan görüntü işleme teknikleri sonucu oluşan öznitelik veri seti ile DR hastalık teşhisi için 4 farklı model kullanılmıştır. Model-1 için LR, MLPNN, RBF ve SVM sınıflandırıcıları kullanılarak elde edilen karışıklık matrisleri Çizelge 4.18, 4.19, 4.20 ve 4.21'de verilmiştir.

Çizelge 4. 18. ImageRet veri tabanında Model-1 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	NonDR
HE	16	4
NonDR	0	17

Çizelge 4. 19. ImageRet veri tabanında Model-1 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	NonDR
HE	18	2
NonDR	0	17

Çizelge 4. 20. ImageRet veri tabanında Model-1 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	NonDR
HE	19	1
NonDR	0	17

Çizelge 4. 21. ImageRet veri tabanında Model-1 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	NonDR
HE	20	0
NonDR	0	17

Model-1 için gerçekleştirilen DR teşhisi için yapılan deneylerde test için kullanılan toplam 37 vektörün 20'si HE (hemoraji ve eksudayı birlikte içeren DR hastalar) sınıfından, 17'si ise NonDR (sağlıklı bireyler) sınıfından oluşmaktadır. Çizelge 4.18'deki LR sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 4 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.19'daki MLPNN sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 2 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.20'deki RBF sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 1 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.21'deki SVM sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi yanlış sınıflandırma gerçekleştirilmemiştir. Yapılan deneysel çalışmaların sonucunda Model-1 için SVM sınıflayıcının başarılı olduğu görülmüştür.

Model-2 için LR, MLPNN, RBF ve SVM sınıflandırıcıları kullanılarak elde edilen karışıklık matrisleri Çizelge 4.22, 4.23, 4.24 ve 4.25'de verilmiştir.

Çizelge 4. 22. ImageRet veri tabanında Model-2 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE+E+H	NonDR
HE+E+H	50	3
NonDR	14	3

Çizelge 4. 23. ImageRet veri tabanında Model-2 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE+E+H	NonDR
HE+E+H	48	5
NonDR	4	13

Çizelge 4. 24. ImageRet veri tabanında Model-2 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE+E+H	NonDR
HE+E+H	50	3
NonDR	4	13

Çizelge 4. 25. ImageRet veri tabanında Model-2 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE+E+H	NonDR
HE+E+H	51	2
NonDR	2	15

Model-2 için gerçekleştirilen DR teşhisi için yapılan deneylerde test için kullanılan toplam 70 vektörün 53'ü HE+E+H (hemorajili DR, eksudalı DR, hemorajili ve eksudalı DR hastalar) sınıfından, 17'si ise NonDR (sağlıklı bireyler) sınıfından oluşmaktadır. Çizelge 4.22'deki LR sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 17 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.23'teki MLPNN sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 9 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.24'teki RBF sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 7 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.25'deki SVM sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 4 durumda yanlış sınıflandırma gerçekleştirilmiştir. Yapılan deneysel çalışmaların sonucunda Model-2 için SVM sınıflayıcının başarılı olduğu görülmüştür.

Model-3 için LR, MLPNN, RBF ve SVM sınıflandırıcıları kullanılarak elde edilen karışıklık matrisleri Çizelge 4.26, 4.27, 4.28 ve 4.29'da verilmiştir.

Çizelge 4. 26. ImageRet veri tabanında Model-3 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	E	H	NonDR
E	4	0	10
H	0	7	12
NonDR	0	0	17

Çizelge 4. 27. ImageRet veri tabanında Model-3 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	E	H	NonDR
E	9	0	5
H	0	15	4
NonDR	0	0	17

Çizelge 4. 28. ImageRet veri tabanında Model-3 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	E	H	NonDR
E	10	0	4
H	0	15	4
NonDR	0	0	17

Çizelge 4. 29. ImageRet veri tabanında Model-3 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	E	H	NonDR
E	12	0	2
H	0	18	1
NonDR	0	1	16

Model-3 için gerçekleştirilen DR teşhisi için yapılan deneylerde test için kullanılan toplam 50 vektörün 14'ü E (eksudalı DR hastalar) sınıfından, 19'u H (hemorajili DR hastalar) sınıfından, 17'si ise NonDR (sağlıklı bireyler) sınıfından oluşmaktadır. Çizelge 4.26'daki LR sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte eksudalı olan 14 durumun 10'u, gerçekte hemorajili olan 19 durumun 12'si olmak üzere toplamda 22 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.27'deki MLPNN sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte eksudalı olan 14 durumun 5'i, gerçekte hemorajili olan 19 durumun 4'ü olmak üzere

toplamda 9 yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.28'deki RBF sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte eksudalı olan 14 durumun 4'ü, gerçekte hemorajili olan 19 durumun 4'ü olmak üzere toplamda 8 yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.29'daki SVM sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte eksudalı olan 14 durumun 2'si, gerçekte hemorajili olan 19 durumun 1'i, gerçekte sağlıklı olan 17 durumun ise 1'i olmak üzere toplamda 4 yanlış sınıflandırma gerçekleştirilmiştir. Yapılan deneysel çalışmaların sonucunda Model-3 için SVM sınıflayıcının başarılı olduğu görülmüştür.

Model-4 için LR, MLPNN, RBF ve SVM sınıflandırıcıları kullanılarak elde edilen karışıklık matrisleri Çizelge 4.30, 4.31, 4.32 ve 4.33'te verilmiştir.

Çizelge 4. 30. ImageRet veri tabanında Model-4 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	E	H	NonDR
HE	12	1	4	3
E	1	5	0	8
H	4	0	12	3
NonDR	0	1	6	10

Çizelge 4. 31. ImageRet veri tabanında Model-4 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	E	H	NonDR
HE	16	2	2	0
E	2	9	1	2
H	1	0	15	3
NonDR	0	2	2	13

Çizelge 4. 32. ImageRet veri tabanında Model-4 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	E	H	NonDR
HE	17	1	2	0
E	2	10	1	1
H	2	0	15	2
NonDR	0	3	2	12

Çizelge 4. 33. ImageRet veri tabanında Model-4 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	E	H	NonDR
HE	19	1	0	0
E	1	11	0	2
H	4	0	12	3
NonDR	0	1	1	15

Model-4 için gerçekleştirilen DR teşhisi için yapılan deneylerde test için kullanılan toplam 70 vektörün 20'si HE (hemoraji ve eksudayı birlikte içeren DR hastalar) sınıfından, 14'ü E (eksudalı DR hastalar) sınıfından, 19'u H (hemorajili DR hastalar) sınıfından, 17'si ise NonDR (sağlıklı bireyler) sınıfından oluşmaktadır. Çizelge 4.30'daki LR sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte hemorajili ve eksudalı olan 20 durumun 8'i, gerçekte eksudalı olan 14 durumun 9'u, gerçekte hemorajili olan 19 durumun 7'si, gerçekte sağlıklı olan 17 durumun ise 7'si olmak üzere toplamda 31 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.31'deki MLPNN sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte hemorajili ve eksudalı olan 20 durumun 4'ü, gerçekte eksudalı olan 14 durumun 5'i, gerçekte hemorajili olan 19 durumun 4'ü, gerçekte sağlıklı olan 17 durumun ise 4'ü olmak üzere toplamda 17 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.32'deki RBF sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte hemorajili ve eksudalı olan 20 durumun 3'ü, gerçekte eksudalı olan 14 durumun 4'ü, gerçekte hemorajili olan 19 durumun 4'ü, gerçekte sağlıklı olan 17 durumun ise 5'i olmak üzere toplamda 16 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.33'teki SVM sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte hemorajili ve eksudalı olan 20 durumun 1'i, gerçekte eksudalı olan 14 durumun 3'ü, gerçekte hemorajili olan 19 durumun 7'si, gerçekte sağlıklı olan 17 durumun ise 2'si olmak üzere toplamda 13 durumda yanlış sınıflandırma gerçekleştirilmiştir. Yapılan deneysel çalışmaların sonucunda Model-4 için SVM sınıflayıcının başarılı olduğu görülmüştür.

4 farklı model için kullanılan sınıflayıcılar sonucu oluşan duyarlılık, özgüllük ve TCC değerleri Çizelge 4.34'te verilmiştir.

Çizelge 4. 34. ImageRet veri tabanında gerçekleştirilen deneylerin başarı oranları

Model	Sınıflayıcı	Sınıf Sayısı	Duy	Özg	TCC
Model-1 (HE / NonDR)	LR	2	100	80	89.2
	MLPNN		100	90	94.6
	RBF		100	95	97.3
	SVM		100	100	100
Model-2 (HE+E+H / NonDR)	LR	2	17.64	94.34	75.71
	MLPNN		76.47	90.57	87.14
	RBF		76.47	94.34	90
	SVM		88.23	96.23	94.29
Model-3 (E / H / NonDR)	LR	3	28.57	100	56
			36.84	100	
			100	43.59	
	MLPNN		64.28	100	82
			78.94	100	
			100	65.38	
	RBF		78.95	100	84
			71.43	100	
			100	68	
	SVM		94.74	94.74	92
			85.72	100	
			94.12	84.21	
Model-4 (HE / E / H / NonDR)	LR	4	60	70.58	55.7
			35.71	71.42	
			63.15	54.55	
			58.82	41.67	
	MLPNN		80	84.21	75.72
			64.29	69.23	
			78.95	75	
			76.47	72.22	
	RBF		85	80.95	77.14
			71.43	71.43	
			78.95	75	
			70.58	80	
	SVM		95	95	88.6
			78.57	84.62	
			89.47	94.44	
			88.24	78.95	

Çizelge 4.34'te görüldüğü gibi iki grupta DR sınıflandırmasının yapıldığı Model-1 için gerçekleştirilen çalışmada SVM sınıflayıcı ile %100 doğru sınıflandırma oranına ulaşılmıştır. Yüksek başarı oranına ulaşılmasında kullanılan görüntü işleme yöntemleri ve sınıflayıcıların etkisi olduğu kadar Model-1'de kullanılan retina görüntülerinin hemoraji ve eksudayı birlikte içermeleri de etkili olmuştur. Bu durum gerçekleştirilen çalışmanın ileri seviye DR hastalar ile sağlıklı kişiler arasında hatasız bir sınıflandırma yaptığını göstermiştir. İki grupta DR sınıflandırmasının yapıldığı diğer bir model olan

Model-2’de ise SVM sınıflayıcı ile %94.29 doğru sınıflandırma oranına ulaşılmıştır. Bu modelde görüntü veri tabanına sadece eksuda ve sadece hemoraji içeren görüntülerin eklenmesi sonucu yapılan yanlış sınıflandırmalar nedeniyle başarı oranında düşme yaşanmıştır. DR hastalığının ilk aşamalarında oluşan sadece hemoraji ve sadece eksudalı hastaların ayrımı için gerçekleştirilen çalışma olan ve üç grupta DR sınıflandırmasının yapıldığı Model 3’te ise SVM sınıflayıcı ile %92 doğru sınıflandırma oranı yakalanmıştır. DR hastalığının hem ileri aşamasında hem de ilk aşamasında olan hastalardan alınan retina görüntülerinde oluşan ve 4 grupta DR sınıflandırmasının yapıldığı Model 4’te ise yine SVM sınıflayıcı ile %88.6 doğru sınıflandırma oranına ulaşılmıştır.

GopRetina veri tabanındaki retina görüntülerine kullanılan görüntü işleme teknikleri sonucu oluşan öznelik veri seti ile DR hastalık teşhisi için ImageRet veri tabanında kullanılan 4 model kullanılmıştır. Model-1 için LR, MLPNN, RBF ve SVM sınıflandırıcıları kullanılarak elde edilen karışıklık matrisleri Çizelge 4.35, 4.36, 4.37 ve 4.38’de verilmiştir.

Çizelge 4. 35. GopRetina veri tabanında Model-1 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	NonDR
HE	20	4
NonDR	0	25

Çizelge 4. 36. GopRetina veri tabanında Model-1 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	NonDR
HE	23	1
NonDR	0	25

Çizelge 4. 37. GopRetina veri tabanında Model-1 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	NonDR
HE	24	0
NonDR	0	25

Çizelge 4. 38. GopRetina veri tabanında Model-1 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	NonDR
HE	24	0
NonDR	0	25

Model-1 için gerçekleştirilen DR teşhisi için yapılan deneylerde test için kullanılan toplam 49 vektörün 24'ü HE (hemoraji ve eksudayı birlikte içeren DR hastalar) sınıfından, 25'i ise NonDR (sağlıklı bireyler) sınıfından oluşmaktadır. Çizelge 4.35'deki LR sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 4 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.36'daki MLPNN sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 1 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.37'deki RBF sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi yanlış sınıflandırma gerçekleştirilmemiştir. Çizelge 4.38'deki SVM sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi yanlış sınıflandırma gerçekleştirilmemiştir. Yapılan deneysel çalışmaların sonucunda Model-1 için RBF ve SVM sınıflayıcıların başarılı olduğu görülmüştür.

Model-2 için LR, MLPNN, RBF ve SVM sınıflandırıcıları kullanılarak elde edilen karışıklık matrisleri Çizelge 4.39, 4.40, 4.41 ve 4.42'de verilmiştir.

Çizelge 4. 39. GopRetina veri tabanında Model-2 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE+E+H	NonDR
HE+E+H	59	4
NonDR	21	4

Çizelge 4. 40. GopRetina veri tabanında Model-2 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE+E+H	NonDR
HE+E+H	60	3
NonDR	1	24

Çizelge 4. 41. GopRetina veri tabanında Model-2 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE+E+H	NonDR
HE+E+H	61	2
NonDR	1	24

Çizelge 4. 42. GopRetina veri tabanında Model-2 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE+E+H	NonDR
HE+E+H	62	1
NonDR	0	25

Model-2 için gerçekleştirilen DR teşhisi için yapılan deneylerde test için kullanılan toplam 88 vektörün 63'ü HE+E+H (hemorajili DR, eksudalı DR, hemorajili ve eksudalı DR hastalar) sınıfından, 25'i ise NonDR (sağlıklı bireyler) sınıfından oluşmaktadır. Çizelge 4.39'daki LR sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 25 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.40'daki MLPNN sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 4 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.41'deki RBF sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 3 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.42'deki SVM sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi 1 durumda yanlış sınıflandırma gerçekleştirilmiştir. Yapılan deneysel çalışmaların sonucunda Model-2 için SVM sınıflayıcının başarılı olduğu görülmüştür.

Model-3 için LR, MLPNN, RBF ve SVM sınıflandırıcıları kullanılarak elde edilen karışıklık matrisleri Çizelge 4.43, 4.44, 4.45 ve 4.46'da verilmiştir.

Çizelge 4. 43. GopRetina veri tabanında Model-3 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	E	H	NonDR
E	9	0	7
H	0	6	17
NonDR	0	0	25

Çizelge 4. 44. GopRetina veri tabanında Model-3 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	E	H	NonDR
E	16	0	0
H	0	17	6
NonDR	0	0	25

Çizelge 4. 45. GopRetina veri tabanında Model-3 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	E	H	NonDR
E	15	0	1
H	0	18	5
NonDR	0	0	25

Çizelge 4. 46. GopRetina veri tabanında Model-3 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	E	H	NonDR
E	16	0	0
H	0	22	1
NonDR	0	1	24

Model-3 için gerçekleştirilen DR teşhisi için yapılan deneylerde test için kullanılan toplam 64 vektörün 16'sı E (eksudalı DR hastalar) sınıfından, 23'ü H (hemorajili DR hastalar) sınıfından, 25'i ise NonDR (sağlıklı bireyler) sınıfından oluşmaktadır. Çizelge 4.43'teki LR sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte eksudalı olan 16 durumun 7'si, gerçekte hemorajili olan 23 durumun 17'si olmak üzere toplamda 24 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.44'teki MLPNN sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte hemorajili olan 23 durumun 6'sı olmak üzere toplamda 6 yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.45'deki RBF sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte eksudalı olan 16 durumun 1'inde, gerçekte hemorajili olan 23 durumun 5'i olmak üzere toplamda 6 yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.46'daki SVM sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte hemorajili olan 23 durumun 1'i, gerçekte sağlıklı olan 25 durumun ise 1'i olmak üzere toplamda 2 yanlış sınıflandırma

gerçekleştirilmiştir. Yapılan deneysel çalışmaların sonucunda Model-3 için SVM sınıflayıcının başarılı olduğu görülmüştür.

Model-4 için LR, MLPNN, RBF ve SVM sınıflandırıcıları kullanılarak elde edilen karışıklık matrisleri Çizelge 4.47, 4.48, 4.49 ve 4.50’de verilmiştir.

Çizelge 4. 47. GopRetina veri tabanında Model-4 için LR ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	E	H	NonDR
HE	12	11	1	0
E	0	16	0	0
H	1	2	12	8
NonDR	0	0	1	24

Çizelge 4. 48. GopRetina veri tabanında Model-4 için MLPNN ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	E	H	NonDR
HE	22	2	0	0
E	3	13	0	0
H	2	0	21	0
NonDR	0	1	2	22

Çizelge 4. 49. GopRetina veri tabanında Model-4 için RBF ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	E	H	NonDR
HE	22	2	0	0
E	2	14	0	0
H	2	0	21	0
NonDR	0	1	1	23

Çizelge 4. 50. GopRetina veri tabanında Model-4 için SVM ile DR sınıflandırması sonucu oluşan karışıklık matrisi

	HE	E	H	NonDR
HE	24	0	0	0
E	2	14	0	0
H	1	0	22	0
NonDR	0	1	1	23

Model-4 için gerçekleştirilen DR teşhisi için yapılan deneylerde test için kullanılan toplam 88 vektörün 24'ü HE (hemoraji ve eksudayı birlikte içeren DR hastalar) sınıfından, 16'sı E (eksudalı DR hastalar) sınıfından, 23'ü H (hemorajili DR hastalar) sınıfından, 25'i ise NonDR (sağlıklı bireyler) sınıfından oluşmaktadır. Çizelge 4.47'deki LR sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte hemorajili ve eksudalı olan 24 durumun 12'si, gerçekte hemorajili olan 23 durumun 11'i, gerçekte sağlıklı olan 25 durumun ise 1'i olmak üzere toplamda 24 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.48'deki MLPNN sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte hemorajili ve eksudalı olan 24 durumun 2'si, gerçekte eksudalı olan 16 durumun 3'ü, gerçekte hemorajili olan 23 durumun 2'si, gerçekte sağlıklı olan 25 durumun ise 3'ü olmak üzere toplamda 10 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.49'daki RBF sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte hemorajili ve eksudalı olan 24 durumun 2'si, gerçekte eksudalı olan 16 durumun 2'si, gerçekte hemorajili olan 23 durumun 2'si, gerçekte sağlıklı olan 25 durumun ise 2'si olmak üzere toplamda 8 durumda yanlış sınıflandırma gerçekleştirilmiştir. Çizelge 4.50'deki SVM sınıflayıcı sonucu oluşan karışıklık matrisinden görüldüğü gibi gerçekte eksudalı olan 16 durumun 2'si, gerçekte hemorajili olan 23 durumun 1'i, gerçekte sağlıklı olan 25 durumun ise 2'si olmak üzere toplamda 5 durumda yanlış sınıflandırma gerçekleştirilmiştir. Yapılan deneysel çalışmaların sonucunda Model-4 için SVM sınıflayıcının başarılı olduğu görülmüştür.

4 farklı model için kullanılan sınıflayıcılar sonucu oluşan duyarlılık, özgüllük ve TCC değerleri Çizelge 4.51'de verilmiştir.

Çizelge 4. 51. GopRetina veri tabanında gerçekleştirilen deneylerin başarı oranları

Model	Sınıflayıcı	Sınıf Sayısı	Duy	Özg	TCC
Model-1 (HE / NonDR)	LR	2	100	83.33	91.8
	MLPNN		100	95.83	98
	RBF		100	100	100
	SVM		100	100	100
Model-2 (HE+E+H / NonDR)	LR	2	93.65	16	71.6
	MLPNN		95.24	96	95.5
	RBF		96.83	96	96.59
	SVM		98.41	100	98.9
Model-3 (E / H / NonDR)	LR	3	56.25	100	62.5
			26.09	100	
			100	51.02	
	MLPNN		100	100	90.6
			73.9	100	
			100	80.64	
	RBF		93.75	100	90.6
			78.26	100	
			100	80.64	
	SVM		100	100	96.9
			95.65	95.65	
			96	96	
Model-4 (HE / E / H / NonDR)	LR	4	50	92.3	72.7
			100	55.17	
			52.17	85.72	
			96	75	
	MLPNN		91.67	81.48	88.64
			81.25	81.25	
			91.3	91.3	
			88	100	
	RBF		91.67	84.62	90.91
			87.5	82.35	
			91.3	95.46	
			92	100	
	SVM		100	88.89	94.3
			87.5	93.33	
			95.65	95.65	
			92	100	

Çizelge 4.51’de görüldüğü gibi iki grupta DR sınıflandırmasının yapıldığı Model-1 için gerçekleştirilen çalışmada RBF ve SVM sınıflayıcı ile %100 doğru sınıflandırma oranına ulaşılmıştır. Yüksek başarı oranına ulaşılmasında kullanılan görüntü işleme yöntemleri ve sınıflayıcıların etkisi olduğu kadar Model-1’de kullanılan retina görüntülerinin hemoraji ve eksudayı birlikte içermeleri de etkili olmuştur. Bu durum gerçekleştirilen çalışmanın ileri seviye DR hastalar ile sağlıklı kişiler arasında hatasız bir sınıflandırma yaptığını göstermiştir. İki grupta DR sınıflandırmasının yapıldığı diğer bir model olan Model-2’de ise SVM sınıflayıcı ile %98.9 doğru sınıflandırma oranına

ulařılmıştır. Bu modelde görüntü veri tabanına sadece eksuda ve sadece hemoraji içeren görüntülerin eklenmesi sonucu yapılan yanlış sınıflandırmalar nedeniyle başarı oranında düşme yaşanmıştır. DR hastalığının ilk aşamalarında oluşan sadece hemoraji ve sadece eksudalı hastaların ayrımı için gerçekleştirilen çalışma olan ve üç grupta DR sınıflandırmasının yapıldığı Model 3'te ise SVM sınıflayıcı ile %96.9 doğru sınıflandırma oranı yakalanmıştır. DR hastalığının hem ileri aşamasında hem de ilk aşamasında olan hastalardan alınan retina görüntülerinde oluşan ve 4 grupta DR sınıflandırmasının yapıldığı Model 4'te ise yine SVM sınıflayıcı ile %94.3 doğru sınıflandırma oranına ulařılmıştır.



5. SONUÇ

Diyabet hastalığının oldukça artış göstermesi nedeniyle hasta yoğunluğu artmakta ve bu yüzden hastaların düzenli olarak takip edilmesi zorlaşmaktadır. Tez çalışması ile göz doktorlarının teşhis işlerini kolaylaştırmak ve zaman kaybının önlenmesi için DR teşhisi ve sınıflandırmasının bilgisayar destekli bir sistem tarafından gerçekleştirilmesi sağlanmıştır.

DR teşhisi ve sınıflandırması için öncelikle retinadaki anatomik yapılar olan OD ve kan damarlarının otomatik tespiti gerçekleştirilmiştir. Optik disk tespiti için sırasıyla HSV renk uzayı, adaptif histogram eşitleme, Gama dönüşümü, Canny kenar bulma algoritması ve çembersel Hough dönüşümü, damar bölütlemesi için sırasıyla RGB renk uzayı, adaptif histogram eşitleme, Gabor ve Top-hat dönüşümü yöntemleri uygulanmıştır. OD tespiti için özellikle HSV renk uzayının RGB renk uzayı çözümüne göre daha başarılı olduğu tespit edilmiştir. İki yöntemde de çembersel Hough dönüşümünün etkili olduğu görülmüştür. Anatomik bölgelerin tespit edilerek gözardı edilmesinden sonra eksuda ve hemoraji lezyonlarının tespit edilmesi için manüel eşikleme ve FFA / PSOA temelli iteratif eşikleme yöntemleri kullanılmıştır. Deneysel çalışmalar iteratif eşikleme yöntemi olarak PSOA'nın FFA'ya göre hem doğru tespit hem de zaman performansı açısından daha başarılı olduğunu göstermiştir. Tüm retina görüntülerinde aynı eşik değerleri kullanıldığı için manüel eşikleme yönteminin iteratif eşikleme yöntemlerine göre daha başarısız olduğu görülmüştür. Kullanılan görüntü işleme yöntemleri sonucunda oluşturulan öznetelik veri setlerine LR, MLPNN, RBF ve SVM gibi farklı sınıflandırıcılar uygulanarak DR teşhisi ve sınıflandırılması gerçekleştirilmiştir. DR sınıflandırması aşamasında 4 farklı model kullanılarak başarı oranları karşılaştırılmıştır. Bu modeller içerisinde en yüksek başarı hastalığın ileri aşaması olan eksuda ve hemorajiyi birlikte içeren retina görüntüleri ile sağlıklı retina görüntüleri içeren Model-1'de SVM ile %100 doğru sınıflandırma performansı ile sağlanmıştır. Her bir lezyonun ayrı sınıflandırıldığı Model 4'te ise SVM ile %94.3 başarı oranı ile DR sınıflandırması gerçekleştirilmiştir. DR teşhisi ve sınıflandırması için 2 farklı görüntü veri tabanındaki görüntülere aynı görüntü işleme, makine öğrenmesi yöntemleri ve karar verme modellerinin uygulanması sonucunda GopRetina veri tabanında ImageRet veri tabanına göre daha başarılı doğru sınıflandırma

performanslarına ulaşılmıştır. Bu durum retina görüntüleri kalitesinin DR teşhis ve sınıflandırma performansını doğrudan etkilediğini göstermiştir. 2 farklı görüntü veri tabanı, 4 farklı DR teşhisi için karar verme modeli ve 4 farklı sınıflayıcı uygulanması sonucu yapılan toplam 32 deneysel çalışma sonucunda SVM temelli sınıflayıcının diğer sınıflayıcılara göre daha başarılı olduğu görülmüştür.

DR teşhisi ve sınıflandırması için yapılan bu deneyler sonucunda literatürün büyük bir kısmının üstünde başarı sağlanmıştır. Dolayısıyla bu tez çalışması, hasta yoğunluğundan dolayı yaşanan muhtemel karışıklıkların önüne geçerek göz doktorlarına ön-tanı imkanı veren karar destek sisteminin gerçekleştirilebilmesi konusunda ümit vericidir.

Gelecek çalışmalarda, standartlara uygun yeni retina görüntülerinin dahil edilmesi, eksuda ve hemoroji lezyonlarının sınıflandırılmasının yanında mikroanevrizma lezyonlarının da sınıflandırılmasının otomatik olarak gerçekleştirilmesi, ateş böceklerinin veya parçacıkların görüntü üzerinde rastgele dağılımlarının optimize edilmesi, farklı optimizasyon algoritmalarının da iteratif eşik değeri tespiti için araştırılması ve yeni makine öğrenmesi yöntemlerinin de kullanılması ile performans ve başarısının arttırılması hedeflenmektedir.

6. KAYNAKLAR

- Abdelazeem, S., 2002. Micro-aneurysm detection using vessels removal and circular hough transform. In Radio Science Conference, Proceedings of the Nineteenth National. 421-426.
- Abdel-Razik, Y.A.A.H., Ghalwash A.Z. ve Abdel-Rahman Ghoneim A.A.S., 2008. Optic disc detection from normalized digital fundus images by means of a vessels direction matched filter. IEEE Trans. Med. Imaging, 27 (1), 11–18.
- Adem, K., Hekim, M., Cömert, O. ve Demir, S., 2016. A novel approach to method for the detection of optic disc location in retinal images using image processing techniques. Journal of New Results in Science, 5 (12).
- Adem, K., Orhan, U. ve Hekim, M., 2015. Image processing based quality control of the impermeable seams in multilayered aseptic packages. Expert Systems with Applications. 42 (7), 3785-3789.
- Agurto, C., Murray V., Barriga E., Murillo S., Pattichis M., Davis H., Russell S., Abramoff M. ve Soliz P., 2010. Multiscale AM-FM methods for diabetic retinopathy lesion detection. IEEE Trans.Med. Imaging. 29 (2), 502–512.
- Akram, M. U. ve Khan S. A., 2012. Automated detection of dark and bright lesions in retinal images for early detection of diabetic retinopathy. Journal of medical systems. 36 (5), 3151-3162.
- Akram, M. U., Khalid S. ve Khan S. A., 2013. Identification and classification of microaneurysms for early detection of diabetic retinopathy. Pattern Recognition. 1 (46), 107-116.
- Akram, M. U., Khalid S., Tariq A., Khan S. A. ve Azam F., 2014. Detection and classification of retinal lesions for grading of diabetic retinopathy. Computers in biology and medicine. 45, 161-171.
- Al-Rawi, M., Qutaishat, M. ve Arrar, M., 2007. An improved matched filter for blood vessel detection of digital retinal images. Computers in Biology and Medicine. 37 (2), 262-267.
- Anonim, 2017a. Göz dibi muayenesi. <http://www.erolkara.net/2014/11/goz-muayenesi-nasl-yaplyor.html> (24.06.2017)
- Anonim, 2017b. Fundus kameralar. <http://fulopoptika.hu/portfolio/fundus> (24.06.2017)
- Anonim, 2017c. DR lazer tedavisi. <http://www.nasilyapilir.com/diyabetik-retinopati-nedir-ve-tedavisi-nasil-yapilir/> (27.04.2017)

- Apaydın, K. C. ve Bilgin, A. B., 2010. Diyabetik retinopatide erken tanı ve medikal tedavi. *Journal of Retina-Vitreous*. 18 (4), 061-065.
- Aptel, F., Denis P., Rouberol F. ve Thivolet C., 2008. Screening of diabetic retinopathy: effect of field number and my driasis on sensitivity and specificity of digital fundus photography. *Diabetes Metab*. 34 (3), 290–293.
- Balcı, K., 2008. Üretim otomasyonunda görüntü tabanlı hata tanıma sistemi. (Doctoral dissertation).
- Bellanger, M., 2000. Digital processing of signal: theory and practice. John Wiley and Sons, USA.
- Bin, Y. ve Jain A.K., 1997. Address block location on complex mail pieces. 18-20 Ağustos, Ulm, Germany.
- Bishop, C.M., 1995. Neural networks for pattern recognition. Oxford university press.
- Buğday, A., 2010. Gerçek zamanlı videolarda ön plan ve arka plan ayrımı. (Yüksek Lisans Tezi) Ankara Üniversitesi Fen Bilimleri Enstitüsü, Ankara.
- Büyükdevrim, S., 1992. İç hastalıklar. Diabetes mellitus. 1inci Baskı, İstanbul: Bayda AŞ. 190-1.
- Canny, J., 1986. A computational approach to edge detection. *IEEE Transactions on pattern analysis and machine intelligence*. (6), 679-698.
- Chapra, C.C. ve Canale, R.P., 2003. Numerical Methods For Engineers. McGraw– Hill.
- Çayırılı, M., 2006. Yanma olayının modellenmesi ve görüntü işleme yoluyla yanma performansının optimizasyonu. (Yüksek Lisans Tezi) Süleyman Demirel Üniversitesi. Fen Bilimleri Enstitüsü, Isparta.
- Çetiner, H. ve Cetişli B., 2014. Retinal görüntülerde yoğunluk ve öznitelik tabanlı optik disk tespiti. In *Signal Processing and Communications Applications Conference (SIU)*, 208-211.
- Ding, L. ve Goshtasby, A., 2001. On the Canny edge detector. *Pattern Recognition*. 34 (3), 721-725.
- Dougherty, E. R. ve Lotufo, R.A., 2003. Hands-on morphological image processing. (59) SPIE press.
- Farid, H., 2001. Blind inverse gamma correction. *IEEE Transactions on Image Processing*. 10 (10), 1428-1433.
- Fleming, A.D., Goatman K.A., Williams G.J., Philip S., Sharp P.F. ve Olson J.A., 2008. Automated detection of blot haemorrhages as a sign of referable diabetic

- retinopathy. in:Proceedings of the Medical Image Understanding and Analysis. 235–239.
- Fleming, A.D., Philip S., Goatman K.A., Olson J.A. ve Sharp P.F., 2006. Automated microaneurysm detection using local contrast normalization and local vessel detection. *IEEE Trans. Med. Imaging*. 25 (9), 1223–1232.
- Fleming, A.D., Philip S., Goatman K.A., Williams G.J., Olson J.A. ve Sharp P.F., 2007. Automated detection of exudates for diabetic retinopathy screening. *Phys. Med. Biol.* 52 (24), 7385.
- Frame, A.J., Undrill P.E., Cree M.J., Olson J.A., McHardy K.C., Sharp P.F. ve Forrester J.V., 1998. A comparison of computer based classification methods applied to the detection of microaneurysms in ophthalmic fluorescein angiograms. *Comput. Biol. Med.* 28 (3), 225–238.
- Ganesan, K., Martis R. J., Acharya U. R., Chua C. K., Min L. C., Ng E. Y. K. ve Laude A., 2014. Computer-aided diabetic retinopathy detection using trace transforms on digital fundus images. *Medical & biological engineering & computing*. 52 (8), 663-672.
- Gang, L., Chutatape, O. ve Krishnan, S.M., 2002. Detection and measurement of retinal vessels in fundus images using amplitude modified second-order Gaussian filter. *IEEE transactions on Biomedical Engineering*. 49 (2), 168-172.
- Gardner, G.G., Keating D., Williamson T.H., Elliott A.T., 1996. Automatic detection of diabetic retinopathy using an artificial neural network: a screening tool. *Br. J. Ophthalmol.* 80, 940–944.
- Goatman, K.A., Fleming, A.D., Philip, S., Williams, G.J., Olson, J.A. ve Sharp, P.F., 2011. Detection of new vessels on the optic disc using retinal photographs. *IEEE transactions on medical imaging*, 30 (4), 972-979.
- Gonzalez R.C. ve Woods R.E., 2002. *Digital image processing*. Second Edition, Prentice Hall.
- Gonzalez R.C. ve Woods R.E., 2004. *Digital image processing using MATLAB*. Prentice Hall.
- Gönül, Ş. ve Kadioğlu E., 2013. Retina sinir lifi tabakası ve diyabet. *Tıp Araştırmaları Dergisi*. 11 (2), 87-93.
- Hansen, A.B., Hartvig N.V., Jensen M.S., Borch-Johnsen K., Lund-Andersen H. ve Larsen M., 2004. Diabetic retinopathy screening using digital nonmydriatic fundus photography and automated image analysis. *Acta Ophthalmol.Scand.* 82 (6), 666–672.

- Hansgen, P., Undrill P.E. ve Cree M.J., 1998. The application of wavelets to retinal image compression and its effect on automatic microaneurysm analysis. *Comput. Methods Programs Biomed.* 56 (1), 1–10.
- Hardy, R.L., 1971. Multiquadric equations of topography and other irregular surfaces. *Journal of Geophysical Research.* 76 (8), 1905–1915.
- Hatanaka, Y., Nakagawa T., Hayashi Y., Kakogawa M., Sawada A., Kawase K., Hara T. ve Fujita H., 2008. Improvement of automatic hemorrhages detection methods using brightness correction on fundus images. in: *Proceedings of the SPIE.* 6915, 69153 E–1.
- Hiller, R, Sperduto R.D., Podgor M.J., Ferris F.L., ve Wilson P.W., 1988. Diabetic retinopathy and cardiovascular disease in type II diabetics. The Framingham Heart Study and the Framingham Eye Study. *Am J Epidemiol.* 128 (2), 402-9.
- Hoover, A., Kouznetsova V. ve Goldbaum M., 2000. Locating blood vessels in retinal images by piece-wise threshold probing of a matched filter response. *IEEE Transactions on Medical Imaging.* 19 (3), 203-210.
- İnan, S., 2014. Retina anatomisi. *Kocatepe Tıp Dergisi.* 15 (2), 207-17.
- İnan, Ü.Ü., 2011. Nonproliferatif diyabetik retinopati. *Journal of Ophthalmology Special Topics.* 4 (3), 1-15.
- Jaya, T., Dheeba J. ve Singh N. A., 2015. Detection of hard exudates in colour fundus images using fuzzy support vector machine-based expert system. *Journal of digital imaging.* 1-8.
- Kahai, P., Namuduri K.R. ve Thompson H., 2006. A decision support framework for automated screening of diabetic retinopathy. *Int.J. Biomed. Imaging.*
- Kande, G.B., Savithri T.S. ve Subbaiah P.V., 2010. Automatic detection of microaneurysms and hemorrhages in digital fundus images. *Journal of digital imaging.* 23 (4), 430-437.
- Kauppi, T., Kalesnykiene, V., Kamarainen, J.K., Lensu, L., Sorri, I., Raninen A., Voutilanen R., Uusitalo, H., Kälviäinen, H. ve Pietilä, J., 2007. DIARETDB1 diabetic retinopathy database and evaluation protocol (ImageRet). Technical report.
- Kaur, J. ve Mittal D., 2015. Segmentation and measurement of exudates in fundus images of the retina for detection of retinal disease. *Journal of Biomedical Engineering and Medical Imaging.* 2 (1), 27.

- Kennedy, J. ve Eberhart, R., 1995. Particle swarm optimization. In Neural Networks, Proceedings., IEEE International Conference. 4, 1942-1948.
- Kittler, J. ve Illingworth J., 1986. Minimum error thresholding. Pattern Recognition. 19 (1), 41-47.
- Kleawsirikul, N., Gulati S. ve Uyyanonvara B., 2013. Automated retinal hemorrhage detection using morphological top hat and rule-based classification. In 3rd International Conference on Intelligent Computational Systems. 39-43.
- Klein, R, Klein B.E., Moss S.E., Davis M.D. ve DeMets D.L., 1984. The Wisconsin epidemiologic study of diabetic retinopathy. III. Prevalence and risk of diabetic retinopathy when age at diagnosis is 30 or more years. Arch Ophthalmol. 102, 527-532.
- Klein, R., Klein B.E., Moss S.E. ve Cruickshanks K.J., 1999. Association of ocular disease and mortality in a diabetic population. Arch Ophthalmol. 117 (11), 1487-95.
- Klein, R., Klein B.E., Moss S.E., Cruickshanks K.J., 1994. The Wisconsin epidemiologic study of diabetic retinopathy. XIV Ten-year incidence and progression of diabetic retinopathy. Arch Ophthalmol. 112 (9), 1217-28.
- Larsen, N., Godt J., Grunkin M., Lund-Andersen H. ve Larsen M., 2003. Automated detection of diabetic retinopathy in a fundus photographic screening population. Invest. Ophthalmol. Visual. 44 (2), 767-771.
- Latha, K. ve Durga S. G., 2014. Automatic detection of diabetic retinopathy by using evolutionary computation algorithm based on feature extraction. In Applied Mechanics and Materials. 573, 819-824.
- Li, H. ve Chutatape O., 2004. Automated feature extraction in color retinal images by a model based approach. IEEE Trans.Biomed.Eng. 51 (2), 246-254.
- Lukac, R., 2003. Adaptive vector median filtering. Pattern Recognition Letters. 24 (12), 1889-1899.
- Nayak, J., Bhat P., Acharya U.R., Lim C.M., Kagathi M., 2008. Automated identification of diabetic retinopathy stages using digital fundus images. J.Med.Syst. 32, 107-115.
- Nergiz, M., Arı Ş. ve Akın M., 2014. Yeni bir algoritma ile retina görüntülerinde optik disk yerinin tespiti. Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi, 4 (2), 109-120.

- Niemeijer, M., vanGinneken B., Russell S.R., Suttorp-Schulten M.S.A. ve Abramoff M.D., 2007. Automated detection and differentiation of drusen, exudates and cotton-wool spots in digital color fundus photographs for diabetic retinopathy diagnosis. *Invest. Ophthalmol. VisualSci.* 48 (5), 2260–2267.
- Niemeijer, M., vanGinneken B., Staal J., Suttorp-Schulten M.S.A. ve Abramoff M. D., 2005. Automatic detection of red lesions in digital color fundus photographs. *IEEE Trans. Med. Imaging.* 124 (5), 584–592.
- Noronha, K., Acharya U.R., Nayak K.P., Kamath S. ve Bhandary S.V., 2013. Decision support system for diabetic retinopathy using discrete wavelet transform. *Proc. Inst. Mech. Eng. HJ. Eng. Med.* 227 (3), 251–261.
- Oloumi, F., Rangayyan, R.M. ve Ells, A.L., 2014. Assessment of vessel tortuosity in retinal images of preterm infants. In *Engineering in Medicine and Biology Society. 36th Annual International Conference of the IEEE.* 5410-5413.
- Osareh, A., Shadgar B. ve Markham R., 2009. A computational-intelligence-based approach for detection of exudates in diabetic retinopathy images. *IEEE Trans. Inf. Technol. Biomed.* 13 (4), 535–545.
- Osuna, E.E., Freund, R. ve Girosi, F., 1997. Support vector machines: training and applications, Massachusetts Institute of Technology and Artificial Intelligence Laboratory. Massachusetts. Pal, M., Mather. 1602, 144.
- Otsu, N., 1979. A threshold selection method from gray level histograms. *IEEE Transactions on Systems, Man and Cybernetics.* 9 (1), 62-66.
- Özçetin, H., 2000. Pratik göz hastalıkları. 2nci Baskı, Bursa: F. Özsan Matbaacılık Ltd Şti. 111-2.
- Petkov, N. ve Wieling, M.B., 2004. Gabor filter augmented with surround inhibition for improved contour detection by texture suppression. Institute for Mathematics and Computing Science, University of Groningen Netherland.
- Philip, S., Fleming A.D., Goatman K.A., Fonseca S., Mcnamee P., Scotland G.S., Prescott G.J., Sharp P.F. ve Olson J.A., 2007. The efficacy of automated “disease/no disease” grading for diabetic retinopathy in a systematic screening programme. *Br.J. Ophthalmol.* 91 (11), 1512–1517.
- Polat, B. ve Batioğlu F., 2007. Diyabetik retinopatide güncel tıbbi tedavi yaklaşımları. *Ret-Vit.* 15, 153-159.
- Ponnibala, M. ve Vijayachitra S., 2014. A sequential learning method for detection and classification of exudates in retinal images to assess Diabetic Retinopathy. *Journal of Biological Systems.* 22 (03), 413-428.

- Press, W.H., Teukolsky, S.A., Vetterling, W.T. ve Flannery, B.P., 2007. Numerical recipes-the art of scientific computing. Cambridge University Press, New York. 139-142.
- Quelleg, G., Lamard M., Josselin P.M., Cazuguel G., Cochener B. ve Roux C., 2008. Optimal wavelet transform for the detection of microaneurysms in retina photographs. *IEEE Trans. Med. Imaging.* 27 (9), 1230–1241.
- Raja, S. S. ve Vasuki S., 2015. Screening diabetic retinopathy in developing countries using retinal images. *Applied Medical Informatics*, 36 (1), 13-22.
- Ridler, T.W. ve Calvard, S., 1978. Picture thresholding using an iterative selection method. *IEEE Transactions on Systems, Man, and Cybern.* 8 (8), 632-632.
- Rizon, M., Haniza, Y., Puteh, S., Yeon, A., Shakaff, M., Abdul Rahman, S. ve Karthigayan, M., 2005. Object detection using circular Hough transform.
- Romero R., Martínez-Carballido J., Hernández-Capistrán J. ve Uribe-Valencia L. J., 2015. A method to assist in the diagnosis of early diabetic retinopathy: Image processing applied to detection of microaneurysms in fundus images. *Computerized Medical Imaging and Graphics.* 44, 41-53.
- Rossant, F., Badellino, M., Chavillon, A., Bloch, I. ve Paques, M., 2011. A morphological approach for vessel segmentation in eye fundus images with quantitative evaluation. *Journal of Medical Imaging and Health Informatics.* 1 (1), 42-49.
- Sanchez, C.I., Garcia M., Mayo A., Lopez M.I. ve Hornero R., 2009. Retinal image analysis based on mixture models to detect hard exudates. *Med. Image Anal.* 13 (4), 650–658.
- Sanchez, C.I., Hornero R., Lopez M.I. ve Poza J., 2004. Retinal image analysis to detect and quantify lesions associated with diabetic retinopathy. in: *Engineering in Medicine and Biology Society, IEMBS'04. 26th Annual International Conference of the IEEE*, 1, 1624–1627.
- Sanchez, C.I., Hornero R., Lopez M.I., Aboy M., Poza J. ve Abasolo D., 2008. A novel automatic image processing algorithm for detection of hard exudates based on retinal image analysis. *Med. Eng. Phys.* 30 (3), 350–357.
- Satman, İ. ve TURDEP-I Çalışma Grubu. 2002. The TURDEP Group. Population based study of diabetes and risk characteristic in Turkey: Results of the Turkish diabetes epidemiology study (TURDEP). *Diabetes Care.* 25 (9), 1551-6.

- Satman, İ. ve TURDEP-II Çalışma Grubu. 2011. TURDEP-II sonuçları. Türk Endokronoloji ve Metabolizma Derneği [homepage on the Internet]. http://www.turkendokrin.org/files/file/TURDEP_II_2011.pdf (26.04.2017).
- Shivaram, J.M., Patil R. ve Anarind H.S., 2009. Automated detection and quantification of hemorrhages in diabetic retinopathy images using image arithmetic and morphological methods. *Recent Trends Eng.* 2 (6), 174-176.
- Sinthanayothin, C., Boyce J.F., Cook H.L. ve Williamson T.H., 1999. Automated localisation of the optic disc, fovea, and retinal blood vessels from digital colour fundus images. *Br.J.Ophthalmol.* 83 (8), 902–910.
- Sinthanayothin, C., Kongbunkiat V., Phoojaruenchanachai S. ve Singalavanija A., 2003. Automated screening system for diabetic retinopathy. in: *Proceedings of the 3rd International Symposium on Image and Signal Processing and Analysis, ISPA2003.* 2, 915–920.
- Soares, J.V., Leandro, J.J., Cesar, R.M., Jelinek, H.F. ve Cree, M.J., 2006. Retinal vessel segmentation using the 2-D Gabor, wavelet and supervised classification. *IEEE Transactions on medical Imaging.* 25 (9), 1214-1222.
- Sophorak, A., Thet New K., Aye Moe Y.N., Dailey M. ve Uyyanonvara B., 2008. Automatic exudate detection with a naive Bayes classifier. in: *International Conference on Embedded Systems and Intelligent Technology.* 139–142.
- Sophorak, A., Uyyanonvara B. ve Barman S., 2013. Simple hybrid method for fine microaneurysm detection from non-dilated diabetic retinopathy retinal images. *Computerized Medical Imaging and Graphics.* 37 (5), 394-402.
- Sophorak, A., Uyyanonvara B., Barman S. ve Williamson T.H., 2008. Automatic detection of diabetic retinopathy exudates from nondilated retinal images using mathematical morphology methods. *Comput. Med. Imaging Graphics.* 32 (8), 720–727.
- Spencer, T., Olson J.A., McHardy K.C., Sharp P.F. ve Forrester J.V., 1996. An image processing strategy for the segmentation and quantification of microaneurysms in fluorescein angiograms of the ocular fundus. *Comput. Biomed. Res.* 29 (4), 284–302.
- Staal, J.J., Abramoff M.D., Niemeijer M., Viergever M.A. ve Van Ginneken B., 2004. Ridge based vessel segmentation in color images of the retina. *IEEE Transactions on Medical Imaging.* 23, 501-509.
- Streeter, L. ve Cree M.J., 2003. Microaneurysm detection in colour fundus images. *Image Vision Comput. NewZealand.* 280–284.

- Sural, S., Qian G. ve Pramanik S., 2002. Segmentation and histogram generation using the HSV color space for image retrieval. in Proceedings of IEEE International Conference on Image Processing. 589-592.
- Taşkın, D., 2007. Sıkıştırılmış video akımının düzensiz haritalar ve başlangıç kodlarına dayalı şifrelenmesi. (Doktora Tezi) Trakya Üniversitesi Fen Bilimleri Enstitüsü, Edirne.
- Telcioğlu, T., 2007. Veri madenciliğinde genetik programlama temelli yeni bir sınıflandırma yaklaşımı ve uygulaması.
- Teo, C. K., 2003. Digital enhancement of night vision and thermal images (Doctoral dissertation, Monterey, California. Naval Postgraduate School).
- Tjandrasa, H., Ariesanti I. ve Anggoro R., 2015. Classification of non-proliferative diabetic retinopathy based on segmented exudates using k-means clustering. International Journal of Image, Graphics and Signal Processing. 7 (1), 1.
- Treigys, P., Šaltenis V., Dzemyda G., Barzdžiukas V. ve Paunksnis A., 2008. Automated optic nerve disc parameterization. Informatica1. 9 (3), 403–420.
- Tunç, M., 2010. Proliferatif diyabetik retinopatide medikal tedavi. Ret-Vit. 18, 66-70
- Vapnik, V., Chappelle, O. ve Guyon, I., 2000. Bounds on error expectation for support vector machines. Neural computation. 12 (9), 2013-2036.
- Vapnik, V., Guyon, I. ve Hastie, T. 1995. Support vector machines. Machine learning, 20, 273-297.
- Walter, T. ve Klein J.C., 1999. Segmentation of color fundus images of the human retina: detection of the optic disc and the vascular tree using morphological techniques. in: J. Crespo, V. Maojo, F. Martin (Eds.), Springer, Berlin, Heidelberg.
- Walter, T., Klein J.C., Massin P. ve Erginay A., 2002. A contribution of image processing to the diagnosis of diabetic retinopathy detection of exudates in color fundus images of the human retina. IEEE Trans. Med. Imaging. 21 (10), 1236–1243.
- Walter, T., Massin P., Erginay A., Ordonez R., Jeulin C. ve Klein J.C., 2007. Automatic detection of microaneurysms in color fundus images. Med. Image Anal. 11 (6), 555–566.
- Wang, D., Haese-Coat, V. ve Ronsin, J., 1995. Shape decomposition and representation using a recursive morphological operation. Pattern Recognition. 28 (11), 1783-1792.

- Welfer, D., Scharcanski J. ve Marinho D.R., 2010. A coarse-to-fine strategy for automatically detecting exudates in color eye fundus images. *Comput.Med. Imaging Graphics*. 34 (3), 228–235.
- Welikala, R. A., Fraz M. M., Dehmeshki J., Hoppe A., Tah V., Mann S. ve Barman S. A., 2015. Genetic algorithm based feature selection combined with dual classification for the automated detection of proliferative diabetic retinopathy. *Computerized Medical Imaging and Graphics*. 43, 64-77.
- Wu, S.W., 2006. U.S. Patent No. D521,872. Washington, DC: U.S. Patent and Trademark Office.
- Yang, X.S., 2008. Firefly Algorithm (chapter 8). *Nature-inspired metaheuristic algorithms*. Luniver Press.
- Yasuda, Y., Dubois, M. ve Huang, T.S., 1980. Data compression for check processing machines. *Proceeding of IEEE*. 68 (7), 874-885.
- Yau, J.W., Rogers S.L., Kawasaki R., 2012. Global prevalence and major risk factors of diabetic retinopathy. *Diabetes Care*. 35 (3), 556-64.
- Yavuz, Z. ve Kose, C., 2015. Vessel segmentation in retinal images using multiscale image enhancement and clustering. In *Signal Processing and Communications Applications Conference (SIU)*, 581-584.
- Yılmaz, İ., 2007. Renk sistemleri, renk uzayları ve dönüşümler. Selçuk Üniversitesi Jeodezi ve Fotogrametri Mühendisliği Öğretiminde 30. Yıl Sempozyumu, Sunulmuş Bildiri.
- Yılmaz, İ., Güllü M., Baybura T. ve Erdoğan A.O., 2002. Renk uzayları ve renk dönüşüm programı (RDP). *Afyon Kocatepe Üniversitesi Fen Bilimleri Dergisi*. 2 (2), 19-35.
- Yu, S., Xiao D. ve Kanagasingam Y., 2016. Automatic detection of neovascularization on optic disk region with feature extraction and support vector machine. In *Engineering in Medicine and Biology Society (EMBC), IEEE 38th Annual International Conference*. 1324-1327.
- Yun, W.L., Acharya U.R., Venkatesh Y.V., Chee C., Min L.C. ve Ng E.Y.K., 2008. Identification of different stages of diabetic retinopathy using retinal optical images. *Inf. Sci*. 178 (1), 106–121.
- Zeljковиć, V., Bojic M., Zhao S., Tameze C. ve Valev V., 2015. Exudates and optic disk detection in retinal images of diabetic patients. *Concurrency and Computation: Practice and Experience*, 27 (1), 172-192.

- Zhang, X. ve Fan G., 2006. Retinal spot lesion detection using adaptive multiscale morphological processing. In Advances in Visual Computing. 490-501.
- Zhang, X., Thibault G., Decenciere E., Marcotegui B., Laÿ B., Danno R. ve Chabouis A., 2014. Exudate detection in color retinal images for mass screening of diabetic retinopathy. Medical image analysis, 18 (7), 1026-1043.



EKLER

Etik Kurul Raporu

KLİNİK ARAŞTIRMALAR ETİK KURULU KARAR FORMU

ARAŞTIRMANIN AÇIK ADI	Görüntü İşleme Yöntemleri Kullanarak Diyabetik Retinopati Hastalığının Teşhisi ve Sınıflandırılması
VARSA ARAŞTIRMANIN PROTOKOL KODU	

ETİK KURUL BİLGİLERİ	ETİK KURULUN ADI	Cumhuriyet Üniversitesi Klinik Araştırmalar Etik Kurulu
	AÇIK ADRESİ:	Cumhuriyet Üniversitesi Eğitim ve Araştırma Hastanesi, Tıp Fakültesi Ek Derslik Binası (Acil Karşısı), Klinik Araştırmalar Etik Kurulu TR-58140 Merkez/Sivas
	TELEFON	0 346 258 00 25
	FAKS	0 346 258 00 24
	E-POSTA	cuetikkurul@gmail.com

BAŞVURU BİLGİLERİ

KOORDİNATÖR/SORUMLU ARAŞTIRMACI UNVANI/ADI/SOYADI	Doç. Dr. Mahmut Hekim			
KOORDİNATÖR/SORUMLU ARAŞTIRMACININ UZMANLIK ALANI	Elektrik Elektronik Mühendisliği			
KOORDİNATÖR/SORUMLU ARAŞTIRMACININ BULUNDUĞU MERKEZ	Gaziosmanpaşa Üniversitesi Elektrik Elektronik Mühendisliği Bölümü			
VARSA İDARİ SORUMLU UNVANI/ADI/SOYADI	--			
DESTEKLEYİCİ	--			
PROJE YÜRÜTÜCÜSÜ UNVANI/ADI/SOYADI (TÜBİTAK vb. gibi kaynaklardan destek alanlar için)	--			
DESTEKLEYİCİNİN YASAL TEMSİLCİSİ	--			
ARAŞTIRMANIN FAZİ VE TÜRÜ	FAZ 1	☐		
	FAZ 2	☐		
	FAZ 3	☐		
	FAZ 4	☐		
	Gözlemsel ilaç çalışması	☐		
	Tıbbi cihaz klinik araştırması	☐		
	İn vitro tıbbi tanı cihazları ile yapılan performans değerlendirme çalışmaları	☐		
	İlaç dışı klinik araştırma	☒		
	Diğer ise belirtiniz:			
ARAŞTIRMAYA KATILAN MERKEZLER	TEK MERKEZ ☒	ÇOK MERKEZLİ ☐	ULUSAL ☐	ULUSLARARASI ☐

Etik Kurul Başkanının
Unvanı/Adı/Soyadı: Prof. Dr. Emin Yener Gültekin
İmza:

Not: Etik kurul başkanı, imzasının yer almadığı her sayfaya imza atmalıdır.

KLİNİK ARAŞTIRMALAR ETİK KURULU KARAR FORMU

ARAŞTIRMANIN AÇIK ADI	Görüntü İşleme Yöntemleri Kullanarak Diyabetik Retinopati Hastalığının Teşhisi ve Sınıflandırılması
VARSA ARAŞTIRMANIN PROTOKOL KODU	

DEĞERLENDİRİLEN BELGELER	Belge Adı	Tarihi	Versiyon Numarası	Dili		
	ARAŞTIRMA PROTOKOLÜ			Türkçe ☒	İngilizce ☐	Diğer ☐
	BİLGİLENDİRİLMİŞ GÖNÜLLÜ OLUR FORMU			Türkçe ☒	İngilizce ☐	Diğer ☐
	OLGU RAPOR FORMU			Türkçe ☐	İngilizce ☐	Diğer ☐
	ARAŞTIRMA BROŞÜRÜ			Türkçe ☐	İngilizce ☐	Diğer ☐
DEĞERLENDİRİLEN DİĞER BELGELER	Belge Adı		Açıklama			
	SİGORTA	☐				
	ARAŞTIRMA BÜTÇESİ	☐				
	BIYOLOJİK MATERYEL TRANSFER FORMU	☐				
	İLAN	☐				
	YILLIK BİLDİRİM	☐				
	SONUÇ RAPORU	☐				
	GÜVENLİLİK BİLDİRİMLERİ	☐				
	DİĞER:	☐				
KARAR BİLGİLERİ	Karar No: 2016-09/13	Tarih: 27.09.2016				
	Yukarıda bilgileri verilen başvuru dosyası ile ilgili belgeler araştırmanın/çalışmanın gerekçe, amaç, yaklaşım ve yöntemleri dikkate alınarak incelenmiş ve uygun bulunmuş olup araştırmanın/çalışmanın başvuru dosyasında belirtilen merkezlerde gerçekleştirilmesinde etik ve bilimsel sakınca bulunmadığına toplantıya katılan etik kurul üye tam sayısının salt çoğunluğu ile karar verilmiştir.					
İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik kapsamında yer alan araştırmalar/çalışmalar için Türkiye İlaç ve Tıbbi Cihaz Kurumu'ndan izin alınması gerekmektedir.						

KLİNİK ARAŞTIRMALAR ETİK KURULU	
ETİK KURULUN ÇALIŞMA ESASI	İlaç ve Biyolojik Ürünlerin Klinik Araştırmaları Hakkında Yönetmelik, İyi Klinik Uygulamaları Kılavuzu
BAŞKANIN UNVANI / ADI / SOYADI:	Prof. Dr. Emin Yener Gültekin


Unvanı/Adı/Soyadı	Uzmanlık Alanı	Kurumu	Cinsiyet	Araştırma ile ilişki	Katılım *	İmza
Prof. Dr. Emin Yener Gültekin	Üroloji	Cumhuriyet Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Prof. Dr. Kürşat Karadayı	Genel Cerrahi	Cumhuriyet Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Prof. Dr. Hülya Tokar	Periodontoloji	Cumhuriyet Üniversitesi	E ☐ K ☒	E ☐ H ☒	E ☒ H ☐	
Doç. Dr. Ayşe Demirkazık	Biyofizik	Cumhuriyet Üniversitesi	E ☐ K ☒	E ☐ H ☒	E ☒ H ☐	
Doç. Dr. Aynur Engin	Enfeksiyon Hastalıkları	Cumhuriyet Üniversitesi	E ☐ K ☒	E ☐ H ☒	E ☒ H ☐	
Doç. Dr. Fatih Bolat	Çocuk Sağlığı ve Hastalıkları	Cumhuriyet Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Doç. Dr. Gülay Yıldırım	Tıp Tarihi ve Etik	Cumhuriyet Üniversitesi	E ☐ K ☒	E ☐ H ☒	E ☒ H ☐	
Doç. Dr. Ali Şahin	Romatoloji	Cumhuriyet Üniversitesi	E ☒ K ☐	E ☐ H ☒	E ☒ H ☐	
Yrd. Doç. Dr. Ziyet Çınar	Biyoistatistik	Cumhuriyet Üniversitesi	E ☐ K ☒	E ☐ H ☒	E ☒ H ☐	

Etik Kurul Başkanının
Unvanı/Adı/Soyadı: Prof. Dr. Emin Yener Gültekin
İmza:

Not: Etik kurul başkanı, imzasının yer almadığı her sayfaya imza atmalıdır.

KLİNİK ARAŞTIRMALAR ETİK KURULU KARAR FORMU

ARAŞTIRMANIN AÇIK ADI	Görüntü İşleme Yöntemleri Kullanarak Diyabetik Retinopati Hastalığının Teşhisi ve Sınıflandırılması
VARSA ARAŞTIRMANIN PROTOKOL KODU	

Yrd. Doç. Dr. Ahmet Altun	Tıbbi Farmakoloji	Cumhuriyet Üniversitesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Uzm. Dr. Levent Sağlam	Aile Hekimi	Sivas Halk Sağlığı Müdürlüğü	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Uzm. Dr. Hüseyin Saygın	Üroloji	Sivas Numune Hastanesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Öğr. Gör. Engin Daşlı	Avukat	Cumhuriyet Üniversitesi	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	
Öğret. Melih Arslan	Sınıf Öğretmeni	Emekli	E ☒	K ☐	E ☐	H ☒	E ☒	H ☐	

*:Toplantıda Bulunma

Etik Kurul Başkanının
Unvanı/Adı/Soyadı: Prof. Dr. Emin Yener Gültekin
İmza:



Not: Etik kurul başkanı, imzasının yer almadığı her sayfaya imza atmalıdır.

ÖZGEÇMİŞ

Kişisel Bilgiler

Adı Soyadı : Kemal ADEM
Doğum Tarihi ve Yeri : 15.07.1987 - MALATYA
Medeni Hali : Evli
Yabancı Dili : İngilizce
Telefon : 533 4959916
e-mail : kemal.adem@gop.edu.tr

Eğitim

Derece	Eğitim Birimi	Mezuniyet Tarihi
Yüksek Lisans	Gaziosmanpaşa Üni. Mekatronik Müh.	2013
Lisans	Fırat Üniversitesi, Bilgisayar Müh.	2008
Lise	Malatya Lisesi, Malatya	2004

İş Deneyimi

Yıl	Yer	Görev
2011-Devam e.	Gaziosmanpaşa Üni. Enformatik Bölümü Tokat	Öğretim Görevlisi
2009-2011	Harran Üni. Bilgi İşlem Dairesi Şanlıurfa	Bilgisayar Mühendisi

Yayınlar

Adem, K., Orhan, U. ve Hekim, M. (2015). Image processing based quality control of the impermeable seams in multilayered aseptic packages. *Expert Systems with Applications*, 42(7), 3785-3789.

Adem K., Hekim, M., Cömert, O. ve Demir, S. (2016). A Novel Approach to Method for the Detection of Optic Disc Location in Retinal Images using Image Processing Techniques. *Journal of New Results in Science*, 5(12).

Adem K., Hekim, M. ve Demir, S. (2016). Retina Görüntülerinde Görüntü İşleme Yöntemleri Kullanılarak Optik Disk Yerinin Tespiti. *Elektrik Elektronik Bilgisayar Sempozyumu. TOKAT.*

Adem K., Hekim, M. ve Cömert, O. (2016). Görüntü İşleme Yöntemleri Kullanılarak Retina Görüntülerinde Kan Damarlarının Bölütlenmesi. *International Academic Research Congress. ANTALYA.*