T.C.
ERCİYES ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

SEZGİSEL ALGORİTMALAR İLE BİYOMEDİKAL GÖRÜNTÜ ANALİZİ

(Yüksek Lisans Tezi)

Hazırlayan
Hakan DURAN

Danışman
Yrd. Doç. Dr. Mehmet Bahadır ÇETİNKAYA

Ocak 2018
KAYSERİ

BİLİMSEL ETİĞE UYGUNLUK

Bu çalışmadaki tüm bilgilerin, akademik ve etik kurallara uygun bir şekilde elde edildiğini beyan ederim. Aynı zamanda bu kural ve davranışların gerektirdiği gibi, bu çalışmanın özünde olmayan tüm materyal ve sonuçları tam olarak aktardığımı ve referans gösterdiğimi belirtirim.

Hakan DURAN



YÖNERGEYE UYGUNLUK

Sezgisel Algoritmalar ile Biyomedikal Görüntü Analizi adlı Yüksek Lisans tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi'ne uygun olarak hazırlanmıştır.

Tezi Hazırlayan

Hakan DURAN

Danışman

Yrd. Doç. Dr. Mehmet Bahadır ÇETİNKAYA

Mekatronik Mühendisliği ABD Başkanı

Prof. Dr. Şahin YILDIRIM

Yrd. Doç. Dr. Mehmet Bahadır ÇETİNKAYA danışmanlığında **Hakan DURAN** tarafından hazırlanan **" Sezgisel Algoritmalar ile Biyomedikal Görüntü Analizi "** adlı bu çalışma, jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Mühendisliği Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

03 /01/2018

JÜRİ:

Başkan : Yrd. Doç. Dr. Mehmet Bahadır ÇETİNKAYA

Üye : Prof. Dr. Şahin YILDIRIM

Üye : Doç. Dr. Serhan YAMAÇLI

ONAY:
Bu tezin kabulü Enstitü Yönetim Kurulunun 09/01/2018 tarih ve 2018/02-04 sayılı kararı ile onaylanmıştır.

09/01/2018

Prof. Dr. Mehmet AKKURT

Enstitü Müdürü

TEŞEKKÜR

Yüksek Lisans eğitimime başladığım ilk günden beri bana her konuda destek olan ve yol gösteren, tez konumun seçiminde, uygulanıp sonuca kavuşturulmasında ve tezin yazımı boyunca ilgi ve yardımlarını hiçbir zaman esirgemeyen, pozitifliği ve olaylara farklı bakış açısı ile büyük katkı sahibi sayın hocam Yrd. Doç. Dr. Mehmet Bahadır ÇETİNKAYA'ya en içten teşekkürlerimi sunarım.

Tezin yönlendirilmesinde katkılarını esirgemeyen değerli hocam Op. Dr. Mehmet Celalettin CİHAN ve yüksek lisans tezime vermiş olduğu katkılardan dolayı Hüseyin Emre CIKIT'e teşekkürlerimi sunarım.

Ayrıca; tüm eğitim hayatım süresince benim yanımda olan, hem maddi hem manevi olarak beni daima destekleyen değerli aileme en içten duygularımla teşekkür ederim.

Hakan DURAN

Kayseri, Ocak 2018

SEZGİSEL ALGORİTMALAR İLE BİYOMEDİKAL GÖRÜNTÜ ANALİZİ

Hakan DURAN

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü

Yüksek Lisans Tezi, Ocak 2018

Danışman: Yrd. Doç. Dr. Mehmet Bahadır Çetinkaya

ÖZET

Tıbbi hastalıklara teşhis konulması ve bu hastalıkların tedavi edilmesi süresince bilgisayarlı görüntüleme ve analiz teknikleri yaygın bir şekilde kullanılmaktadır. Bilgisayar tabanlı analiz yöntemleri ile özellikle retinal hastalıklar başarılı bir şekilde tespit edilerek tedavi edilebilmektedir. Retinal hastalıkların bir sonucu olarak kılcal damarlarda meydana gelen daralma, genişleme ve kanamalar hastalık hakkında bilgiler vermektedir. Bu nedenle, retinal görüntülerde yapısal değişimlerin yüksek doğrulukta tespit edilebilmesi hastalığın teşhis ve tedavisi açısından son derece önemlidir.

Bu tez çalışmasında ilk olarak damar bölütleme uygulaması ile kılcal damarların tespiti ve analizi gerçekleştirilmiştir. Daha sonra diyabet hastalığından kaynaklı ortaya çıkan yeni kanamalı bölgelerin tespit edilerek belirginleştirilmesi ve piksel tabanlı alan hesaplamalarının yapılmasına yönelik yaklaşımlar geliştirilmiştir. Retinal görüntü analizleri K-means, yapay arı koloni (artificial bee colony, ABC) ve parçacık sürüsü optimizasyon (particle swarm optimisation, PSO) algoritmaları kullanılarak gerçekleştirilmiştir. Benzetim sonuçları incelendiğinde, klasik yaklaşımlardan olan K-means algoritması ile kümeleme tabanlı sezgisel ABC ve PSO algoritmalarının retinal görüntü analizinde başarılı bir şekilde kullanılabileceği görülmüştür.

Anahtar Kelimeler: Retinal görüntü analizi, kümeleme, K-means algoritması, yapay arı koloni algoritması, parçacık sürüsü optimizasyon algoritması.

BIOMEDICAL IMAGE ANALYSIS BY USING HEURISTIC ALGORITHMS

Hakan DURAN

Erciyes University, Graduate School of Natural and Applied Sciences

M.Sc. Thesis, January 2018

Supervisor: Assist. Prof. Dr. Mehmet Bahadır ÇETİNKAYA

ABSTRACT

Computer based imaging and analysis techniques are frequently used for the diagnosis and treatment of medical diseases. Especially retinal diseases can successfully be detected and treated by using computer based analysis methods. Arteriolar stenosis, arteriolar dilatation and vascular bleeding due to retinal diseases give important information about the disease. Therefore, to detect structural changes in retinal images with high accuracy is extremely important for diagnosis and treatment of the disease.

In this thesis, firstly, the detection and analysis of retinal blood vessels is realized with vessel segmentation. Then, approaches have been improved for the aims of identification, clarification and pixel based area calculation of the new hemorrhagic regions arising from diabetes mellitus. Retinal image analyses are realized by using K-means, artificial bee colony (ABC) and particle swarm optimization (PSO) algorithms. From the simulation results it is observed that both the K-means algorithm which is one of the classical approaches and the clustering based heuristic ABC and PSO algorithms can successfully be used in retinal image analysis.

Keywords: Retinal image analysis, clustering, K-means algorithm, artificial bee colony algorithm, particle swarm optimization algorithm.

İÇİNDEKİLER

SEZGİSEL ALGORİTMALAR İLE BİYOMEDİKAL GÖRÜNTÜ ANALİZİ

Sayfa

BİLİMSEL ETİĞE UYGUNLUK i
YÖNERGEYE UYGUNLUK ii
ONAY iii
TEŞEKKÜR iv
ÖZET v
ABSTRACT vi
İÇİNDEKİLER vii
KISALTMA VE SİMGELER viii
TABLOLAR LİSTESİ ix
ŞEKİLLER LİSTESİ x

1. BÖLÜM

GİRİŞ

1.1. Göz Anatomisi 1
1.2. Retinal Yapı 2
1.3. Retinal Görüntülerde Damar Tespiti 3
1.4. Diyabetik Retinopati 4
1.4.1. Fundus Floresein Anjiografi (FFA) 6

2. BÖLÜM

RENK UZAYLARI VE KÜMELEME YÖNTEMİ

2.1. Renk Uzayları 9

2.1.1. RGB Renk Uzayı 10
2.1.2. CIE Lab Renk Uzayı 13
2.1.3. Gri Seviyeli Görüntü 15
2.1.4. İkili Görüntü 15
2.2. Görüntü Zenginleştirme Yaklaşımları 16
2.2.1. Top- hat ve Bottom-hat Dönüşümleri 16
2.2.2. Morfolojik İşlemler 17
2.2.2.1. Açma ve Kapama Morfoloji Operatörleri 18
2.2.3. Kontrast Zenginleştirme 20
2.3. Kümeleme Yöntemi 20
2.3.1. K-means Kümeleme Yöntemi 21

3. BÖLÜM
SEZGİSEL ALGORİTMALARA DAYALI KÜMELEME

3.1. Yapay Arı Koloni Algoritması 23
3.2. Parçacık Sürüsü Optimizasyon Algoritması 27

4. BÖLÜM
BENZETİMLER VE SONUÇLAR

4.1. Retinal Görüntülerde Kılcal Damarların Tespiti 31
4.2. DR Hastalıklı Retinal Görüntülerde Kanamalı Bölgelerin Tespiti 37

5. BÖLÜM
SONUÇ VE DEĞERLENDİRME

KAYNAKLAR 46
ÖZGEÇMİŞ 52

KISALTMALAR VE SİMGELER

Sembol	Anlamı	Birimi
DR	Diyabetik Retinopati	
FFA	Fundus Floresein Anjiografi	
SVM	Support Vector Machine	
FCM	Fuzzy C-means	
ABC	Yapay Arı Koloni (Artificial bee colony)	
PSO	Parçacık Sürü Optimizasyonu (Particle Swarm Optimization)	
3D	3Dimensional	
RGB	Kırmızı-Yeşil-Mavi (Red-Green-Blue)	
HSV	Hue Saturation Value	
HSI	Hue Saturation Intensity	
CMY	Cyan Magenta Yellow	
CMYK	Cyan Magenta Yellow Key	
CIE	Commission Internationale de l'Eclairage	
SSE	Karesel Hataların Toplamı (Sum of Squares Error)	
HRF	High Resolation Fundus	
MSE	Ortalama Karesel Hata (Mean Square Error)	

TABLOLAR LİSTESİ

Tablo 2.1. RGB Uzayında köşegen noktaların oluşturduğu renk değerleri …….… 11
Tablo 4.1. Algoritmalara ait parametre değerleri …….…...…… 31

ŞEKİLLER LİSTESİ

Şekil 1.1. Göz yapısı ……..... 2

Şekil 1.2. Retinal görüntü ve retinanın temel bölümleri ……..... 3

Şekil 1.3. (a) Sağlıklı retina, (b) Diyabetik retinopati hastalıklı retina …..……..…. 6

Şekil 1.4. Fundus görüntüleri için kullanılan sayısal görüntüleme cihazı ……. 7

Şekil 2.1. RGB renk küpü ……..... 10

Şekil 2.2. RGB Renk Uzayı Köşegen Noktalardaki Renk Karşılıkları ……... 11

Şekil 2.3. RGB Uzayında Renk Oluşumu ……... 11

Şekil 2.4. RGB renk uzayında örnek bir görüntü ……..... 12

Şekil 2.5. RGB renk uzayının katmanları ve bu katmanlara ait görüntülerin histogram grafikleri: (a) R katmanına ait görüntü ve histogramı, (b) G katmanına ait görüntü ve histogramı, (c) B katmanına ait görüntü ve histogramı ……. 12

Şekil 2.6. CIE Lab uzayında renklerin oluşumu ……..… 13

Şekil 2.7. Lab renk uzayında örnek bir görüntü …….. 13

Şekil 2.8. Lab renk uzayının katmanları ve bu katmanlara ait görüntülerin histogram grafikleri: (a) L katmanına ait görüntü ve histogramı, (b) a katmanına ait görüntü ve histogramı, (c) b katmanına ait görüntü ve histogramı ……..… 14

Şekil 2.9. Örnek bir gri seviyeli görüntü ve histogram grafiği …… 15

Şekil 2.10. Örnek bir ikili görüntü ……. 15

Şekil 2.11. Top-hat dönüşümünden önce ve sonra elde edilen görüntüler ……...…. 17

Şekil 2.12. Bottom-Hat Dönüşümünden Önce ve Sonra Görüntü ……. 17

Şekil 2.13. Morfolojik yapı elemanı örnekleri …….. 18

Şekil 2.14. (a) İkili görüntü (b) Açma operatörü uygulanması sonucunda oluşan görüntü ……...…….. 19

Şekil 2.15. (a) İkili görüntü (b) Kapama operatörü sonucunda oluşan görüntü …… 19

Şekil 2.16. Temel kontrast ayarlama işlemi ……..…. 20

Şekil 3.1. ABC algoritmasının akış diyagramı ……...…. 24

Şekil 4.1. Retinal kan damarlarının tespitine yönelik kullanılan görüntüler ……... 30

Şekil 4.2. Kanamalı bölgelerin tespitine yönelik kullanılan görüntüler …….. 30

Şekil 4.3. Retinal görüntülere 4.2 eşitliği ile tanımlanan görüntü zenginleştirme işlemi uygulandıktan sonra elde edilen yeni görüntüler ……..…… 32

Şekil 4.4. Şekil 4.3 (a) ve (b)'de verilmiş olan retinal görüntülerin R, G, ve B katmanları ……...…. 33

Şekil 4.5. Görüntü zenginleştirme işlemleri sonrasında elde edilen ve kümeleme işlemi uygulanacak olan retinal görüntüler ..…… 34
Şekil 4.6. Kümeleme tabanlı K-means, ABC ve PSO algoritmaları ile retinal kılcal damar tespiti sonucunda elde edilen ikili görüntüler ……...… 35
Şekil 4.7. Şekil 4.1 (a) ve (b) ile verilen retinal görüntüler için kılcal damar tespitinde kullanılan kümeleme tabanlı ABC ve PSO algoritmalarının yakınsama grafikleri ……..……..… 37
Şekil 4.8. Görüntü zenginleştirme işlemleri sonucunda elde edilen retinal görüntüler ...…….. 38
Şekil 4.9. Şekil 4.8 ile verilen retinal görüntülerin CIE Lab renk uzayındaki karşılıkları ve katmanları …..……... 39
Şekil 4.10. Kümeleme tabanlı K-means, ABC ve PSO algoritmaları ile retinal görüntülerde kanamalı bölgelerin tespiti sonucunda elde edilen ikili görüntüler ……. 40
Şekil 4.11. Hastalıklı bölgeleri tespit edilmiş ve çizdirilmiş retinal görüntüler …….... 41
Şekil 4.12. Şekil 4.2 (a) ve (b) ile verilen retinal görüntülerde kanamalı bölgelerin tespiti için kullanılan kümeleme tabanlı ABC ve PSO algoritmalarının yakınsama grafikleri …… 42

1. BÖLÜM

GİRİŞ

1.1. Göz Anatomisi

Görme fonksiyonu sayesinde beyin ile dış çevre arasında bilgi iletişimi kurulmakta ve dış çevreden elde edilen veriler beyne iletilmektedir. Görüntüler, gözün ön kısmında bulunan mercek yapı sayesinde arka kısımdaki ışığa duyarlı retina tabakasına (ağ tabaka) aktarılır. Retina tabakasına aktarılan görüntüler sinir hücreleri tarafından beyindeki görme merkezine iletilir ve böylece görüntü algılama işlemi gerçekleşmiş olur.

Göz anatomisi incelendiğinde gözün sert tabakaolarak adlandırılan bir tabaka ile çevrelendiği görülmektedir. Sert tabakanın gözün ön kısmında bulunan saydam bölgesi *kornea* tabakası olarak adlandırılır. Kornea'nın arkasında göz bebeği denilen açıklık ve buaçıklığı çevreleyen *iris* tabakası yer alır. İris tabakasını kontrol eden göz kasları kornea tabakasından gelen ışığın şiddetine göre göz bebeğinin genişliğini değiştirir. Işık iris tabakasının arkasında bulunan göz merceğinden geçerek arka kısmındaki retina tabakasına ulaşır. Net bir görme işlevi, göz merceğinin şişkinliğini azaltıp artırarak odaklama işlemini en uygun şekilde yapması ile gerçekleşir.

Retina tabakası *chroid* olarak adlandırılan damar tabakası tarafından beslenir. Chroid tabakası rod hücreler ve koni hücreler olmak üzere iki hücre tipini içermektedir. Rod hücreler ışığı algılarken, koni hücreler rengi algılarlar. Rod ve koni hücrelerinin ışık enerjisini elektriksel enerjiye dönüştürmesi sonucunda sinir uçları uyarılmakta ve birleşmektedir. Optik sinirler olarak tanımlanan bu yapı sayesinde elektriksel uyarılar beyindeki görme merkezine ulaşır ve böylece görünen cisim algılanmış olur.

Göz merceğinin karşısında çukur bir yapıya sahip *fovea* tabakası bulunmaktadır. Fovea tabakası hem yoğun bir koni hücre popülasyonu hem de sarı leke (makula lutea) olarak adlandırılan ve merkezi görmeyi sağlayan bölgeyi içermektedir. Bu bölge aynı zamanda görüntü kalitesini de belirlemektedir.

Gözün anatomik yapısının sağladığı bir diğer önemli özellik ise üç boyutlu görmedir. Görme alanının sağ yanı beynin sol yarı küresinde, sol yanı ise sağ beyin yarı küresinde gerçekleşmektedir. Bunun bir sonucu olarak iki göz aynı yönde aynı cisme baksa bile farklı görüş açıları ortaya çıkar. Bu ise görme fonksiyonuna bir derinlik katar ve böylece üç boyutlu görme meydana gelmiş olur [1,2].

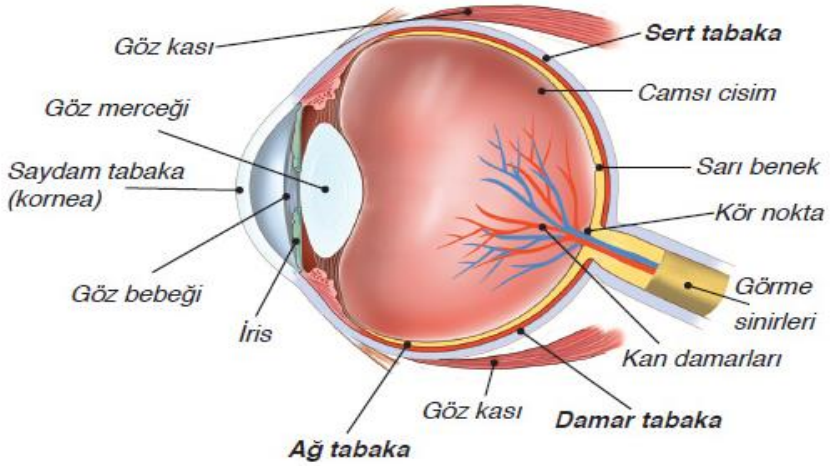

Şekil 1.1. Göz yapısı

1.2. Retinal Yapı

İnsan gözü üç temel tabaka olan sert tabaka, damar tabaka ve retina tabakasından oluşmaktadır. Gözün dış kısmında bulunan beyaz renkli bölüm olan sert tabakanın görevi gözü dış etkilerden korumaktır. Sert tabaka ayrıca ışığı kırma özelliğine de sahiptir. Damar tabaka ise gözü besleyen kılcal damarların (kan damarlarının) bulunduğu tabakadır ve sert tabakanın altında yer alır. Retina tabakası renkli görmenin gerçekleştiği, ışığa ve renge duyarlı hücrelerin bulunduğu, göz küresinin en iç kısmını kaplayan ve görme işlemini gerçekleştiren sinirsel tabakadır. Retina tabakasında bulunan makula bölgesi keskin görüntü oluşmasını sağlayan ışığa ve renge duyarlı hücrelerden meydana gelir. Retina tabakası ayrıca görüntüyü beyne ileten ve görme hücrelerinden oluşan görme sinirlerini (optik sinirler) içerir. Retina tabakasının

arkasında kör nokta (optik disk) olarak adlandırılan bir bölge mevcuttur. Kör nokta ışığı algılayan fotoreseptör hücrelerini içermediği için bu bölgeye düşen ışık algılanamamaktadır. Genelde sarımsı renkte olan kör nokta yuvarlak ya da elips biçimindedir ve retinal görüntülerdeki en parlak bölümdür. Kör nokta ayrıca kılcal damarların ve görme sinirlerinin retinaya girdiği bölgedir. Retina tabakasının yapısı bozulur veya zarar görürse görme fonksiyonunda eksiklikler ortaya çıkar. Şekil 1.2'de örnek bir retinal görüntü ve retinanın temel bölümleri gösterilmiştir.

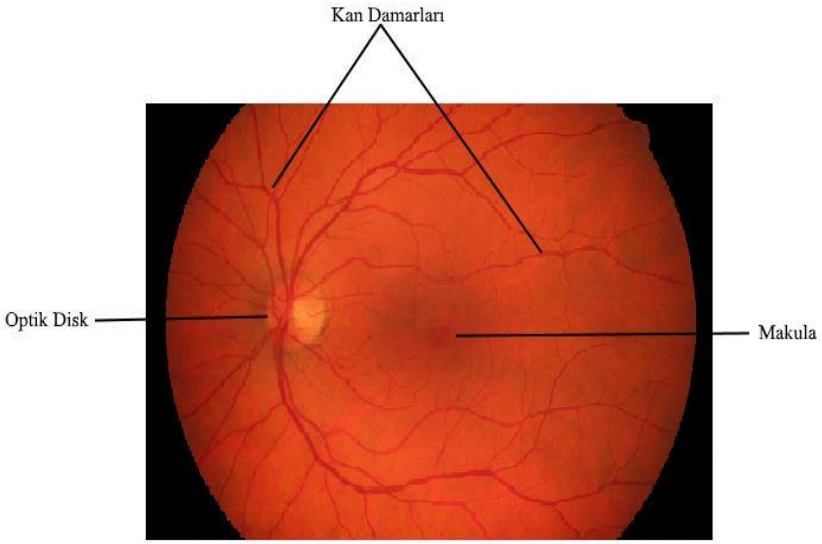

Şekil 1.2. Retinal görüntü ve retinanın temel bölümleri

1.3. Retinal Görüntülerde Damar Tespiti

Retina tabakasındaki kılcal damarlarda hipertansiyon, glukoma ve damar sertliği gibi birçok hastalık görülebilmektedir. Kılcal damarların yapısında meydana gelen değişimler bu hastalıkların teşhis ve tedavisine yönelik önemli bilgiler sağlamaktadır. Bu nedenle, retina tabakasındaki kılcal damarların doğru bir şekilde bölütlenmesi son derece önemlidir. Literatürde damar bölütleme uygulamasına yönelik çok sayıda çalışma bulunmaktadır ve bu çalışmalar genel olarak altı kategoride incelenmektedir. Bunlar; örüntü tanımaya dayalı yöntemler, uyumlu süzgeçleri temel alan yöntemler (2 boyutlu uyumlu süzgeçler, Gabor süzgeçler, Frangi süzgeçler,..v.b.), morfolojik yöntemler, damar izlemeye dayalı yöntemler, çok ölçekli yaklaşımlar, model tabanlı yaklaşımlar olarak kategorize edilebilirler [3].

Örüntü tanımaya dayalı yöntemler incelendiğinde bu yöntemlerin denetimli ve denetimsiz olmak üzere iki alt gruba ayrıldığı görülmektedir. Denetimli yöntemler ile damar bölütleme işleminde görüntüdeki her bir pikselin öznitelik değerinin hesaplanmasından sonra sınıflandırıcı eğitilmesi süreci ile her bir pikselin damar ya da arka plan olarak sınıflandırılması gerçekleştirilir. Literatürde damar bölütleme uygulamasına yönelik en sık kullanılan denetimli yöntemlerin K-en yakın komşular sınıflandırıcı [4], Bayesgil sınıflandırıcı [5], destek vektör makineleri [6] ve yapay sinir ağları [7] olduğu söylenilebilir. Denetimsiz yöntemler kullanıldığında ise görüntüdeki her bir pikselin öznitelik değerinin hesaplanmasından sonra herhangi bir eğitim süreci gerçekleştirilmeksizin kümeleme yaklaşımı kullanılarak damar bölütleme işlemi gerçekleştirilir. Literatürde denetimsiz örüntü tanıma yöntemleri olarak genellikle K-ortalama ve Bulanık C-ortalama kümeleme yöntemleri [8] kullanılmaktadır.

Uyumlu süzgeçleri temel alan yöntemlerde kılcal damarların yapısına uygun 2 boyutlu uyumlu süzgeçlerin tasarımı gerçekleştirilmektedir. Uyumlu süzgeç kullanılarak tüm görüntü farklı yönlerde konvolüsyon işlemine tabi tutulur. Konvolüsyon işleminde her bir piksel için maksimum bir piksel değeri tanımlanarak kılcal damarların daha net tespit edilebildiği uyumlu süzgeç tepkisi elde edilir. Bu yaklaşım ile yapılan ilk çalışma 1998 Gauss fonksiyonu kullanılarak Chaudhuri ve arkadaşları tarafından gerçekleştirilmiştir [9]. Bu çalışmada kullanılan uyumlu süzgeç yapısı ile 15^{0} aralıklarla 12 farklı yönde konvolüsyon işlemi uygulanarak her bir piksele maksimum bir piksel değeri atanmıştır. Süzgeç çıktısının siyah-beyaz görüntüye dönüştürülmesinde Otsu algoritması kullanılmış ve daha sonra damar bölütleme işlemi gerçekleştirilmiştir. Benzer bir uyumlu süzgeç çalışması ise Hoover ve arkadaşları tarafından gerçekleştirilmiş ve bu çalışmada siyah-beyaz görüntüye dönüşüm özel bir bölge büyütme yöntemi ile sağlanmıştır [10]. Benzer yöntemler kullanılarak damar bölütleme çalışmaları Gauss fonksiyonunun yerine parametre değerleri ayarlanabilen Gabor süzgeci kullanılarak da gerçekleştirilmiştir [8, 11].

[12,13] numaralı çalışmalarda morfolojik yöntemlere dayalı görüntü analizi gerçekleştirilmiştir. Görüntünün bir dizi matematiksel işlemlerden geçirilerek görüntü işleme tekniklerinin uygulanması morfolojik yöntemler olarak değerlendirilmektedir. Bu çalışmalarda morfolojik yöntemlerin görüntü işleme teknikleri ile uygulanması ve kılcal damar bölütlemesi yapılmıştır.

Yerel kan damarlarının özellikleri kullanılarak kan damarlarının izlenmesi damar izlemeye dayalı yöntemeler olarak adlandırılmaktadır. Bu yaklaşımla tüm damarları izlemek yerine bir ya da iki damar parçasının izlenmesi amaçlanmaktadır. Damar izlemeye dayalı yöntemlerde damar bölütlemenin ötesinde damar özelliklerinin (damar yönü, damar kalınlığı, v.b.) ölçülmesi amaçlanmaktadır [14,15].

Kan damarlarının farklı kalınlıklarda olmasından dolayı görüntü işleme esnasında bazı bölgelerde veri kayıpları oluşabilmektedir. Bu veri kayıplarını en aza indirmek amacıyla çok ölçekli yöntemler kullanılabilmektedir [16,17]. Bu çalışmalarda, damarlar arasındaki kalınlık farkından kaynaklanan veri kayıplarının önüne geçebilmek için farklı süzgeç yapıları ve görüntü işleme yaklaşımları önerilmiştir.

Son olarak, kan damarlarına ilişkin modeller kullanılarak damar bölütleme işleminin gerçekleştirilmesi model tabanlı yaklaşım olarak adlandırılmaktadır. Model tabanlı yaklaşımla damar bölütleme işleminin gerçekleştirildiği [18,19] numaralı çalışmalarda damar profilinin modellenmesi ve aktif sınır modeli yaklaşımları kullanılmıştır.

1.4. Diyabetik Retinopati

Diyabet, insan vücudunda kalıcı etkiler bırakabilen en önemli hastalıklardan birisidir. İnsülin hormonundaki yetersizlik veya bu hormonun etkinliğinin az olması sonucunda kan şekeri artmakta ve diyabet hastalığı ortaya çıkmaktadır. Çok sayıda hastalığın tetikleyici unsuru olmasına karşın diyabetin yol açtığı en önemli hasarlar çoğunlukla göz üzerinde ortaya çıkmaktadır. Özellikle retina tabakasındaki kılcal damarların hasar görmesi sonucunda damar yapıları bozulmakta ve görme kayıpları ortaya çıkabilmektedir. Diyabetik retinopati (Diabetic Retinopathy, DR) diyabete bağlı olarak retina tabakasındaki kılcal damarların zarar görmesi sonucu ortaya çıkan ve ileri seviyelerinde körlüğe neden olabilecek bir hastalıktır.

DR hastalığının başlangıç seviyelerinde hafif görme kayıpları oluşurken, daha ileri aşamalarda kılcal damarlarda meydana gelen kanamalardan dolayı ani körlükler ortaya çıkabilmektedir. DR hastalığının genel belirtileri şunlardır,

- Bulanık, perdeli, çift görme,
- Gece iyi görememe,
- Gözde yanıp sönen ışıklar ve renksiz noktalar,

- Parlak ya da loş ışığa uyum sağlayamama,
- Gözde koyu renkli uçuşan noktalar,
- Dalgalı görme,
- Tek ya da her iki gözde ağrı ve basınç hissi,
- Renkli görmede bozukluklar,
- Gözlerin dış kenarlarında kalan yerleri görmede zorlanma,
- Görme kaybı,

Retina tabakasında diyabet hastalığından kaynaklı sorunlar ilerledikçe retina yüzeyinde yeni kan damarları oluşur. Oluşan bu yeni kan damarları zayıf ve düzensiz olmalarının yanı sıra kanamaya yatkın olup ışığın retinaya ulaşmasına engel olurlar. DR hastalığı görülen ve görülmeyen retinalara ait örnek görüntüler Şekil 1.3 ile verilmiştir. Şekil 1.3.a'da sağlıklı bir retina görüntüsü, Şekil 1.3.b'de ise DR hastalıklı bir retina görüntüsü görülmektedir.

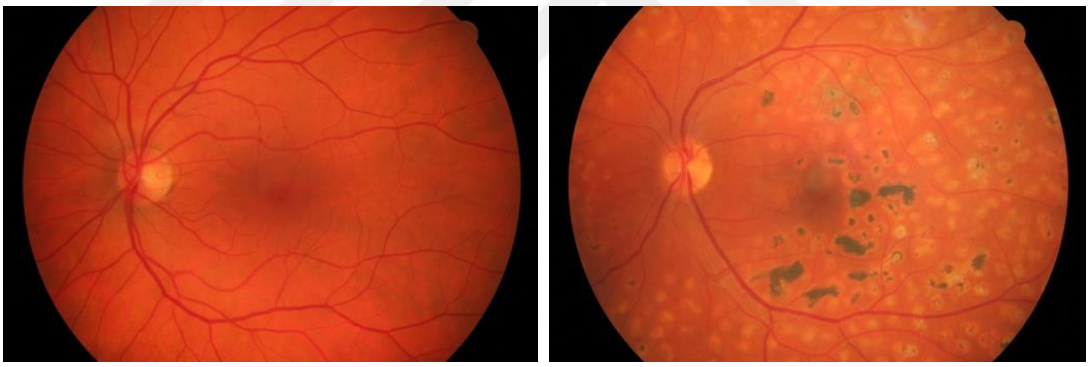

(a) (b)

Şekil 1.3. (a) Sağlıklı retina, (b) Diyabetik retinopati hastalıklı retina

1.4.1 Fundus Floresein Anjiografi (FFA)

Fundus Floresein Anjiografi (FFA) yöntemi retina damar yapısının değerlendirilmesi, retina damar tıkanıklıklarının tespit edilmesi, retina kan akımının incelenmesi ve retina üzerindeki hastalıklı bölgelerin belirginleştirilmesi gibi amaçlarla yaygın olarak kullanılan bir retina görüntüleme tekniğidir. Floresein maddeler belirli bir dalga boyunun ışıkla uyarılması sonucunda daha uzun dalga boylu ışık yayan maddelerdir. Floresein madde el ya da koldaki toplardamarlar vasıtasıyla hastaya enjekte edildiğinde

dolaşım sistemine karışarak kısa bir süre içerisinde bütün dokuları boyar. Örneğin, floresein madde enjekte edildikten sonra, retina üzerindeki kılcal damarlar, kanamalı bölgeler veya diğer hastalıklı bölgeler çok net bir şekilde görüntülenebilmektedir. Görüntüleme esnasında kullanılan kamera mavi ve sarı-yeşil süzgeçlere sahiptir. Mavi süzgeç retinaya sadece mavi ışığın ulaşmasına izin verirken sarı-yeşil süzgeç yansıyan ışığın mavi bileşenini bloke eder. Böylece kamera sadece floresein maddenin görüntüsünü kaydetmiş olur [20].

Şekil 1.4'de floresein madde uygulandıktan sonra retina görüntülerini elde etmek için kullanılan örnek bir fundus sayısal görüntüleme cihazı verilmiştir.



Şekil 1.4. Fundus görüntüleri için kullanılan sayısal görüntüleme cihazı

Literatürde DR hastalığının ileri seviye görme kayıpları veya körlük ile sonuçlanabilen olumsuz etkilerini en aza indirgeyerek en uygun teşhis ve tedavi süreçlerini oluşturmaya yönelik çeşitli çalışmalar bulunmaktadır. Bu çalışmalar incelendiğinde; glisemik kontrol ile DR hastalığının erken teşhisi [21], retina görüntüsü üzerinde optik disk tespiti, kan damarlarının yapısı, kanaması ve otomatik tespiti [22], fundus görüntülerde kanamalı bölgelerin özelliklerinin çıkarılması [23], morfolojik işlemler ve support vector machine (SVM) teknikleri ile DR hastalığının otomatik tespiti [24], sert eksüda yapılarının otomatik tespiti [25], yapay sinir ağları ile DR hastalıklı göz görüntülerinin sınıflandırılması [26], fuzzy C-means (FCM) kümeleme algoritması ile nesne sınıflandırılması [27], proliferatif DR görüntülerde hastalıklı bölgelerin tespiti [28], gauss modeli ile DR hastalıklı bölgelerin tespiti ve sınıflandırılması [29,30], otsu algoritması ve yoğunluk temelli eşikleme [31], machine learning algorithm yaklaşımı ile

hastalık tespiti [32], active contour-based method ile sert eksüda yapılarının tespiti [33] gibi çalışmaların bulunduğu görülmektedir.

Bu tez çalışmasında, Karaboğa [34] tarafından 2005 yılında önerilen Yapay Arı Koloni (Artificial Bee Colony, ABC) ile Kennedy ve Eberhart [35] tarafından 1995 yılında önerilen Parçacık Sürüsü Optimizasyon (Particle Swarm Optimization, PSO) algoritmaları retinal görüntü analizine yönelik geliştirilmiştir. Algoritmalar, retinal görüntülerde kılcal damar bölütlemesi ve yeni kanamalı bölgelerin tespitine yönelik kullanılmıştır.

Tez çalışmasının ilk bölümünde, göz anatomisi ve retinal yapı hakkında temel bilgiler verildikten sonra retinal görüntülerde damar bölütlemesi ile DR hastalıklı retinal görüntüler anlatılmıştır. Daha sonra retinal görüntü analizinde kullanılan en önemli yöntemlerden birisi olan FFA görüntüleme tekniği anlatılarak bu tekniğin özellikle DR hastalıklı göz görüntülerinde hastalık teşhisindeki önemi açıklanmıştır. Bu bölümde ayrıca retinal görüntülerde damar bölütleme ve DR hastalıklı retinal görüntülerde kanamalı bölgelerin tespiti uygulamalarına yönelik detaylı bir literatür taraması da verilmiştir.

İkinci bölümde, görüntü analizinde yaygın olarak kullanılan renk uzayları detaylı bir şekilde anlatılmıştır. Ayrıca, en temel kümeleme algoritması olan K-means kümeleme algoritmasına ve görüntü zenginleştirmede kullanılan temel morfolojik işlemlere de bu bölümde değinilmiştir.

Üçüncü bölümde, bu tez çalışmasında kullanılan sürü zekasına dayalı temel ABC ve PSO algoritmaları detaylı bir şekilde açıklanmıştır.

Tez çalışmasının dördüncü bölümünde ise benzetim sonuçları ve performans mukayeseleri verilmiştir. Öncelikle, damar bölütleme ve yeni kanamalı bölgelerin tespitine yönelik geliştirilmiş olan kümeleme tabanlı ABC ve PSO algoritmaları anlatılmıştır. Daha sonra, algoritmalar tarafından elde edilen sonuçlar detaylıca analiz edilerek performans mukayeseleri gerçekleştirilmiştir.

Son olarak, beşinci bölümde sonuç ve değerlendirmelere yer verilmiştir.

2. BÖLÜM

RENK UZAYLARI VE KÜMELEME YÖNTEMİ

2.1. Renk Uzayları

Renk uzayının (renk modeli veya renk sistemi) amacı, bir takım standartlar getirerek renk tanımlamalarını kolaylaştırmaktır. Bir renk uzayı, koordinat sistemi ve bu koordinat sistemi içerisinde her bir rengin tek bir nokta ile temsil edildiği bir alt uzayı tanımlar [36]. Yani, renk uzayları renkleri tanımlamada kullanılan matematiksel modellerdir ve bütün renkleri temsil edecek şekilde oluşturulurlar.

Renkmetri biliminin temelini oluşturan Grassmann'a göre bir rengi belirlemede birbirinden bağımsız üç değişkene ihtiyaç vardır. Bu nedenle renk uzayları üç boyutlu (3Dimensional, 3D) olarak tasarlanırlar. Her renk uzayının renkleri oluşturmada kendisine özgü standartları vardır. Renk uzayları oluşturulurken doğrusal ya da doğrusal olmayan yöntemlerle farklı renk uzaylarına dönüşüm yapılabilecek şekilde tasarlanmalıdırlar [37].

Renk uzayları oluşturulurkeneğer rengin üretimi cihazın nitelik ve niceliğine bağlıysa oluşan renk uzayı cihaz bağımlı bir renk uzayı olarak tanımlanır. Cihaz bağımlı renk uzaylarına örnek olarak; Kırmızı-Yeşil-Mavi (Red-Green-Blue, RGB), Hue Saturation Value (HSV), Hue Saturation Intensity (HSI), Cyan Magenta Yellow (CMY) ve Cyan Magenta Yellow Key (CMYK) renk uzayları verilebilir. Diğer taraftan, eğer üretilen renkler her ortamda aynı özellikleri taşıyorsa oluşan renk uzayı cihaz bağımsız bir renk uzayı olarak tanımlanır. Örneğin; Commission Internationale de l'Eclairage renk uzayları (CIE Lab, CIE Luv veya CIE XYZ), ışık değişimlerinin kolaylıkla algılanabildiği (HSV ve LCH) renk uzayları, özellikle televizyon sistemlerinde kullanılan Luminance Chorama Blue Chorama Red renk uzayları (YCbCr, YUV, YIQ)

ve ticari amaçlı üretilmiş Munsell, Ostwald, RAL ve NCS gibi renk uzayları cihaz bağımsız renk uzaylarıdır [38].

2.1.1. RGB Renk Uzayı

Kırmızı, yeşil ve mavi dalga boylarının çeşitli oranlarda kullanılmasıyla elde edilen renk uzayı RGB renk uzayı olarak adlandırılır. RGB renk uzayı Şekil 2.1'de gösterildiği gibi bir kartezyen koordinat sistemi ile ve küp formunda sembolize edilir. RGB ana renk değerleri küpün üç köşesinde; ara renkler olan cyan, magenta ve sarı renkleri ise küpün diğer üç köşesinde; siyah orijinde; beyaz ise orijinin en uzak köşesinde yer alır. Bu modelde gri skala yani RGB değerlerinin eşit olduğu noktalar siyah ve beyaz renklerini birleştiren doğru boyunca oluşur. Küpün üzerindeki ve içerisindeki noktalar farklı renkleri temsil ederlerve bu noktalar orijinden uzanan vektörler ile tanımlanırlar. RGB renk uzayı genellikle R,G ve B renk değerleri [0,1] aralığına normalize edilerek kullanılır. Şekil 2.1'de görülen küp bu nedenle bir birim küptür.

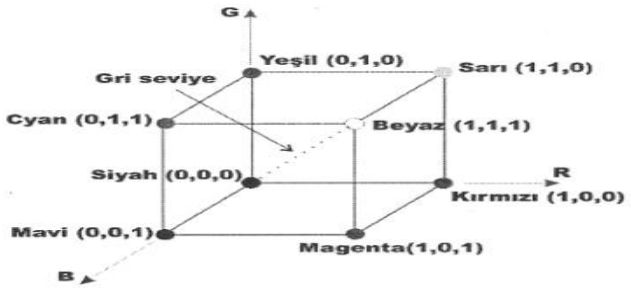

Şekil 2.1. RGB renk küpü

RGB renk uzayında bir görüntü üç ana rengin belirli tonlarda birleşmesi ile oluşur. Her bir ana renk (kırmızı, yeşil ve mavi) 8 bit ile temsil edilmektedir. Yani, bir ana renk 2^8 adet farklı tona sahiptir. Buna göre, RGB renk uzayında $(2^8)^3$= 16.777.216 adet renk oluşturulabilmektedir. Dolayısıyla bu renk uzayında her bir piksel 24 bit ile temsil edilmektedir. Renk uzayında teorik olarak tüm renkler bir küpün içerisinde veya yüzeyinde yer alır. Ayrıca küpün köşegen noktalarında gri tonlar bulunur. Şekil 2.2 ve Şekil 2.3'te köşegen noktalarda renk oluşumları ve Tablo 2.1'de ise renk oluşumlarına karşılık gelen renk değerleri görülmektedir.

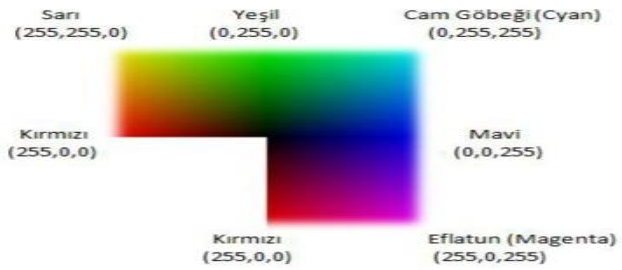

Şekil 2.2. RGB Renk Uzayı Köşegen Noktalardaki Renk Karşılıkları

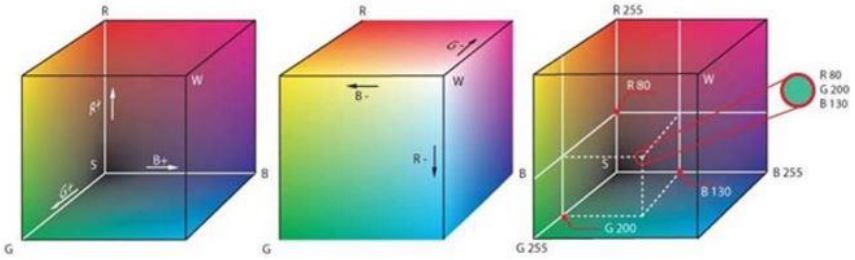

Şekil 2.3. RGB Uzayında Renk Oluşumu

Tablo 2.1. RGB Uzayında köşegen noktaların oluşturduğu renk değerleri

	Beyaz	Sarı	Cyan	Yeşil	Magenta	Kırmızı	Mavi	Siyah
Kırmızı (R)	255	255	0	0	255	255	0	0
Yeşil (G)	255	255	255	255	0	0	0	0
Mavi (B)	255	0	255	0	255	0	255	0

Şekil 2.4 ile verilen örnek bir RGB görüntünün katmanları ve bu katmanlara ait renklerin yoğunluğunu ve skaladaki dağılımını gösteren histogram grafikleri Şekil 2.5 ile gösterilmiştir. Histogram grafikleri görüntüyü oluşturan renklerin yoğunlukları ve bunların skaladaki dağılımları hakkında bilgi verdikleri için görüntü analizinde önemli bir yer tutarlar.



Şekil 2.4. RGB renk uzayında örnek bir görüntü



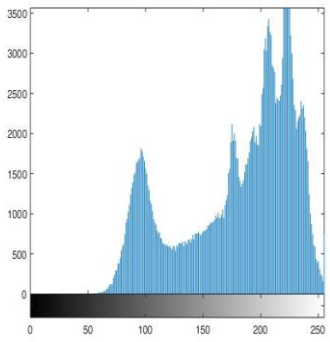

(a)



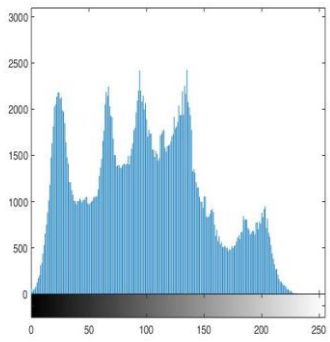

(b)



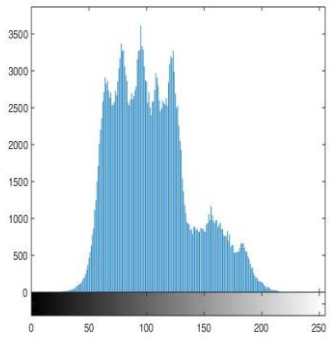

(c)

Şekil 2.5. RGB renk uzayının katmanları ve bu katmanlara ait görüntülerin histogram grafikleri: (a) R katmanına ait görüntü ve histogramı, (b) G katmanına ait görüntü ve histogramı, (c) B katmanına ait görüntü ve histogramı.

2.1.2. CIE Lab Renk Uzayı

İnsan gözünün algısına en uygun renk uzaylarından birisi Şekil 2.6 ile gösterilmiş olan CIE Lab renk uzayıdır. 1976 yılında görsel medya için geliştirilmiş olan CIE Lab renk uzayı çeşitli alanlarda standart bir renk uzayı olarak kullanılmakta ve birçok uygulama alanı bulunmaktadır. Bu renk uzayı insan gözünün algılayabildiği tüm renkleri tanımlar ve bu renk uzayındaki 3-boyutlu renk koordinatları sırasıyla aşağıdaki gibidir,

- L - Açıklık (lightness) koordinatı (L = 0 siyahı ve L = 100 beyazı gösterir)
- a – Kırmızı/Yeşil koordinatıdır, +a kırmızı rengi ve- a ise yeşil rengi belirtir
- b –Sarı/Mavi koordinatıdır, +b sarı rengi ve -b ise mavi rengi belirtir.

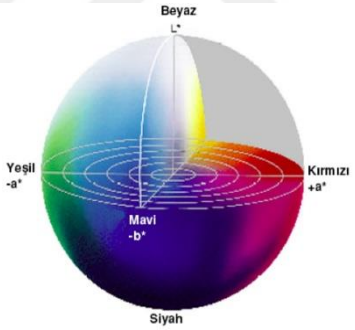

Şekil 2.6. CIE Lab uzayında renklerin oluşumu

CIE Lab renk uzayında tanımlanmış örnek bir görüntü aşağıda Şekil 2.7 ile verilmiştir.



Şekil 2.7. Lab renk uzayında örnek bir görüntü

Lab renk uzayına ait renk katmanları ve bu renk katmanlarının histogram grafikleri Şekil 2.8'de örnek bir görüntü üzerinde verilmiştir. Histogram grafiklerini analiz ederek ilgili renk katmanına ait ön bilgiler elde edilebilmektedir.

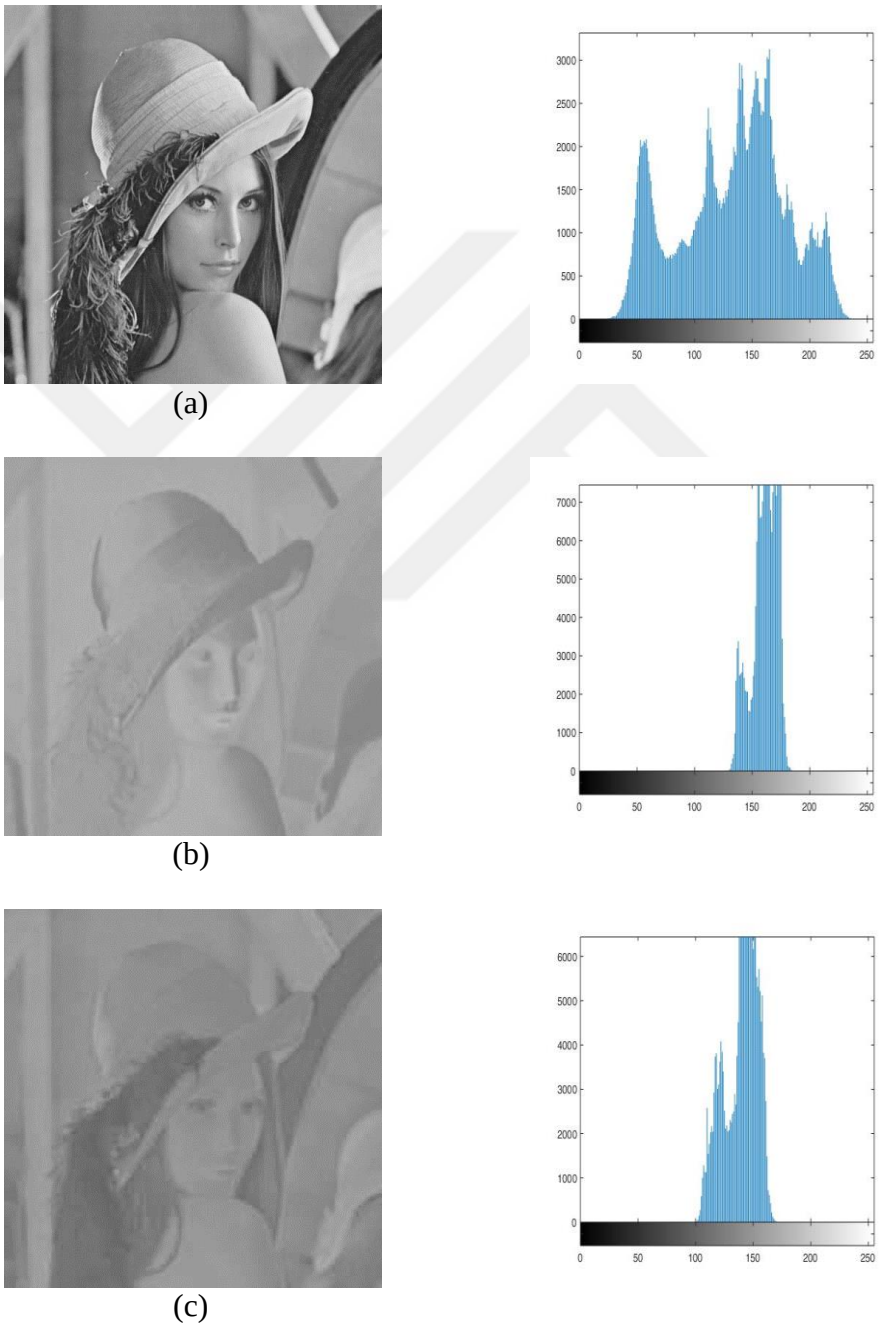

Şekil 2.8. Lab renk uzayının katmanları ve bu katmanlara ait görüntülerin histogram grafikleri: (a) L katmanına ait görüntü ve histogramı, (b) a katmanına ait görüntü ve histogramı, (c) b katmanına ait görüntü ve histogramı.

2.1.3. Gri Seviyeli Görüntü

Gri seviyeli görüntülerde her bir piksel, 0 (siyah) ile 255 (beyaz) arasında bir tam sayı değeri almakta ve her bir piksel *1 byte (8 bit)* uzunluk ile temsil edilmektedir. Gri seviyeli bir görüntü, 0-255 aralığında grinin tonlarından oluşan piksel değerlerinden meydana gelir. Örnek bir gri seviyeli görüntü ve bu görüntüye ait histogram grafiği aşağıda Şekil 2.9 ile verilmiştir.

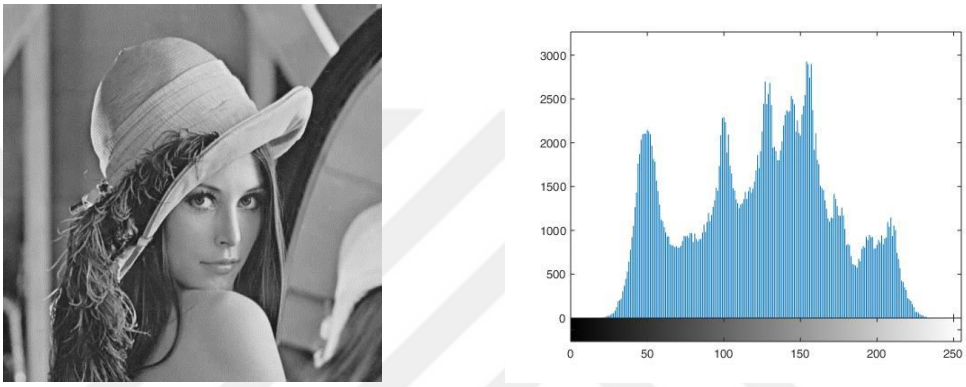

(a) (b)

Şekil 2.9. Örnek bir gri seviyeli görüntü ve histogram grafiği

2.1.4. İkili Görüntü

İkili (binary) görüntülerde her bir piksel ya 0 (siyah) ya da 1 (beyaz) değerini alır. İkili görüntüler genellikle siyah-beyaz görüntü olarak da ifade edilirler. Aşağıda Şekil 2.10 ile örnek bir ikili görüntü verilmiştir.



Şekil 2.10. Örnek bir ikili görüntü

2.2. Görüntü Zenginleştirme Yaklaşımları

Görüntüler analiz edilmeden önce bazı önişlemler ile analize daha uygun hale getirilirler ve analizler genellikle ön işlemler ile uygunlaştırılmış bu görüntüler üzerinde gerçekleştirilirler. Görüntüye uygulanan önişlemler *Görüntü Zenginleştirme* yöntemleri olarak tanımlanır. Bu tez çalışması kapsamında analiz edilen görüntülere uygulanan görüntü zenginleştirme yöntemleri aşağıda açıklanmıştır.

2.2.1. Top-hat ve Bottom-hat Dönüşümleri

Top-hat dönüşümü görüntü üzerindeki küçük öğeleri ve ayrıntıları belirginleştirmek için kullanılan bir işlemdir. Bu dönüşüm sadece gri seviyeli görüntülere ve ikili görüntülere uygulanabilir. Bu dönüşüm ile görüntü öncelikle yapı elemanları (süzgeçler) kullanılarak morfolojik açma/kapama işlemine tabi tutulur ve sonrasında elde edilen görüntü orijinal görüntüden çıkartılır.

Top-hat dönüşümü white top-hat ve black top-hat olmak üzere iki farklı şekilde gerçekleştirilebilmektedir. White top-hat dönüşümü orijinal görüntünün yapı elemaları tarafından morfolojik açılması sonucunda elde edilen görüntünün orijinal görüntüden çıkarılması olarak ifade edilmektedir. Black top-hat dönüşümü ise orijinal görüntünün yapı elemaları tarafından morfolojik kapatılması sonucunda elde edilen görüntünün orijinal görüntüden çıkarılması olarak ifade edilmektedir.

White top-hat dönüşümü orijinal görüntüde kullanılan yapı elemanına bağlı olarak bu yapı elemanının daha küçük ve daha parlak olan çevrelerindeki nesneleri veya elemanları içeren yeni bir görüntü oluşturur. Black top-hat dönüşümü ise orijinal görüntüde kullanılan yapı elemanına bağlı olarak bu yapı elemanının daha küçük ve daha koyu olan çevrelerindeki nesneleri veya elemanları içeren yeni bir görüntü oluşturur.

Görüntü üzerinde top-hat dönüşümü ile belirginleştirilecek olan elemanların boyutu veya genişliği, yapı elemanının seçimi ile kontrol edilebilir. Ayrıca top-hat dönüşümü, tüm piksel değerleri pozitif olan yani negatif değerli pikseller içermeyen görüntülere uygulanabilen bir dönüşümdür. Top-hat dönüşümünün uygulandığı örnek bir görüntü Şekil 2.11 ile verilmiştir.

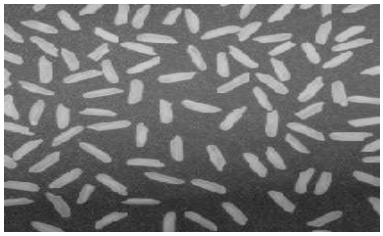

(a) Orijinal görüntü

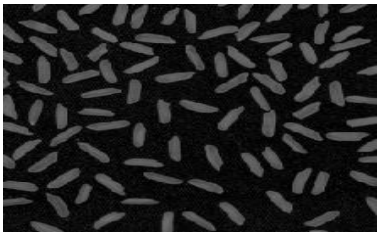

(b) Top-hat dönüşümlü görüntü

Şekil 2.11. Top-hat dönüşümünden önce ve sonra elde edilen görüntüler

Bottom-hat dönüşümü, morfolojik açma ve kapama işlemleri kullanılarak kaldırılacak olan nesnelerle aynı yapıda olmayan farklı yapıda yapı elemanları kullanarak görüntüden nesnelerin çıkarılmasıdır. Bottom-hat morfolojik işleminde, morfolojik kapama sonucu elde edilen görüntüden orijinal görüntü çıkarır.

Top-hat dönüşümü karanlık bir zemindeki aydınlık nesneler için kullanılırken, bottom-hat dönüşümü aydınlık bir zemin üzerine koyu renkli nesneler için kullanılmaktadır. Şekil 2.12'de bottom-hat dönüşümü uygulanmış bir görüntü verilmiştir.





Şekil 2.12. Bottom-hat dönüşümünden önce ve sonra görüntü

2.2.2. Morfolojik İşlemler

Morfolojik işlemler küme teorisi, topoloji ve rastgele fonksiyonlara dayalı görüntü analiz ve görüntü işleme yöntemleridir. Görüntü içerisinden ayırt etmek istediğimiz nesneleri, görüntü içerisindeki diğer bölgelerden veya nesnelerden ayırt etmek için kullanılırlar [39]. Bu işlemler genellikle Yapı Elemanı *(Structuring Element)* olarak adlandırılan matrisler kullanılarak gerçekleştirilir. Morfolojik yapı elemanlarına iki örnek Şekil 2.13 ile verilmiştir. Yapı elemanı görüntü üzerinde dolaştırılır ve uygulanan

morfolojik işlemin tanımına göre, görüntüdeki piksel değerleri ile yapı elemanının değerleri karşılaştırılarak, sonuç görüntüsünde kullanılacak değer elde edilir. Yapı elemanları farklı şekil ve büyüklüklerde olabilmekle birlikte hepsinin bir merkez noktası bulunur ve işlenecek görüntünün her bir pikseli bu noktaya oturtularak morfolojik işlem gerçekleştirilir [40].

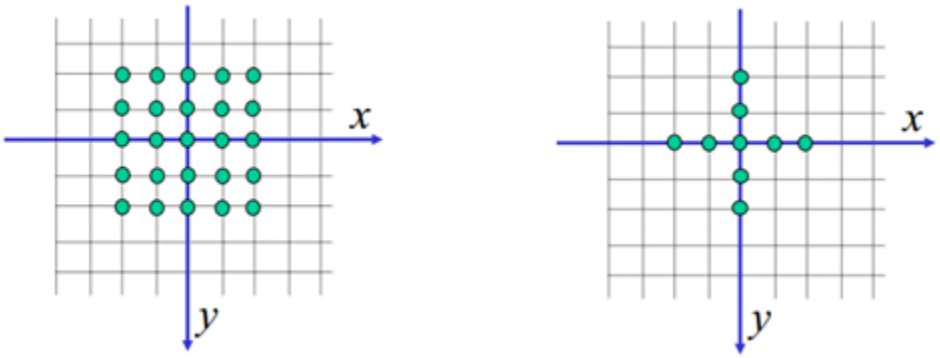

Şekil 2.13. Morfolojik yapı elemanı örnekleri

2.2.2.1 Açma ve Kapama Morfoloji Operatörleri

Açma operatörü, aşınma ve genişleme operatörlerinin ardından kullanılan bir matematiksel morfoloji operatörüdür. Temel prensibi yapı elamanından daha az sayıda piksele sahip grupların elenmesi ve diğer veri gruplarının ise aynı şekilde kalmasıdır. Açma işlemi sonucunda nesnelerdeki ince çizgiler ortadan kalkar, ufak benekler yok olur, nesnelerin keskin ayrıntıları yumuşar. Bu işlem sonucunda yapı elemanından daha ince bağlarla birbirine bağlanmış nesneler birden çok bölgeye ayrılabilir. Açma işlemi geometrik olarak, bir yapı elemanını bir bölgenin içinde gezdirme ve bu elemanın bölge içinde ulaştığı yerlerin sınırlarını çizme işlemine benzetilebilir [41]. Açma işlemine bir örnek Şekil 2.14 ile verilmiştir.

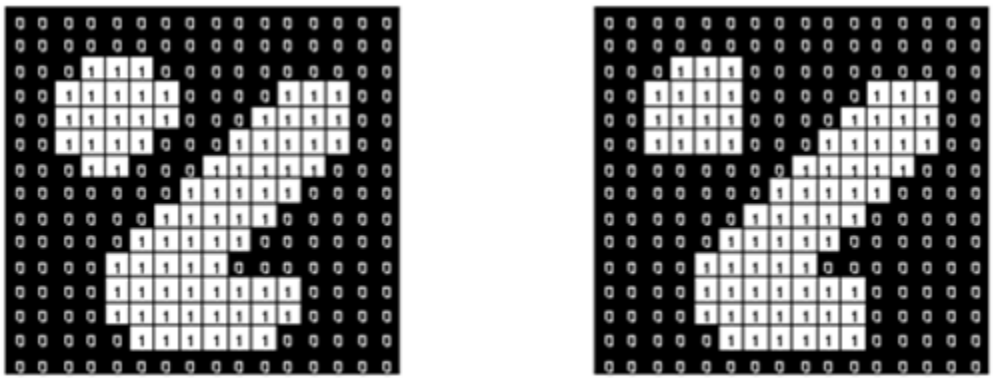

(a) (b)

Şekil 2.14. (a) İkili görüntü (b) Açma operatörü uygulanması sonucunda oluşan görüntü

Kapama operatörü ise açma operatörünün tam tersidir. Genişleme ve aşınma operatörlerinin ardından kullanılan kapama operatöründeki temel amaç veri grupları arasındaki boşlukları kapatmaktır. Kapama işlemi sonucunda nesnelerdeki ufak girintiler ve ince uzun körfezler ortadan kalkar, küçük delikler yok olur. Kapama işlemi geometrik olarak, bir yapıtaşı elemanını bir bölgenin dışında gezdirmeye benzetilebilir. Bu durumda bölgenin dışına doğru taşan detaylar özelliklerini biraz kaybetmelerine karşın göreceli olarak sağlam kalırlar ancak bölgenin sınırlarındaki girintiler yok olur [41]. Şekil 2.15'te kapama operatörü öncesinde ve sonrasında elde edilen görüntüler görülmektedir.

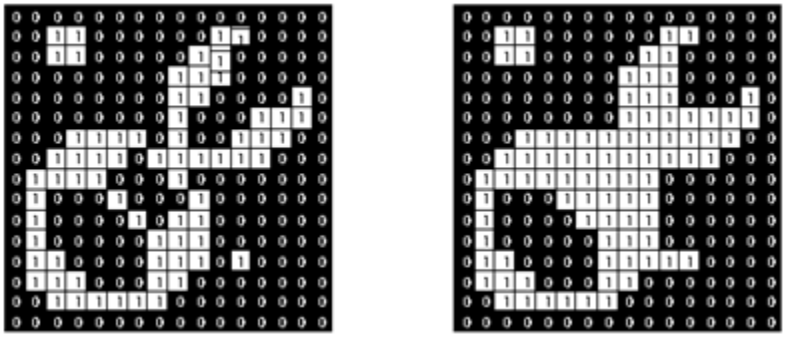

(a) (b)

Şekil 2.15. (a) İkili görüntü (b) Kapama operatörü sonucunda oluşan görüntü

2.2.3. Kontrast Zenginleştirme

Kontrast veya diğer bir ifade ile karşıtlık, görüntünün ayırt edilebilirliğini ifade etmek için kullanılır ve görüntünün en parlak bölümü ile en karanlık bölümü arasındaki genişliği tanımlar. En parlak bölümleri temsil eden beyaz bölgeler ile en karanlık bölümleri temsil eden siyah bölgeler arasındaki kontrast aralığı genişledikçe, gri tonlar daha net ayırt edilebilir hale gelmektedir. İnsan gözü yaklaşık 30 adet gri renk tonunu ayırt edebilmektedir. Bu nedenle düşük kontrastlı görüntülerde detayların insan gözü tarafından yeterince algılanamadığı söylenebilir. Düşük kontrastlı görüntülerin histogramları incelendiğinde gri skalanın dar bir aralığında çok sayıda pikselin yoğunlaştığı görülmektedir [42]. Bu tarz görüntülerin insan gözüne uygunlaştırılması işlemi kontrast zenginleştirme olarak tanımlanır. Eşitlik 2.1, en temel kontrast zenginleştirme yaklaşımını göstermektedir.

$$g\,(x,y) = \;\; a\,[\,f(x,y)] \tag{2.1}$$

a katsayısının değeri a>1 olarak seçilirse bütün piksel değerleri artacağından görüntü beyaz seviyeye yaklaştırılmış olur yani görüntünün kontrastı artar. a<1 olduğunda ise bütün piksel değerleri azalacağından görüntü siyah seviyeye yaklaşmış olur yani görüntünün kontrastı azalır. Kontrast artırma veya azaltma işlemine bir örnek Şekil 2.16 ile verilmiştir [42].



Şekil 2.16. Temel kontrast ayarlama işlemi

2.3. Kümeleme Yöntemi

Kümeleme analizi (Clustering analysis) bir veri matrisinde yer alan ve gruplama yapıları net olarak bilinmeyen birimlerin, değişkenlerin veya birim ve değişkenlerin arasında benzerlik olanları belirli alt kümelere (sınıf, grup) ayırma işlemidir.

Kümeleme analizindeki temel amaç aralarında benzerlik olan birim ya da nesneleri aynı küme içerisinde sınıflandırmak ve bu kümelerin mümkün olduğunca kendi içinde homojen olmasını sağlamaktır. Kümeleme işleminin başarımı aynı küme içerisindeki nesnelerin geometrik olarak birbirine olabildiğince yakın, farklı kümelerdeki nesnelerin ise geometrik olarak birbirine olabildiğince uzak olması şartına bağlıdır.

Kümeleme analizi ile temelde dört amaca yönelik işlemler gerçekleştirilir.

i. *n* adet birimi, *p* adet değişkene göre belirlenen özellikleri dikkate alarak kendi içinde aynı türden ve kendi aralarında farklı türden alt gruplara ayırmak,

ii. *p* adet değişkeni, *n* adet birim ile belirlenen kriterlere göre ortak özellikli alt gruplara ayırmak ve ortak faktör yapıları belirlemek,

iii. birim ve değişkenleri birlikte ele alıp *n* adet birimi, *p* adet değişkene göre belirlenen ortak özellikleri kullanarak alt kümelere ayırmak,

iv. birimleri, *p* adet değişken tarafından belirlenen değerlere göre analiz edip izledikleri biyolojik ve tipolojik sınıflamayı belirlemek

Kümeleme analizinin aşamaları veri matrisinin hazırlanması, benzerlik veya uzaklık matrisinin elde edilmesi, kümeleme yönteminin belirlenmesi, sonuçların yorumlanması olarak ifade edilir.

2.3.1. K-means Kümeleme Yöntemi

Literatürde en yaygın olarak kullanılan gözetimsiz öğrenme yöntemlerinden birisi olan K-means kümeleme algoritması 1967 yılında J.B. MacQueen tarafından geliştirilmiştir [43]. K-means kümeleme algoritması, *n* adet veriden oluşan bir veri kümesi oluşturarak bu veri kümesini giriş parametresi olan *k* adet kümeye bölümler. Algoritmanın temel amacı küme içerisindeki değerleri birbirine en yakın şekilde yerleştirmek ve bunu yaparken *k* adet kümenin de birbirine mümkün olduğunca benzememesini sağlamaktır. Veriler arasındaki küme benzerliğini tespit etmek için kümenin ağırlık merkezi olarak kabul edilen nesne ile kümedeki diğer nesneler arasındaki uzaklıkların ortalama değeri hesaplanır [44,45]. K-means kümeleme algoritmasında kümeleme yönteminin değerlendirilmesi yapılırken yaygın olarak Karesel Hataların Toplamı (Sum of Squares Error, SSE) kriteri kullanılır. En düşük SSE değerine sahip küme en iyi sonucu

vermektedir. Nesnelerin bulundukları kümenin merkez noktalarına olan uzaklıklarının karelerinin toplamı Eşitlik 2.2 ile hesaplanmaktadır [46].

$$\mathrm{SSE} = \sum_{i=1}^{K} \sum_{x \epsilon C_i} \mathrm{dist}^2(m_i, x) \tag{2.2}$$

K-means kümeleme algoritmasının adımları aşağıda verilmiştir [47].

1. Küme sayısına (*k*) bağlı olarak rastgele *k* adet küme merkezi belirlenir.
2. Küme merkezleri dışındaki tüm gözlemlerin küme merkezlerine uzaklıklarına göre kümelere ataması yapılır.
3. Yapılan kümelemeye göre yeni merkezlerin hesaplanması veya eski merkezlerin yeni merkeze kaydırılması gerçekleştirilir.
4. Tüm gözlemlerin ait olduğu küme değişmeyinceye kadar 2. ve 3. adımlar tekrarlanır.

3. BÖLÜM

SEZGİSEL ALGORİTMALARA DAYALI KÜMELEME

Bu tez çalışmasında, kümeleme yaklaşımını temel alan biyomedikal görüntü analizleri gerçekleştirilmiştir. Analizlerde literatürde yaygın olarak kullanılan klasik kümeleme yaklaşımlarından K-means kümeleme algoritmasının yanı sıra sürü zekasına dayalı sezgisel algoritmalardan olan yapay arı koloni ve parçacık sürüsü optimizasyon algoritmaları kullanılmıştır. Sürü halinde hareket eden canlıların gösterdiği zeki davranışların matematiksel olarak modellenmesi sonucunda geliştirilen algoritmalar sürü zekasına dayalı algoritmalar olarak adlandırılmaktadır [44]. Kuş, balık ve böcek gibi hayvan sürülerinin belirli bir amaç etrafında ortak hareketlerinden esinlenerek geliştirilen sürü zekasına dayalı algoritmalar yüksek performanslarından dolayı son yıllarda bir çok alanda yaygın şekilde kullanılmaktadır [34]. ABC ve PSO algoritmalarının genel yapıları aşağıda detaylı bir şekilde anlatılmıştır.

3.1. Yapay Arı Koloni Algoritması

Yapay arı koloni algoritması, optimizasyon problemlerine bal arısı sürülerinin zeki davranışlarını temel alan matematiksel modeller ile çözüm üreten sürü zekasına dayalı bir yapay zeka algoritmasıdır. Karaboğa tarafından 2005 yılında önerildikten sonra literatürde çok boyutlu, çok modlu, sınırlı ve sınırsız birçok sayısal optimizasyon problemine uygulanmış ve elde edilen sonuçlar ABC algoritmasının başarımını ortaya koymuştur [49-51].

ABC algoritmasında arı kolonisi görevli arılar, gözcü arılar, ve kaşif arılar olmak üzere üç grup arıdan oluşmaktadır. ABC algoritmasında olası çözümleri temsil eden her bir yiyecek kaynağının nektar miktarı (kalite değeri, fitness değeri) sadece bir görevli arı tarafından hesaplanır. Yani görevli arıların sayısı yiyecek kaynağı sayısına eşittir. Bu

çalışmada kullanılan ABC algoritmasında, başlangıç popülasyonunun yarısı görevli arılardan diğer yarısı ise gözcü arılardan oluşmaktadır. Belirli sayıda değerlendirmeye rağmen kalite değeri geliştirilemeyen kaynaklar nektarı tükenmiş kaynaklar olarak tanımlanır ve bu kaynakların görevli arıları çözüm uzayında araştırma yaparak yeni çözümler arayan kaşif arılara dönüşürler. ABC algoritmasının temel akış diyagramı Şekil 3.1 ile verilmiştir [52].

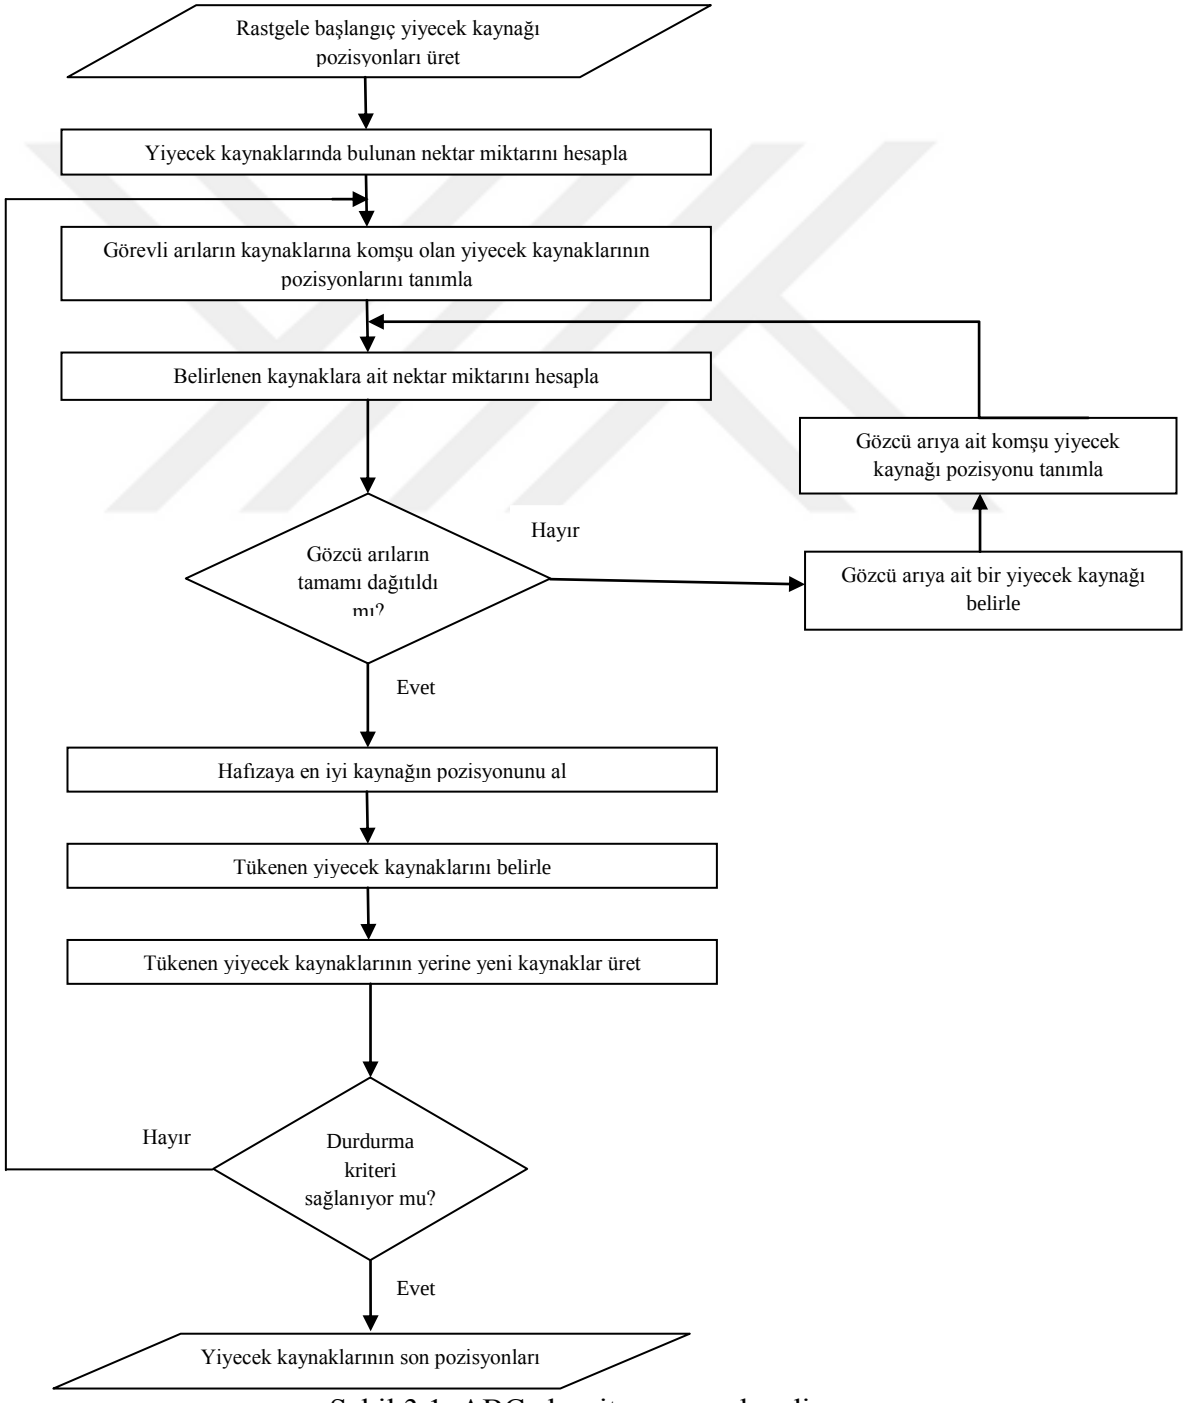

Şekil 3.1. ABC algoritmasının akış diyagramı

Başlangıçta *SN* adet olası çözümden oluşan rastgele bir *P* başlangıç popülasyonu üretilir. Optimize edilecek parametre sayısını *D* olarak tanımlarsak, popülasyondaki her bir x_i ($i=1,2,...,SN$) çözümü de *D* boyutlu bir vektör şeklinde oluşur. Başlangıç popülasyonundaki herhangi bir x_i çözümüne ait kalite değeri o çözümün görevli arısı tarafından hesaplanır. Çözümlerin kalite değerleri hesaplandıktan ve algoritmaya ait kontrol parametre değerleri belirlendikten sonra araştırmanın her çevrimi aşağıdaki 3 aşama ile gerçekleştirilir [53,54].

Aşama 1 Görevli arıların ilgili yiyecek kaynağına gönderilmesi, bu yiyecek kaynağına ve komşuluğunda üretilen yeni bir yiyecek kaynağına ait nektar bilgilerinin hesaplanması ve elde edilen nektar bilgilerinin gözcü arılara aktarılması,

Aşama 2 Gözcü arıların görevli arılardan aldıkları nektar bilgilerine göre yiyecek kaynağına gönderilmesi, ilgili yiyecek kaynağına ve komşuluğunda üretilen yeni bir yiyecek kaynağına ait nektar bilgilerinin elde edilmesi,

Aşama 3 Kaşif arıların belirlenmesi ve rastgele yeni yiyecek kaynakları bulmak için araştırma alanına gönderilmesi.

İlk aşamada, görevli arılar kendileri için tanımlanmış olan yiyecek kaynağının ve onun komşuluğunda ürettikleri yeni bir yiyecek kaynağının nektar bilgilerini hesaplar. Elde ettiği nektar bilgilerini mukayese eder ve yeni yiyecek kaynağındaki nektar miktarının eski yiyecek kaynağındaki nektar miktarına eşit ya da yüksek çıkması durumunda eski yiyecek kaynağı hafızadan silinip yerine yeni yiyecek kaynağı kaydedilir. Diğer durumlarda ise eski yiyecek kaynağı hafızada tutulmaya devam eder. Bu seçme prosedürü Açgözlü Seçme (Greedy Selection) olarak isimlendirilir [55]. Görevli arılar araştırma görevlerini tamamladıktan sonra kovana dönerler ve hafızalarında tutmuş oldukları yiyecek kaynaklarına ait nektar ve pozisyon bilgilerini gözcü arılara aktarırlar.

İkinci aşamada, gözcü arılar görevli arılardan aldıkları nektar bilgilerini kullanarak kendilerine bir yiyecek kaynağı seçerler. Gözcü arıların yiyecek kaynaklarına yerleştirilmesi Rulet Tekerleği yöntemi ile gerçekleştirilir [56]. Rulet tekerleği yönteminde, bir yiyecek kaynağının gözcü arılar tarafından seçilme olasılığını yiyecek kaynağına ait nektar miktarı ile doğru orantılıdır yani bir yiyecek kaynağının nektar miktarı ne kadar fazla ise gözcü arılar tarafından seçilme olasılığı o kadar yüksek

olacaktır. Diğer taraftan, ABC algoritmasında gözcü arıların yiyecek kaynaklarına dağılması işlemi tamamen rasgele gerçekleştirildiğinden bu dağılım homojen olmayabilir. Yani, bazı yiyecek kaynaklarına birden fazla gözcü arı giderken bazılarına hiçbir gözcü arı gitmeyebilir. Gözcü arılar gittikleri yiyecek kaynağı ileonun komşuluğunda belirledikleri yeni bir yiyecek kaynağına ait nektar bilgisini hesaplar. Nektar miktarı yüksek olan çözüm hafızaya kaydedilir.

Son aşamada, arılar tarafından nektarı tüketilmiş olan yiyecek kaynaklarının görevli arıları algoritma tarafından kaşif arı haline dönüştürülür. Kaşif arılar herhangi bir ön bilgiye sahip olmaksızın tamamen rasgele bir araştırma prosedürü ile araştırma uzayında yeni yiyecek kaynakları aramaya başlarlar. Kaşif arıların seçilme süreci *limit* parametresi ile kontrol edilmektedir. *limit* parametre sayısınca denemeye rağmen geliştirilemeyen çözümlerin görevli arıları, kaşif arılara dönüştürülür.

Yukarıda anlatılmış olan üç aşama durdurma kriteri sağlanıncaya kadar araştırmanın her bir çevriminde tekrar edilir.

Herhangi bir yiyecek kaynağının gözcü arılar tarafından seçilme olasılığı p_i aşağıdaki ifade ile tanımlanmaktadır,

$$p_i = \frac{fit_i}{\sum_{n=1}^{SN} fit_n} \tag{3.1}$$

burada, fit_i, yiyecek kaynağının nektar miktarı olan *i.* çözüme ait kalite değerini temsil etmektedir. Çözümlere ait kalite değerleri aşağıdaki gibi hesaplanmaktadır.

$$fit_i = \frac{1}{1+f_i} \tag{3.2}$$

burada, f_i, *i.* çözüm tarafından üretilen hata değerini temsil etmektedir. Görevli ve gözcü arıların hafızalarında kayıtlı olan yiyecek kaynağının komşuluğunda üretecekleri yeni yiyecek kaynağına ait pozisyon aşağıdaki ifade ile belirlenmektedir.

$$v_{ij} = x_{ij} + \emptyset_{ij}(x_{ij} - x_{kj}) \tag{3.3}$$

burada, $k \in \{1,2,\ldots,SN\}$ ve $j \in \{1,2,\ldots,D\}$ rastgele seçilen indislerdir. Hafızadaki yiyecek kaynağına ait pozisyon bilgisi ile onun komşuluğunda üretilen yiyecek kaynağının pozisyon bilgisinin aynı olmaması için $k \neq i$ olması gerektiği görülmektedir. $\emptyset_{ij}$ ise [-1,1] aralığında rastgele üretilen bir katsayısıdır. Eşitlik 3.3'te ifade edildiği gibi

x_{ij} ve x_{kj} arasındaki farkın azalmasına bağlı olarak x_{ij} pozisyonundaki değişimde azalmaktadır. Bu sebeple araştırma uzayında iyi çözümlere doğru yaklaşılması adım büyüklüğünün adaptif olarak azalmasını sağlayacaktır [57]. Mevcut x_{ij} çözümü ile onun komşuluğunda üretilen her bir v_{ij} çözümü arasında açgözlü seçme prosedürü uygulandıktan sonra kaşif arılar tarafından bulunan çözümlerin değerlendirilme sürecine geçilir.

Nektarı tüketilmiş olan yiyecek kaynaklarının çözüm uzayından atılır ve bunların yerine kaşif arılar tarafından bulunan yeni yiyecek kaynakları değerlendirme sürecine dahil edilir. Yani hafızada kayıtlı olan ve nektarı tüketilmiş olan kaynaklara ait pozisyon vektörlerinin yerine, rasgele kaynak pozisyon vektörleri üretilir [58]. Bir x_i çözümü *limit* parametre sayısınca denemeye rağmen geliştirilememiş ise bu çözüm popülasyondan atılır ve yerine Eşitlik 3.4. ile elde edilen yeni çözüm popülasyona dahil edilir.

$$x_i^j = x_{min}^j + rand[0,1](x_{max}^j - x_{min}^j) \tag{3.4}$$

Burada, $j \in \{1,2,\ldots,D\}$ rastgele seçilen indisler ve x_i nektarı tüketilmiş yiyecek kaynağıdır.

ABC algoritmasının diğer sezgisel algoritmalara göre en önemli avantajı, kontrol parametre sayısının az ve parametre bağımlılığının düşük olmasıdır. Temel ABC algoritmasının koloni büyüklüğü (yiyecek kaynaklarının sayısı), çevrim sayısı ve *limit* parametreleri olmak üzere üç adet kontrol parametresi bulunmaktadır. ABC algoritmasının yüksek kaliteli çözümleri keşfedebilme hızı diğer bir ifade ile yakınsama hızı, yiyecek kaynaklarının algoritma tarafından başarılı bir şekilde yönlendirilebilmesine bağlıdır. ABC algoritmasında görevli ve gözcü arılar keşfedilmiş kaynaklardan faydalanma süreci ile ilgiliyken kaşif arılar yeni kaynakların keşfedilmesi sürecini kontrol etmektedir.

3.2. Parçacık Sürüsü Optimizasyon Algoritması

Parçacık sürüsü optimizasyon algoritması sürü halinde yaşayan canlıların sosyal davranışlarını, özellikle yiyecek arama sırasında göstermiş oldukları etkileşimleri ve kollektif davranışları modelleyen popülasyon tabanlı sürü zekasına dayalı sezgisel bir algoritmadır. Kennedy ve Eberhart tarafından 1995 yılında geliştirilmiş olan PSO

algoritması [35] özellikle çok parametreli problemlerin optimizasyonunda olmak üzere literatürde birçok alanda kullanılmaktadır.

PSO algoritmasında araştırma ve geliştirme süreci rasgele üretilmiş olası çözümlerden oluşan *D*-boyutlu bir uzayda gerçekleştirilir. Popülasyonu oluşturan her bir bireyin pozisyon bilgisi her bir çevrimde daha düşük hata değerini üretecek şekilde güncellenmeye çalışılır. Herhangi bir çevrim boyunca bireyin o an sahip olduğu pozisyon bilgisi olası bir çözümü temsil eder. Bireyin pozisyon bilgisi, ürettiği hata değerine göre, o bireye ait kalite değerini tanımlar. Düşük hata değeri üreten pozisyonlara sahip bireyler daha kaliteli çözümleri temsil ederler. Her bir bireyin hız bilgisi ise araştırmanın yönünü tayin eder.

PSO algoritması rasgele üretilmiş bir başlangıç popülasyonunda bireylerin konumlarını ve hızlarını güncelleyerek en iyi sonuçlara ulaşmaya çalışır. Başlangıç popülasyonu oluşturulurken her bir bireye araştırma uzayında uniform bir şekilde rasgele konumlar atanır. Konum bilgileri, o ana kadar ki en iyi çözüm olan [$\vec{p}(t)$] ve popülasyonun en iyi çözüm olan [$\vec{g}(t)$] bilgileri kullanılarak güncellenir. Bu sayede iyi çözümler hakkındaki bilgilerin sürü boyunca yayılması sağlanır ve diğer bireyler çözüm uzayında iyi çözümlerin olduğu bölgelere doğru hareket etmeye başlarlar. Başlangıç popülasyonunda bireylerin başlangıç hız bilgileri ise bir [v_{min} , v_{max}] aralığında rasgele seçilen hızlardan oluşturulur. Her bir çevrimde bireyin mevcut $\vec{v}(t)$ hızı güncellenir ve birey farklı bir pozisyon olan $\vec{x}(t+1)$ pozisyonuna hareket eder. Bireyin yeni pozisyonu, önceki pozisyona ait hız değeri ile yeni hızının toplamı şeklinde aşağıdaki gibi elde edilir.

$$\vec{x}(t+1) = \vec{x}(t) + \vec{v}(t+1) \tag{3.5}$$

Her bir bireye ait hız bilgisinin eski değerinden yeni değerine güncellenmesi işlemi ise Eşitlik 3.6 kullanılarak gerçekleştirilir.

$$\vec{v}(t+1) = \omega\vec{v}(t) + r_1 c_1\big(\vec{p}(t) - \vec{x}(t)\big) + r_2 c_2(\vec{g}(t) - \vec{x}(t)) \tag{3.6}$$

burada, r_1 ve r_2 katsayıları uniform dağılımdan alınan rasgele sayılardır. ω parametresi eylemsizlik faktörü (initeriafactor) olarak adlandırılır ve bireyin eski hızı olan $\vec{v}(t)$ hızının genliğini tanımlar. c_1 katsayısı $\vec{p}(t)$ vektörünün, c_2 katsayısı ise $\vec{g}(t)$ vektörünün katsayılarıdır.

PSO algoritmasının temel adımları aşağıdaki gibi ifade edilebilir,

Başlangıç popülasyonunun üretilmesi

Repeat

Her bir parçacığa ait kalite değerinin hesaplanması

Popülasyon içerisindeki en iyi parçacığın geliştirilmesi

Popülasyon içerisindeki en iyi parçacığın bulunması

Her bir parçacığa ait hızların hesaplanması

Her bir parçacığın son pozisyonlarının güncellenmesi

Until (durdurma kriteri sağlanıncaya kadar)

Eğer hızların toplamı v_{max} hızının değerini aşarsa araştırma uzayının o noktasındaki hız v_{max} ile sınırlandırılacaktır.

4. BÖLÜM

BENZETİMLER VE SONUÇLAR

Bu tez çalışmasında, retinal görüntülerde kılcal damarların ve kanamalı bölgelerin tespitine yönelik kümeleme tabanlı ABC ve PSO algoritmaları geliştirilmiştir. Geliştirilmiş olan algoritmaların performansları literatürde yaygın olarak kullanılan K-means kümeleme algoritması ile mukayese edilmiştir.

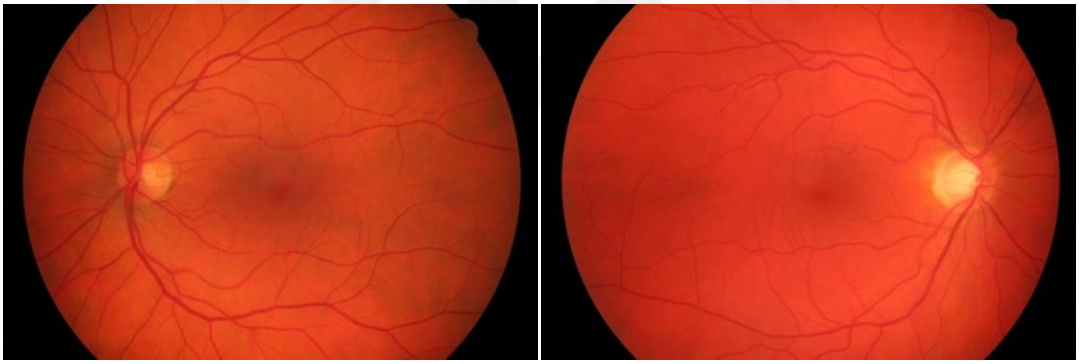

(a) Retinal görüntü 1 (b) Retinal görüntü 2

Şekil 4.1. Retinal kan damarlarının tespitine yönelik kullanılan görüntüler

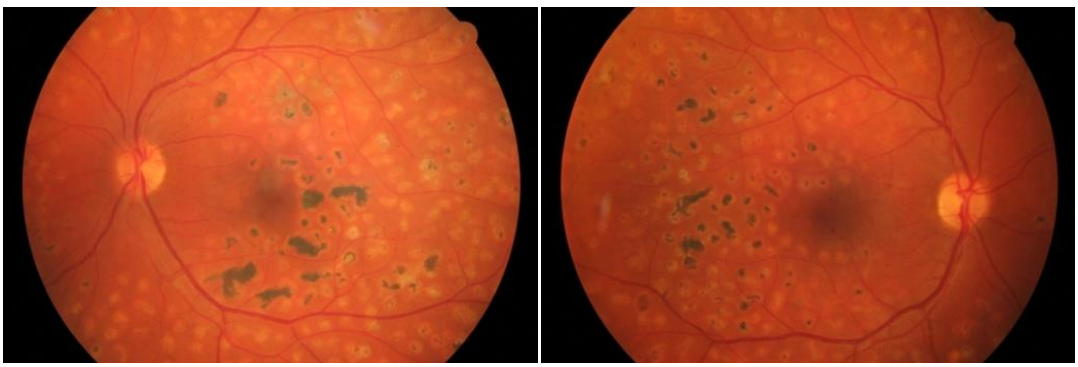

(a) Retinal görüntü 1 (b) Retinal görüntü 2

Şekil 4.2. Kanamalı bölgelerin tespitine yönelik kullanılan görüntüler

Benzetimlerde kullanılan retinal görüntüler, *High Resolation Fundus (HRF)* [58] veritabanından alınmıştır. Retinal kan damarları ve kanamalı bölgelerin tespitinde kullanılan görüntüler, sırasıyla, Şekil 4.1 ve Şekil 4.2 ile verilmiştir.

Benzetimlerde kullanılan algoritmalara ait parametre değerleri aşağıda Tablo 4.1.'de verilmiştir.

Tablo 4.1. Algoritmalara ait parametre değerleri

<table>
<tr><th>K-means</th><th>ABC</th><th>PSO</th></tr>
<tr><td rowspan="2">Maksimum İterasyon =100</td><td>Koloni Boyutu=10</td><td>Koloni Boyutu=10</td></tr>
<tr><td>Limit değeri =12</td><td>Eylemsizlik faktörü=0.72
Bilişsel faktör=1.49
Sosyal faktör=1.49</td></tr>
<tr><td rowspan="2">Mesafe=SSE</td><td>X_{max}ve X_{min} sırasıyla, görüntünün en yüksek ve en düşük piksel değerleri,</td><td>X_{max}ve X_{min} sırasıyla, görüntünün en yüksek ve en düşük piksel değerleri,
V_{max}=25, V_{min}=-25</td></tr>
<tr><td>Çevrim Sayısı=100</td><td>Çevrim Sayısı=100</td></tr>
</table>

K-Means kümeleme algoritmasında kümeleme hataları Eşitlik (2.2) ile verilmiş olan SSE hatası kullanılarak hesaplanırken, ABC ve PSO algoritmalarında kümeleme hataları Eşitlik (4.1) ile verilen Ortalama Karesel Hata (Mean Squared Error, MSE) hata fonksiyonu kullanılarak optimize edilmiştir.

$$\mathrm{MSE} = \frac{1}{\mathrm{N}} \sum_{\mathrm{i}=1}^{\mathrm{N}} (\mathrm{f_i} - \mathrm{y_i})^2 \tag{4.1}$$

burada, *N* retinal görüntüdeki toplam piksel sayısını, f_i, *i.* piksele en yakın küme merkezinin değerini ve y_i ise *i.* pikselin temsil ettiği değeri tanımlamaktadır.

4.1. Retinal Görüntülerde Kılcal Damarların Tespiti

Retinal görüntüler kümeleme işlemine tabi tutulmadan önce, literatürde kullanılmakta olan bazı görüntü zenginleştirme işlemleri uygulanmıştır. Öncelikle kılcal damarlar ile görüntü art alanı arasındaki kontrast farkını artırmak amacıyla RGB retinal görüntünün her bir renk katmanı belirli bir katsayı ile çarpılmıştır. Kılcal damarlar ile görüntü art

alanı arasında yüksek kontrast elde edebilmek amacıyla Kırmızı (R), Yeşil (G) ve Mavi (B) renk bileşenlerine uygulanmış olan ön işlem aşağıda Eşitlik 1 ile verilmiştir [59].

$$G = 0.1 * K + 0.7 * Y + 0.2 * M \quad (4.2)$$

Şekil 4.1 ile verilmiş olan retinal görüntülerde kılcal damarların tespitine yönelik gerçekleştirilen işlemler aşağıda adım adım anlatılmıştır. Şekil 4.1 ile verilen görüntülere Eşitlik 4.2 ile tanımlanmış olan görüntü zenginleştirme işlemi uygulandıktan sonra elde edilen yeni görüntüler aşağıda Şekil 4.3. ile verilmiştir. Zenginleştirilmiş olan bu görüntler yine 3 katmanlı RGB görüntüleridir.

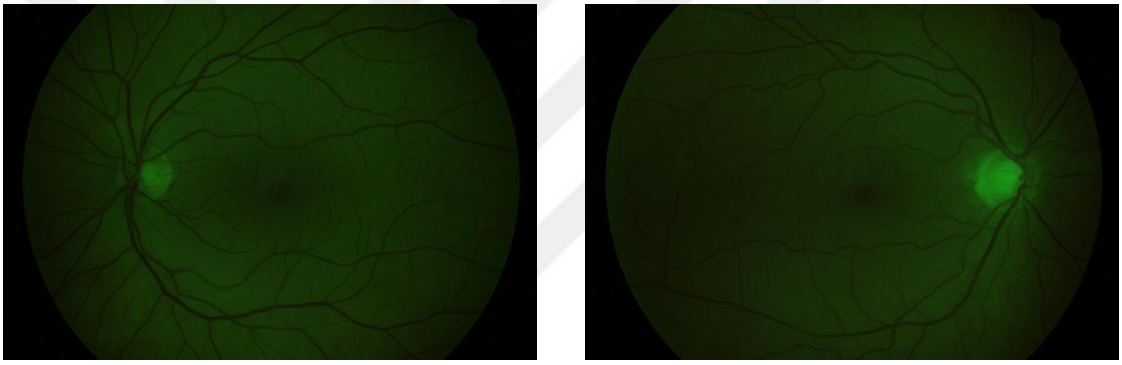

(a) Görüntü 1 (b) Görüntü 2

Şekil 4.3. Retinal görüntülere 4.2 eşitliği ile tanımlanan görüntü zenginleştirme işlemi uygulandıktan sonra elde edilen yeni görüntüler

Bu aşamadan sonra yukarıda verilen RGB görüntülerin R, G ve B katmanları ayrı ayrı incelenecek ve en uygun katman üzerinden görüntü analizine devam edilecektir. Örnek teşkil etmesi açısından Şekil 4.3 (a) ve (b) ile gösterilmiş olan retinal görüntülere ait R, G, ve B katmanları Şekil 4.4 ile verilmiştir.

Elde edilen retinal görüntülerin her bir katmanı ayrı ayrı incelendiğinde en yüksek kümeleme performansının her iki görüntü için de Yeşil (G) katmanda elde edildiği görülmüştür. Bu nedenle, bu aşamadan sonra görüntü analizine Yeşil (G) katman üzerinden devam edilmiştir.



(a) Görüntü 1 *R* katmanı

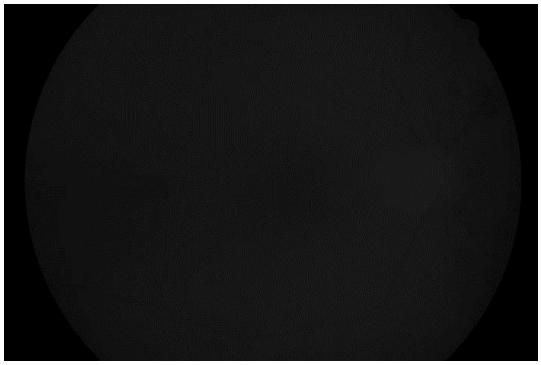

(a) Görüntü 2 *R* katmanı



(b) Görüntü 1 *G* katmanı



(b) Görüntü 2 *G* katmanı

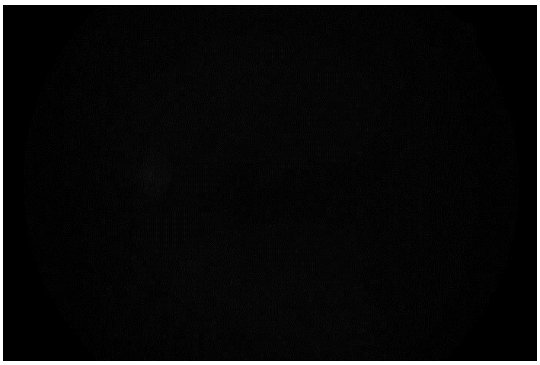

(c) Görüntü 1 *B* katmanı

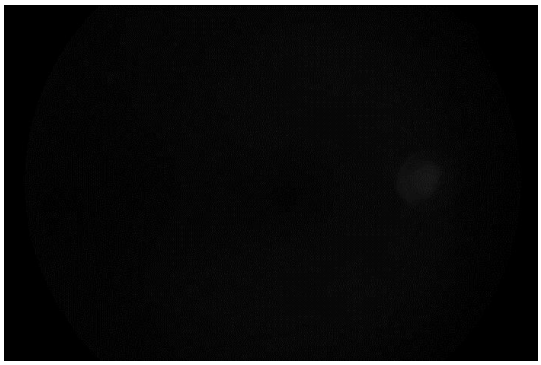

(c) Görüntü 2 *B* katmanı

Şekil 4.4. Şekil 4.3 (a) ve (b)'de verilmiş olan retinal görüntülerin R, G, ve B katmanları

Eşitlik 4.2 ile verilen ve parlaklık değerlerinin iyileştirildiği ön işlemden sonra kılcal damarlar ile görüntü art alanı arasındaki kontrast farkının yüksek kümeleme performansı elde edebilmek için yeterli seviyede olmadığı görülmüştür. Bu nedenle bir sonraki adımda literatürde bottom-hat dönüşümü yani asıl görüntünün morfolojik olarak kapanmış olan görüntüden çıkarılması olarak adlandırılan ikinci bir ön işlem

uygulanmıştır. Bottom-hat dönüşümü retinal görüntüdeki parlak seviyeler arasındaki karşıtlığı artırmakta ve bu sayede farklı parlaklık seviyesine sahip bölgeler birbirinden daha başarılı şekilde ayırt edilebilmektedir. Bottom-hat dönüşümü Eşitlik 4.3 ile verilmektedir.

$$bottom - hat(g) = g - (g \bullet nB) \tag{4.3}$$

bu eşitlikte, g retinal görüntüyü, B kullanılacak olan yapı elemanını ve n ise bottom-hat dönüşümünü tanımlamaktadır. Bu çalışmada, yapı elemanı olarak yarıçapı r=8 piksel yarıçaplı bir disk ve n =8 bottom-hat dönüşümü kullanılmıştır. Kümeleme öncesinde uygulanan son ön işlem ise kontrast zenginleştirme işlemidir. Kontrast zenginleştirme sonucunda kılcal damarlar ile retinal görüntü art alanı arasındaki karşıtlık kümeleme için en uygun seviyeye ulaşmaktadır.

Literatürde yaygın şekilde kullanılan ve yukarıda tanımlanmış olan üç ön işlem sonrasında elde edilen ve kümelemeye tabii tutulacak olan retinal görüntüler aşağıda Şekil 4.5 ile gösterilmiştir.

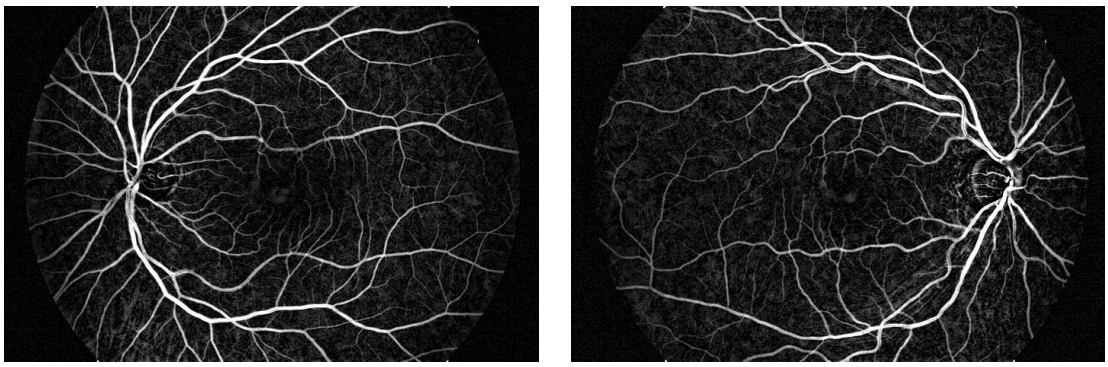

(a) Görüntü 1 (b) Görüntü 2

Şekil 4.5. Görüntü zenginleştirme işlemleri sonrasında elde edilen ve kümeleme işlemi uygulanacak olan retinal görüntüler

Şekil 4.5 ile verilmiş olan zenginleştirilmiş görüntüler K-means, ABC ve PSO algoritmaları ile kümeleme işlemine tabi tutulduktan sonra elde edilen retinal görüntüler Şekil 4.6.'da gösterilmiştir.

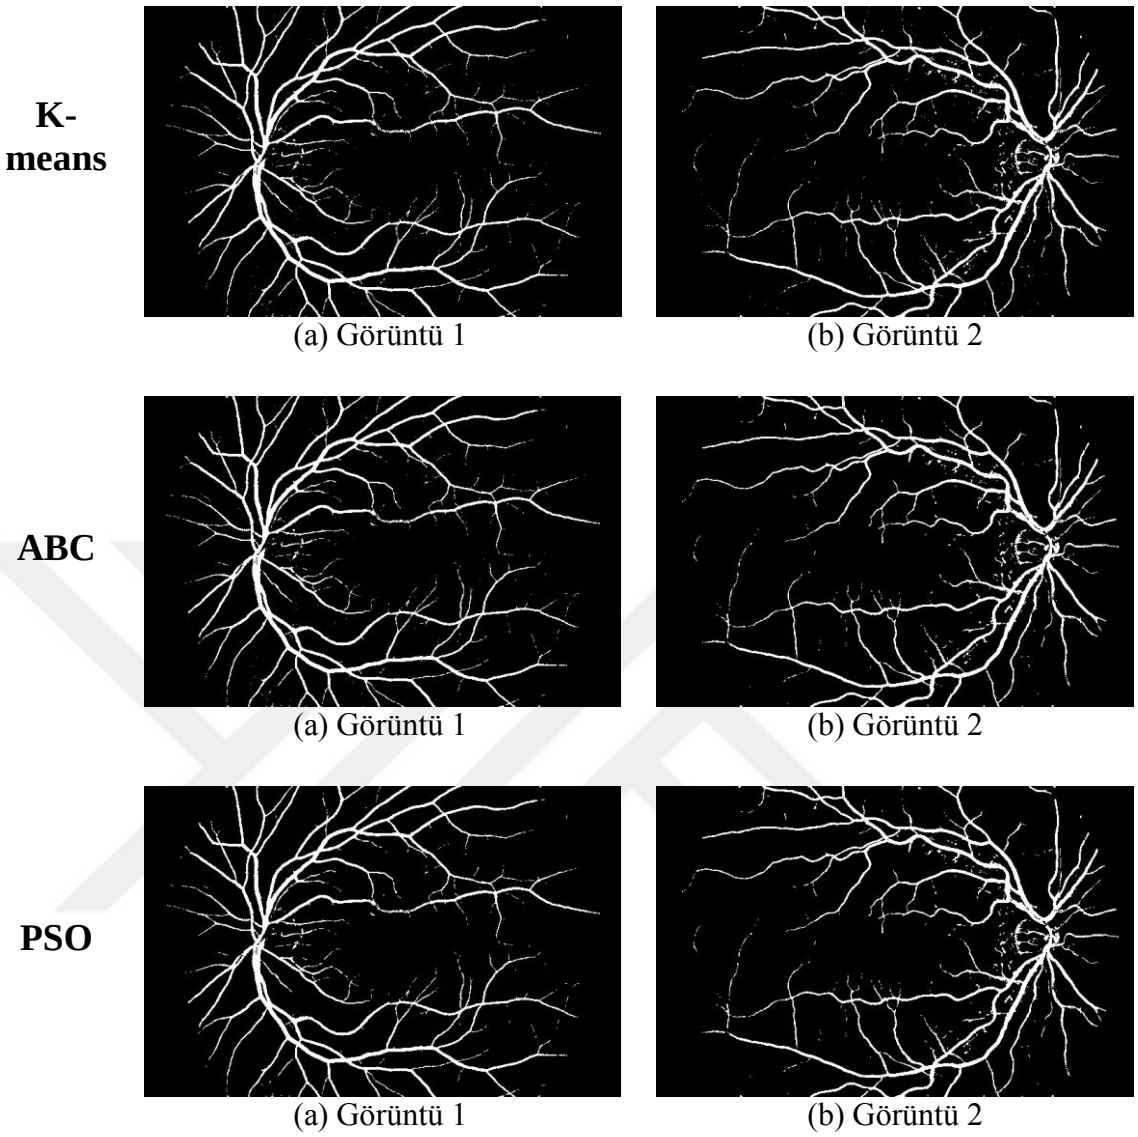

Şekil 4.6 Kümeleme tabanlı K-means, ABC ve PSO algoritmaları ile retinal kılcal damar tespiti sonucunda elde edilen ikili görüntüler

Benzetim sonuçları incelendiğinde, bu tez çalışması kapsamında geliştirilen kümeleme tabanlı ABC ve PSO algoritmaları ile literatürde retinal kılcal damar tespiti probleminde yaygın olarak kullanılan K-means algoritmasının benzer performanslar gösterdiği görülmektedir. Bununla birlikte geliştirilmiş olan sezgisel tabanlı yaklaşımlar daha esnek yapıya sahip olmaları, parametre bağımlılıklarının düşük olması ve rasgele araştırma yeteneklerinden dolayı küresel en iyi çözümlere ulaşabilmeleri gibi önemli avantajlara sahiptirler.

ABC ve PSO algoritmalarının her birisi için 20 rasgele koşmanın ortalamasından elde edilen yakınsama grafikleri aşağıda Şekil 4.7 ile verilmiştir. Yakınsama grafikleri incelendiğinde her iki retinal görüntü için ABC ve PSO algoritmalarının benzer hata değerlerine benzer çevrimlerde ulaştığı görülmekle birlikte, PSO algoritmasının nispeten daha iyi sonuçlar ürettiği söylenebilir. Yani, kümeleme tabanlı retinal kılcal damar tespitinde ABC ve PSO algoritmalarının ortalama karesel hata ve yakınsama hızı açısından benzer performansa sahip olduğu görülmüştür.

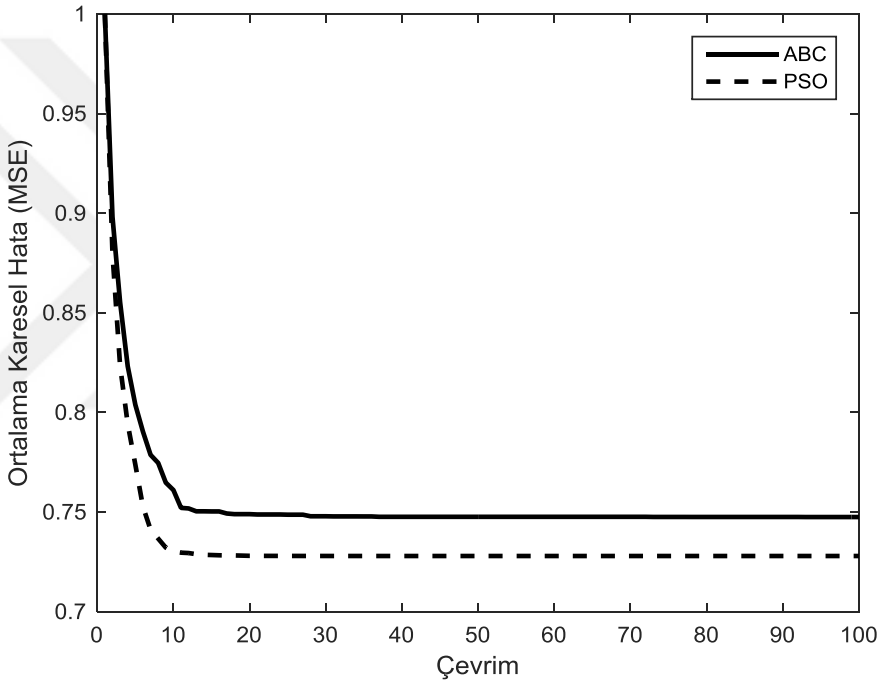

(a) Görüntü 1

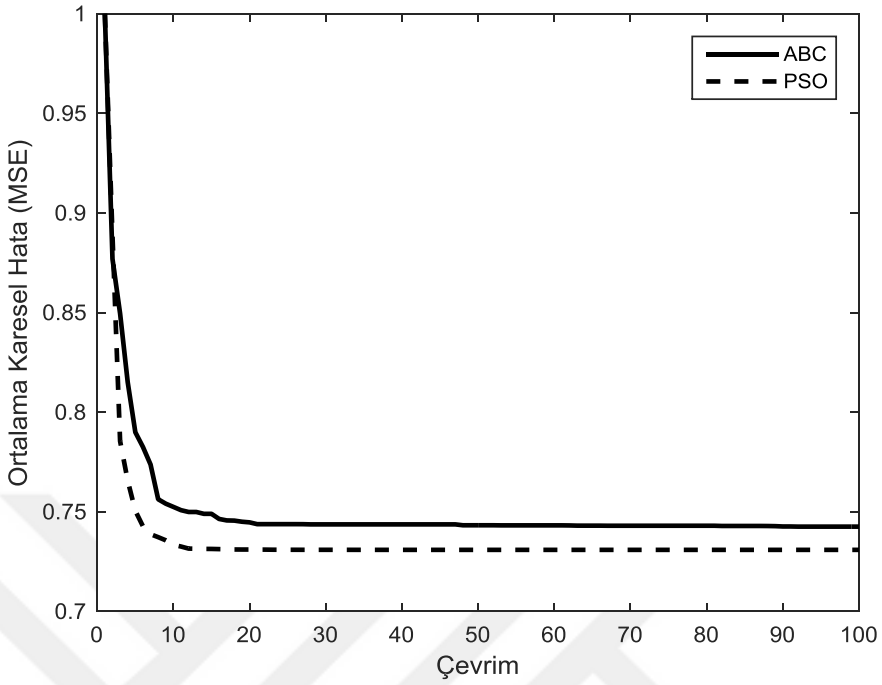

(b) Görüntü 2

Şekil 4.7. Şekil 4.1 (a) ve (b) ile verilen retinal görüntüler için kılcal damar tespitinde kullanılan kümeleme tabanlı ABC ve PSO algoritmalarının yakınsama grafikleri

4.2. DR Hastalıklı Retinal Görüntülerde Kanamalı Bölgelerin Tespiti

Görüntüleme cihazları kullanılarak elde edilen FFA'lı DR hastalıklı retinal görüntüler incelendiğinde iki önemli dezavantajın olduğu görülmektedir. Bunlar, *i.)* hastalıklı bölgeler ile görüntü art alanının piksel değerlerinin çok yakın olması ve *ii.)* hastalıklı bölgelerin ve makula bölgesinin piksel değerlerinin çok yakın olması. Bu iki dezavantajın etkisini azaltarak daha başarılı bir kümeleme performansı elde edebilmek amacıyla retinal görüntüler kümeleme işleminden önce bazı görüntü zenginleştirme işlemlerine tabii tutulmuştur. Öncelikle hastalıklı bölgeler ile diğer bölgeler arasındaki piksel farkını belirginleştirmek için retinal görüntü morfolojik açma işlemine tabii tutulmuştur. Daha sonra bu görüntüye sırasıyla kontrast keskinleştirme ve morfolojik aşındırma işlemleri uygulanarak hastalıklı bölgelerin piksel değerleri kümeleme işlemi için daha uygun hale getirilmiştir.

Şekil 4.2 (a) ve (b)'de verilmiş olan retinal görüntülere görüntü zenginleştirme işlemleri uygulandıktan sonra elde edilen yeni görüntüler aşağıda Şekil 4.8 ile verilmiştir.

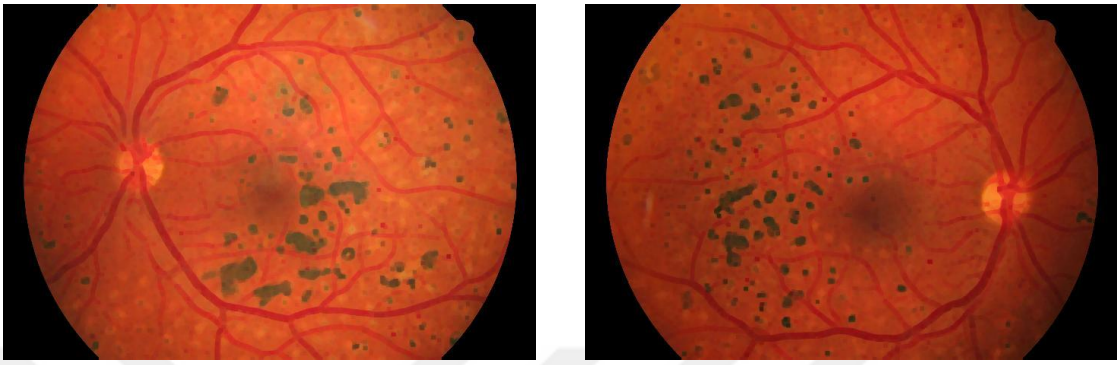

(a) Görüntü 1 (b) Görüntü 2

Şekil 4.8 Görüntü zenginleştirme işlemleri sonucunda elde edilen retinal görüntüler

Retinal görüntüler genellikle RGB formatında elde edilmekte olup çok farklı renk tonları içermektedir. Bununla birlikte, bu görüntüler RGB formatında analiz edildiklerinde kümeleme performansının yeterince başarılı olmadığı görülmektedir. Bu nedenle, retinal görüntüler genellikle piksel ve kontrast değerleri açısından kümeleme işlemine daha uygun bir renk uzayı olan CIE Lab renk uzayında analiz edilirler. Şekil 4.8 ile verilmiş olan retinal görüntülerin CIE Lab renk uzayındaki karşılıkları aşağıda Şekil 4.9 ile gösterilmiştir.

Bu adımdan sonra retinal görüntü analizine *L*, *a* veya *b* katmanlarından birisi üzerinden devam edilecektir. Yapılan benzetimlerden en yüksek kümeleme performansının *a* katmanı ile elde edildiği görülmüştür. Bu nedenle, K-means, ABC ve PSO algoritmaları ile kümeleme işlemi *a* katmanı üzerinde gerçekleştirilecektir.

Şekil 4.9 (b)'de verilmiş olan *a* katmanları K-means, ABC ve PSO algoritmaları ile kümeleme işlemine tabi tutulduktan sonra elde edilen retinal görüntüler Şekil 4.10 ile gösterilmiştir.

Benzetim sonuçları incelendiğinde K-means, ABC ve PSO algoritmalarının benzer kümeleme performanslarına sahip olduğu görülmektedir.

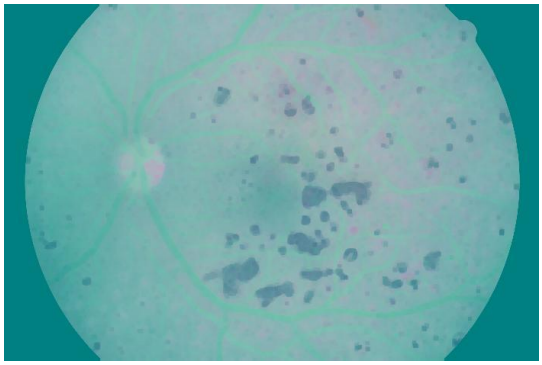

(a) Görüntü 1 için CIE Lab uzayı

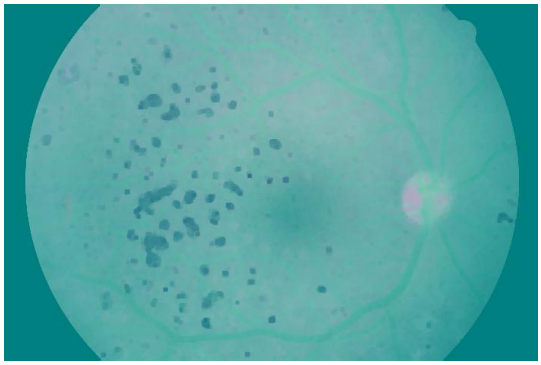

(a) Görüntü 2 için CIE Lab uzayı

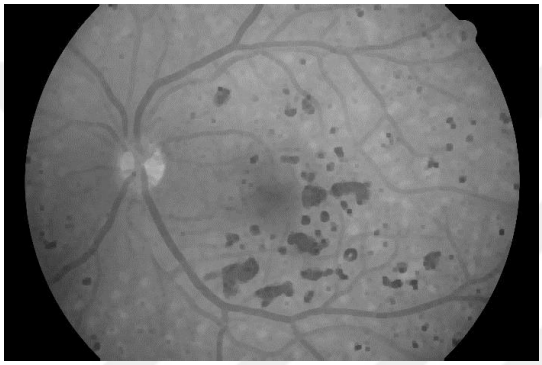

(b) Görüntü 1 için *L* katmanı

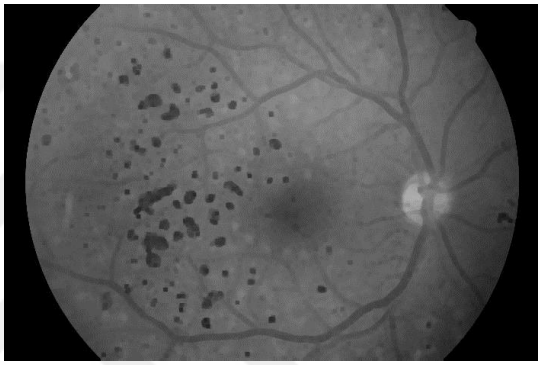

(b) Görüntü 2 için *L* katmanı

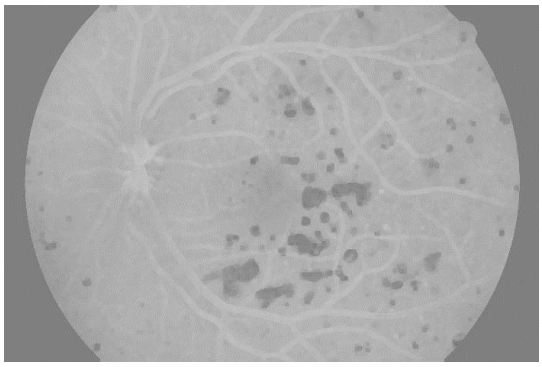

(c) Görüntü 1 için *a* katmanı

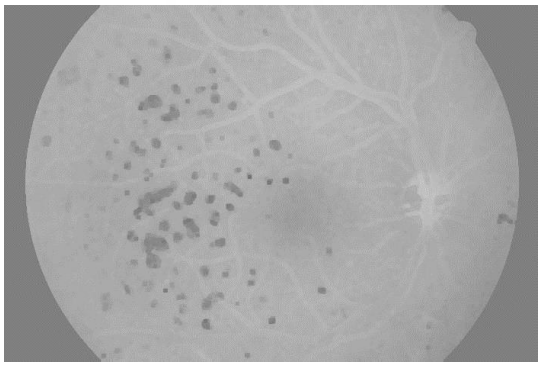

(c) Görüntü 2 için *a* katmanı

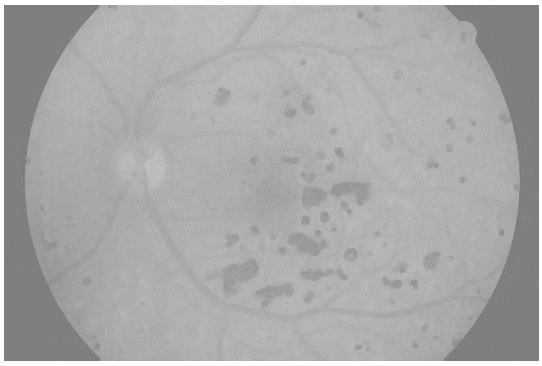

(d) Görüntü 1 için *b* katmanı

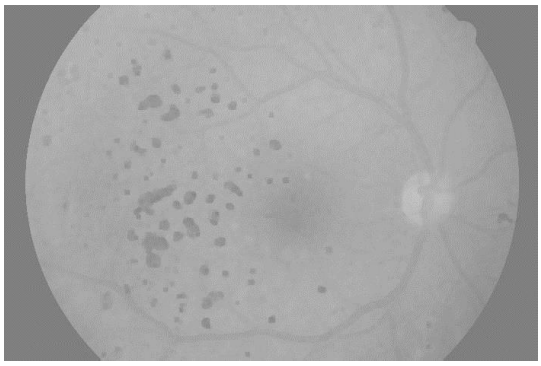

(d) Görüntü 2 için *b* katmanı

Şekil 4.9. Şekil 4.8 ile verilen retinal görüntülerin CIE Lab renk uzayındaki karşılıkları ve katmanları

Orijinal görüntüler ile kümeleme sonrasında elde edilen görüntüler mukayese edildiğinde, bu tez çalışmasında geliştirilmiş olan kümeleme tabanlı ABC ve PSO algoritmaları ile hastalıklı bölgelerin çok yüksek doğrulukta tespit edilebildiği görülmektedir. Bununla birlikte, Görüntü 2'nin özellikle kenar bölgelerinde kümeleme performansının her üç algoritma için de düştüğü görülmektedir. Bunun temel nedeni ise görüntüden kaynaklı olarak bu bölgelerdeki piksel değerlerinin görüntü zenginleştirme işlemlerinden sonra bile yeterince belirginleştirilememesidir.

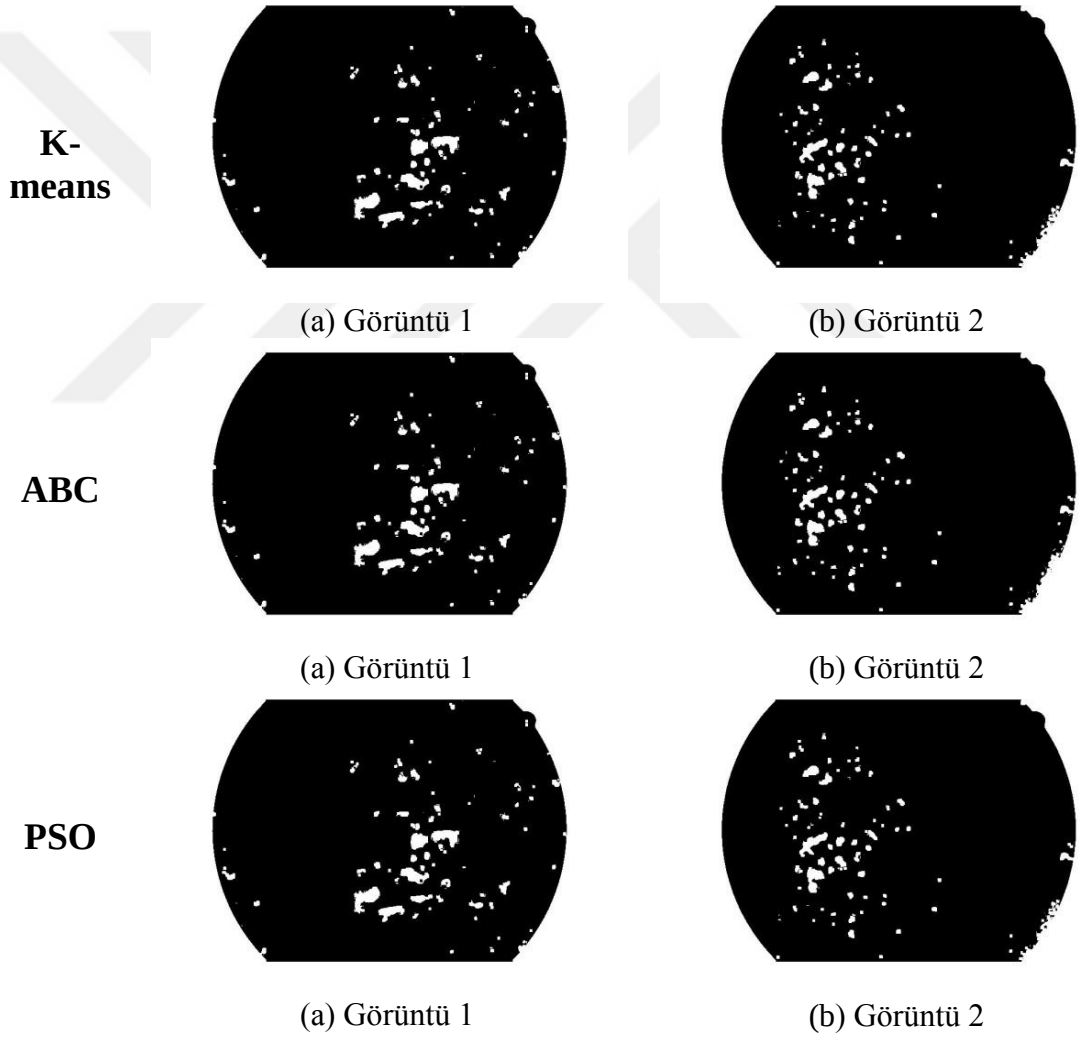

Şekil 4.10 Kümeleme tabanlı K-means, ABC ve PSO algoritmaları ile retinal görüntülerde kanamalı bölgelerin tespiti sonucunda elde edilen ikili görüntüler

Kümeleme sonucunda elde edilen retinal görüntülerdeki kanamalı bölgelerin çizdirilmiş hali Şekil 4.11 ile verilmiştir. Kanamalı bölgelerin belirginleştirilmesi ile hastalığın

yüksek doğrulukta teşhis ve tedavisine olanak sağlayacak görsel görüntüler elde edilmektedir.

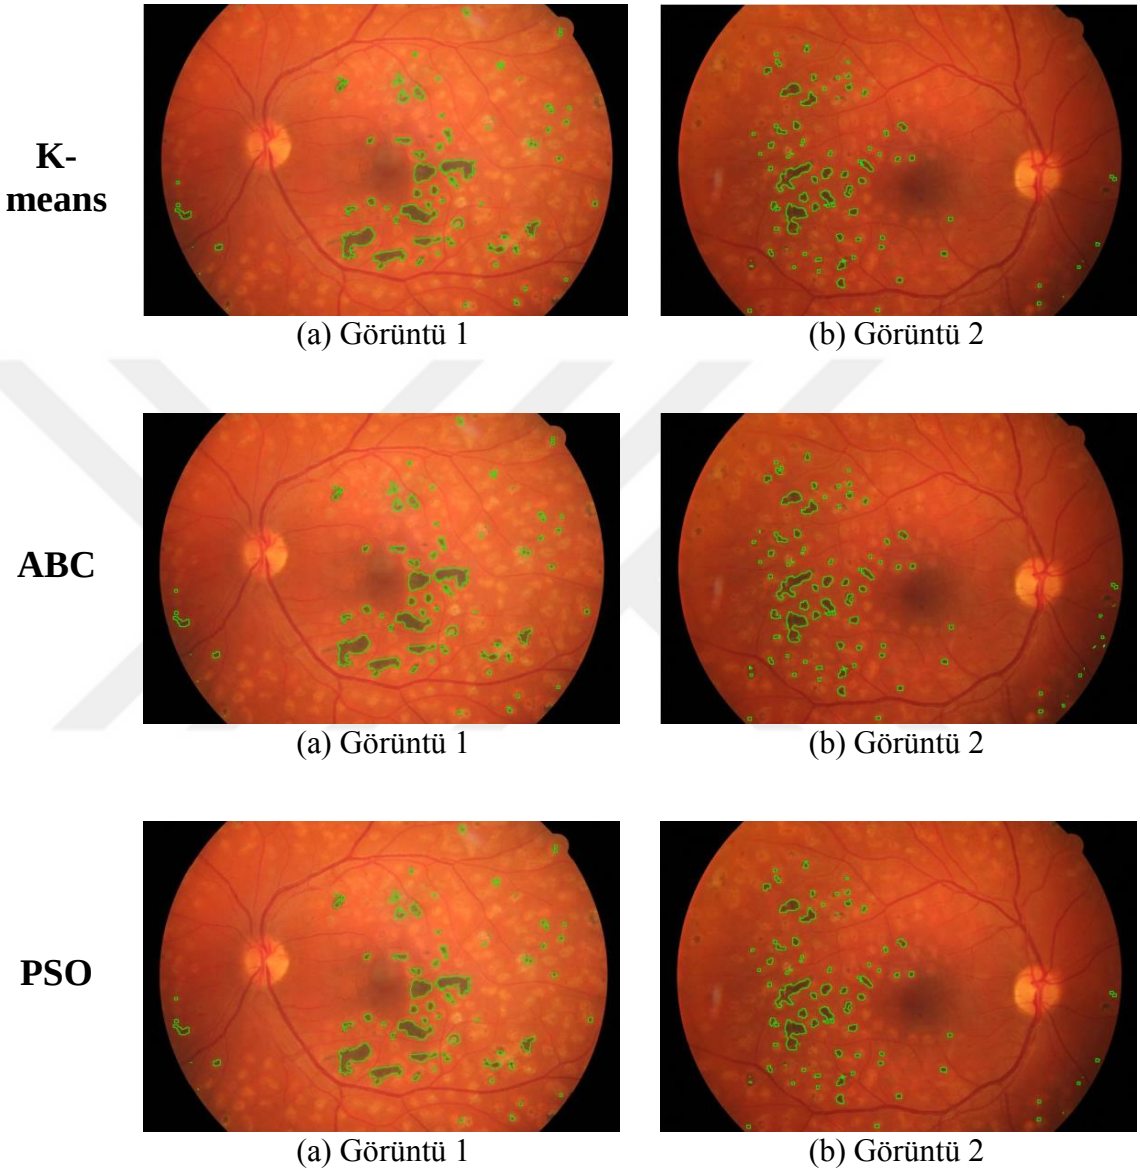

Şekil 4.11. Hastalıklı bölgeleri tespit edilmiş ve çizdirilmiş retinal görüntüler

Retinal görüntülerde DR hastalığından kaynaklanan kanamalı bölgelerin tespitinde ABC ve PSO algoritmalarının ortalama karesel hata ve yakınsama performansları Şekil 4.12 ile gösterilmiştir. 20 rasgele koşmanın ortalamasından elde edilen grafiklerden görüldüğü gibi her iki algoritmada en iyi hata değerlerine benzer çevrimlerde ulaşmaktadır. PSO algoritmasının ortalama karesel hata açısından biraz daha iyi performans gösterdiği görülmektedir.

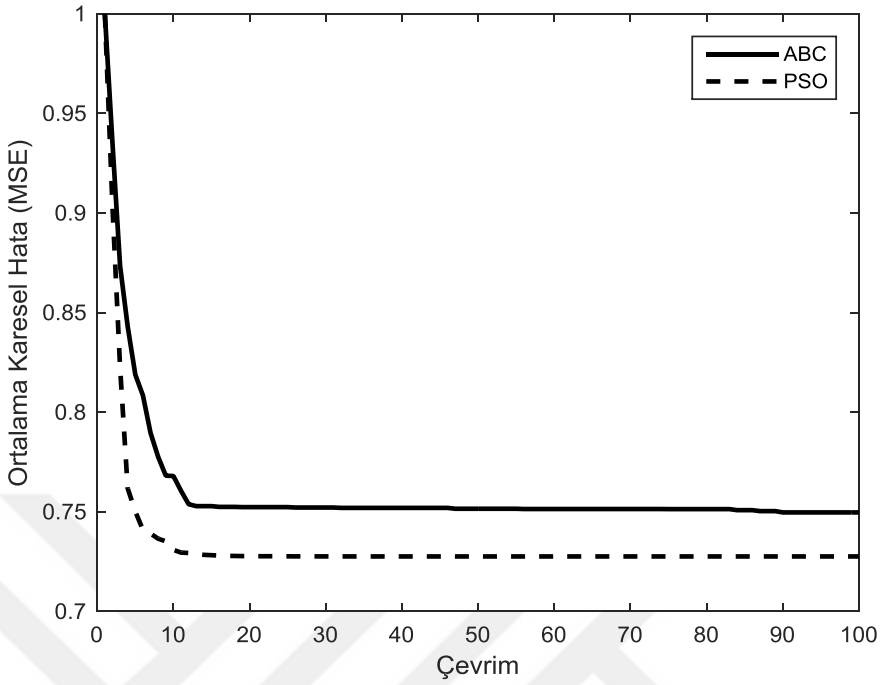

(a) Görüntü 1

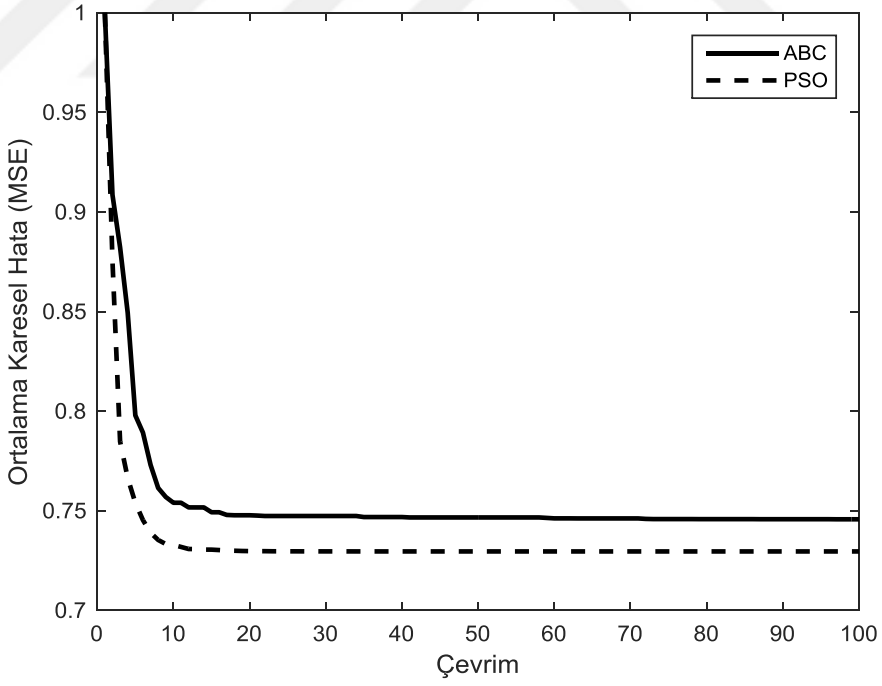

(b) Görüntü 2

Şekil 4.12. Şekil 4.2 (a) ve (b) ile verilen retinal görüntülerde kanamalı bölgelerin tespiti için kullanılan kümeleme tabanlı ABC ve PSO algoritmalarının yakınsama grafikleri

Bu tez çalışması kapsamında, DR hastalığına ait matematiksel bir veri tabanı oluşturacak bir yaklaşımın geliştirilmesi de amaçlanmıştır. Buna yönelik olarak DR hastalıklı retinal görüntüler üzerinde yeni kanamalı bölgelerin toplam alanının (θ_i), göz görüntüsünün toplam alanına (β_i) oranı piksel tabanlı olarak hesaplanmıştır. Bu oran belirli periyotlar ile takip edilerek veri tabanı oluşturulduğu takdirde hastalığın seyri ve ilerleyişi hakkında önemli bilgiler verebilmektedir. Şekil 4.2 (a) ve (b) retinal görüntüleri için algoritmalar tarafından elde edilen piksel tabanlı alan oranları aşağıda verilmiştir.

Şekil 4.2 (a) görüntüsü, $\frac{\theta_i}{\beta_i} = 0.032988$

Şekil 4.2 (b) görüntüsü, $\frac{\theta_i}{\beta_i} = 0.024702$

5. BÖLÜM

SONUÇ VE DEĞERLENDİRME

Bilgisayarlı görüntüleme ve analiz teknikleri hastalıklara teşhis konulmasında ve tedavi edilmesinde yaygın bir şekilde kullanılmaktadır. Özellikle retinal hastalıklar bilgisayar tabanlı analiz yöntemleri ile başarılı bir şekilde tespit edilerek tedavi edilebilmektedir. Retinal hastalıkların bir sonucu olarak kılcal damarlarda meydana gelen daralma, genişleme ve kanamalar hastalık hakkında bilgiler vermektedir.

Bu tez çalışmasında, Karaboğa tarafından geliştirilen ve literatürde farklı alanlarda başarılı bir şekilde kullanılan sürü zekasına dayalı ABC algoritmasının retinal görüntü analizindeki başarımı detaylı bir şekilde incelenmiştir. Ayrıca, literatürde yaygın olarak kullanılan klasik algoritmalardan K-means algoritmasının ve bir diğer sürü zekasına dayalı sezgisel algoritma olan PSO algoritmasının retinal görüntü analizindeki performansları incelenerek ABC algoritması ile mukayese edilmiştir.

Tez çalışmasının ilk bölümünde, göz anatomisi ve retinal yapı anlatılarakretinal görüntülerde damar bölütlemenin önemi açıklanmıştır. Ayrıca DR hastalıklı retinal görüntülere de bu bölümde değinilmiş ve retinal görüntü analizinde kullanılan en önemli yöntemlerden birisi olan FFA görüntüleme tekniği anlatılarak bu tekniğin özellikle DR hastalıklı göz görüntülerinde hastalık teşhisindeki önemi analiz edilmiştir. Bu bölümde ayrıca retinal görüntülerde damar bölütleme ve DR hastalıklı retinal görüntülerde kanamalı bölgelerin tespiti uygulamalarına yönelik detaylı bir literatür taraması da sunulmuştur.

Tez çalışmasının ikinci bölümünde, görüntü analizinde kullanılan renk uzayları, K-means kümeleme algoritması ve görüntü zenginleştirmede kullanılan temel morfolojik işlemler detaylı bir şekilde anlatılmıştır.

Tez çalışmasının üçüncü bölümü ise retinal görüntü analizinde kullanılan sürü zekasına dayalı ABC ve PSO algoritmalarının detaylı bir şekilde anlatımını içermektedir.

Tez çalışmasının dördüncü bölümünde damar bölütleme ve yeni kanamalı bölgelerin tespitine yönelik elde edilen benzetim sonuçları verilmiştir. Damar bölütleme uygulamalarında K-means, ABC ve PSO algoritmalarının damarları başarılı bir şekilde ayırt edebildiği ve benzer sonuçlar ürettiği görülmüştür. Ayrıca, ABC ve PSO algoritmalarının yakınsama grafikleri incelendiğinde her iki algoritmanında en düşük hata değerlerine yaklaşık olarak aynı çevrimde ulaştığı görülmektedir. DR hastalıklı retinal görüntülerde yeni kanamalı bölgelerin tespitine yönelik gerçekleştirilen benzetimlerde de K-means, ABC ve PSO algoritmalarının yeni kanamalı bölgeleri başarılı bir şekilde tespit edebildiği görülmüştür. Ayrıca tespit edilen yeni kanamalı bölgelerin çevrelerinin çizdirilmesine yönelik geliştirilen yaklaşım sayesinde bu bölgeler daha belirgin hale getirilmiş böylece teşhis ve tedavi anlamında daha yüksek doğrulukta kararların verilmesine olanak sağlanmıştır. Yeni kanamalı bölgelerin tespit edilerek belirginleştirilmesinin yanı sıra bu bölgelerin piksel tabanlı alan hesaplamalarının yapılmasına yönelik geliştirilmiş olan yaklaşım sayesinde hastanın belirli periyotlar ile takip edilerek hastalığının seyri ve ilerleyişi hakkında önemli bilgiler elde edilmesi amaçlanmıştır. ABC ve PSO algoritmaları için yeni kanamalı bölgelerin tespitinde elde edilen yakınsama grafikleri incelendiğinde her iki algoritmanında benzer hata değerlerine yaklaşık olarak aynı çevrimlerde ulaştığı görülmektedir. Her iki uygulama içinde elde edilen sonuçlar incelendiğinde K-means, ABC ve PSO algoritmalarının kümeleme tabanlı görüntü analizinde başarılı bir şekilde kullanılabileceği görülmüştür. Sezgisel yaklaşımların, K-means algoritması gibi klasik yaklaşımlarla benzer performansa sahip olmasına karşın, düşük parametre bağımlılığı ve yüksek yakınsama hızı gibi önemli avantajları bulunmaktadır. Bu nedenle retinal görüntü analizinde sezgisel yaklaşımların etkin bir şekilde kullanılabileceği söylenebilir.

KAYNAKLAR

1. Gözün Yapısı ve Çalısması 12 Mayıs 2007. (Web sayfası: **http://saglik.tnn.net/altbolumler.asp?SecID=13&SubID=100**), (Erişim tarihi: Eylül 2017)

2. Yahya H., Gözdeki Mucize, Global Kitap, İstanbul, Aralık 2000.

3. M. M. Fraz, P. Remagnino, A. Hoppe, B. Uyyanonvara, A. R. Rudnicka, C. G. Owen, and S. A. Barman, "Blood vessel segmentation methodologies in retinal images-a survey", **Comput. Methods Programs Biomed., vol. 108**, no. 1, pp. 407–433, Oct. 2012.

4. J. Staal, M. D. Abràmoff, M. Niemeijer, M. A. Viergever, and B. Van Ginneken, "Ridge-based vessel segmentation in color images of the retina", **IEEE Trans. Med. Imaging, vol. 23**, no.4, pp. 501–509, 2004.

5. J. V. B. Soares, J. J. G. Leandro, R. M. Cesar Júnior, H. F. Jelinek, and M. J. Cree, "Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification", **IEEE Trans. Med. Imaging, vol. 25**, no. 9, pp. 1214–1222, Sep. 2006.

6. E. Ricci and R. Perfetti, "Retinal blood vessel segmentation using line operators and support vector classification", **IEEE Trans. Med. Imaging, vol. 26**, no. 10, pp. 1357–1365, Oct.2007.

7. D. Marín, A. Aquino, M. E. Gegúndez-Arias, and J. M. Bravo, "A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features", **IEEE Trans. Med. Imaging, vol. 30**, no. 1, pp. 146–158, 2011.

8. A. Bhuiyan, B. Nath, J. Chua, and R. Kotagiri, "Blood vessel segmentation from color retinal images using unsupervised texture classification" , 2007. ICIP 2007. **IEEE International Conference on Image Processing, 2007, vol. 5**, pp. 521–524.

9. S. Chaudhuri, S. Chatterjee, N. Katz, M. Nelson, and M. Goldbaum, "Detection of blood vessels in retinal images using two-dimensional matched filters", **IEEE Trans. Med. Imaging, vol. 8**, pp. 263–269, 1989.

10. A. Hoover, V. Kouznetsova, and M. Goldbaum, “Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response”, **IEEE Trans. Med. Imaging, vol. 19**, no. 3, pp. 203–210, 2000.

11. Z. Yavuz and C. Kose, “Blood vessel segmentation from retinal images based on enhencement methods” in Signal Processing and Communications Applications Conference (SIU), 2014 22. , 2014, pp. 907–910.

12. M. M. Fraz, A. Basit, P. Remagnino, A. Hoppe, and S. A. Barman, “Retinal vasculature segmentation by morphological curvature, reconstruction and adapted hysteresis thresholding”, in 2011 7th International Conference on Emerging Technologies, 2011, pp.1-6.

13. A. M. Mendonça and A. Campilho, “Segmentation of retinal blood vessels by combining the detection of centerlines and morphological reconstruction”, **IEEE Trans. Med. Imaging, vol. 25**, no. 9, pp. 1200–13, Sep. 2006.

14. O. Chutatape, L. Zheng, and S. M. Krishnan, “Retinal blood vessel detection and tracking by matched Gaussian and Kalman filters” in Engineering in Medicine and Biology Society, 1998. **Proceedings of the 20th Annual International Conference of the IEEE, vol. 6**, pp. 3144–3149, 1998,

15. F. K. H. Quek and C. Kirbas, “Vessel extraction in medical images by wave-propagation and traceback”, **Med. Imaging, IEEE Trans., vol. 20**, no. 2, pp. 117–131, 2001.

16. M. Frangi, Alejandro F. and Niessen, Wiro J. and Vincken, KoenL. and Viergever, “Multiscale vessel enhancement filtering”, **Medical Image Computing and Computer-Assisted Interventation, 1998, vol. 1496**, pp. 130–137.

17. M. E. Martinez-Perez, A. D. Hughes, S. A. Thom, A. A. Bharath, and K. H. Parker, “Segmentation of blood vessels from red-free and fluorescein retinal images”, **Med. Image Anal., vol. 11**, no. 1, pp. 47–61, Feb. 2007.

18. L. Espona, M. Carreira, M. Ortega, and M. Penedo, "A snake for retinal vessel segmentation", **Pattern Recognition and Image Analysis, vol. 4478,** pp. 178–185, 2007.

19. B. Al-Diri, A. Hunter, and D. Steel, "An active contour model for segmenting and measuringretinal vessels", **IEEE Trans. Med. Imaging, vol. 28**, no. 9, pp. 1488–97, Sep. 2009.

20. Prof. Dr. Ovalı T., Fulya Retina, Makula Dekolmanı, Yaşa Bağlı Makula Dejeneresansı, 19 Ekim 2012, (Web sayfası: **http://www.fulyaretina.com**), (Erişim tarihi: Eylül 2017)

21. Chen, K.Y, Fuh, C.S., 2009. High Dynamic Range Image Processing To Screen Diabetic Retinopathy. Graduate Institute of Biomedical Electronics and Bioinformatics, National Taiwan University. (Web sayfası: **https://www.csie.ntu.edu.tw/~fuh/personal/HighDynamicRangeImageProcessingtoScreenDiabetic.pdf**), (Erişim tarihi: Eylül 2017)

22. Li Helen K, Horton Mark, Bursell Sven-Erik, Cavallerano Jerry, Zimmer-GallerIngrid, Tennant Mathew, et al. Telehealth practice recommendations for diabetic retinopathy. **Telemedicine Journal and e-Health, vol. 10**, no. 4, pp. 469-482, 2011.

23. Luo,G., Chutatape, O., LI, G., Krishnan, S.M., 2001, Abnormality detection in automated mass screening system of diabetic retinopathy, Computer–Based Medical Systems.Proceedings 14th IEEE Symposium On, 132-137.

24. Archarya, U.R., Lim, C.M., et al., 2009. Computer based detection of diabetes retinopathy stages using digital fundus images. Proceedings of the Institution of Mechanical Engineers, Part H. **Journal of Engineering in Medicine, vol. 223**, no. 7, pp. 545-553.

25. Sanchez, C.I., Hornero, R., 2007. A Novel Automatic Image Processing Algorithm For Detection Of Hard Exudates Based On Retinal Image Analysis. **Medical Engineering & Physics, vol. 30,** no. 3, 350–357.

26. Gardner, G.G., Keating, D., 1996. Automatic detection of diabetic retinopathy using an artificial neural network: a screening tool. **British Journal Optohomology, vol. 80**, no. 11, pp. 940- 944.

27. Singh, N., Tripathi, C.R, 2010. International Journal of Computer Applications. **BIJCA Journal, vol. 9**, no. 3, pp. 1186-1648.

28. Sinthanayothin, C., Boyce, J.F., 2002. Automated detection of diabetic retinopathy on digital fundus images. **Diabetic Medicine, vol. 19**, no.2, pp. 105–112.

29. Saravanan, P., 2008. Retinal fundus image constrast normalization using mixture of Gaussians., 42nd Asilomar Conference on Signals. Systems and Computers, pp. 647-650.

30. Yin D., Pan J., 2008. Medical Image Categorization Based on Gaussian Mixture Mode, BMEI 2008. International Conference on BioMedical Engineering and Informatics, pp. 128 - 131.

31. Smith R.T., Nagasaki T., Sparrow J.R., BarbazettoI, Klaver CC, Chan JK. A method of drusen measurement based on the geometry of fundus reflectance. **Biomed. Eng. Online; vol. 2**, no. 10, 2003.

32. Van Grinsven M.J., Lechanteur Y.T., Vande Ven J.P., Van Ginneken B., Hoyng C.B., Theelen T, et.al., Automatic drusen quantification and risk assessment of age-related macular degeneration on color fundus images. **In vest Ophthalmol Vis Sci 2013, vol.54**, pp. 3019–3027.

33. B. Harangi ,I. Lazar, A. Hajdu, Automatic exudate detection using active contour model and region wise classification, Proceedings of the Conference of the Engineering in Medicine and Biology Society (EMBC2012), 2012, pp.5951–5954.

34. Karaboga, D., 2005. Technical Report: An Idea based on Honey Bee Swarm for Numerical Optimization. Computer Engineering Department, Engineering Faculty, Erciyes University, Turkey. (Web sayfası **http:// mf.erciyes.edu.tr/abc/pub/tr06_2005.pdf**), (Erişim tarihi: Eylül 2017)

35. Kennedy, J., Eberhart, R., 1995. Particle swarm optimization, pp. 1942-1948. IEEE International Conference on Neural Networks, 27 November-01 December, 1995, Perth.

36. Rafael C. Gonzalez, Richard E. Woods, Steven L. Eddins, Digital Image Processing Using MATLAB, Prentice Hall, 2003.

37. Yılmaz İ., Renk Uzayları ve Dönüşüm Algoritmaları, Doktora Tezi, Selçuk Üniversitesi Fen bilimleri Enstitüsü, Konya, 138, (2002).

38. Trémeau A., 2006 Lecture on Color spaces and digital color, Laboratoire LIGIV Université Saint Etienne,France IPCV 2006 – Budapest.

39. Serra J. Image Analysis and Mathematical Morphology, Academic Press, London.

40. Acar U. ve Bayram B. (2009). Building Extraction With Morphology, International Conference on Modelling Optimization and Computing, Cilt. 38, Sayfa: 3573-3578.

41. Girod, B. (2007). Digital Image Processing, Ders Notları, Stanford Üniversitesi Elektrik Mühendisliği Bölümü, Kaliforniya.

42. Bellanger, M. (2000). Digital Processing of Signal, Theory and Practice, John Wiley and Sons, USA.

43. MacQueen, J. B. (1965). On convergence of K-means and partitions with minimum average variance. **Annals of Mathematical Statistics, vol. 36**, pp. 1084.

44. Kamber M. 2001. Data Mining Concepts and Techniques, Morgan Kauffmann Publishers Inc. San Francisco 550s.

45. Kogan J., Nicholas C., Teboulle M., ed. 2006. Survey of Clustering Data Mining Techniques. Grouping Multidimensional Data, pp. 25-71, USA

46. Tan, P. N.,Steinbach, M., and Kumar, V. 2006. Introductionto Data Mining, Addison Wesley, 165s.

47. Nathan S. N., Angela Y. W. 2002. An Efficient K-Means Clustering Algorithm: Analysis and Implementation. **IEEE Transactions On Pattern Analysis And Machine Intelligence, 44**(2002), 881-892.

48. Bonabeau, E., Dorigo, M., Theraulaz, G., Swarm Intelligence: From Natural to Artificial Systems, Oxford University Press, New York, 1999.

49. Karaboga, D., Akay, B., 2009. A comparative study of Artificial Bee Colony algorithm. **Applied Mathematics and Computation, vol. 214**, no. 1, pp. 108-132.

50. Karaboga, D., Akay, B., 2011. A modified Artificial Bee Colony (ABC) algorithm for constrained optimization problems. **Applied Soft Computing, vol. 11,** no. 3, pp. 3021- 3031.

51. Karaboga, D.,Basturk, B., 2008. On the performance of artificial bee colony (ABC) algorithm. **Applied Soft Computing, vol. 8**, no. 1, pp. 687-697.

52. Karaboğa, N., 2009. A New Design Method Based On Artificial Bee Colony Algorithm for Digital IIR Filters, **Journal of the Franklin Institute, vol. 346**, no. 4, pp. 328-348.

53. Karaboga, D., Basturk, B., 2007. A Powerful and Efficient Algorithm for Numerical Function Optimization: Artificial Bee Colony (ABC) Algorithm, **Journal of Global Optimization, vol. 9**, no. 3, pp. 459-471.

54. Karaboga, D., Akay, B., 2009. A Comparative Study of Artificial Bee Colony Algorithm. **Applied Mathematics and Computation, vol. 214**, no. 1, pp. 108-132.

55. Karaboga, D., Basturk, B., 2007. A Powerful and Efficient Algorithm for Numerical Function Optimization. Artificial Bee Colony (ABC) Algorithm, **Journal of Global Optimization, vol. 9**, no. 3, pp. 459-471.

56. Karaboga, D., Basturk, B., 2008. On the Performance of Artificial Bee Colony (ABC) Algorithm, **Applied Soft Computing, vol. 8**, no. 1, pp. 687-697.

57. Karaboga, D., Basturk, B., 2007. A Powerful and Efficient Algorithm for Numerical Function Optimization. Artificial Bee Colony (ABC) Algorithm. **Journal of Global Optimization, vol. 9**, no. 3, pp. 459-471

58. Karaboga, D., Basturk, B., 2007. Artificial Bee Colony (ABC) Optimization Algorithm for Solving Constrained Optimization Problems, Lecture Notes in Computer Science. **Advances in Soft Computing, vol. 4529**, pp. 789-798,

59. High-Resolution Fundus (HRF) Image Database (Web sayfası: **http://www5.cs.fau.de**), (Erişim tarihi: Eylül 2017)

60. Z. Yavuz and C. Kose, "Vessel Segmentation in Retinal Images using Multiscale Image Enhancement and Clustering" Signal Processing and Communications Applications Conference (SIU), 2015 23nd, pp. 581–584.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı, Soyadı: Hakan DURAN
Uyruğu: Türkiye (TC)
Doğum Tarihi ve Yeri: 10 Nisan 1991, Sürmene
Medeni Durumu: Bekâr
Tel: +90 536 544 07 51
email: hakanduran@erciyes.edu.tr
Yazışma Adresi: Erciyes Üniversitesi Mühendislik Fakültesi Mekatronik Mühendisliği Bölümü 38030 Melikgazi/KAYSERİ

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Lisans	ERÜ Mühendislik Fakültesi Mekatronik Mühendisliği Bölümü	2013
Lise	Sürmene Hasan Sadri Yetmişbir Anadolu Lisesi, Trabzon	2009

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2016- Halen	Erciyes Üniversitesi Mühendislik Fakültesi	Araştırma Görevlisi

YABANCI DİL

İngilizce

YAYINLAR

1. Çetinkaya M.B., Duran H., "Kümeleme Tabanlı Diferansiyel Gelişim Algoritması Kullanarak Retinal Kılcal Damarların Bölütlenmesi", Tıp Tekno 2017 Tıp Teknolojileri Kongresi, TRABZON, TÜRKIYE, 12-14 Ekim 2017, pp.109-112

2. Çetinkaya M.B., Duran H., Cikit H.E., Cihan M.C., "Fundus Floresan Anjiografi Görüntülerinde Diyabetik Retinopati Nedeniyle Oluşan Kanama Alanlarının Belirlenmesi", 20. Biyomedikal Mühendisliği Ulusal Toplantısı, İZMİR, TÜRKIYE, 3-5 Kasım 2016, ss.14-14