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

YAPAY ARI KOLONİ ALGORİTMASI KULLANILARAK DİYABETİK RETİNOPATİ HASTALIĞININ TESPİTİ

Hazırlayan
Hüseyin Emre CIKIT

Danışman
Dr. Öğr. Üyesi Mehmet Bahadır ÇETİNKAYA

Yüksek Lisans Tezi

Haziran 2019
KAYSERİ

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

YAPAY ARI KOLONİ ALGORİTMASI KULLANILARAK DİYABETİK RETİNOPATİ HASTALIĞININ TESPİTİ

(Yüksek Lisans Tezi)

Hazırlayan
Hüseyin Emre CIKIT

Danışman
Dr. Öğr. Üyesi Mehmet Bahadır ÇETİNKAYA

Bu çalışma, Erciyes Üniversitesi Bilimsel Araştırma Projeleri Birimi tarafından 7187 kodlu proje ile desteklenmiştir.

Haziran 2019
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.

Hüseyin Emre CIKIT



"Yapay Arı Koloni Algoritması Kullanılarak Diyabetik Retinopati Hastalığının Tespiti" adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi' ne uygun olarak hazırlanmıştır.

Hazırlayan
Hüseyin Emre CIKIT

Danışman
Dr. Öğr. Üyesi Mehmet Bahadır ÇETİNKAYA

Mekatronik Mühendisliği ABD Başkanı

Prof. Dr. Şahin YILDIRIM

Dr. Öğr. Üyesi Mehmet Bahadır ÇETİNKAYA danışmanlığında **Hüseyin Emre CIKIT** tarafından hazırlanan **"Yapay Arı Koloni Algoritması Kullanılarak Diyabetik Retinopati Hastalığının Tespiti"** adlı bu çalışma jürimiz tarafından Erciyes Üniversitesi Fen Bilimleri Enstitüsü **Mekatronik Mühendisliği** Anabilim Dalında **Yüksek Lisans** tezi olarak kabul edilmiştir.

27 / 06 / 2019

JÜRİ:

Danışman : Dr. Öğr. Üyesi Mehmet Bahadır ÇETİNKAYA .....

Üye : Prof. Dr. Şahin YILDIRIM .....

Üye : Dr. Öğr. Üyesi Nuri KAPUCU .....

ONAY:

Bu tezin kabulü Enstitü Yönetim Kurulunun 02/07/2019 tarih ve 2019/37-09 sayılı kararı ile onaylanmıştır.

02 / 07 / 2019

Prof. Dr. Mehmet AKKURT

Enstitü Müdürü

TEŞEKKÜR

Tez çalışmam süresince ilgi, alaka ve samimiyetiyle her türlü desteği ve fedakârlığı sağlayan, hem bilimsel katkılarıyla hem de tecrübesiyle çalışmama yön veren değerli hocam Dr. Öğr. Üyesi Mehmet Bahadır ÇETİNKAYA'ya teşekkürü bir borç bilirim.

Ayrıca, bu çalışmayı 7187 proje numaralı bilimsel araştırma projesi ile destekleyen Erciyes Üniversitesi Bilimsel Araştırma Projeleri (BAP) Birimine teşekkür ederim.

Son olarak bugünlere gelmemdeki en büyük pay sahibi olan ve bana her türlü maddi ve manevi desteği bir an olsun esirgemeyen aileme en içten teşekkürlerimi ve saygılarımı sunarım.

Hüseyin Emre CIKIT

Haziran 2019, KAYSERİ

YAPAY ARI KOLONİ ALGORİTMASI KULLANILARAK DİYABETİK RETİNOPATİ HASTALIĞININ TESPİTİ

Hüseyin Emre CIKIT

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Haziran 2019
Danışman: Dr. Öğr. Üyesi Mehmet Bahadır ÇETİNKAYA

ÖZET

Diyabetik Retinopati (Diabetic Retinopathy, DR) insülin hormonunun yetersiz ve düzensiz salgılanmasına bağlı olarak ortaya çıkan ve retina tabakasındaki kan damarlarının yapısını bozan ilerleyici bir hastalıktır. DR hastalığı doğru bir şekilde teşhis edilerek uygun tedavi yöntemleri geliştirilmez ise zamanla önemli oranlarda görme kayıpları ortaya çıkar. DR hastalığının yüksek doğrulukta teşhis edilmesini sağlayan en etkili yöntemlerden birisi Fundus Floresein Anjiyografi (FFA) yöntemi olup, FFA ile DR hastalığının tanısı ve takibi etkin bir şekilde yapılabilmektedir.

Bu tez çalışmasında, FFA retinal görüntüler üzerinde DR hastalığı sonucu oluşan yeni kanamalı bölgeler tespit edilerek hastalığın seyrinin izlenmesine yönelik sezgisel algoritmalara dayalı yaklaşımlar geliştirilmiştir. Birçok hastalıkta olduğu gibi DR hastalığının da tespiti, tedavisi ve hastanın tedaviye cevap verip veremediğinin takibi son derece önemlidir. Geliştirilmiş olan sezgisel tabanlı yöntemler sayesinde yüksek doğrulukta elde edilen bilimsel veriler kullanılarak belirli dönemlerle hastalığın seyrinin izlenmesi sağlanabilecektir.

Retinal görüntüler üzerindeki yeni kanamalı bölgeler; K-means kümeleme, sezgisel algoritmalar olan Yapay Arı Koloni (ABC) ve Diferansiyel Gelişim (DE) algoritmaları kullanılarak tespit edilmiştir. İlk olarak, yeni kanamalı bölgelerin daha net ve anlaşılır bir şekilde görülebilmesi için bu bölgelerin çevreleri algoritmalar ile çizdirilerek daha belirgin hale getirilmiştir. Daha sonra, bu bölgelerin piksel tabanlı alan hesaplamaları algoritmalar ile yapılarak hastalık ve hastalığın seyri hakkında daha objektif verilerin elde edilmesi sağlanmıştır. Son olarak, geliştirilmiş olan algoritmaların performansları mukayese edilerek sonuçlar üzerinden değerlendirmeler yapılmıştır.

Anahtar Kelimeler: Diyabetik Retinopati (DR), K-means Kümeleme Algoritması, Yapay Arı Koloni (ABC) Algoritması, Diferansiyel Gelişim (DE) Algoritması

DIAGNOSIS OF DIABETIC RETINOPATHY BY USING ARTIFICIAL BEE COLONY ALGORITHM

Hüseyin Emre CIKIT

Erciyes University, Graduate School of Natural and Applied Sciences
Master Thesis, June 2019
Supervisor: Asst. Prof. Dr. Mehmet Bahadır ÇETİNKAYA

ABSTRACT

Diabetic retinopathy (DR) is a progressive disease caused by insufficient and irregular secretion of insulin hormone and leads to deterioration in the structure of blood vessels in the retinal layer. If DR cannot be correctly diagnosed and appropriate treatment methods are not developed, the risk of vision loss arises significantly. Fundus Fluorescein Angiography (FFA) is one of the most effective methods used in the diagnosis and follow up of the disease.

In this thesis, approaches based on heuristic algorithms have been improved in order to identify the new hemorrhagic regions on a FFA retinal image and monitor the course of the disease. By means of the data with high accuracy obtained by using the heuristic methods improved a database of the disease can be created and thus the course of the disease can be followed up in certain periods.

In order to identify the new hemorrhagic regions on retinal images, K-means clustering which is one of the most common conventional clustering methods, swarm based artificial bee colony (ABC) and population based differential evolution (DE) algorithms have been used. First of all, in order to make the new hemorrhagic regions more visible, these regions have been clarified by the algorithms. Then, pixel based area calculation of the new hemorrhagic regions have been made by the algorithms in order to provide more objective data about the disease and course of disease. Finally, the performances of the improved algorithms have been compared and the results were evaluated.

Keywords: Diabetic retinopathy (DR), K-means Clustering Algorithm, Artificial Bee Colony (ABC) Algorithm, Differential Evolution (DE) Algorithm.

İÇİNDEKİLER

YAPAY ARI KOLONİ ALGORİTMASI KULLANILARAK DİYABETİK RETİNOPATİ HASTALIĞININ TESPİTİ

BİLİMSEL ETİĞE UYGUNLUK ii
YÖNERGEYE UYGUNLUK iii
KABUL VE ONAY iv
TEŞEKKÜR v
ÖZET vi
ABSTRACT vii
İÇİNDEKİLER viii
KISALTMALAR x
TABLOLAR LİSTESİ xi
ŞEKİLLER LİSTESİ xii

GİRİŞ 1

1. BÖLÜM
GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. Göz Anatomisi 4
1.2. Diyabetik Retinopati Hastalığı 5
1.3. Fundus Floresein Anjiografi Yöntemi ile DR Hastalığının Teşhisi 8

2. BÖLÜM
RENK UZAYLARI VE KÜMELEME YÖNTEMİ

2.1. Renk Uzayları 11
2.1.1 RGB Renk Uzayı 12
2.1.2. CIE Lab Renk Uzayı 13
2.1.3. Gri Seviyeli Görüntü 14

2.1.4. İkili Görüntü 15
2.2 Histogram Analizi 16
2.3 Görüntü Zenginleştirme 18
2.3.1 Filtreleme 19
2.3.2 Morfolojik İşlemler 20
2.4. Kümeleme Yöntemi 22
2.4.1 K-Means Kümeleme Algoritması 23

3. BÖLÜM
RETİNAL GÖRÜNTÜ ANALİZİNDE KULLANILAN SEZGİSEL ALGORİTMALAR

3.1. Yapay Arı Koloni Algoritması 26
3.2. Diferansiyel Gelişim Algoritması 31
3.2.1. Başlangıç Popülasyonu 32
3.2.2. Mutasyon 32
3.2.3. Çaprazlama 33
3.2.4. Seleksiyon 33

4. BÖLÜM
BENZETİMLER

4.1. Benzetimler ve Sonuçlar 35

5. BÖLÜM

SONUÇ VE TARTIŞMA 48
KAYNAKÇA 50
ÖZGEÇMİŞ 53

KISALTMALAR

Sembol	Anlamı
ABC	Yapay Arı Koloni (Artificial Bee Colony)
CIE Lab	Commission Internationale de I'Eclairage Lab
CR	Çaprazlama Oranı (Crossover Rate)
D	Optimize edilecek parametre sayısı
DE	Diferansiyel Gelişim (Differential Evolution)
DR	Diyabetik Retinopati (Diabetic Retinopathy)
F	Ölçekleme faktörü (Scaling Factor)
FFA	Fundus Fluoresein Anjiografi
ED	Öklid Mesafesi (Euclidean Distance)
HRF	High-Resolution Fundus
MSE	Ortalama Karesel Hata (Mean Squared Error)
NP	Popülasyon Sayısı (Number of Population)
RGB	Kırmızı (Red, R), Yeşil (Green, G) ve Mavi (Blue, B)
WHO	Dünya Sağlık Örgütü (World Health Organization)

TABLOLAR LİSTESİ

Tablo 4.1. Retinal görüntü analizine yönelik geliştirilmiş olan kümeleme tabanlı ABC ve DE algoritmalarına ait parametre değerleri 36

ŞEKİLLER LİSTESİ

Şekil 1.1. Gözün yapısı 5
Şekil 1.2. Sağlıklı ve DR hastalığı bulunan retina görüntüleri 6
Şekil 1.3. Sızıntılar sonrası ortaya çıkan kandaki yağ elemanları 7
Şekil 1.4. Retinada damarlardan dışarıya sızan kan 8
Şekil 1.5. Retinada beyaz pamuksu doku oluşumu 8
Şekil 1.6. Sağlıklı bir gözün FFA yöntemiyle elde edilen görüntüsü 9
Şekil 1.7. DR hastalığı bulunan bir gözün FFA yöntemiyle elde edilen görüntüsü 10
Şekil 2.1. Renk uzayları 12
Şekil 2.2. RGB renk uzayı 12
Şekil 2.3. RGB renk uzayında peppers.png görüntüsü 13
Şekil 2.4. CIE Lab renk uzayı 14
Şekil 2.5. CIE Lab renk uzayında peppers.png görüntüsü 14
Şekil 2.6. Gri seviye renk skalası 15
Şekil 2.7. RGB renk uzayındaki bir görüntünün ikili görüntü karşılığı 15
Şekil 2.8. RGB renk uzayının katmanları ve bu katmanlara ait görüntülerin histogram grafikleri 17
Şekil 2.9. Lab renk uzayının katmanları ve bu katmanlara ait görüntülerin histogram grafikleri 18
Şekil 2.10. Gri seviyeli görüntü ve bu görüntüye ait histogram grafiği 18
Şekil 2.11. Filtreleme işlemi 19
Şekil 2.12. Unsharp filtresinin uygulanması 20
Şekil 2.13. Morfolojik işlemler için kullanılabilecek örnek iki yapısal filtre elemanı 20
Şekil 2.14. Morfolojik aşındırma işlemi 21
Şekil 2.15. Morfolojik açma işlemi 22
Şekil 2.16. Örnek çalışma uzayı 24
Şekil 2.17. Küme merkezlerinin belirlenmesi 24
Şekil 2.18. Küme merkezlerine göre sınıflandırma 24
Şekil 2.19. Sınıflandırma ve en iyi çözümün gerçekleştirilmesi 25
Şekil 3.1. ABC algoritmasının akış diyagramı 31
Şekil 4.1. DR hastalıklı retinal görüntüler 35

Şekil 4.2. Görüntü zenginleştirme işlemleri sonucu elde edilen göz görüntüleri 37
Şekil 4.3. RGB renk uzayındaki retinal görüntülerin CIE Lab renk uzayındaki karşılıkları 38
Şekil 4.4. CIE Lab renk uzayındaki retinal görüntülerin L, a ve b katmanları 39
Şekil 4.5. DR hastalıklı retinal görüntülerde yeni kanamalı bölgelerin tespiti sonucu elde edilen görüntüler (MSE hata fonksiyonu).....41
Şekil 4.6. DR hastalıklı retinal görüntülerde yeni kanamalı bölgelerin tespiti sonucu elde edilen görüntüler (ED hata fonksiyonu).....42
Şekil 4.7. Retinal görüntülerde yeni kanamalı bölgelerin çevrelerinin çizdirilmesi (MSE hata fonksiyonu).....43
Şekil 4.8. Retinal görüntülerde yeni kanamalı bölgelerin çevrelerinin çizdirilmesi (ED hata fonksiyonu).....44
Şekil 4.9. Birinci retinal görüntü için ABC ve DE algoritmalarının MSE ve ED yakınsama performansları 46
Şekil 4.10. İkinci retinal görüntü için ABC ve DE algoritmalarının MSE ve ED yakınsama performansları 47

GİRİŞ

Görüntü işleme, görüntü işaretlerinin sayısal yöntemler ile işlenerek dönüştürülmesi, görüntüden bilgi çıkarılması veya görüntüye bilgi eklenmesi gibi işlemleri içermektedir. Görüntü işleme yöntemleri kullanılarak bir görüntü üzerinde iyileştirme, onarma, kenar belirleme, morfolojik işlemler, bölütleme, tanıma, nesne izleme, nesne takibi, şablon eşleme ve görüntü sıkıştırma gibi işlemler yapılabilmektedir.

Görüntü işlemenin en önemli uygulama alanlarından birisi biyomedikal görüntü analizidir. Literatürde retinal görüntü analizi, tomografik görüntü analizi, ultrason görüntü analizi, lenfoma görüntü analizi, damar bölütleme, manyetik rezonans görüntüleme, kırık belirleme ve nodül tespiti gibi biyomedikal görüntü işleme uygulamaları yaygın bir şekilde kullanılmaktadır. Bu tez çalışmasında, en sık karşılaşılan göz hastalıklarından birisi olan Diyabetik Retinopati (Diabetic Retinopathy, DR) hastalığının teşhis ve tedavisine yönelik görüntü işleme uygulamalarının geliştirilmesi amaçlanmıştır.

Günümüzde retinal hastalıkların teşhis ve tedavi sürecinin belirlenmesinde, doktorlar genellikle görüntüler üzerinde göz kararı inceleme yaparak karar vermektedir. Bu çalışmanın temel amacı retinal görüntüler üzerindeki hastalıklı bölgelerin görsel ve matematiksel olarak daha net tanımlanabilmesidir. Böylece verilerin anlık ve periyodik olarak izlenmesi sonucunda hastalığın seyrinin takibi kolaylaşacak ve bunun bir sonucu olarak daha etkili teşhis ve tedavi yaklaşımları ortaya çıkacaktır. Periyodik kontroller sonucunda elde edilen matematiksel veriler karşılaştırılarak hastanın tedaviye verdiği cevap incelenebilecektir. Hastalardan elde edilen verilerden oluşturulacak bir veri tabanı daha sonra bu hastalıkla karşılaşabilecek olan hastalar içinde ne tür bir tedavi uygulanması gerektiği hakkında yardımcı olacaktır.

Benzetimler sonucunda elde edilen verilerin literatür ile uyumlu ve mukayese edilebilir olması gerekmektedir. Bu nedenle kullanılan retinal görüntülerin hastanelerde çekilen ham görüntüler olması geliştirilen yöntemlerin doğruluğu ve uygulanabilirliği açısından önem arz etmektedir. Literatürde yapılan çalışmalarda kullanılan retinal görüntüler genellikle High-Resolution Fundus (HRF) Image, DRIVE veya STARE veri tabanlarından alınmaktadırlar.

Hastalıklı bölgelerin yüksek doğrulukta tespit edilmesinde görüntü işleme teknikleri kullanılırken karşılaşılabilecek iki önemli problem vardır. Bunlar, sağlıklı bölgelerin kontrast değerine çok yakın olan hastalıklı bölgelerin ve çok küçük boyutlu hastalıklı bölgelerin tespit edilmesinin son derece zor olmasıdır. Bu çalışmada filtreleme, morfolojik işlemler, korelasyon, konvolüsyon, eşikleme, bölgesel ayrıştırmayla analiz ve görüntü işleme algoritmalarının kullanılmasıyla bu ve benzeri problemlerin aşılması sağlanmıştır. Görüntü işleme tekniklerinin kullanılmasından sonra hastalıklı bölgeler en yüksek doğrulukta tespit edilmiş ve matematiksel olarak modellenmiş görüntüler elde edilmiştir.

Bu tez çalışmasında, Karaboğa [1] tarafından 2005 yılında önerilmiş olan Yapay Arı Koloni (Artificial Bee Colony, ABC) algoritması ile Price ve Storn [2] tarafından 1995 yılında önerilen Diferansiyel Gelişim (Differential Evolution, DE) algoritmaları, DR hastalıklı göz görüntüleri üzerindeki yeni kanamalı bölgelerin tespitine yönelik kümeleme tabanlı olarak geliştirilmiştir.

Tez çalışmasının ilk bölümünde öncelikle göz anatomisi analiz edilmiştir. Daha sonra DR hastalığının aşamaları, göz üzerindeki etkileri ve yol açabileceği komplikasyonlar açıklanarak bu hastalığın tespit ve teşhisinde kullanılan FFA yöntemi detaylı bir şekilde anlatılmıştır. Son olarak, biyomedikal görüntü işleme alanında göz hastalıklarının teşhisine yönelik yapılan çalışmaları kapsayan bir literatür özeti sunulmuştur.

İkinci bölümde görüntü işleme teorisinin temelini oluşturan renk uzayları ve kümeleme konuları üzerinde durulmuştur. Görüntü oluşumunda önemli bir yere sahip olan renk uzaylarının çeşitleri verilen örnekler ile analiz edilmiştir. Daha sonra kümeleme yönteminin teorisi detaylıca açıklanmış ve en temel kümeleme algoritması olan K-means kümeleme algoritması incelenmiştir.

Üçüncü bölümde ise bu tez çalışmasında kullanılan sürü zekasına dayalı ABC ve popülasyon tabanlı DE algoritmaları detaylı bir şekilde açıklanmıştır.

Çalışmanın dördüncü bölümünde, yeni kanamalı bölgelerin tespitine yönelik geliştirilmiş olan kümeleme tabanlı ABC ve DE algoritmaları anlatıldıktan sonra benzetim sonuçları ve performans mukayeseleri verilmiştir. Benzetimlerde elde edilen sonuçlar detaylıca analiz edilerek performans mukayeseleri gerçekleştirilmiştir.

Son olarak, beşinci bölümde sonuç ve değerlendirmelere yer verilmiştir.

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. Göz Anatomisi

Göz, görme fonksiyonunu gerçekleştiren ve yaklaşık 2,5 cm çapında küresel bir yapıya sahip olan bir duyu organıdır. Anatomik yapısı incelendiğinde göz organının sert tabaka, damar tabaka ve ağ tabaka olmak üzere üç temel tabakayı içerdiği görülmektedir. En dış kısımda bulunan ve gözü çevreleyen sert tabakanın görevi gözü harici etkilere karşı korumaktır. Sert tabaka gözün ön kısmında küresel yapıya sahip saydam bir koruyucu tabaka oluşturur. Kornea olarak adlandırılan bu koruyucu tabakanın görevi gelen ışığı odaklayarak göz bebeğine göndermektir. Kornea tabakası kan damarları içermez fakat içerisinde çok sayıda sinir ucu bulunduğu için çok hassas bir yapıya sahiptir. Gözü çevreleyen ikinci tabaka ise sert tabaka ile ağ tabaka arasında bulunan damar tabakadır. Damar tabaka, içerisinde, göz hücrelerini besleyen kan damarlarını ve yansımayı önleyerek net görüntü elde edilmesini sağlayan siyah renk pigmentlerini içerir. Ayrıca iris ve göz bebeği de damar tabaka içerisinde oluşmaktadır. İris, göze rengini veren ve kaslardan meydana gelen bir tabakadır. İris tabakasını kontrol eden kaslar, korneadan giren ışığın miktarına göre göz bebeğinin büyümesini veya küçülmesini sağlar. İris tabakası tarafından göz bebeğinde oluşturulan büyüme ve küçülme hareketleri sayesinde göze giren ışık miktarı en net görüntüyü elde edecek şekilde ayarlanmış olur. Gözün üçüncü ve en içteki tabakası ise ağ tabaka veya retina olarak adlandırılan tabakadır. Retina, görme sinirlerinin bulunduğu ve görme olayının gerçekleştiği tabakadır. Retina kendi içerisinde göz merceği, sarı benek ve kör nokta bölgelerini içerir. Göz merceği, retinanın gözün ön kısmında bulunan bölgesidir ve görevi göz bebeğinden gelen ışınları göz kasları sayesinde kırarak oluşan ters görüntüyü sarı beneğe iletmektir. Göz merceği aynı zamanda kırma derecesini değiştirerek görüntüsü alınan cismin uzaklığına bağlı

olarak odaklama ayarı yapar ve görmenin net olmasını sağlar. Sarı benek ise retina içerisinde en net görüntünün ters olarak oluştuğu bölgedir. Retina içerisindeki bir diğer yapı olan kör nokta ise sarı benekten alınan ters görüntünün beyine iletilmesini sağlar. Kör nokta görme duyu hücrelerini içermez ve bu nedenle kör noktada görüntü oluşmaz.

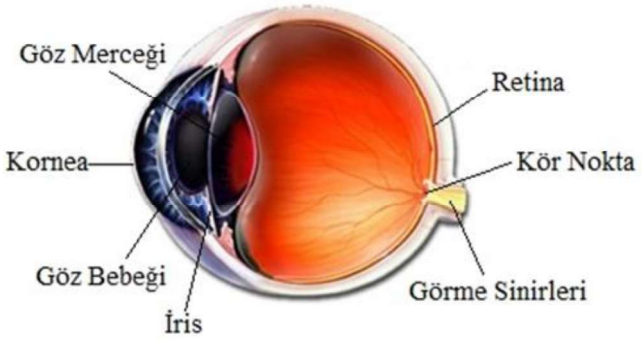

Şekil 1.1. Gözün yapısı

Gözün bir görüntüyü algılayabilmesi için öncelikle cisimlerden yansıyan ışınlara ihtiyaç vardır. Bu yansıyan ışık ışınları, korneadan girerek irisin arkasında yer alan göz merceğine gelir. Göz merceğinde kırılan ışınlar, gözün arka kısmındaki retina tabakasının üzerine düşer ve burada bulunan sarı benek üzerinde ters bir görüntü oluşturur. Bu ters görüntü milyonlarca sinir ucu tarafından alınarak beyindeki görme merkezine iletilir ve bu şekilde görüntü algılanır.

1.2. Diyabetik Retinopati Hastalığı

İnsülin hormonundaki yetersizlik veya hormonal etkideki azalma sonucunda vücutta kan şekeri seviyesi (Hiperglisemi) yükselmekte ve bunun bir sonucu olarak diyabet hastalığı (Diabetes Mellitus) ortaya çıkmaktadır. Dünya Sağlık Örgütü (World Health Organization, WHO) tarafından yayınlanan kronik hastalıklar raporuna göre diyabet hastalığı en yaygın görülen kronik hastalıkların başında gelmektedir. Yaşam tarzı ve beslenme alışkanlıklarındaki değişimlere bağlı olarak diyabet hastalığının önümüzdeki yüz yıllarda da dünyanın karşı karşıya kalacağı en büyük ve küresel sağlık sorunları arasında yer alacağı öngörülmektedir [3-5].

Diyabet hastalığının vücudumuzun birçok bölgesinde olduğu gibi göz üzerinde de olumsuz etkileri bulunmaktadır. Diyabet hastalığına bağlı olarak ortaya çıkan göz

hastalıkları tedavi edilmemeleri durumunda görme fonksiyonlarını zayıflatabilmekte veya tamamen yok edebilmektedir. Diyabetik Retinopati (Diabetic Retinopathy, DR), vücutta kanlanması olan tüm organları etkileyen diyabet hastalığının gözdeki en sık karşılaşılan bulgularından birisidir. DR, retina tabakasındaki hassas kan damarlarının yapısını bozarak bu kan damarlarının sertleşmesine ve çatlamasına yol açar. Retina içerisinde yapısı bozulan kan damarları mikroanevrizmalar, kanamalar, sert eksuda ve pamuk noktalar gibi çeşitli komplikasyonlara neden olur [6-8].

High-Resolution Fundus (HRF) Image Database [9] veri tabanından alınan diyabetik retinopati hastalığı görülen ve görülmeyen hastalara ait FFA görüntüleri aşağıda Şekil 1.2 ile verilmiştir.

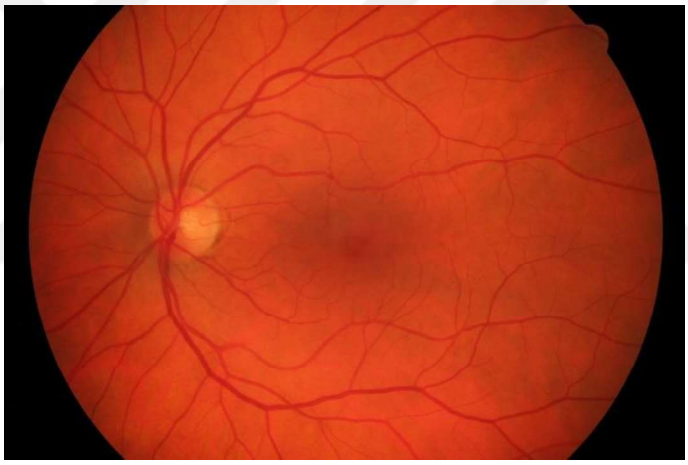

a) Sağlıklı retina

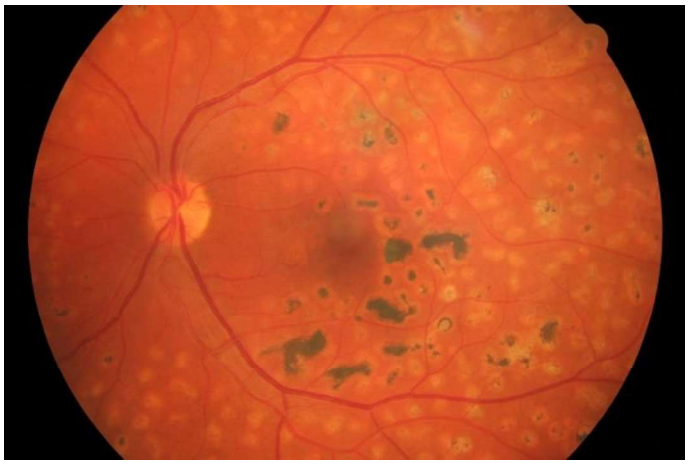

b) Diyabetik retinopati hastalığı bulunan retina

Şekil 1.2. Sağlıklı ve DR hastalığı bulunan retina görüntüleri

DR, kan damarlarındaki yapısal değişimler sonucunda ortaya çıkan ve gözde farklı türde hasarlar meydana getiren bir hastalıktır. Kan damarlarının yapısının bozulması sonucunda küçük baloncuklar oluşur ve bu baloncuklar kanamalara ve damar içindeki sıvının dokulara sızmasına yol açar. Bu sızıntılar ilerleyen aşamalarda retina üzerinde istenmeyen yeni damarlar oluşturur ve bunlar göz içinde ani kanamalara neden olabilir. Kanamalar ilk aşamalarda görme kaybına sebep olmaz ancak hastalık ilerledikçe görmede zayıflık yaşanır ve bu süreç görme kaybı ile sonuçlanabilir.

DR hastalığının ilk aşamasında retina üzerinde küçük kanamalar oluşur. Bir sonraki aşamada ise kan damarlarında tıkanmalar meydana gelir. Son aşama ise zayıf ve kendiliğinden kolayca kanayabilen yeni damarların oluşumu şeklindedir. İnce kan damarlarında oluşan ve dışarıya sıvı sızmasına sebep olan balonlaşmalara mikroanevrizma adı verilmektedir. Bu sızıntılar maküla ödemi adı verilen şişliklere yol açar ve bunun sonucunda retina tabakası üzerinde sıvı artıkları oluşur. Bu sarı renkli birikimler şeklinde görülen artıklar genellikle kandaki yağ elemanlarıdır. Şekil 1.3 ve Şekil 1.4'te başlangıç seviyede diyabetik retinopatisi olan bir hastanın retina görüntüleri verilmiştir. Siyah ok, damar geçirgenliğinin artması sonucunda damar içindeki bazı yağ içeren maddeleri (sert eksudalar) gösterirken, beyaz ok ise damardan dışarıya sızan kanı (mikrohemorajiler) göstermektedir.

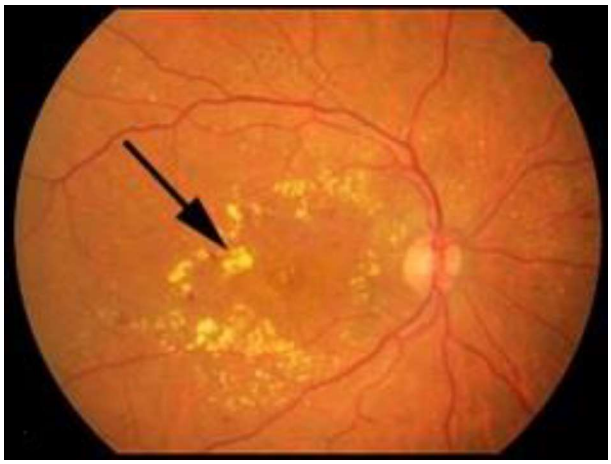

Şekil 1.3. Sızıntılar sonrası ortaya çıkan kandaki yağ elemanları

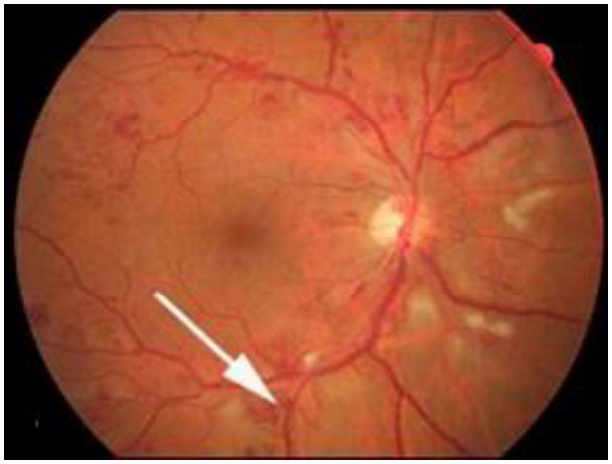

Şekil 1.4. Retinada damarlardan dışarıya sızan kan

Yeterli oksijen bulunmaması durumda, ince kan damarları tıkanabilir ve retinada oksijen eksikliğine bağlı olarak pamuk parçaları gibi beyaz pamuksu dokular ortaya çıkar. Bu pamuksu dokuların en yüksek doğrulukta tespiti için Fundus Fluoresein Anjiografi (FFA) olarak adlandırılan görüntüleme yöntemi kullanılır. Şekil 1.5'de görülen daha koyu renkli alanlar bu pamuksu dokuları göstermektedir.

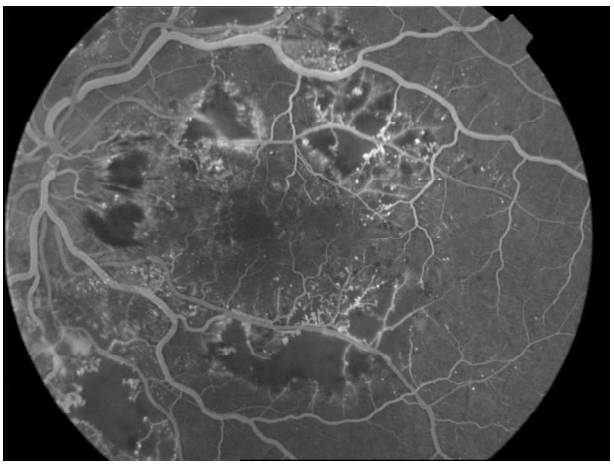

Şekil 1.5. Retinada beyaz pamuksu doku oluşumu

1.3. Fundus Floresein Anjiografi Yöntemi ile DR Hastalığının Teşhisi

Fundus floresein anjiografi (FFA) tekniğini, Indiana Üniversitesinden iki tıp öğrencisi H.R. Novotny ve D.L. Alvis 1961 yılında tanımlamış ve uygulamışlardır. 1967 yılında ise Donald Gass bu tekniğe ilişkin deneyimlerini yayımlamaya başlamış ve bu çalışmalar retinal hastalıkların değerlendirilmesinde FFA tekniğinin kullanımını kabul

edilebilirliğini artırmıştır. Dijital görüntüleme ve bilgisayar yazılımlı analiz gibi modern gelişmeler yoluyla bu teknikten alınan verim arttırılmıştır [10].

Retina çıplak gözle görülemeyecek bir yapıya sahiptir. FFA, retinadaki ayrıntıları görmemizi sağlayan ve bu gözlemden tespit yapma imkânı veren bir yöntemdir. Bu yöntemde floresein olarak adlandırılan bir boya maddesi kullanılmaktadır. Bu boya maddesi ile birlikte yüksek çözünürlükte kameralar kullanılarak görüntüleme işlemi gerçekleştirilmektedir. Bu yöntemde göze sarı turuncu renkte, mavi ışık altında floresans veren floresein boyası verilir. Kameranın optik eksenine ise mavi ve sarı-yeşil süzgeç olmak üzere iki adet süzgeç yerleştirilir. Mavi süzgeç retinaya giden ışıktan sadece mavinin geçmesine izin verirken, sarı-yeşil süzgeç yansıyan ışığın mavi bileşenini bloke eder. Bunun sonucunda kameranın çektiği görüntüde sadece floresein boyanın görüntüsü görülür.

Sağlıklı bir gözün FFA yöntemiyle elde edilen görüntüsü Şekil 1.6 ile verilmiştir. Bu görüntü incelendiğinde, retinada, herhangi bir sızıntıya ait parlak renkte beyazlıklar izlenmemektedir. DR hastalığı bulunan bir gözün FFA yöntemiyle elde edilen görüntüsü ise Şekil 1.7 ile verilmiştir. Damarların beyaz boyanması floresein boyası ile dolduğunu göstermektedir. Damar yapısı bozulduğunda floresein dışarı sızmakta ve siyak ok ile gösterildiği gibi hiperfloresans izlenmektedir.

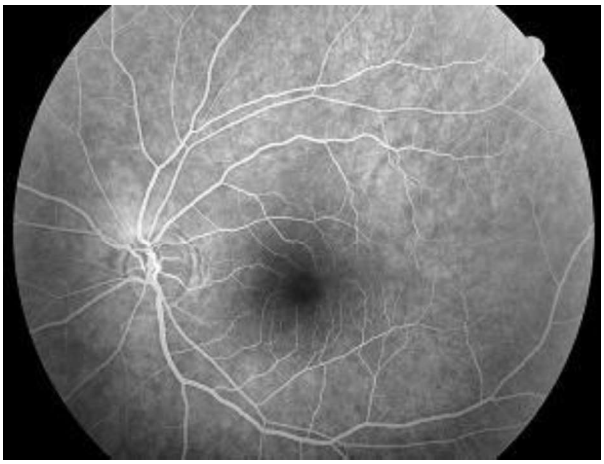

Şekil 1.6. Sağlıklı bir gözün FFA yöntemiyle elde edilen görüntüsü

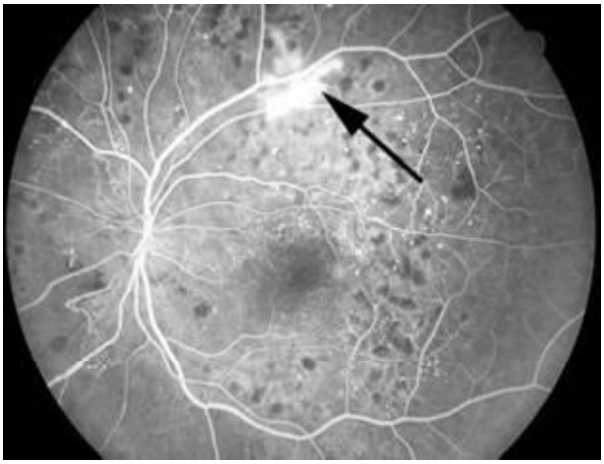

Şekil 1.7. DR hastalığı bulunan bir gözün FFA yöntemiyle elde edilen görüntüsü

FFA yönteminde, floresein maddesi hastanın kolundan veya elinden damar yolu ile enjekte edilir. Daha sonra kan yoluyla dolaşıma katılan floresein bütün dokuları çok kısa bir sürede boyar. Boya damardan verildikten sonra bir göze öncelik verilerek ilk saniyelerde daha sık olmak üzere hastalığın seviyesine bağlı olarak belirli aralıklarla göz dibinin dijital fotoğraf çekimleri yapılır.

Son yıllarda göz hastalıklarının teşhisine yönelik biyomedikal görüntü işleme alanında yapılan çalışmalar incelendiğinde yapay sinir ağları ile retinal hastalıkların teşhisi [11], fuzzy C-means algoritması ve morfolojik yöntemler kullanılarak retinal görüntülerde otomatik eksüda tespiti [12], fuzzy C-means tabanlı kümeleme ve yapay sinir ağlarını kullanarak eksüdatif makulopatinin otomatik olarak tanınması [13], retina görüntülerinde yaşa bağlı makula dejenerasyonunun bilgisayar destekli tespiti [14], retina görüntülerinde yaşa bağlı makula dejenerasyonunun otomatik bölütlenmesi [15], DR hastalığına yol açan kanamalı bölgelerin FFA görüntüleri üzerinde görüntü iyileştirme ve temel sınıflama metotlarını kullanarak tanımlanması [16], retinal görüntülerde optik disk ve makulanın tespiti ve değerlendirilmesi [17], DR tespitinde yeni bir algoritma kullanılarak optik disk yerinin kestirimi [18], retina görüntülerinin kalite değerlendirmesi ve DR hastalığının tespiti [19] gibi çalışmaların yapıldığı görülmektedir.

2. BÖLÜM

RENK UZAYLARI VE KÜMELEME YÖNTEMİ

2.1. Renk Uzayları

Farklı dalga boylarına sahip ışığın, cisimlere çarptıktan sonra yansıyarak retina tabakasına ulaşması sonucu görme duyumuzda bıraktığı etkiye renk denir. Renk veya renk tonları maddelere çarpan ışığın soğurulmasına veya yansımasına bağlı olarak çeşitlilik göstermektedir. İnsan gözünün algıladığı renklerin temelinde kırmızı, yeşil ve mavi ışık renkleri bulunur. Diğer renkler bu üç ana rengin belirli oranlarda karışımıyla elde edilir. Yansıyan ışığın tamamının gözümüze ulaşması sonucu beyaz, ışığın herhangi bir dalga boyunun ulaşmaması sonucunda ise siyah renk algılanır.

Renkleri gruplandırmak amacıyla renk uzayları kullanılmaktadır. Renk uzayları çok sayıda rengin belli bir standarda göre kümelenmesini ve her kümenin kendine özgü bir yapıya sahip olmasını sağlamaktadır. Renk uzayları renkleri tanımlamak için kullanılan matematiksel bir model olmakla birlikte, bütün renkleri temsil edecek şekilde oluşturulmuştur. Renk uzayları oluşturulurken dikkat edilen nokta, her renk uzayının üç boyutlu olarak tasarlanmasıdır. Bu durum Renkmetri biliminin temelini oluşturan Grassmann tarafından belirlenmiş olup, Grassmann'ın birinci kanununa göre bir rengi belirlemek için birbirinden bağımsız üç değişkenin bulunması gerekmektedir [20]. Bu değişkenler her bir rengin renk uzayındaki yerini belirlemektedir. Her bir renk uzayı kendi özel durumlarına göre oluşturulmuş olup doğrusal ya da doğrusal olmayan yöntemlerle renk uzayları arasında dönüşümler yapılabilmektedir.

Şekil 2.1'de verildiği üzere renk uzayları genel olarak cihaz bağımlı ve cihaz bağımsız renk uzayları olarak iki gruba ayrılır. Bu gruplandırma renk uzayının kullanılacağı cihazla

ilişkilendirilerek yapılmıştır. Buna göre cihaz bağımlı renk uzaylarında renkler tamamen cihazın teknik özelliklerine bağlı olarak üretilirken, cihaz bağımsız renk uzayları ise Commission Internationale de I'Eclairage (CIE) Lab tarafından geliştirilen ve bütün renkler için renk ölçümünü sağlayan uzaylardır.

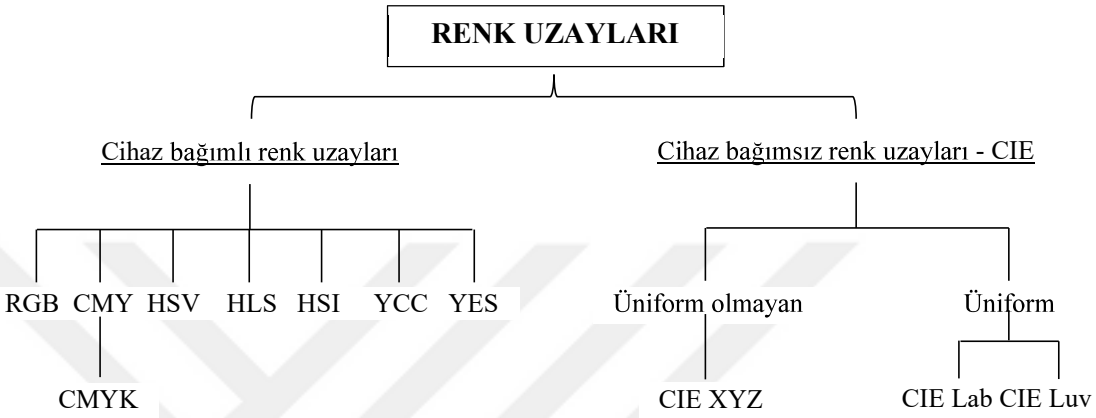

Şekil 2.1. Renk uzayları

2.1.1 RGB Renk Uzayı

RGB renk uzayı; kırmızı (red, R), yeşil (green, G) ve mavi (blue, B) renkleri kullanılarak oluşturulmuş üç boyutlu bir renk uzayıdır. Şekil 2.2'de gösterildiği gibi aynı zamanda koordinat eksenleri kırmızı, yeşil ve mavi olan üç boyutlu bir uzay olarak da düşünülebilir. Bu üç temel rengin belirli oranlarda karıştırılmasıyla çeşitli renkler ve renk tonları elde edilmektedir.

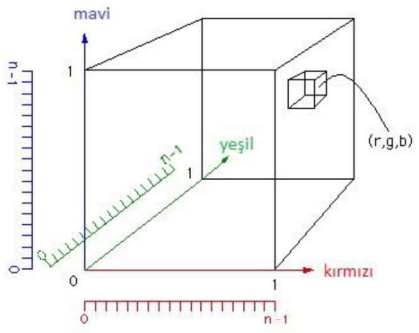

Şekil 2.2. RGB renk uzayı

Görüntü piksel olarak adlandırılan birim elemanların bir araya gelmesiyle oluşur ve her bir piksel kırmızı, yeşil ve mavinin belirli yoğunlukta karıştırılması ile elde edilen bir renk koduna sahiptir. Örneğin, bir RGB görüntüde R, G ve B katmanlarının her birisi için renk değerleri [0,255] skalasında değiştiğine göre kırmızı rengin elde edilebilmesi için kırmızı rengin piksel değeri 255 olurken, yeşil ve mavi renk için piksel değerleri 0 olmalıdır. Beyaz rengin elde edilebilmesi için R, G ve B bileşenlerinin her üçünün de piksel değerinin 255 olması, siyah renkte ise 0 olması gerekmektedir. RGB renk uzayında bir görüntüye örnek olarak, *"peppers.png"* görüntüsü Şekil 2.3 ile verilmiştir.



Şekil 2.3. RGB renk uzayında *peppers.png* görüntüsü

2.1.2. CIE Lab Renk Uzayı

CIE (Commission Internationale de I'Eclairage) Lab renk uzayı görsel medya için tasarlanmış, ekrandan bağımsız ve insanın algılama sistemine en uygun renk uzayı modelidir [21]. Parlaklık (L), kırmızı-yeşil (a) ve sarı-mavi (b) bileşenlerinden oluşan bu renk uzayında L bileşeni aydınlığı ifade eder ve 0 olması durumunda en karanlık, 100 olması durumunda ise en aydınlık seviye oluşmaktadır. Bu renk uzayına ait görsel Şekil 2.4 ile gösterilmiştir.



Şekil 2.4. CIE Lab renk uzayı

Günümüzde çeşitli alanlar için standart renk uzayı olarak da kullanılan CIE Lab renk uzayı ayrıca renk uzayları arasında dönüşüm yapmak için de kullanılmaktadır. Renk uzayları arasında dönüşüm yapılırken ilk olarak ilgili renk uzayı CIE Lab renk uzayına dönüştürülür ve daha sonra hedef renk uzayına çevrim gerçekleştirilir. CIE Lab renk uzayında çizdirilmiş olan *"peppers.png"* görüntüsü Şekil 2.5 ile verilmiştir.



Şekil 2.5. CIE Lab renk uzayında peppers.png görüntüsü

2.1.3. Gri Seviyeli Görüntü

Gri seviyeli görüntüler her bir pikselin renk bilgisi olarak gri skalada tek bir değer aldığı tek boyutlu görüntülerdir. Gri seviyeli bir görüntüde, her bir piksel siyah ile beyaz arasındaki gri tonlardan oluşmaktadır. Her bir piksel [0,255] aralığında veya normalize edilerek [0,1] aralığında değerler almaktadır. 0 değeri siyaha karşılık gelirken, 255 veya 1 ise beyaza karşılık gelmektedir. Gri seviyeli görüntülerde piksellerin değerlerini aldığı gri seviye renk skalası Şekil 2.6 ile gösterilmiştir.

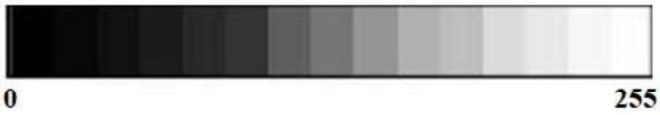

Şekil 2.6. Gri seviye renk skalası

2.1.4. İkili Görüntü

İkili görüntüler sadece siyah ve beyaz renklerinden oluşan görüntülerdir. Yani her bir pikselin alabileceği yalnızca iki farklı değer vardır. Bu değerler 0 veya 1 değerleridir. 0 değerine sahip bir piksel siyah renk olurken, 1 değerini alan piksel ise beyaz renkli olmaktadır. Şekil 2.7.a.'da verilen RGB görüntünün belli bir eşik değeri verilerek elde edilen ikili görüntüsü aşağıda Şekil 2.7.b. ile verilmiştir.



a) RGB görüntü



b) İkili görüntü

Şekil 2.7. RGB renk uzayındaki bir görüntünün ikili görüntü karşılığı

2.2 Histogram Analizi

Bir görüntünün herhangi bir katmanındaki renklerin gri skaladaki dağılım yoğunluğu, o katmana ait histogram grafiği ile tanımlanır. Özellikle çok boyutlu görüntülerde görüntü analizinin hangi katman üzerinden yapılması gerektiğine histogram grafikleri kullanılarak karar verilir. Histogram grafikleri incelendiğinde daha yoğun ve homojen renk dağılımına sahip katmanların görüntü analizi açısından daha iyi sonuçlar ürettiği görülmektedir. Şimdi, örnek teşkil etmesi açısından *"peppers.png"* için RGB, CIE Lab ve gri seviyeli görüntülerine ait histogram grafiklerini inceleyelim.

"peppers.png" görüntüsü için R, G ve B katmanları ve bu katmanlara ait histogram grafikleri aşağıda Şekil 2.8 ile gösterilmiştir.

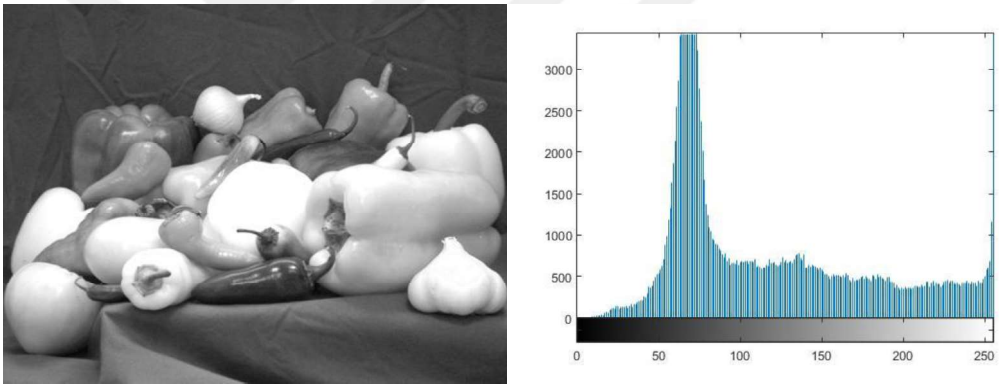

a) R katmanına ait görüntü ve histogram grafiği

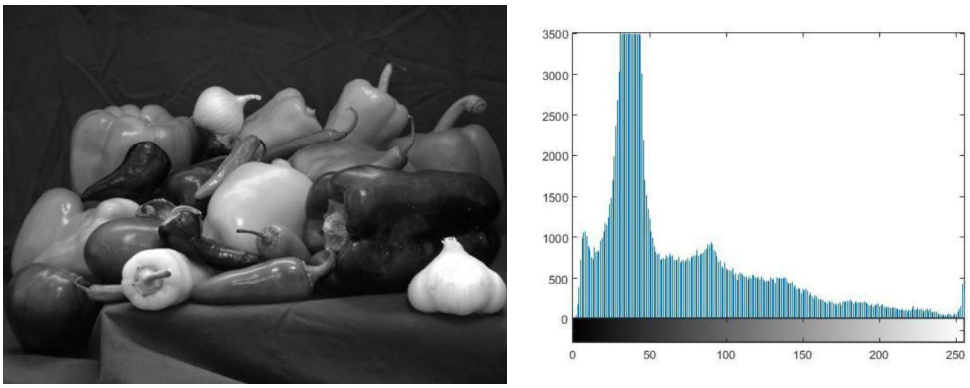

b) G katmanına ait görüntü ve histogram grafiği

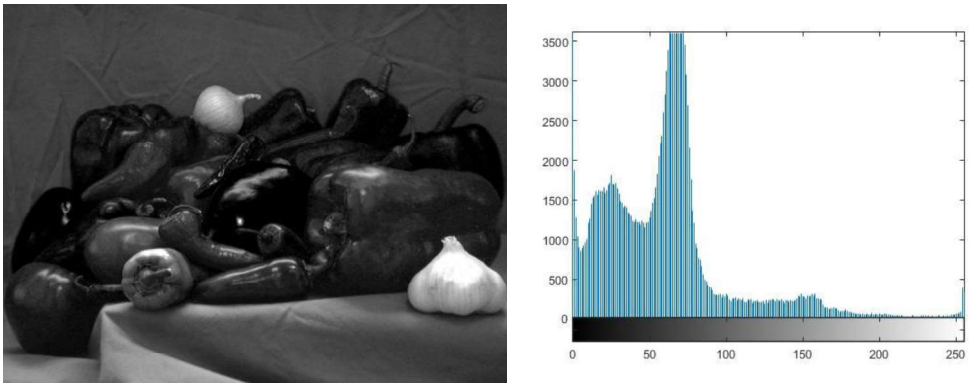

c) B katmanına ait görüntü ve histogram grafiği

Şekil 2.8. RGB renk uzayının katmanları ve bu katmanlara ait görüntülerin histogram grafikleri

CIE Lab renk uzayında verilmiş olan "*peppers.png*" görüntüsü için L, a ve b katmanları ve bu katmanlara ait histogram grafikleri Şekil 2.9 ile gösterilmiştir.

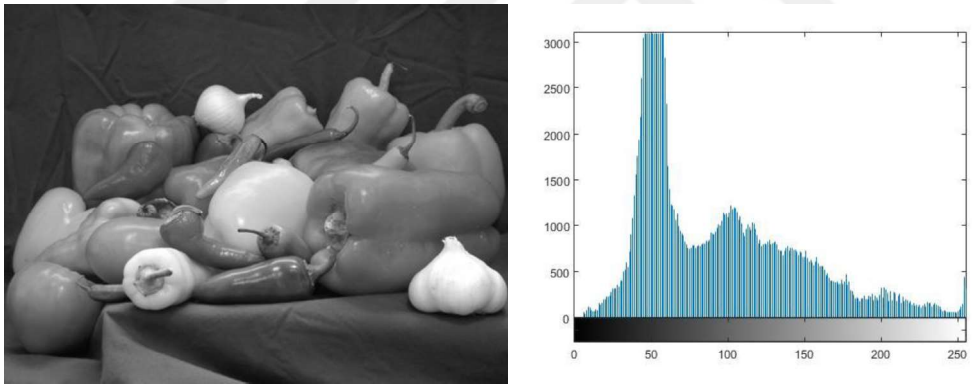

a) L katmanına ait görüntü ve histogram grafiği

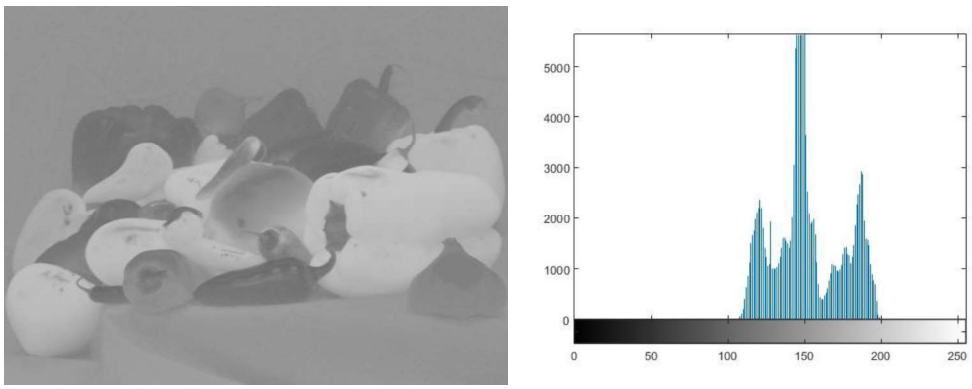

b) a katmanına ait görüntü ve histogram grafiği

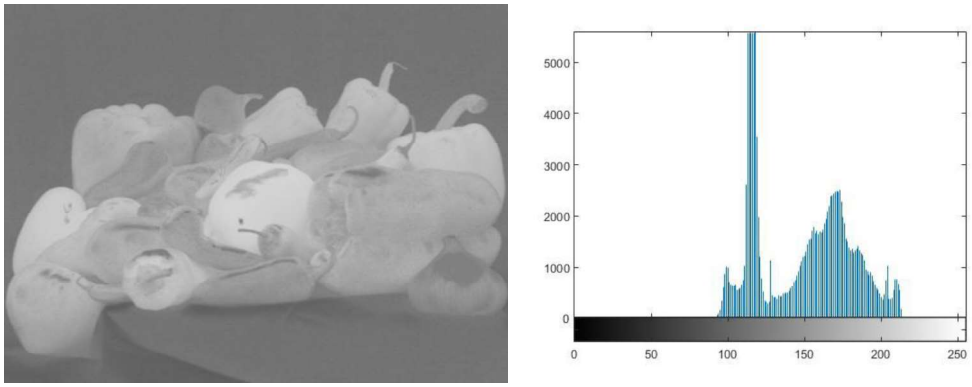

c) b katmanına ait görüntü ve histogram grafiği

Şekil 2.9. LAB renk uzayının katmanları ve bu katmanlara ait görüntülerin histogram grafikleri

Son olarak gri seviyeli "*peppers.png*" görüntüsü ve bu görüntüye ait histogram grafiği aşağıda verilmiştir.

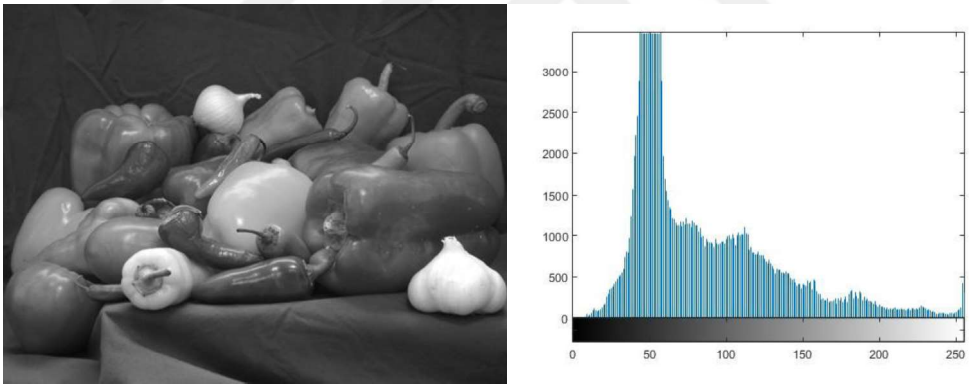

Şekil 2.10. Gri seviyeli görüntü ve bu görüntüye ait histogram grafiği

İkili görüntüler ise yalnızca 1 ve 0 değerlerinden oluştukları için histogram grafikleri genellikle kullanılmamaktadır.

2.3 Görüntü Zenginleştirme

Görüntü zenginleştirme işlemleri problemin çözümüne yönelik çalışmanın hazırlık aşaması olarak ifade edilebilmektedir. Orijinal görüntü üzerinde yapılan filtreleme ve morfolojik işlemler görüntü üzerindeki fazlalıkları kaldırmada ve bazı özellikleri ortaya çıkartmada önemli faydalar sağlamaktadır. Bu sebeple algoritma tabanlı analizler yapılmadan önce görüntüler üzerinde çeşitli görüntü zenginleştirme işlemleri

gerçekleştirilerek görüntüler analize daha uygun hale getirilmektedir. En temel görüntü zenginleştirme işlemleri olan filtreleme ve morfolojik işlemler aşağıda anlatılmaktadır.

2.3.1 Filtreleme

Görüntü üzerinde netleştirme, belirli ayrıntıları ortaya çıkarma, görüntüyü yumuşatma, kenar keskinleştirme veya kenar bulma gibi işlemler filtreleme ile gerçekleştirilir. Filtreleme işleminde (*n*x*m*) boyutlu bir filtre kullanılarak görüntünün her bir piksel değeri yeniden hesaplanır. Bu işlem yapılırken merkezi bir piksel (ilgilenilen piksel) etrafında rasgele tanımlanmış bir komşuluktaki kaynak resmin gri tonları belirli bir algoritmayla işlenmektedir. Bu işlemin sonucu yeni bir gri tondur ve bu değer sonuç resmin ilgilenilen pikseline atanır. Her iki resimdeki ilgilenilen pikselin pozisyonu aynıdır ancak piksel değeri komşuluğundaki piksel değerlerini baz alarak değişecek ve farklı bir değer alacaktır. Merkezi piksel etrafında tanımlanan komşuluklar *maske* veya *pencere* olarak isimlendirilirler.

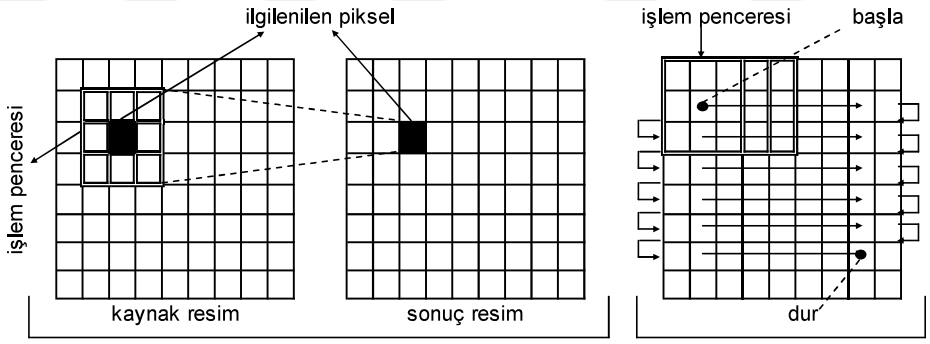

Şekil 2.11. Filtreleme işlemi

Bu tez çalışması kapsamında görüntü zenginleştirme aşamasında unsharp filtresi kullanılarak görüntü netleştirme işlemi yapılmıştır. Unsharp filtresi görüntüdeki ayrıntıları ve keskin geçişleri belirginleştirmek, bulanıklaştırılmış görüntülerdeki ayrıntıları yeniden ortaya çıkarmak için kullanılmaktadır. Şekil 2.12'de verilen orijinal ve unsharp filtresi uygulanmış görüntülerden de anlaşılacağı gibi unsharp filtre görüntünün netleştirilmesini sağlamaktadır.

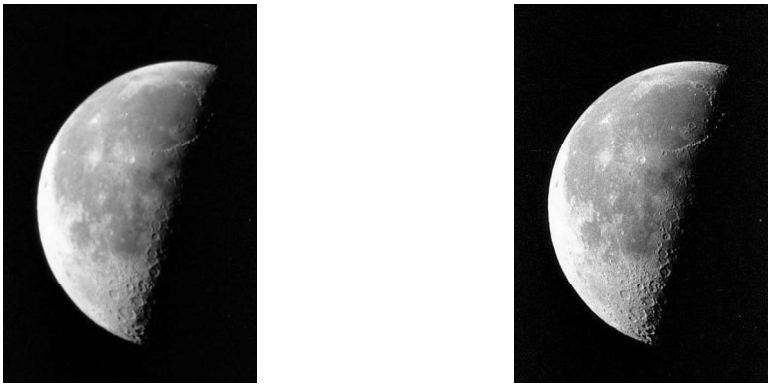

a) Orijinal görüntü b) Unsharp filtre ile netleştirilmiş görüntü

Şekil 2.12. Unsharp filtresinin uygulanması

2.3.2 Morfolojik İşlemler

Morfolojik işlemler görüntü üzerinde oluşturulan yapısal veya şekilsel değişiklikler olarak tanımlanabilir. Morfolojik işlemlerin gerçekleştirilebilmesi için operatörün uygulanacağı görüntüye ve yapısal filtre elamanına ihtiyaç vardır. Yapısal filtre elemanları farklı şekil ve büyüklükteki geometrik şekillerden oluşmakla beraber genellikle kare, dikdörtgen ve daire şeklindedir. Bu filtre elemanlarının bir merkez noktası bulunmaktadır ve bu nokta morfolojik işlemin uygulanacağı görüntünün her bir pikselinin üzerinden geçerek filtreleme işlemi gerçekleştirilir. Görüntüyü morfolojik işlemlere tabi tutarken kullanılabilecek yapısal filtre elemanlarına iki örnek Şekil 2.13 ile gösterilmiştir.

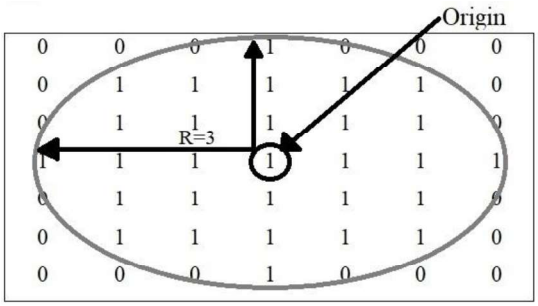

1	0	0
1	**1**	0
0	0	1

(a) (b)

Şekil 2.13. Morfolojik işlemler için kullanılabilecek örnek iki yapısal filtre elemanı

Morfolojik işlemler ile açma, kapama, genişletme, aşındırma, boşluk doldurma, kenar bulma ve kenar birleştirme gibi işlemler yapılabilmektedir. Ancak morfolojik görüntü işlemenin en temel iki işlemi aşındırma ve açma işlemleridir ve diğer işlemler bu iki işlem temelinde gerçekleştirilmektedir.

Aşındırma işlemi, işlemin gerçekleştiği bölgelerde bulunan sınır bölgelerinin aşındırılması amacıyla kullanılmaktadır. Görüntü üzerinde gerçekleştirilen küçültme veya inceltme işlemleri şekillerde bulunan gürültülerin düzelmesini sağlamaktadır. Aşındırma işleminin uygulandığı görüntü ve işlem sonrası elde edilen görüntü Şekil 2.14 ile gösterilmiştir.



a) Orijinal görüntü b) Aşındırma işlemi sonrası yeni görüntü

Şekil 2.14. Morfolojik aşındırma işlemi

Açma işlemi ise aşındırma ve genişletme işleminin ardışık olarak uygulanması sonucu oluşmaktadır. Bu işlemle görüntüde bulunan iki nesnenin görüntüye zarar vermeden ayrılması sağlanır. Bununla birlikte görüntüde bulunan ve istenmeyen küçük nesnelerin ortadan kaldırılması da sağlanmaktadır. Açma işleminin uygulandığı görüntü ve işlem sonrası elde edilen görüntü Şekil 2.15 ile verilmiştir.



a) Orijinal görüntü b) Açma işlemi sonrası yeni görüntü

Şekil 2.15. Morfolojik açma işlemi

2.4. Kümeleme Yöntemi

Kümeleme analizi bir araştırmadaki birimleri inceleyerek, bu birimleri benzerliklerine göre gruplandırmak ve bu gruplardaki birimlerin ortak özelliklerini tespit ederek genel tanımlarını yapmak amacıyla kullanılır [22]. İlk olarak, 1939 yılında R. C. Tryon tarafından önerilen kümeleme yöntemi ilerleyen yıllarda görüntü işleme uygulamalarının da temelini oluşturmuştur [23].

Kümeleme yönteminde içeriği hakkında bilgi sahibi olunmayan kümelerin, benzer özelliklere sahip olan üyeleri aynı gruba, farklı özelliklere sahip olanları ise birbirinden farklı gruplara ayrılarak alt kümeler elde edilir. Bu alt kümeler, küme özelliklerinin karakterize edilebilmesini ve küme hakkında detaylı yorum yapılabilmesini sağlar.

Kümeleme analizi temel olarak dört farklı amaç için kullanılmaktadır. Birincisi, *n* adet birimi *p* adet değişkene göre belirlenen özelliklerle mümkün olduğu kadar kendi içinde benzer ve kendi aralarında farklı alt gruplara ayırmaktır. İkincisi, *p* sayıda değişkeni *n* sayıda birimde belirlenen değerlere göre ortak özellikleri ortaya koyduğu düşünülen alt kümelere ayırmak ve ortak faktör yapıları ortaya çıkarmaktır. Üçüncü kullanım amacı hem birimleri hem de değişkenleri birlikte düşünerek ortak *n* birimi *p* değişkene göre ortak özellikli alt kümelere ayırmaktır. Dördüncü ve en son olanı ise birimlerin *p* değişkene göre belirlenen değerlere göre izledikleri biyolojik ve tipolojik sınıflamayı ortaya koymaktır [24].

2.4.1 K-Means Kümeleme Algoritması

Kümeleme yönteminde en sık kullanılan algoritma, 1967 yılında yılında J.B. MacQueen tarafından geliştirilmiş olan K-means kümeleme algoritmasıdır [25]. K-means kümeleme algoritması, kümeleme yönteminde olduğu gibi *n* adet veriden oluşan bir veri kümesi oluşturarak bu veri kümesini giriş parametresi olan *k* adet kümeye bölümler. Burada amaç özelliklerine göre ayrılmış grup verisinin küme özelliklerine uygun olarak hangi kümeye ait olduğunu tespit etmektir. Bu tespit gerçekleştirirken aynı küme içindeki değerlerin birbirlerine mümkün olduğunca yakın olması beklenirken, *k* adet kümenin de birbirinden mümkün olduğunca farklı özellikte olması hedeflenmektedir. Veriler arasındaki küme benzerliğini tespit etmek için kümenin ağırlık merkezi olarak kabul edilen nesne ile kümedeki diğer nesneler arasındaki uzaklıkların ortalama değeri hesaplanır [26-28].

K-means kümeleme algoritmasının adımları açıklanacak olursa; ilk olarak *k* adet küme sayısı belirlenir. Daha sonra veri kümesinden rasgele seçilen *k* adet başlangıç küme merkezi belirlenir. Diğer küme elemanlarının küme merkezlerine olan mesafesi hesaplanarak en yakın olduğu küme merkezine göre küme atamaları gerçekleştirilir. Bu adımdan sonra her küme için yeni küme merkezleri hesaplanır. Bu yeni küme merkezleri ile eski küme merkezleri karşılaştırılır. Eğer bu merkez noktaları birbirine eşit ise işlem sona erdirilir, değilse yeni küme merkezleri ile yeniden gruplandırma yapılır ve işlemler bu şekilde tekrarlanır [29].

K-means algoritmasını temel adımları aşağıda verilmiştir,

Rasgele küme merkezleri belirle
REPEAT
Mesafelere göre örnekleri kümele
Kümeleme sonrasında rasgele yeni küme merkezleri belirle
UNTİL (*Tüm örneklerin ait olduğu küme değişmeyinceye kadar*)

Çalışma uzayı olarak Şekil 2.16 ile verilen koordinat düzeyi düşünülecek olursa ve bu uzayda bulunan verileri iki adet kümeye ayrılması istendiğinde izlenecek adımlar aşağıdaki gibi sıralanabilir.

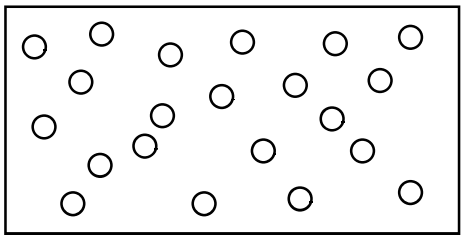

Şekil 2.16. Örnek çalışma uzayı

İlk olarak yukarıda verilen uzayda, hedeflenen küme sayısına uygun olarak iki adet küme merkezi rasgele belirlenir.

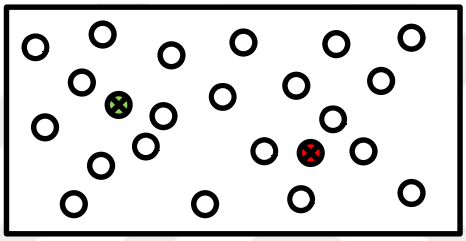

Şekil 2.17. Küme merkezlerinin belirlenmesi

Bu küme tanımlamalarına uygun olarak her bir verinin küme merkezine olan uzaklıkları hesaplanarak en yakın küme merkezine göre sınıflandırma yapılır.

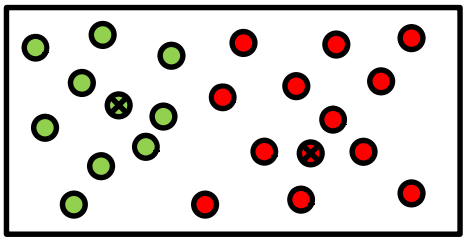

Şekil 2.18. Küme merkezlerine göre sınıflandırma

Sınıflandırma sonucu oluşan kümelerin küme merkezleri değiştirilerek daha iyi çözümlerin bulunması amaçlanır. Bir önceki merkezle yapılan karşılaştırmaya göre daha iyi olan çözüm alınır ve en iyi çözüme elde edilene kadar döngü devam eder.

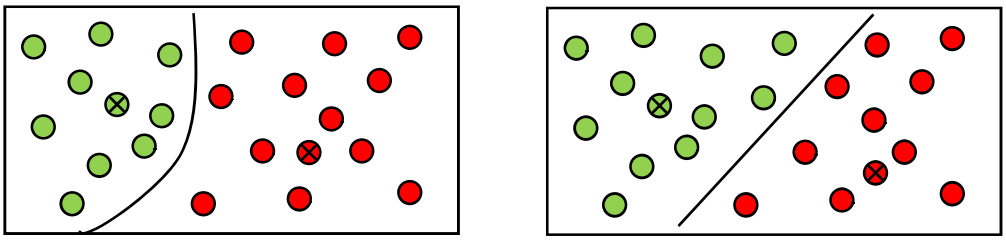

Şekil 2.19. Sınıflandırma ve en iyi çözümün gerçekleştirilmesi

Böylece uzaydaki veriler birbirine en yakın özelliklere sahip olanlar aynı kümede yer alacak şekilde iki adet farklı kümeye ayrılmıştır.

3. BÖLÜM

RETİNAL GÖRÜNTÜ ANALİZİNDE KULLANILAN SEZGİSEL ALGORİTMALAR

Bu tez çalışmasında, literatürde en yaygın kullanılan klasik yaklaşım olan K-means algoritmasının yanı sıra sezgisel yaklaşımlar da retinal görüntü analizine uygulanmıştır. Sürü zekasına dayalı yapay arı koloni ve popülasyon tabanlı diferansiyel gelişim algoritmaları DR hastalıklı göz görüntülerinin analizine yönelik kümeleme tabanlı olarak geliştirilmiş ve performans mukayeseleri yapılmıştır. ABC ve DE algoritmaları aşağıda detaylı bir şekilde anlatılmaktadır.

3.1. Yapay Arı Koloni Algoritması

Doğal yaşamda sürü veya koloni halinde yiyecek arama faaliyeti gerçekleştiren canlıların zeki davranışlarını modelleyen algoritmalar sürü zekâsına dayalı algoritmalar olarak adlandırılmaktadır. Parçacık sürüsü optimizasyon algoritması, yapay arı koloni algoritması, karınca koloni optimizasyon algoritması, ateşböceği sürüsü optimizasyon algoritması ve yapay balık sürüsü algoritması gibi algoritmalar sürü zekasına dayalı algoritmalara örnek olarak gösterilebilir.

2005 yılında Derviş Karaboğa tarafından geliştirilmiş olan ABC algoritması [1] çok farklı alanlardaki mühendislik problemlerinin optimizasyonunda etkin şekilde kullanılmaktadır. ABC algoritmasında arı kolonisi; görevli arılar, gözcü arılar ve kâşif arılardan oluşan 3 grup arıdan meydana gelmektedir. Görevli arılar keşfetmiş oldukları belirli kaynaklara ait nektarı kovana getirirler ve kaynak hakkındaki bilgileri kovanda bekleyen diğer arılarla paylaşırlar. Kovanda bekleyen arılar gözcü arılardır ve görevli arıları izleyerek elde ettikleri bilgileri kullanarak yeni kaynaklara yönelirler. Kâşif arılar ise çevrede rastgele yiyecek kaynağı arayışı içerisinde olan arı grubudur.

Arılar çeşitli dans hareketleri ile yiyecek kaynağının yeri ve kalite miktarı hakkındaki bilgiyi diğer arılarla paylaşırlar. Bu etkileşim, diğer arıların dans eden arıya antenleriyle dokunmasıyla gerçekleşir. Kaynağa ait bilgiyi alan arılar nektar bakımında kaliteli olan kaynağa yönelirler. Yön bilgisini gözcü arıdan alan arılar güneşten faydalanarak yönü, tükettiği enerji miktarına göre de noktaya olan uzaklığı hesaplayarak hedeflerine ulaşırlar.

Arıların davranışlarındaki pozitif geri besleme, negatif geri besleme, salınım ve çoklu etkileşim gibi temel özellikler arıların kendi kendine organize olabilme özelliklerinden kaynaklanmaktadır. Kaynağın nektar miktarı arttıkça o kaynağı seçen arı miktarının artması pozitif geri besleme, tükenen kaynağı arıların terk etmesi ise negatif beslemeye örnektir. Kâşif arı adı verilen arıların rastgele olarak gerçekleştirdiği yiyecek kaynağı arama davranışı salınımları oluşturmaktadır. Çoklu etkileşim ise arıların yiyecek arama faaliyetleri sırasında yiyecek kaynağı ile ilgili olarak dans alanındaki paylaşımları olarak ifade edilebilir.

Temel ABC algoritmasında popülasyonun yarısı görevli, diğer yarısı ise gözcü arılardan oluşmaktadır. Her bir kaynağın nektarı, tek bir görevli arı tarafından alındığından yiyecek kaynağının sayısı görevli arı sayısına eşit olmaktadır. Yiyecek kaynakları optimize edilmeye çalışılan probleme ait olası çözümleri temsil eder ve bir yiyecek kaynağının nektar miktarı ilgili çözümün kalite değerini verir. Bunun bir sonucu olarak, görevli arıların veya gözcü arıların sayıları popülasyondaki çözüm sayısına eşit olmaktadır. Nektarı tüketilen yiyecek kaynağının görevli arısı, rasgele yeni çözümler aramak üzere, kâşif arıya dönüştürülür.

Temel ABC Algoritmasının adımları aşağıda verilmiştir,

Başlangıç yiyecek kaynağı bölgelerinin rasgele üretilmesi

REPEAT

Görevli arıların yiyecek kaynağı bölgelerine gönderilmesi
Gözcü arıların seleksiyon işleminde kullanacakları olasılık değerlerinin hesaplanması
Gözcü arıların yiyecek kaynağı bölgelerini seçmeleri
Tükenen kaynağı bırakma ve kaşif arı üretimi

UNTIL *(çevrim sayısı = Maksimum çevrim sayısı)*

ABC algoritmasında ilk olarak her birisi bir yiyecek kaynağını temsil eden *SN* adet çözümden oluşan rastgele bir başlangıç popülasyonu üretilir. Eşitlik 3.1 kullanılarak üretilen bu başlangıç popülasyonunda parametre değerleri optimizasyon probleminin özelliğine göre belirli alt ve üst sınır değerler arasında sınırlandırılmaktadır.

$$x_{i,j} = x_j^{min} + rand(0,1)\left(x_j^{max} - x_j^{min}\right) \tag{3.1}$$

burada, *D*, optimize edilecek parametre sayısını tanımlamaktadır. *i* = 1,…,*SN* ve *j* = 1,…,*D* aralığında değerlere sahip olup, x_j^{max} ve x_j^{min}, *j.* parametrenin alt ve üst sınırlarını temsil etmektedir. ABC algoritmasında her bir yiyecek kaynağının komşuluğunda o yiyecek kaynağından daha yüksek nektar miktarına sahip daha iyi kaynaklar araştırılır. Eğer bir yiyecek kaynağının komşuluğunda daha yüksek nektar miktarına sahip kaynaklar bulunamıyor ise o yiyecek kaynağı daha fazla geliştirilemiyor demektir. ABC algoritmasında, *i.* kaynağın geliştirilememe sayısı "$failure_i$" olarak tanımlanan bir değişken ile tutulur ve başlangıçta bu değişkene sıfır değeri atanır.

Başlangıç popülasyonu oluşturulduktan ve kontrol parametre değerleri tanımlandıktan sonra görevli arı, gözcü arı ve kâşif arı aşamaları ile araştırmaya devam edilir. Görevli arılar kendileri için belirlenen yiyecek kaynağına giderek o kaynağın nektar miktarını hesaplarlar. Daha sonra her bir görevli arı Eşitlik 3.2'yi kullanarak ilgili yiyecek kaynağının komşuluğunda yeni bir yiyecek kaynağı daha belirler ve bu komşu yiyecek kaynağının da nektar miktarını hesaplar. Bu iki yiyecek kaynağının nektar miktarları karşılaştırılır ve daha yüksek nektar miktarına sahip olan daha iyi çözüm hafızada tutulurken diğer çözüm hafızadan silinerek sonraki çevrimlere aktarılmaz.

$$v_{ij} = x_{ij} + \phi_{ij}\left(x_{ij} - x_{kj}\right) \tag{3.2}$$

Eşitlik 3.2'de, x_{ij} : *i.* çözümün *j.* parametresini tanımlarken, x_{kj} rastgele seçilen komşu çözümün (k ∈ 1,…,*SN*) *j.* parametresini temsil etmektedir. Her bir kaynak için *D* adet parametre arasından rastgele seçilen *j.* parametre değiştirilerek, x_{ij} komşuluğunda v_{ij} kaynağı bulunur. Mevcut kaynak çözüm ile komşu kaynak çözüm arasındaki fark, [-1,1] aralığında rastgele değer alan ϕ_{ij} değişkeni ile ölçeklendikten sonra elde edilen sonuç mevcut kaynak çözüme eklenerek yeni komşu çözüm v_{ij} elde edilir. Yeni üretilen v_{ij}

çözümünde sınır değerlerini aşan parametreler var ise bu parametrelerin değerleri Eşitlik 3.3.'te gösterildiği gibi ölçeklenerek alt veya üst sınır değerlerine çekilir.

$$v_{ij} = \begin{cases} x_j^{min} , & v_{ij} < x_j^{min} \\ v_{ij} , & x_j^{min} \leq v_{ij} \leq x_j^{max} \\ x_j^{max} , & v_{ij} > x_j^{max} \end{cases} \tag{3.3}$$

Mevcut çözümün komşuluğunda üretilen bu yeni v_{ij} kaynağının kalite değeri bir kalite fonksiyonu vasıtasıyla hesaplanır. Farklı problemler için farklı kalite fonksiyonları olmasına karşın bu tez çalışmasında çözümlerin kalite değerleri literatürde en yaygın kullanılan ve Eşitlik 3.4 ile verilmiş olan kalite fonksiyonu ile hesaplanmıştır.

$$fitness_i = \begin{cases} 1/(1+f_i) & , f_i \geq 0 \\ 1 + abs(f_i) , & f_i < 0 \end{cases} \tag{3.4}$$

Burada f_i, v_{ij} çözümünün kalite değerini temsil etmektedir. Yeni üretilen v_{ij} kaynağı ile eski x_{ij} kaynağının kalite değerleri mukayese edilerek yüksek kalite değerine sahip kaynak iyi çözüm olarak bir sonraki çevrime aktarılmak üzere hafızaya kaydedilir. Diğer kaynak ise hafızadan silinir. Şayet eski kaynak geliştirilememişse geliştirilememe sayacı $failure_i$ bir artırılır, geliştirilirse sıfırlanır. Bu iyi olanı seçme özelliği açgözlü (greedy) seçme işlemi olarak adlandırılır.

Bu aşamadan sonra görevli arılar tarafından nektar miktarları yani kalite değerleri belirlenmiş olan yiyecek kaynaklarına ait bilgiler, kovanda gözcü arılar ile paylaşılır. Gözcü arılar bu bilgileri kullanarak yiyecek kaynaklarının nektar miktarı ile doğru orantılı olarak bir kaynak seçer. Kalite değerleri ile doğru orantılı olarak gerçekleştirilen bu olasılıksal seçme işlemi *Rulet Tekerleği* prensibine göre yapılır. Rulet tekerleğinde uygunluk değeri arttıkça o kaynağa ait ayrılan dilimde artmaktadır. Bu sayede dilim açısı büyüdükçe o kaynağın seçilme ihtimali de artmaktadır. Bir kaynağın seçilme olasılığı Eşitlik 3.5'te gösterildiği gibi, o kaynağın uygunluk değerinin diğer tüm kaynakların uygunluk değerleri toplamına oranı ile bulunmaktadır.

$$p_i = \frac{fit_i}{\sum_{n=1}^{SN} fit_n} \tag{3.5}$$

fit_i , *i.* kaynağın kalite değerini ve fit_n ise 1,…,*SN* aralığında *n.* çözümün kalite değerini vermektedir. Eşitlik 3.5'ten görüldüğü gibi *SN* adet yiyecek kaynağının nektar miktarı toplamı her zaman aynı olacağından, *i.* kaynağın değerlerindeki değişime göre seçilme olasılığı da değişecektir. Uygunluk değeri ne kadar fazla ise o kaynağın gözcü arılar tarafından seçilme olasılığı da o kadar fazla olacaktır.

Her bir yiyecek kaynağının olasılık değerleri hesaplandıktan sonra [0,1] aralığında rasgele bir değer üretilir ve bu değer ile p_i değeri karşılaştırılır. Eğer p_i değeri üretilen değerden büyükse gözcü arılar Eşitlik 3.2'ye göre kaynak bölgesinin komşuluğunda yeni çözümler üretir. Üretilen bu yeni çözümlere açgözlü seçme prosedürü uygulanır ve iyi olan çözüm hafızada tutulur. Eski çözüm daha iyi ise bu çözüm geliştirilememiş demektir ve bu durumda $failure_i$ sayacı bir artırılır. Yeni çözüm daha iyi ise $failure_i$ sayacı sıfırlanır.

Çevrim tamamlandıktan sonra kaynakların çözüm geliştirememe sayaçları ($failure_i$) kontrol edilir. Bu değer *limit* olarak tanımlanan kontrol parametre değerinden yüksek ise ilgili kaynak hafızadan silinir ve o kaynakta çözüm arayışı sonlandırılır. Daha sonra hafızadan silinen bu kaynağın görevli arısı rasgele yeni çözüm kaynakları araştırmak üzere kâşif arıya dönüştürülür ve Eşitlik 3.1'i kullanarak çözüm uzayında yeni çözümler araştırır. Temel ABC algoritmasında her çevrimde yalnız bir kâşif arının çıkmasına izin verilir. Bu şekilde çözüm arayışları gerçekleştirilerek en uygun sonuca ulaşılır [30].

Temel ABC algoritmasına ait akış diyagramı Şekil 3.1 ile verilmiştir.

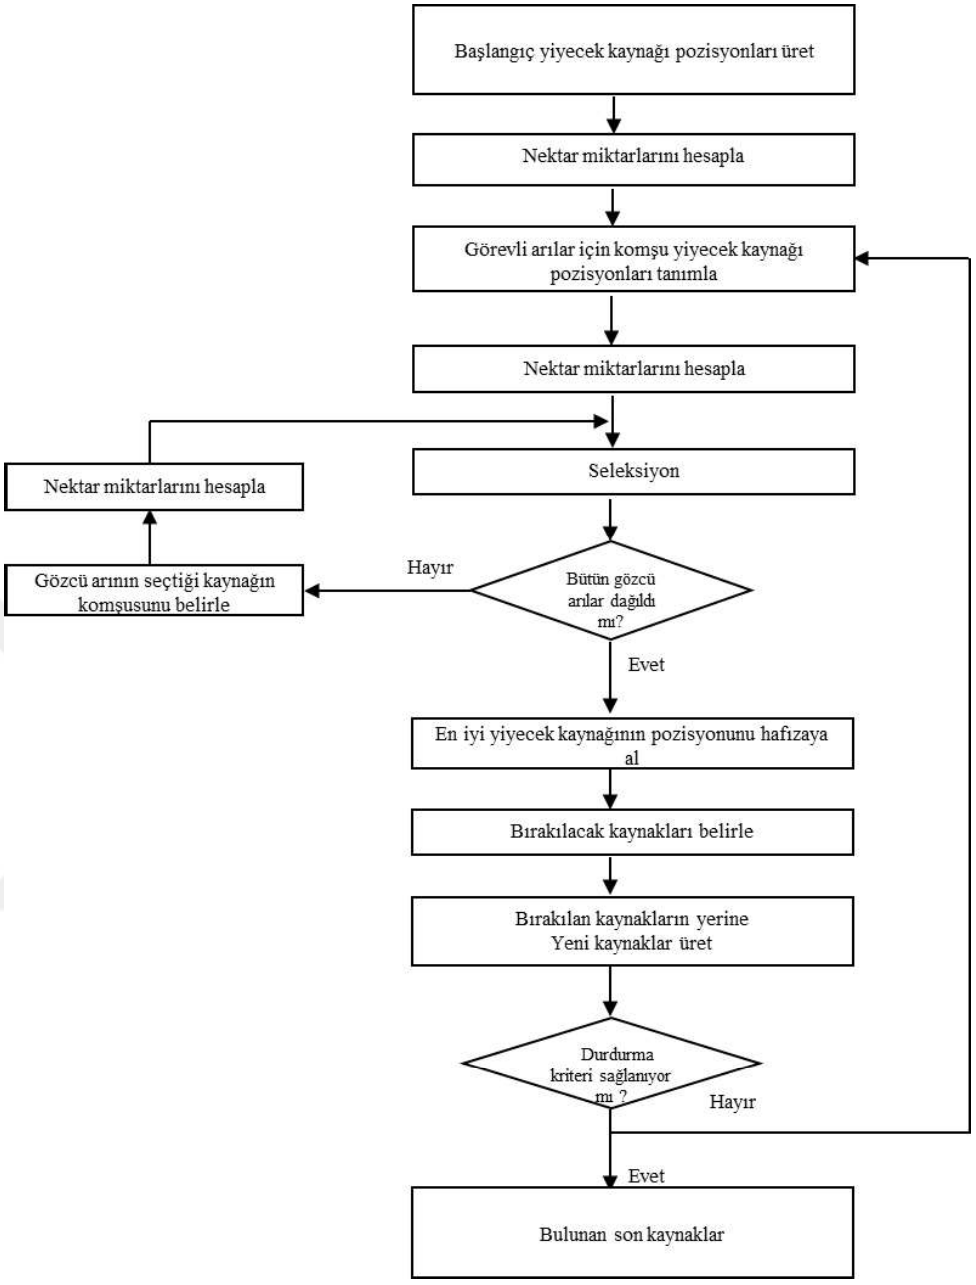

Şekil 3.1. ABC algoritmasının Akış Diyagramı

3.2. Diferansiyel Gelişim Algoritması

Diferansiyel gelişim (DE) algoritması, Price ve Storn tarafından 1995 yılında geliştirilmiş olan popülasyon tabanlı sezgisel bir optimizasyon algoritmasıdır [2]. Özellikle sürekli fonksiyonların optimizasyonunda etkin sonuçlar üreten DE algoritmasının, ayrık değişkenler veya sürekli ve ayrık değişkenlerin kombinasyonu ile çalışan versiyonları da bulunmaktadır [31,32].

DE algoritmasının üç temel kontrol parametresi popülasyon büyüklüğü (number of population, *NP*), çaprazlama oranı (crossover rate, *CR*) ve ölçekleme faktörü (scaling factor, *F*) olarak tanımlanmaktadır. Optimize edilecek parametre sayısı D olan bir problem için her bir olası çözüm D boyutlu bir vektör şeklinde tanımlanacağından, DE algoritmasında öncelikle *NP* adet D boyutlu çözüm vektöründen oluşan bir başlangıç popülasyonu rasgele üretilir. Daha sonra bu popülasyon en iyi çözüme ulaşabilmek amacıyla mutasyon, çaprazlama ve seleksiyon operatörleri uygulanarak geliştirilir.

DE algoritmasının temel adımları aşağıdaki gibi verilebilir,

Başlangıç popülasyonunun oluşturulması
Değerlendirme
Repeat
  Mutasyon
  Rekombinasyon
  Değerlendirme
  Seleksiyon
Until (*durdurma kriteri sağlanıncaya kadar*)

3.2.1. Başlangıç Popülasyonu

NP adet D boyutlu çözüm vektöründen oluşan bir başlangıç popülasyonu Eşitlik 3.6 kullanılarak rasgele üretildikten sonra popülasyondaki her bir çözümün kalite değeri Eşitlik 3.6 ile hesaplanır.

$$x_{j,i,G} = x_j^{min} + rand_j[0,1].\left(x_j^{max} - x_j^{min}\right) \tag{3.6}$$

burada, i=1,2,…,*NP* ve j=1,2,…,D olmak üzere, $x_{j,i,G}$= *G.* jenerasyona ait i çözümünün *j.* parametresini, x_j^{min} = Parametreye ait alt sınır değeri, x_j^{max} = Parametreye ait üst sınır değeri ve son olarak $rand_j[0,1]$ = j parametresi için [0,1] aralığında rastgele üretilen bir sayıdır. DE algoritması olası çözümleri geliştirirken bir mevcut çözüm ve iki adet deneme çözümünü kullandığı için popülasyon boyutu en az üç veya daha fazla olmalıdır.

3.2.2. Mutasyon

Mutasyon operatörü çözüm uzayında mevcut çözümden farklı diğer yeni çözümlere ulaşabilmek amacıyla kullanılır. Böylece çözüm uzaydaki birbirinden farklı çözümler test edilerek en uygun çözüme ulaşılmaya çalışılır. Daha önce belirlenen *NP* adet çözüm

içerisinden mevcut çözüme ilave olarak üç farklı çözüm daha rasgele seçilerek mutasyon işlemi gerçekleştirilir. Seçilen çözümlerden iki tanesinin farkı alınarak ağırlıklandırılmış ölçekleme faktörü (scaling factor,*F*) ile çarpılır. *F* çarpanı belirli bir değer aralığına sınırlandırılmamış ve en iyi değeri optimizasyon problemine göre farklılık gösteren bir kontrol parametresidir. Elde edilen fark vektörü ile seçilen üçüncü çözüm toplanır ve böylece çaprazlama aşamasında kullanılacak olan yeni çözüm elde edilir.

$$n_{j,i,G+1} = x_{j,r_3,G} + F.\left(x_{j,r_1,G} - x_{j,r_2,G}\right) \tag{3.7}$$

burada, i=1,2,…,NP ve j=1,2,…,D olmak üzere, $n_{j,i,G+1}$ = mutasyon ve çaprazlamaya tabi tutulan ara kromozom, $r_{1,2,3}$ = yeni kromozomun üretilmesinde kullanılacak rastgele seçilen kromozomlar r_1 , r_2 , $r_3 \in \{1,2,..., NP\}$ $r_1 \neq r_2 \neq r_3 \neq i$.

3.2.3. Çaprazlama

Çaprazlama işleminde, mutasyonda elde edilen çözüm kullanılarak olasılıksal bir deneme çözümü üretilmektedir. En iyi parametreyi seçme işlemi çaprazlama oranı (crossover rate, *CR*) olarak adlandırılan ve [0,1] aralığında değer alan kontrol parametresi ile gerçekleştirilir. Her bir parametre için [0,1] aralığında rasgele üretilen bir değer ile *CR* değeri karşılaştırılır. Rasgele üretilen değer *CR*'den küçükse, ilgili parametrenin yeni değeri mutasyon işlemine tabi tutulan $n_{j,i,G+1}$ vektöründen, büyükse mevcut çözüm vektöründen alınır. Bu sayede mevcut çözümdeki belirli sayıda parametre değiştirilerek yeni olası çözümlerin elde edilmesi amaçlanmaktadır. Çaprazlama işlemi aşağıda Eşitlik 3.8 ile gösterilmiştir.

$$u_{j,i,G+1} = \begin{cases} n_{j,i,G+1} & rand[0,1] \leq CR \; için \\ x_{j,i,G} & aksi \; durumlar \; için \end{cases}, \; j = 1,2,\dots,D \tag{3.8}$$

burada, $u_{j,i,G+1}$ çaprazlama işlemi sonucunda elde edilmiş olan yeni çözüm vektörüdür.

3.2.4. Seleksiyon

Mevcut çözüm vektörü ile yeni üretilen çözüm vektöründen hangisinin bir sonraki jenerasyona aktarılacağı seleksiyon işlemi ile belirlenir. Bunun için her bir çözüm

vektörünün kalite değeri hata fonksiyonları kullanılarak hesaplanır ve daha düşük hata değeri üreten yani kalite değeri daha yüksek olan çözüm bir sonraki jenerasyona aktarılır. Seleksiyon işlemi Eşitlik 3.9 ile gerçekleştirilmektedir.

$$x_{i,G+1} = \begin{cases} u_{i,G+1} \; f(u_{i,G+1}) \leq f(x_{i,G}) \; için \\ x_{i,G} \qquad aksi \; durumlar \; için \end{cases}, \; i = 1,2,\dots,D \tag{3.9}$$

Görüldüğü gibi, yeni üretilen çözüm vektörünün hata değeri mevcut çözüm vektörünün hata değerine eşit ya da ondan daha küçük ise bir sonraki jenerasyona yeni üretilen çözüm vektörü aktarılmaktadır. Aksi durumda ise mevcut çözüm korunmaktadır.

4. BÖLÜM

BENZETİMLER

4.1. Benzetimler ve Sonuçlar

Bu tez çalışmasında, diyabetik retinopati hastalığı nedeniyle oluşan yeni kanamalı bölgeler tespit edilerek hastalığın varlığı, seyri ve ciddiyeti hakkında hekimlere önemli bilgilerin sağlanmasına yönelik sezgisel ABC ve DE algoritmaları kümeleme tabanlı olarak geliştirilmiştir. Ayrıca geliştirilmiş olan algoritmalar ile yeni kanamalı bölgelerin çevreleri çizdirilerek bu bölgelerin piksel tabanlı alan hesaplamaları yapılmıştır. Böylece hekimler tarafından daha anlaşılır görüntüler elde edilebildiği ve hastalıklı bölgeler matematiksel olarak hesaplanabildiği için teşhis ve tedavi süreci önemli ölçüde iyileşmiştir. DR hastalıklı retinal görüntülerde hastalıklı bölgelerin tespitine yönelik benzetimler Şekil 4.1 ile verilen görüntüler üzerinde gerçekleştirilmiştir. Benzetimlerde kullanılan retinal görüntüler, High Resolation Fundus (HRF) Image Database [9] veri tabanından alınmıştır.

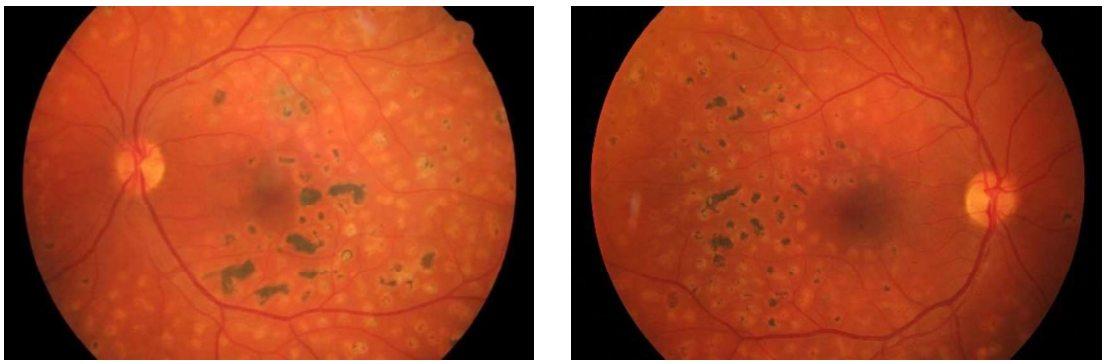

a) Birinci retinal görüntü b) İkinci retinal görüntü

Şekil 4.1. DR hastalıklı retinal görüntüler

DR hastalıklı göz görüntülerinin kümeleme tabanlı analizinde kullanılan K-means, ABC ve DE algoritmalarında kümeleme hataları Eşitlik 4.1 ile verilen Ortalama Karesel Hata (Mean Squared Error, MSE) ve Eşitlik 4.2 ile verilen Öklid Mesafesi (Euclidean Distance, ED) hata fonksiyonları kullanılarak optimize edilmiştir.

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

MSE hata fonksiyonunda, N değeri retinal görüntüdeki toplam piksel sayısını; x_i, *i.* piksele en yakın küme merkezinin değerini ve y_i ise *i.* pikselin temsil ettiği değeri tanımlamaktadır.

$$ED = dist(x, y) = \sqrt{\sum_{i=1}^{N}(x_i - y_i)^2} \tag{4.2}$$

ED hata fonksiyonunda ise N değeri retinal görüntüdeki toplam piksel sayısını temsil etmektedir. x_i, *i.* piksele en yakın küme merkezinin değerini verirken, y_i ise *i.* pikselin temsil ettiği değeri vermektedir.

Retinal görüntü analizine yönelik geliştirilmiş olan kümeleme tabanlı ABC ve DE algoritmaları için benzetimlerde kullanılan parametre değerleri Tablo 4.1 ile verilmiştir.

Tablo 4.1. Retinal görüntü analizine yönelik geliştirilmiş olan kümeleme tabanlı ABC ve DE algoritmalarına ait parametre değerleri

ABC				**DE**			
Koloni Boyutu	Limit değeri	X_{max} ve X_{min}	Çevrim sayısı	Popülasyon Büyüklüğü	Çaprazlama Oranı	Ölçekleme Faktörü	Çevrim sayısı
20	24	Görüntünün en yüksek ve en düşük piksel değerleri	100	20	0.8	0.4	100

Tablo 4.1'de verilen parametrelere ek olarak K-means, ABC ve DE algoritmalarının kümeleme işleminde referans alacağı küme sayısını tanımlayan k parametre değeri k=2 olarak alınmıştır. k parametre değeri aynı zamanda algoritmaların verdiği sonuç

görüntüsünün kaç renk içereceğini tanımlamaktadır. Retinal görüntülerde bütün sağlıklı bölgeler ve bütün hastalıklı bölgeler kendi içerisinde yakın piksel değerlerine sahip oldukları için kümeleme sonucunda elde edilen görüntünün iki renkli olması yani iki küme merkezi etrafında kümeleme analizinin yapılması yeterli olmaktadır.

DR hastalığının tespitinde kullanılan FFA yöntemiyle elde edilen retinal görüntülerin analizinde karşılaşılan en önemli sorun yeni kanamalı bölgeler ile diğer bölgelerin çok yakın piksel değerlerine sahip olmasıdır. Bu nedenle retinal görüntüler analiz edilmeden önce çeşitli görüntü zenginleştirme işlemlerinden geçirilerek kanamalı bölgeler ile diğer bölgelerin piksel değerleri arasındaki farkın artırılması gerekmektedir. Bu tez çalışması kapsamında yapılan benzetimlerde retinal görüntüye ilk olarak filtreleme ve morfolojik işlemler uygulanarak görüntü zenginleştirme işlemleri gerçekleştirilmiştir. Filtreleme, resmin her bir piksel değerinin bir filtre vasıtasıyla yeniden hesaplanması işlemidir. Filtreleme ile piksel değerleri uygunlaştırılır ve bunun bir sonucu olarak görüntü netleşir ve ayrıntılar daha belirgin hale gelir. Morfolojik aşındırma ve genişletme işlemleri ise retinal görüntüyü kümeleme işlemine daha da uygun hale getirmek için uygulanmaktadır.

Şekil 4.1 ile verilen retinal görüntülerin filtreleme, morfolojik aşındırma ve morfolojik genişletme işlemleri sonrasında elde edilen görüntüleri Şekil 4.2 ile verilmiştir.

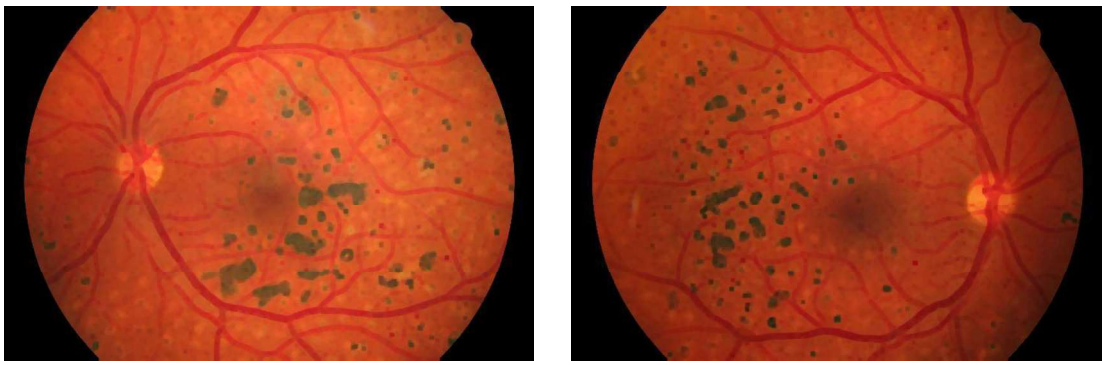

a) Birinci retinal görüntü b) İkinci retinal görüntü

Şekil 4.2. Görüntü zenginleştirme işlemleri sonucu elde edilen göz görüntüleri

Literatürde yaygın olarak kullanılan HRF, DRIVE ve STARE veri tabanlarında yayımlanan retinal görüntüler RGB renk uzayında elde edilen görüntülerdir. Bununla birlikte gerek bu tez çalışması kapsamında gerekse literatürde yapılan analizlerde, retinal görüntüler CIE Lab renk uzayında analiz edildiğinde RGB renk uzayına göre daha iyi

sonuçların elde edildiği görülmüştür. Bu nedenle, retinal görüntülere RGB renk uzayında görüntü zenginleştirme işlemleri uygulandıktan sonra bu görüntüler CIE Lab uzayına dönüştürülerek işlemlere devam edilmektedir. Şekil 4.2 ile verilmiş olan RGB renk uzayındaki retinal görüntülerin CIE Lab renk uzayına dönüştürülmüş karşılıkları aşağıda Şekil 4.3 ile verilmiştir.

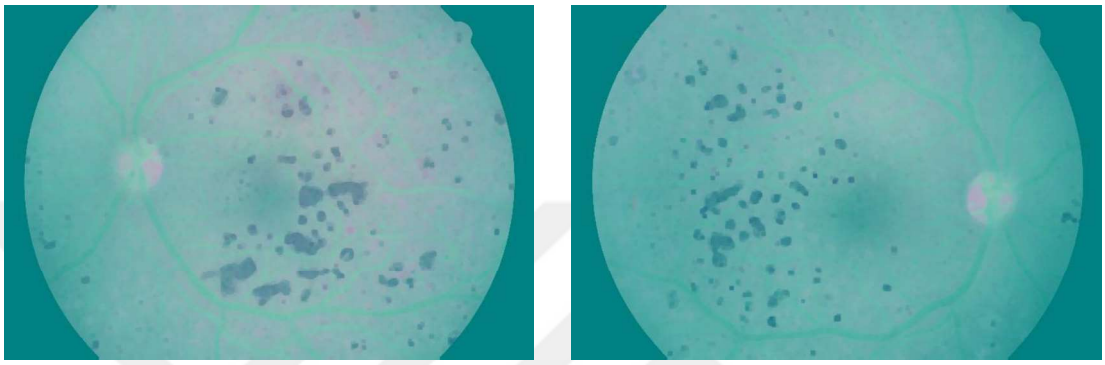

a) Birinci retinal görüntü b) İkinci retinal görüntü

Şekil 4.3. RGB renk uzayındaki retinal görüntülerin CIE Lab renk uzayındaki karşılıkları

CIE Lab renk uzayında elde edilen retinal görüntüler L, a ve b katmanlarından oluşan üç boyutlu yani üç katmanlı görüntülerdir. Şekil 4.3 ile verilmiş olan CIE Lab renk uzayındaki retinal görüntülerin L, a ve b katmanları Şekil 4.4'te gösterilmiştir.

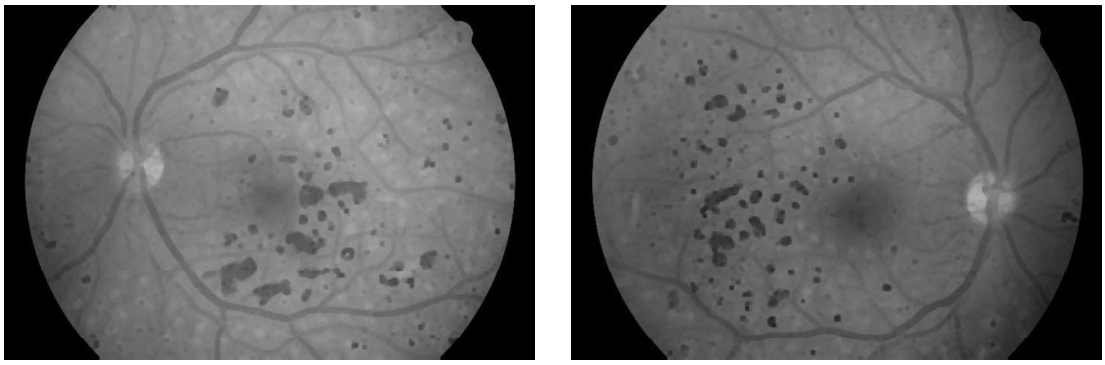

a) Birinci retinal görüntü L katmanı b) İkinci retinal görüntü L katmanı

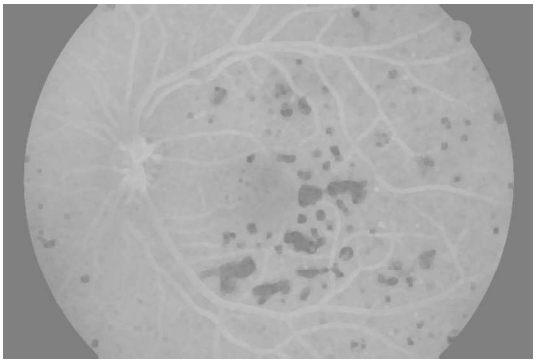

c) Birinci retinal görüntü a katmanı

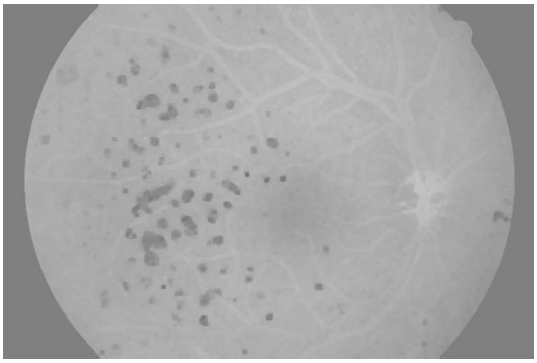

d) İkinci retinal görüntü a katmanı

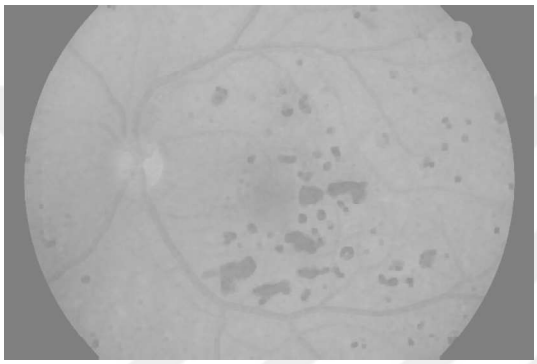

e) Birinci retinal görüntü b katmanı

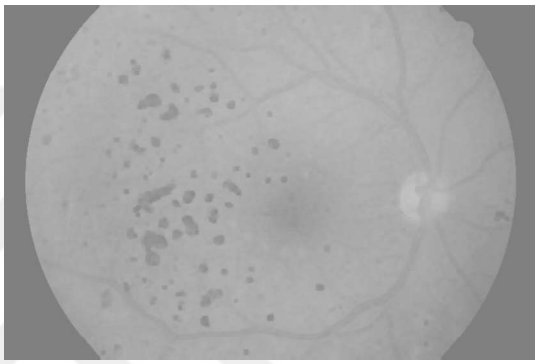

f) İkinci retinal görüntü b katmanı

Şekil 4.4. CIE Lab renk uzayındaki retinal görüntülerin L, a ve b katmanları

Kümeleme işlemi tek katman üzerinde gerçekleştirileceği için öncelikle görüntünün en yüksek kümeleme performansını üretecek katmanının seçilmesi gerekmektedir. L, a ve b katmanlarına ayrı ayrı kümeleme işlemi uygulandıktan sonra her iki görüntü içinde en yüksek kümeleme performansının a katmanı üzerinde elde edildiği görülmüştür. Bu nedenle, K-means, ABC ve DE algoritmaları ile kümeleme işlemi a katmanı üzerinde gerçekleştirilmiştir.

Şekil 4.4'te verilmiş olan a katmanları K-means, ABC ve DE algoritmaları ile kümeleme işlemine tabi tutulduktan sonra elde edilen retinal görüntüler Şekil 4.5 ve Şekil 4.6'da gösterilmiştir. Kümeleme işlemi sonucunda elde edilen bu görüntüler, Şekil 4.1'de verilen orijinal görüntüler ile mukayese edildiğinde K-means, ABC ve DE algoritmalarıyla yapılan kümeleme işlemlerinin her birisinde kanamalı bölgelerin yüksek doğrulukla tespit edildiği görülmektedir. Detaylı analiz etmek gerekirse, birinci retinal görüntü incelendiğinde görüntünün bütününde yüksek doğrulukta kümeleme

gerçekleştirilirken, ikinci retinal görüntünün sınır bölgelerinde kümeleme performansının düştüğü görülmektedir.

Bu tez çalışması kapsamında geliştirilmiş olan kümeleme tabanlı sezgisel ABC ve DE algoritmaları sayesinde K-means algoritması ile benzer kümeleme performansına sahip fakat parametre bağımlılığı düşük, yakınsama hızı yüksek, daha esnek ve uyarlanabilir kümeleme yöntemleri elde edilmiştir.

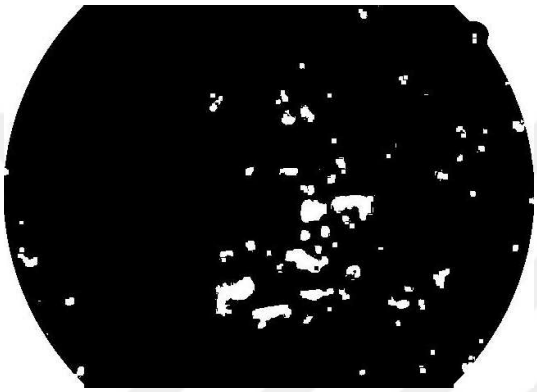

a) Birinci retinal görüntü (K-means)

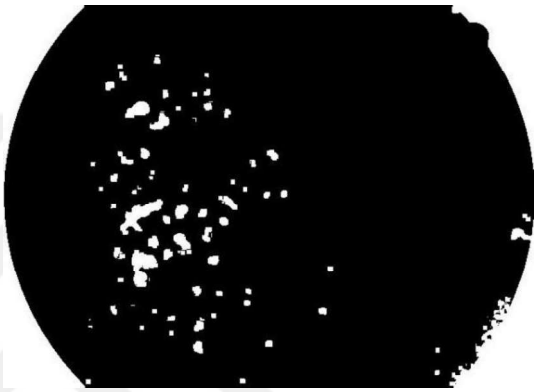

b) İkinci retinal görüntü (K-means)

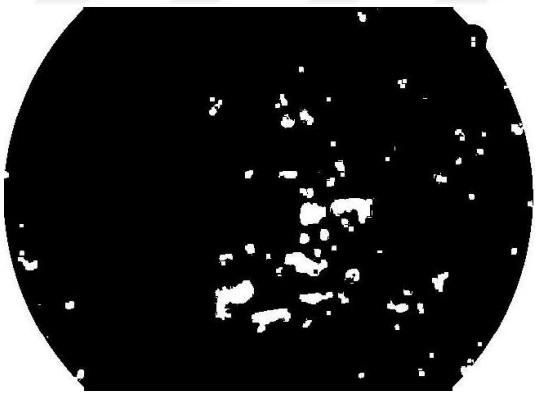

c) Birinci retinal görüntü (ABC)

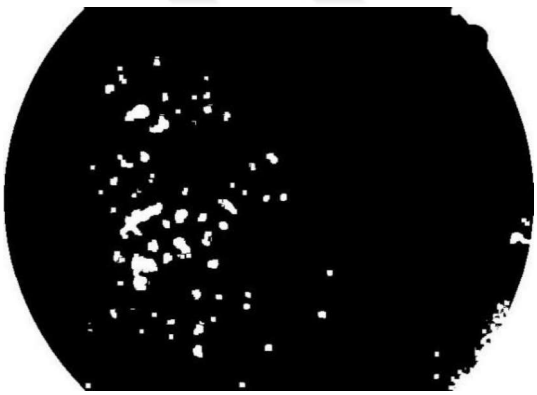

d) İkinci retinal görüntü (ABC)

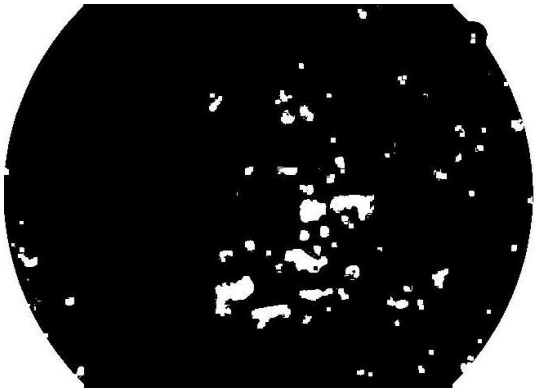

e) Birinci retinal görüntü (DE)



f) İkinci retinal görüntü (DE)

Şekil 4.5. DR hastalıklı retinal görüntülerde yeni kanamalı bölgelerin tespiti sonucu elde edilen görüntüler (MSE hata fonksiyonu)

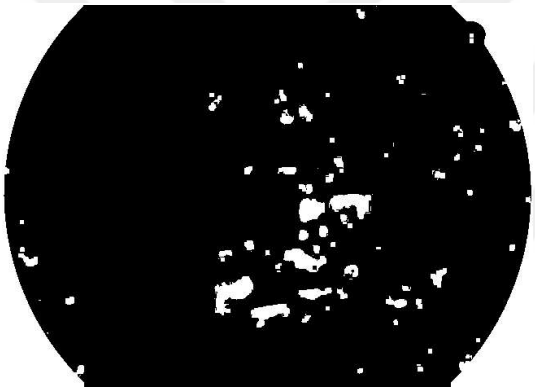

a) Birinci retinal görüntü (K-means)



b) İkinci retinal görüntü (K-means)

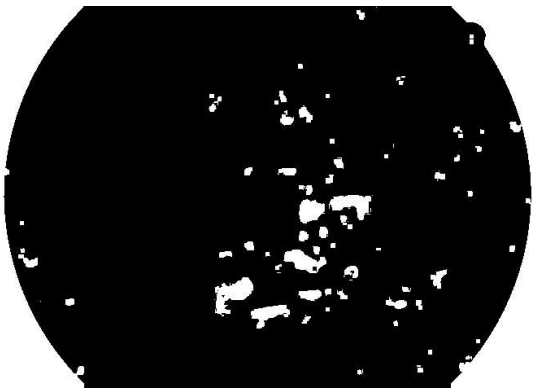

c) Birinci retinal görüntü (ABC)

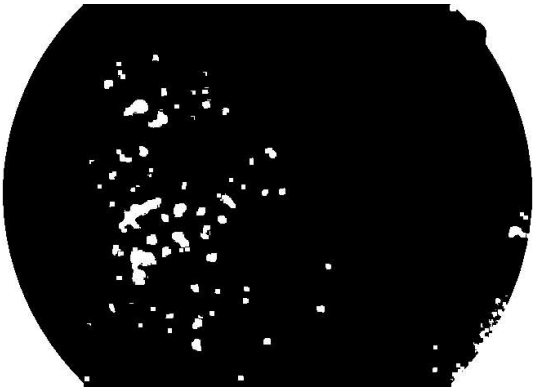

d) İkinci retinal görüntü (ABC)

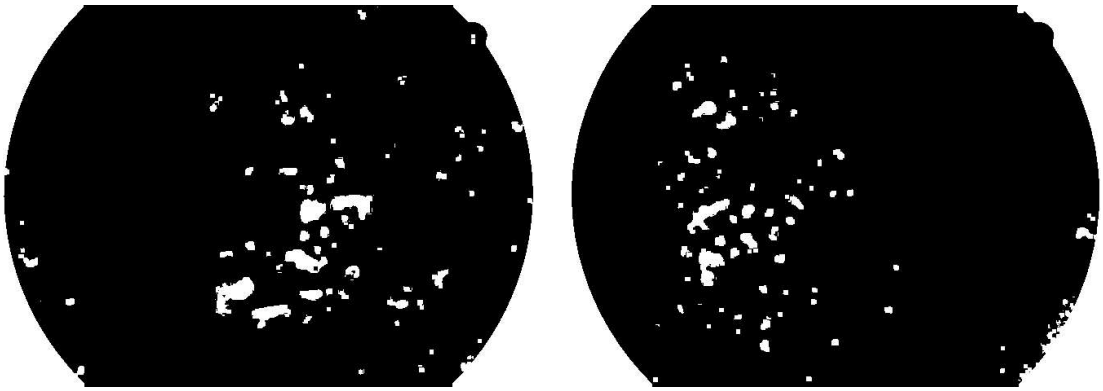

e) Birinci retinal görüntü (DE) f) İkinci retinal görüntü (DE)

Şekil 4.6. DR hastalıklı retinal görüntülerde yeni kanamalı bölgelerin tespiti sonucu elde edilen görüntüler (ED hata fonksiyonu)

Retinal görüntülerde yeni kanamalı bölgelerin yüksek doğrulukta ve daha belirgin bir şekilde tespit edilebilmesi DR hastalığının teşhis ve tedavi süreci için son derece önemlidir. Bu tez çalışmasında ayrıca K-means, ABC ve DE algoritmaları yeni kanamalı bölgelerin çevrelerini çizdirerek piksel tabanlı alan hesaplaması yapabilecek şekilde geliştirilmiştir. Yeni kanamalı bölgelerin çevrelerinin çizdirilmesi ve bu bölgelerin piksel tabanlı alan hesaplamaları için aşağıda verilen adımlar uygulanmıştır.

Çevre Çizdirme :

Kanamalı bölgeler tespit edilir
Tespit edilen bölgelerin sınır bilgileri kaydedilir
Repeat
    Belirlenen sınır noktaları çizilir
Until (*tüm sınırlar tamamlanana kadar*)

Piksel tabanlı alan hesabı ve bu alanların toplanması :

Kapalı alanlı bölgeler tespit edilir
Tespit edilen bölgelerin alanları (içerdikleri piksel sayısı) hesaplanır
Repeat
    Alanlar toplanır
Until (*tüm bölgeler toplanıncaya kadar*)

Kümeleme sonucunda elde edilen görüntüler için yeni kanamalı bölgelerin çevrelerinin çizdirilmesi ile elde edilen retinal görüntüler aşağıda Şekil 4.7 ve Şekil 4.8 ile verilmiştir.

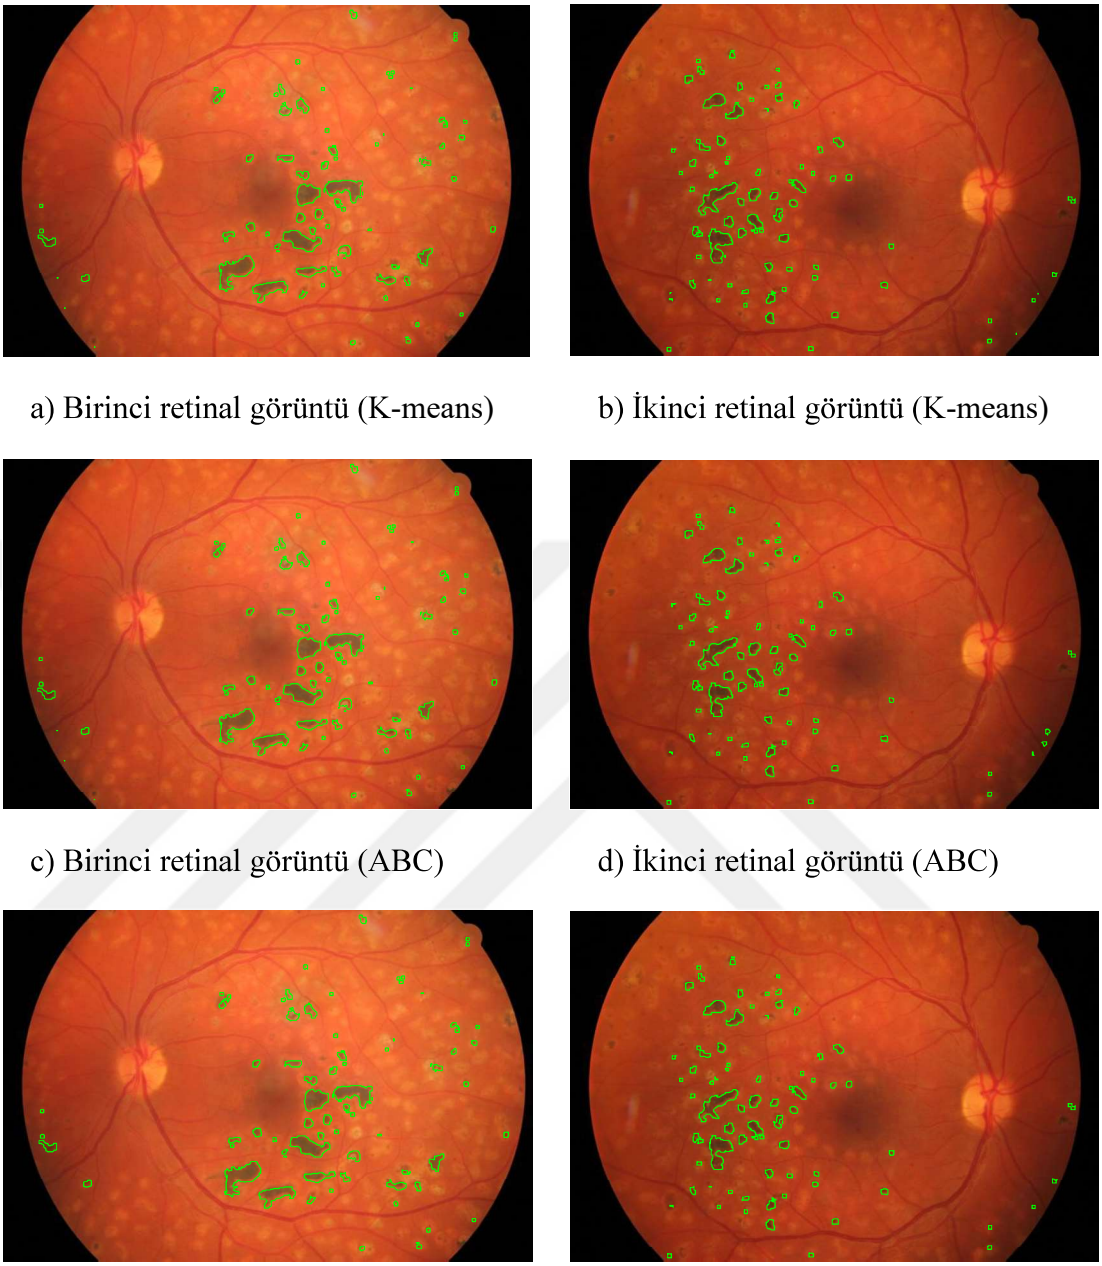

a) Birinci retinal görüntü (K-means) b) İkinci retinal görüntü (K-means)

c) Birinci retinal görüntü (ABC) d) İkinci retinal görüntü (ABC)

e) Birinci retinal görüntü (DE) f) İkinci retinal görüntü (DE)

Şekil 4.7. Retinal görüntülerde yeni kanamalı bölgelerin çevrelerinin çizdirilmesi (MSE hata fonksiyonu)

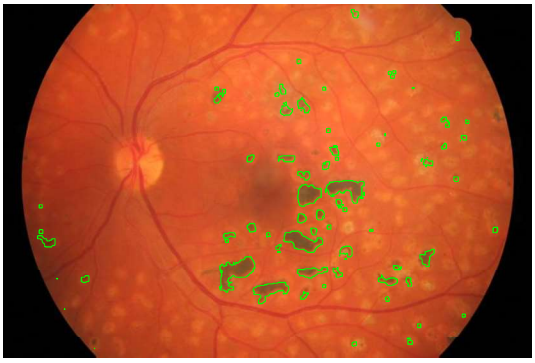

a) Birinci retinal görüntü (K-means)

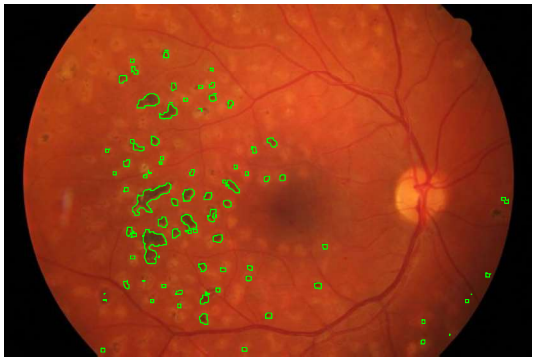

b) İkinci retinal görüntü (K-means)

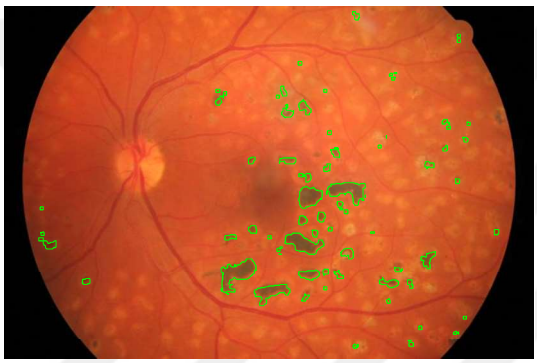

c) Birinci retinal görüntü (ABC)

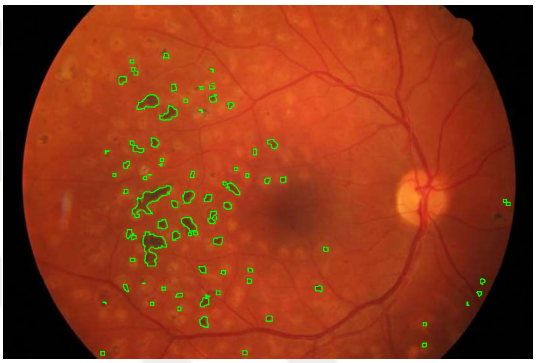

d) İkinci retinal görüntü (ABC)

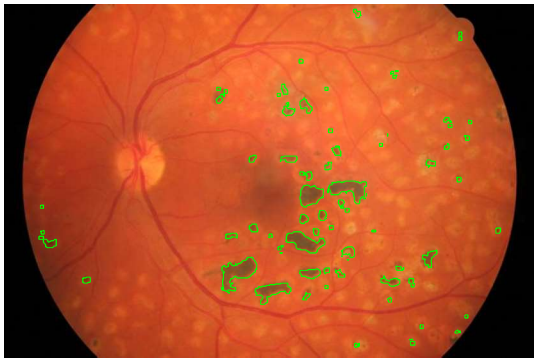

e) Birinci retinal görüntü (DE)

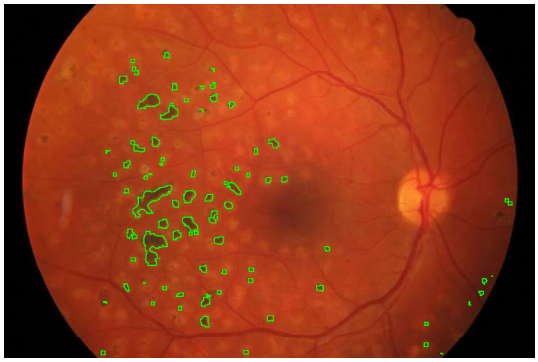

f) İkinci retinal görüntü (DE)

Şekil 4.8. Retinal görüntülerde yeni kanamalı bölgelerin çevrelerinin çizdirilmesi (ED hata fonksiyonu)

Buna göre, yeni kanamalı bölgelerin (θ_i) toplam alanının, göz görüntüsünün toplam alanına (β_i) oranı piksel tabanlı olarak hesaplanmıştır. Geliştirilmiş olan algoritmalar için benzetimlerde elde edilen alan değerleri aşağıda Eşitlik 4.3, Eşitlik 4.4 ve Eşitlik 4.5 ile verilmiştir.

K-means kümeleme algoritmasıyla elde edilen sonuçlarda piksel tabanlı alan oranı,

$$\frac{\sum \theta_i}{\beta_i} = 0.032988 \tag{4.3}$$

ABC algoritmasıyla elde edilen sonuçlarda piksel tabanlı alan oranı,

$$\frac{\sum \theta_i}{\beta_i} = 0.032861 \tag{4.4}$$

DE algoritmasıyla elde edilen sonuçlarda piksel tabanlı alan oranı,

$$\frac{\sum \theta_i}{\beta_i} = 0.032861 \tag{4.5}$$

Bu uygulama hasta üzerinde periyodik olarak yapıldığında hastalığın seyri ve olası riskler hakkında bir veri tabanı oluşturarak tedavi sürecinde daha etkili kararların alınabilmesine olanak sağlayacaktır.

Sezgisel algoritmaların en önemli performans kriterlerinden birisi en iyi çözümlere ulaşma hızını tanımlayan yakınsama hızıdır. DR hastalığı nedeniyle oluşan yeni kanamalı bölgelerin tespitinde kullanılan kümeleme tabanlı ABC ve DE algoritmalarının performans değerlendirmelerinde MSE ve ED hata fonksiyonlarına ait yakınsama grafikleri Şekil 4.9 ve Şekil 4.10 ile verilmiştir. Her bir algoritma için 30 koşmanın ortalaması ile elde edilen yakınsama grafikleri incelendiğinde, ABC algoritmasının her iki retinal görüntü içinde hem MSE ve ED hata performansı açısından hem de en iyi çözümlere yakınsama hızı açısından DE algoritmasına göre daha iyi performansa sahip olduğu görülmektedir. İki farklı hata kriteri ve retinal görüntü için ABC ve DE algoritmalarının benzer sonuçlar üretmesi her iki algoritmanın da kararlı bir şekilde optimizasyon yaptığının ve farklı alanlarda farklı görüntüler içinde kullanılabileceğinin bir göstergesidir.

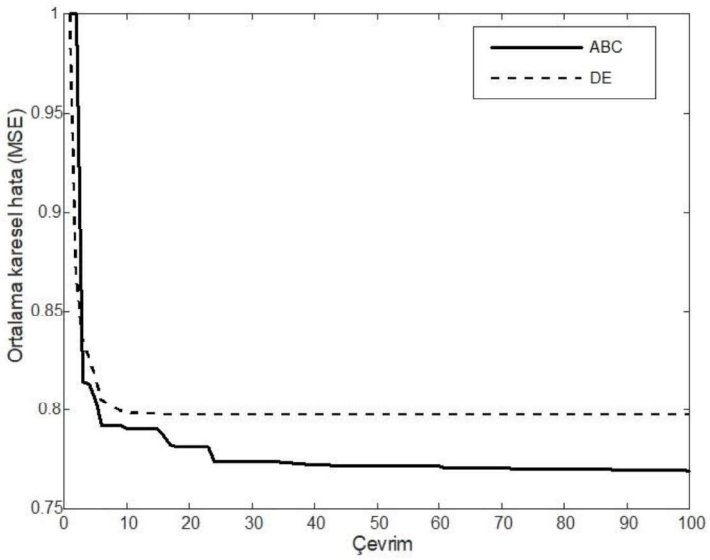

a) MSE hata fonksiyonu için algoritmaların yakınsama hızları

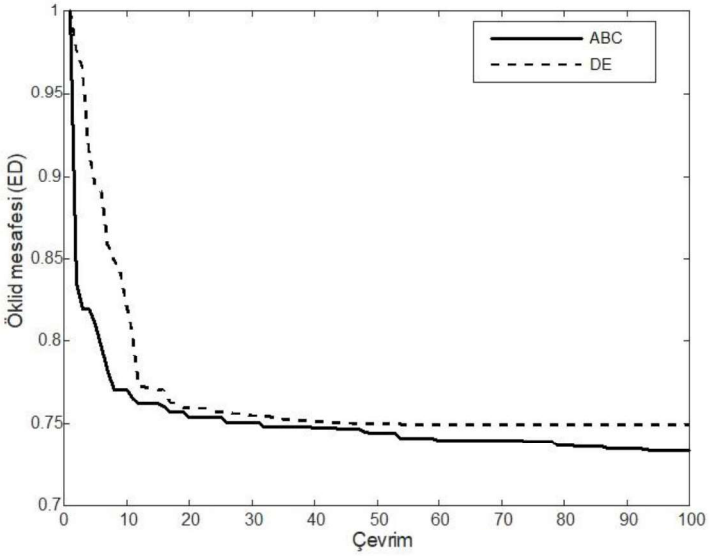

b) ED hata fonksiyonu için algoritmaların yakınsama hızları

Şekil 4.9. Birinci retinal görüntü için ABC ve DE algoritmalarının MSE ve ED yakınsama performansları

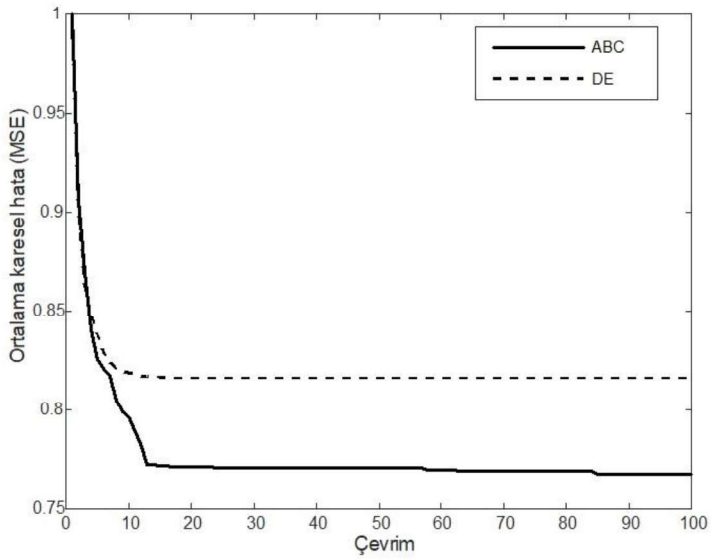

a) MSE hata fonksiyonu için algoritmaların yakınsama hızları

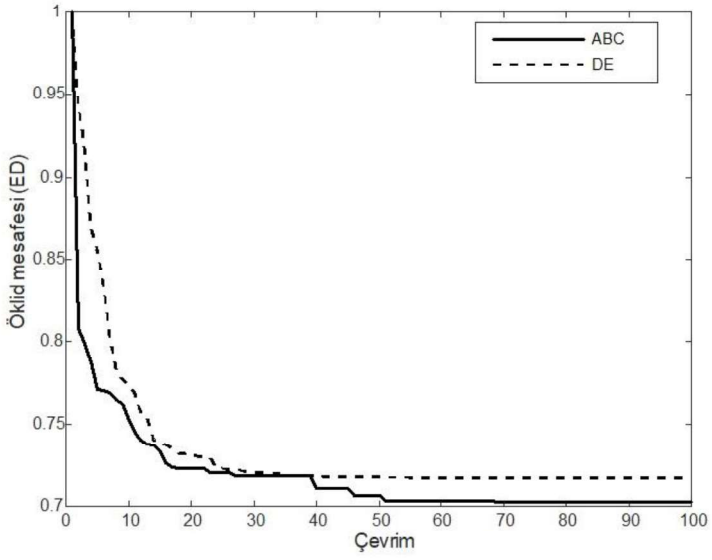

b) ED hata fonksiyonu için algoritmaların yakınsama hızları

Şekil 4.10. İkinci retinal görüntü için ABC ve DE algoritmalarının MSE ve ED yakınsama performansları

5. BÖLÜM

SONUÇ VE TARTIŞMA

Bu tez çalışmasında, FFA yöntemiyle elde edilen retinal görüntüler üzerinde yeni kanamalı bölgelerin tespitine yönelik benzetimler ve analizler yapılmıştır. Sezgisel yaklaşımlardan olan ABC ve DE algoritmaları kümeleme tabanlı olarak geliştirilmiş ve K-means kümeleme algoritması ile performans mukayeseleri gerçekleştirilmiştir.

Tez çalışmasının birinci bölümünde göz anatomisi detaylı bir şekilde incelendikten sonra DR hastalığı ve bu hastalığın nedenleri, belirtileri, gelişimi ve sonuçları üzerinde durulmuştur. Bu bölümde ayrıca DR hastalığının teşhisinde kullanılan FFA yöntemi anlatılarak biyomedikal görüntü işleme alanında yapılan çalışmaları içeren detaylı bir literatür bilgisi de verilmiştir.

İkinci bölümde ise renk uzayları, görüntü zenginleştirme işlemleri ve kümeleme yöntemi detaylı bir şekilde anlatılmıştır. Görüntüyü zenginleştirerek kümeleme performansını artırmak amacıyla uygulanan filtreleme işlemi ve morfolojik işlemler ile bu işlemlerin görüntü üzerindeki etkileri analiz edilerek literatürde yaygın olarak kullanılan klasik algoritmalardan olan K-means kümeleme algoritması anlatılmıştır.

Tez çalışmasının üçüncü bölümünde sürü zekasına dayalı temel ABC ve popülasyon tabanlı DE algoritmaları detaylı bir şekilde açıklanmıştır.

Çalışmanın dördüncü bölümünde retinal görüntülerde yeni kanamalı bölgelerin tespitine ve matematiksel olarak tanımlanabilmesine yönelik geliştirilmiş olan sezgisel ABC ve DE algoritmalarının performansları detaylı bir şekilde analiz edilmiştir. DR hastalıklı göz görüntüleri üzerinde gerçekleştirilen filtreleme ve morfolojik işlemler üzerinden görüntü zenginleştirme işlemleri anlatılarak bu işlemlerin retinal görüntüler üzerindeki etkileri gösterilmiştir. Daha sonra retinal görüntüler üzerinde gerçekleştirilen renk uzayı değişimi

ve katman seçimi işlemleri anlatılarak bu işlemler sonucunda elde edilen görüntüler verilmiştir. Görüntü zenginleştirme işlemlerinin ardından K-means, ABC ve DE algoritmaları ile kümeleme işlemine tabi tutulan görüntüler üzerinde yeni kanamalı bölgelerin çevreleri çizdirilerek hastalıklı bölgeler daha belirgin hale getirilmiştir. Zenginleştirilmiş retinal görüntüler üzerinde yeni kanamalı bölgelerin piksel tabanlı alanları hesaplanarak, hastalığın durumu ve tedavi sürecinin etkileri hakkında matematiksel verilerin elde edilmesi sağlanmıştır.

Yeni kanamalı bölgelerin çevreleri çizdirilerek elde edilen görüntüler ile orijinal görüntüler mukayese edildiğinde K-means, ABC ve DE algoritmaları ile yapılan kümeleme işleminde yeni kanamalı bölgelerin yüksek doğrulukta tespit edilebildiği görülmüştür. Ayrıca, ABC ve DE algoritmaları için 30 koşmanın ortalaması ile elde edilen yakınsama grafikleri incelendiğinde ABC algoritmasının MSE ve ED hata fonksiyonlarının her ikisi için de DE algoritmasına göre daha iyi performansa sahip olduğu ve en iyi çözümlere daha hızlı bir şekilde yakınsadığı görülmüştür.

Sezgisel ABC ve DE algoritmaları ile klasik K-means algoritmasının performanslarının benzer olmasına karşın sezgisel yaklaşımlar esneklikleri, kontrol parametre değerlerine daha az bağımlı olmaları, yerel minimumlara takılmayarak küresel çözümlere ulaşabilmeleri ve yüksek yakınsama hızı gibi önemli avantajlara sahiptirler. Benzetim sonuçları incelendiğinde, ABC ve DE algoritmalarının kümeleme tabanlı görüntü analizinde başarılı bir şekilde kullanılabileceği görülmüştür.

KAYNAKÇA

1. Karaboğa, D., 2005. An Idea Based On Honey Bee Swarm For Numerical Optimization, Technical Report-TR06, Erciyes University.
2. Storn, R., Price, K., 1995. Differential Evolution: A Simple and Efficient Adaptive Scheme for Global Optimization over Continuous Spaces, Technical Report TR-95-012, International Computer Science Institute, Berkeley.
3. International diabetes federation: diabetes atlas, 7th edition, 2015, (Web sayfası: **http://www.diabetesatlas.org**), (Erişim Tarihi: 30.05.2017).
4. Standards of medical care in diabetes-2011. **American Diabetes Association, 34** (1), 11-61, 2011.
5. World Health Organization: Definition and Diagnosiss of Diabetes Mellitus and Intermedia Hyperglycemia. Report of WHO/IDF Consultation. Geneva, Switzerland, 2006.
6. Frank, R. N., 1995. Diabetic retinopathy. **Progress in retinal and eye research, 14**: 361–392.
7. Özçetin, H., Pratik Göz Hastalıkları. F. Özsan Matbaacılık Ltd Şti, Bursa, 200.
8. Olson, J. A., Strachana, F. M., Hipwell, J. H., Goatman, K. A., McHardy, K. C., Forrestera, J. V., and Sharp, P. F., 2003. A comparative evaluation of digital imaging, retinal photography and optometrist examination in screening for diabetic retinopathy. **Diabetic Medicine, 20**: 528–534.
9. High-Resolution Fundus (HRF) image database. (Web sayfası: **http://www5.cs.fau.de** (Erişim Tarihi: 28.04.2016).
10. Novotny, HR, Alvis, DL., 1961. A method of photographing fluorescence in circulating blood in the human retina. **Circulation, 24**: 82-86
11. Yağmur, F. D., 2008. Yapay Sinir Ağları İle Retinada Hastalık Teşhisi, Haliç Üniversitesi, Yüksek Lisans Tezi, İstanbul, 75.

12. Sopharak, A., Uyyanonvara, B., Automatic exudates detection from diyabetic retinopathy retinal ımage using fuzzy c-means and morphological methods, 359-364. Advances in Computer Science and Technology, April 2-4 2007, Phuket, Thailand, 568.
13. Osareh, A., Mirmehdi, M., Thomas, B., Markham, R., Automatic recognition of exudative maculopathy using fuzzy c-means clustering and neural networks. 49–52, Medical Image Understanding and Analysis, July 2001, Birmingham BMVA Press.
14. Çalık, E., 2013. Retina Görüntülerinde Yaşa Bağlı Makula Dejenerasyonunun Bilgisayar Destekli Tespiti. Marmara Üniversitesi, Yüksek Lisans, İstanbul, 77.
15. Şevik, U., 2007. Retina Görüntülerinde Yaşa Bağlı Makula Dejenerasyonunun Bilgisayar Destekli Tespiti. Karadeniz Teknik Üniversitesi, Yüksek Lisans Tezi, Trabzon, 79.
16. Çetin Taş, İ., 2012. Diyabetik Retinopatiye Yol Açan Kanamalı Bölgelerin Fundus Flouresan Anjiografi Görüntüleri Üzerinde Görüntü İyileştirme Ve Temel Sınıflama Metotlarını Kullanarak Tanımlanması, Yüksek Lisans Tezi, Adana, 80.
17. İkibaş, C., 2012. Retinal İmgelerde Optik Disk Ve Makulanın Tespiti Ve Değerlendirilmesi, Doktora Tezi, Trabzon, 169.
18. Nergiz, M., 2013. Diyabetik Retinopati Tespitinde Yeni Bir Algoritma Kullanılarak Optik Disk Yerinin Kestirimi, Yüksek Lisans Tezi, Diyarbakır, 93.
19. Şevik, U., 2014. Retina Görüntülerinin Kalite Değerlendirmesi Ve Diyabetik Retinopati Hastalığının Tespiti, Doktora Tezi, Trabzon, 151.
20. Grassmann, H., Schubring G., 1996. Hermann Günther Grassmann (1809-1877): Visionary Mathematician, Scientist And Neohumanist Scholar: Papers From A Sesquicentennial Conference, Springer, 370/78.
21. Jain, A.K., 1989 Fundamentals Of Digital İmage Processing, Prentice Hall International Editions, 569.
22. Kaufman, L., Rousseeuw, P.J., 1990. Finding Groups In Data: An Introduction To Cluster Analysis, Wiley-Interscience, 342.
23. Anderberg, M.R., 1973. Cluster Analysis For Applications, Academic Press, 376.
24. Özdamar, K., 2004. Paket Programlar ile İstatistiksel Veri Analizi (Çok Değişkenli Analizler), Kaan Kitabevi, 279.

25. MacQueen, J. B. 1965. Some methods for classification and analysis of multivariate observations, 281–297. Proceeding of the Fifth Berkeley Symposium on Mathematical Statisics and Probability, 21 Haziran-18 Temmuz, California, 666.
26. Han, J., Kamber, M. 2001. Data Mining Concepts and Techniques, Morgan Kauffmann Publishers Inc., 500.
27. Berkhin, P., 2006. Survey of clustering data mining techniques, 25-71. Grouping Multidimensional Data (Eds: J. Kogan, C. Nicholas, M. Teboulle). Springer, Berlin, Heidelberg.
28. Tan, P. N., Steinbach, M., Kumar, V., 2006. Introduction to Data Mining, Addison Wesley, 769.
29. Kanungo T., Mount, D.M., Netanyahu, N.S., Piatko C.D., Silverman R., Wu A.Y., 2002. An efficient k-means clustering algorithm: analysis and ımplementation. **IEEE Transactions On Pattern Analysis And Machine Intelligence, 24** (7), 881-892.
30. Karaboğa D., 2014. Yapay Zeka Optimizasyon Algoritmaları, Nobel Akademik Yayıncılık, 246.
31. Shiakolas, P. S., Koladiye, D., Kebrle, J., 2005. **On the optimum synthesis of six-bar linkages using differential evolution and the geometric centroid of precision positions technique. Mechanism and Machine Theory, 40** (3), 319-335.
32. Lin, Y.C., Hwang, K.S., Wang, F.S., 2004. A mixed-coding scheme of evolutionary algorithms to solve mixed-ınteger nonlinear programming problems. **Computers and Mathematics with Applications, 47** (8-9), 1295-1307.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı:	Hüseyin Emre Cıkıt
Uyruğu:	Türkiye (T.C.)
Doğum Tarihi ve Yeri:	09.07.1992 - Giresun
Medeni Durum:	Bekâr
e-mail:	huseyinemrecikit@gmail.com
Yazışma Adresi:	Mehmet Akif Ersoy Mah. 295. Cad. Yenimahalle Belediye Siteleri B2 Blok No: 4F/26 Yenimahalle/ANKARA

EĞİTİM

Derece	Kurum	Mezuniyet Tarihi
Yüksek Lisans	Erciyes Üniversitesi, Mekatronik Müh.	-
Lisans	Erciyes Üniversitesi, Mekatronik Müh.	2015
Lise	Anamur Anadolu Lisesi, Mersin	2010

İŞ DENEYİMLERİ

Yıl	Kurum	Görev
2017-Halen	Türk Standardları Enstitüsü (TSE)	Uzman Yardımcısı

YABANCI DİL

İngilizce

YAYINLAR

1. Çetinkaya M., Duran H., Cıkıt H. E., Cihan M. (2016). Fundus Floresan Anjiografi Görüntülerinde Diyabetik Retinopati Nedeniyle Oluşan Kanama Alanlarının Belirlenmesi. *20. Biyomedikal Mühendisliği Ulusal Toplantısı (BİYOMUT 2016), İzmir, Türkiye, 3 - 5 Kasım 2016*, ss 14.

2. Çetinkaya M.B., Cıkıt H. E. (2017). Differential Evolution Algorithm based Approach to Determine New Hemorrhagic Regions on Fundus Fluorescein Angiography Images. *Second International Symposium on Industrial Design & Engineering (ISIDE 2017), Nevşehir, Türkiye, 13 - 15 Ekim 2017*, ss.120-125.

3. Çetinkaya M.B., Cıkıt H. E. (2019). Artificial Bee Colony Algorithm Based Approach To Determine New Hemorrhagic Regions On Fundus Fluorescein Angiography Images, *4th International Conference on Engineering Technology and Applied Sciences (ICETAS 2019), Kiev/Ukraine 24-28 Nisan 2019,* ss. 186-189.