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

META-SEZGİSEL ALGORİTMALARA DAYALI RETİNAL DAMAR BÖLÜTLEME

Hazırlayan
Kader TAŞKIRAN

Danışman
Doç. Dr. Mehmet Bahadır ÇETİNKAYA

Yüksek Lisans Tezi

Mayıs 2023
KAYSERİ

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

META-SEZGİSEL ALGORİTMALARA DAYALI RETİNAL DAMAR BÖLÜTLEME

(Yüksek Lisans Tezi)

Hazırlayan
Kader TAŞKIRAN

Danışman
Doç. Dr. Mehmet Bahadır ÇETİNKAYA

Mayıs 2023
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.

Kader TAŞKIRAN

İmza

“Meta-Sezgisel Algoritmalara Dayalı Retinal Damar Bölütleme” adlı Yüksek Lisans Tezi, Erciyes Üniversitesi Lisansüstü Tez Önerisi ve Tez Yazma Yönergesi’ ne uygun olarak hazırlanmıştır.

Hazırlayan	**Danışman**
Kader TAŞKIRAN	Doç. Dr. Mehmet Bahadır ÇETİNKAYA
İmza	İmza

Mekatronik Mühendisliği ABD Başkanı

Prof. Dr. Şahin YILDIRIM

İmza

TEŞEKKÜR

Bu çalışmanın gerçekleştirilmesinde, güler yüzünü, ilgisini ve yardımlarını benden esirgemeyen, lisans hayatıma başladığım günlerden beri bilgisi ve birikimleriyle bana daima yol gösteren, farklı bakış açısı ve enerjisiyle büyük katkı sahibi değerli hocam Doç. Dr. Mehmet Bahadır ÇETİNKAYA'ya sonsuz teşekkürlerimi sunarım.

Ayrıca; sevgisini daima yanımda hissettiğim, maddi ve manevi desteğini hiçbir zaman esirgemeden beni bugünlere getiren, hayattaki en büyük şansım olan aileme teşekkürü borç bilirim.

Kader TAŞKIRAN

Mayıs 2023, KAYSERİ

META-SEZGİSEL ALGORİTMALARA DAYALI RETİNAL DAMAR BÖLÜTLEME

Kader TAŞKIRAN

Erciyes Üniversitesi, Fen Bilimleri Enstitüsü
Yüksek Lisans Tezi, Mayıs 2023
Danışman: Doç. Dr. Mehmet Bahadır ÇETİNKAYA

ÖZET

Biyomedikal görüntülerin yüksek doğrulukta analiz edilebilmesi ilgili hastalığın teşhis ve tedavi süreci açısından son derece önemlidir. Yapay zekâ algoritmalarını temel alan bilgisayar destekli yaklaşımlar son yıllarda biyomedikal görüntü analizinde etkin bir şekilde kullanılmaktadır. Retina tabakası kılcal damar yapısında ortaya çıkan daralma, genişleme ve kanama gibi yapısal değişimler retinal hastalıklar hakkında ön bilgi verebilmektedir. Bu nedenle, retinal görüntülerde damar tespitine yönelik meta-sezgisel algoritmalara dayalı analiz yöntemlerinin geliştirilmesi son yıllarda önemli bir çalışma alanı haline gelmiştir.

Bu tez çalışmasında, en güncel sürü zekâsına dayalı meta-sezgisel algoritmalardan olan Vahşi At Optimizasyon (Wild Horse Optimization, WHO) ve Kel Kartal Araştırma (Bald Eagle Search, BES) Optimizasyon algoritmaları kümeleme tabanlı olarak geliştirilmiş ve retinal görüntülerde damar piksellerinin yüksek doğrulukta tespitine yönelik uygulanmışlardır. Ayrıca, bu algoritmaların performansları literatürdeki en etkin sürü zekâsına dayalı meta-sezgisel algoritmalardan birisi olan Gri Kurt Optimizasyon (Grey Wolf Optimization, GWO) algoritması ile mukayese edilmiştir. Sonuçlar incelendiğinde, retinal görüntülerde çok yakın piksel değerlerine sahip olan art alan pikselleri ile damar piksellerinin WHO, BES ve GWO algoritmaları tarafından başarılı bir şekilde ayırt edilebildikleri görülmüştür. Sonuç olarak, meta-sezgisel algoritmaların kümeleme tabanlı çözüm gerektiren diğer mühendislik problemlerinde de başarılı bir şekilde kullanılabileceği ifade edilebilir.

Anahtar Kelimeler : Retinal Damar Bölütleme, Vahşi At Optimizasyon Algoritması, Kel Kartal Araştırma Algoritması, Gri Kurt Optimizasyon Algoritması.

RETINAL VESSEL SEGMENTATION BASED ON META-HEURISTIC ALGORITHMS

Kader TAŞKIRAN

Erciyes University, Graduate School of Natural and Applied Sciences
Master Thesis, May 2023
Supervisor: Assoc. Prof. Dr. Mehmet Bahadır ÇETİNKAYA

ABSTRACT

Analysis of the biomedical images with high accuracy is extremely important for the diagnosis and treatment process of the related diseases. In recent years, computer-aided approaches based on artificial intelligence algorithms have been used effectively in biomedical image analysis. The structural changes occurring in the vessel structure of the retinal layer due to arteriolar stenosis, arteriolar dilatation and vascular bleeding are able to give preliminary information about retinal diseases. Therefore, the improvement of meta-heuristic algorithms based analysis methods for vessel segmentation in retinal images has become an important area of research in recent years.

In this thesis, Wild Horse Optimization (WHO) and Bald Eagle Search (BES) optimization algorithms, which are among the most recently proposed swarm intelligence algorithms, have been improved as clustering based and then applied for the segmentation of pixels in retinal images with higher-accuracy. In addition, the performances of these algorithms have been compared with the Gray Wolf Optimization (GWO) algorithm, which is one of the most effective swarm intelligence meta-heuristic algorithms in the literature. The results obtained represent that the background pixels and vessel pixels, which have close pixel values in retinal images, can successfully be segmented by WHO, BES and GWO algorithms. As a result, it can be stated that meta-heuristic algorithms can successfully be used in other engineering problems that require clustering-based solutions.

Keywords: Retinal Vessel Segmentation, Wild Horse Optimization Algorithm, Bald Eagle Research Algorithm, Gray Wolf Optimization Algorithm.

İÇİNDEKİLER

META - SEZGİSEL ALGORİTMALARA DAYALI RETİNAL DAMAR BÖLÜTLEME

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

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. Genel Bilgiler…….1

1.1.1. Kümeleme (Clustering) Yaklaşımı…….……2

1.1.2. DRİVE ve STARE Veri Tabanları……..……..….3

1.1.3. Görüntü Zenginleştirme Yaklaşımları…….……4

1.2. Literatür Araştırması……...6

2. BÖLÜM

YÖNTEM VE MATERYAL

2.1.Vahşi At Optimizasyon (WHO) Algoritması…….……9

2.2. Kel Kartal Araştırma (BES) Optimizasyon Algoritması……13

3. BÖLÜM

BULGULAR

3.1. Retinal Görüntülere Uygulanan Ön İşlemler 16

3.1.1. Band Seçme Ön İşlemi 16

3.1.2. Alt-şapka Dönüşümü Ön İşlemi 19

3.1.3. Kontrast Germe Ön İşlemi 20

4. BÖLÜM

TARTIŞMA-SONUÇ ve ÖNERİLER

SONUÇ 35

KAYNAKÇA 37

ÖZGEÇMİŞ 41

KISALTMALAR

DR	: Diyabetik Retinopati (Diabetic Retinopati)
DRİVE	: The Digital Retinal Images for Vessel Extraction
STARE	: The Structured Analysis of the Retina
RGB	: Kırmızı-Yeşil-Mavi (Red-Green-Blue)
WHO	: Vahşi At Optimizasyon (Wild Horse Optimization)
BES	: Kel Kartal Araştırma (Bald Eagle Search)
WHO	: Gri Kurt Optimizasyon (Grey Wolf Optimization)
MSE	: Ortalama Karesel Hata (Mean Squared Error)
CPU	: Merkezi İşlem Birimi (Central Processing Unit)
TP	: Doğru Pozitif (True Positive)
TN	: Doğru Negatif (True Negative)
FP	: Yanlış Pozitif (False Positive)
FN	: Yanlış Negatif (False Negative)

TABLOLAR LİSTESİ

Tablo 3.1. Algoritmalara ait parametre değerleri 21
Tablo 3.2. WHO, BES ve GWO algoritmaları için ortalama merkezi işlemci süreleri 28
Tablo 3.3. DRIVE veri tabanına yönelik benzetimlerde WHO, BES ve GWO Algoritmaları için elde edilen En Düşük MSE, Ortalama MSE ve Standart Sapma değerleri 31
Tablo 3.4. STARE veri tabanına yönelik benzetimlerde WHO, BES ve GWO algoritmaları için elde edilen En Düşük MSE, Ortalama MSE ve Standart Sapma değerleri 32
Tablo 3.5. Meta-sezgisel algoritmaların Duyarlılık ve Kesinlik açısından istatiksel Analizi 33

ŞEKİLLER LİSTESİ

Şekil 1.1. Diyabetik retinopati hastalığının retina tabakası üzerindeki etkisi, (a) Sağlıklı retinal görüntü, (b) Hastalıklı retinal görüntü 1

Şekil 1.2. DRIVE ve STARE veri tabanlarından alınan örnek retinal görüntüler ve bu görüntülere ait maske görüntüleri 5

Şekil 1.3. DRIVE veri tabanından alınan örnek retinal görüntüye Alt-şapka dönüşümü uygulandıktan sonra elde edilen görüntü 6

Şekil 2.1. WHO algoritması için başlangıç popülasyonu yapısı 11

Şekil 3.1. DRIVE veri tabanından alınan test görüntüleri için Band Seçme Ön İşlemi sonrasında elde edilen zenginleştirilmiş retinal görüntüler 18

Şekil 3.2. STARE veri tabanından alınan test görüntüleri için Band Seçme Ön İşlemi sonrasında elde edilen zenginleştirilmiş retinal görüntüler 19

Şekil 3.3. DRIVE veri tabanından alınan test görüntüleri için WHO algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler .. 22

Şekil 3.4. DRIVE veri tabanından alınan test görüntüleri için BES algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler .. 23

Şekil 3.5. DRIVE veri tabanından alınan test görüntüleri için GWO algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler. 24

Şekil 3.6. STARE veri tabanından alınan test görüntüleri için WHO algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler. 25

Şekil 3.7. STARE veri tabanından alınan test görüntüleri için BES algoritmasına dayalı

Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler. 26

Şekil 3.8. STARE veri tabanından alınan test görüntüleri için GWO algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler 27

Şekil 3.9. DRIVE veri tabanından alınan retinal görüntüler için kümeleme tabanlı WHO, BES ve GWO algoritmalarının yakınsama performans mukayeseleri..... 29

Şekil 3.10. STARE veri tabanından alınan retinal görüntüler için kümeleme tabanlı WHO, BES ve GWO algoritmalarının yakınsama performans mukayeseleri..... 30

1. BÖLÜM

GENEL BİLGİLER ve LİTERATÜR ÇALIŞMASI

1.1. Genel Bilgiler

Diyabet hastalığı farklı uzuvlar üzerinde deformasyonlar oluşturan ve fonksiyon kayıplarına yol açan önemli bir hastalıktır. Bu hastalığın bir sonucu olarak en yaygın karşılaşılan kayıplar ise göz içerisinde Retina Tabaka üzerindeki kılcal damarlarda ortaya çıkmaktadır. Diyabetik Retinopati (Diabetic Retinopathy, DR) olarak adlandırılan ve kılcal damarlar üzerinde yapısal bozulmalara yol açan bu hastalığa sahip örnek bir retinal görüntü aşağıda Şekil 1.1 (b) ile gösterilmiştir.

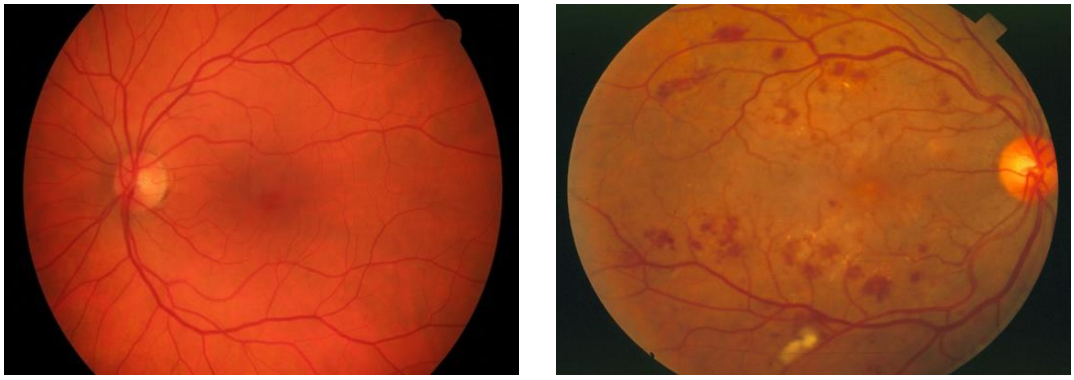

(a) (b)

Şekil 1.1. Diyabetik Retinopati hastalığının retina tabakası üzerindeki etkisi, (a) Sağlıklı retinal görüntü, (b) Hastalıklı retinal görüntü

DR veya benzeri hastalıkların bir sonucu olarak kılcal damarlarda ortaya çıkan bu zayıflamalar, genişlemeler ve kanamalar hipertansiyon, glukoma ve damar sertliği gibi retinal hastalıklara yol açar ve bu hastalıkların bir sonucu olarak da ışık ile retina tabakası

arasındaki iletişim zayıflayarak görme bozuklukları veya tamamen görme kayıpları ortaya çıkar.

Retinal hastalıkların teşhis ve tedavisine yönelik etkin yöntemlerin geliştirilebilmesi için kılcal damarlar üzerinde oluşan yapısal bozuklukların yüksek doğrulukta tespit edilerek gelişimlerinin iyi bir şekilde takip edilmesi gerekmektedir. Retinal görüntüler incelendiğinde ise retina art alanı ile damar piksel değerlerinin birbirine çok yakın değerlerde olduğu görülmektedir. Bu nedenle, retinal görüntülerde art alan pikselleri ile damar piksellerinin birbirinden yüksek doğrulukta ayırt edilmesi yani *Retinal Damar Bölütleme* işleminin yüksek doğrulukta gerçekleştirilebilmesi son derece önemlidir.

Görüntü bölütleme işlemine yönelik literatürde yaygın bir şekilde kullanılan geleneksel görüntü işleme yaklaşımları aşağıdaki gibi gruplandırılabilir,

- Örüntü tanımaya dayalı yöntemler,
- İki-boyutlu (2-D) süzgeç yapıları ile süzgeçleme yöntemleri,
- Morfolojik görüntü işleme yöntemleri,
- Damar izlemeye yönelik yöntemler,
- Çok ölçekli yaklaşımlar,
- Model tabanlı yaklaşımlar.

Son yıllarda, geleneksel yaklaşımlara göre daha etkin çözümler üretebilme yeteneğine sahip türeve dayalı algoritmalar, sezgisel algoritmalar ve özellikle meta-sezgisel algoritmalar gibi yaklaşımlar damar bölütleme işlemine yönelik olarak kullanılmaya başlanmıştır.

Literatürde sunulmuş olan benzetim tabanlı ve uygulama tabanlı çalışmalar incelendiğinde geleneksel, türeve dayalı ve sezgisel yaklaşımların tamamı için görüntü bölütleme işlemlerinin çok büyük bir kısmının *Kümeleme (Clustering) Yaklaşımı* temel alınarak gerçekleştirildiği görülmektedir.

1.1.1. Kümeleme (Clustering) Yaklaşımı

Kümeleme, bir veri setini oluşturan verilerin probleme yönelik tanımlanan kurallara uygun şekilde alt gruplara/sınıflara ayrıştırılması işlemidir. Kümeleme işlemi sonucunda veri seti içerisinde aralarında benzerlikler bulunan veriler aynı gruplar içerisinde olacak

şekilde sınıflandırılırlar ve bu sayede toplam veri seti daha homojen bir yapıya getirilmiş olur.

Kümeleme işlemi aşağıda belirtilen dört farklı amaca yönelik olarak gerçekleştirilebilir [1],

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 işlemine yönelik belirlenen grup/sınıf sayısı *Küme Merkezi Sayısı* olarak tanımlanır ve *k* değişkeni ile sembolize edilir. Optimal *Küme Merkezi Sayısı (k)* probleme özgü olup, problem sınırları dâhilinde olmak koşulu ile alabileceği değer açısından herhangi bir kısıt bulunmamaktadır. Bununla birlikte, belirlenen küme merkezi sayısı görüntü bölütleme performansını doğrudan etkileyen önemli bir faktördür.

Bu tez çalışması kapsamında analiz edilen retinal görüntülerde piksel değerleri ***Damar Pikselleri*** (*vessel pixels*) ve ***Damar Olmayan Pikseller*** (*non-vessel pixels*) olarak iki gruba ayrıştırılmış yani küme merkezi sayısı, $\boldsymbol{k = 2}$ olarak belirlenmiştir. Retinal görüntüyü oluşturan her bir piksel [0,255] aralığında piksel değerleri alabileceği için kümeleme işlemi aşağıdaki gibi tanımlanmıştır,

- [*küme merkezi 1* *küme merkezi 2*] piksel aralığında kalan piksel değerleri ***Damar Pikselleri*** olarak sınıflandırılmıştır.
- [*0* *küme merkezi 1*] ve [*küme merkezi 2* *255*] piksel aralıklarında kalan piksel değerleri ise ***Damar Olmayan Pikseller*** olarak sınıflandırılmıştır.

1.1.2. DRIVE ve STARE Veri Tabanları

Literatürde retinal damar bölütleme uygulamalarına yönelik standardize edilmiş retinal görüntüleri içeren ve en yaygın olarak tercih edilen veri tabanları; *i.) The Digital Retinal*

Images for Vessel Extraction (DRIVE) [2,3] ve, *ii.) The Structured Analysis of the Retina (STARE)* [2,4] veri tabanlarıdır.

DRIVE veri tabanında bulunan retinal görüntüler CanonCR5 3CCD kamera kullanılarak 45° 'lik açı altında çekim yapılarak Kırmızı-Yeşil-Mavi (Red-Green-Blue, RGB) kanallarının her birisi için *(565 × 584)* piksel çözünürlüğünde elde edilmiştir. STARE veri tabanında bulunan retinal görüntüler ise TopCon TRV-50 kamera kullanılarak 35° açı altında yapılan çekimlerde tüm kanallar için *(700 × 605)* piksel çözünürlüğünde elde edilmişlerdir.

DRIVE ve STARE veri tabanlarının her ikisinde de 20 adet retinal görüntü ve ayrıca bu retinal görüntülere ait *Maske Görüntüler* bulunmaktadır. Orijinal görüntülere ait ideal damar haritasını veren bu maske görüntüler kullanılarak elde edilen sonuçların doğrulukları test edilebilmekte ve ayrıca kullanılan yöntemlerin başarımına yönelik detaylı istatistiksel analizler gerçekleştirilebilmektedir. DRIVE ve STARE veri tabanlarından alınmış olan örnek retinal görüntüler ve bunlara ait maske görüntüler aşağıda Şekil 1.2 ile gösterilmiştir.

1.1.3. Görüntü Zenginleştirme Yaklaşımları

Retinal görüntüler analiz edilirken karşılaşılan en önemli zorluk ***Damar Piksel*** değerleri ile ***Damar Olmayan Piksel*** (*art alan pikselleri*) değerleri arasında yüksek benzerliklerin görülmesidir. Bu durum ise görüntü bölütleme işlemi esnasında kullanılan yapay zekâ algoritmalarının başarımını önemli oranda düşürebilmektedir. Bu nedenle, orijinal retinal görüntünün damar bölütleme işlemi için algoritmaya uygulanmadan hemen önce bazı *Görüntü Zenginleştirme* işlemlerine tabi tutulması gerekmektedir. Bu tez çalışmasında, damar piksel değerleri ile art alan piksel değerleri arasındaki farkları belirginleştirmek amacıyla algoritmalara uygulanmadan önce retinal görüntüler *Alt-şapka* (*Bottom-hat) Süzgeçleme* ve *Kontrast Zenginleştirme* ön işlemlerine tabi tutularak zenginleştirilmişlerdir.

Alt-şapka Süzgeçleme işlemi ile parlak bir görüntü art alanı içerisindeki koyu nesneler yapısal elemanlar yani süzgeçler kullanılarak belirginleştirilmektedir. Bu dönüşüm Gri Skalada gerçekleştirilir ve dönüşüm esnasında *Diamond, Disk, Line, Rectangle, Sphere* ve *Cube* gibi süzgeç yapıları kullanılır. Bu tez çalışması kapsamında gerçekleştirilen

benzetimlerde alt-şapka dönüşümü gerçekleştirilirken süzgeç yapısı olarak 8-birim yarı çaplı düzlemsel bir *Disk* süzgeç kullanılmıştır. Aşağıda Şekil 1.3'te örnek bir retinal görüntü ve alt-şapka dönüşümü sonrası elde edilen görüntüsü verilmiştir.

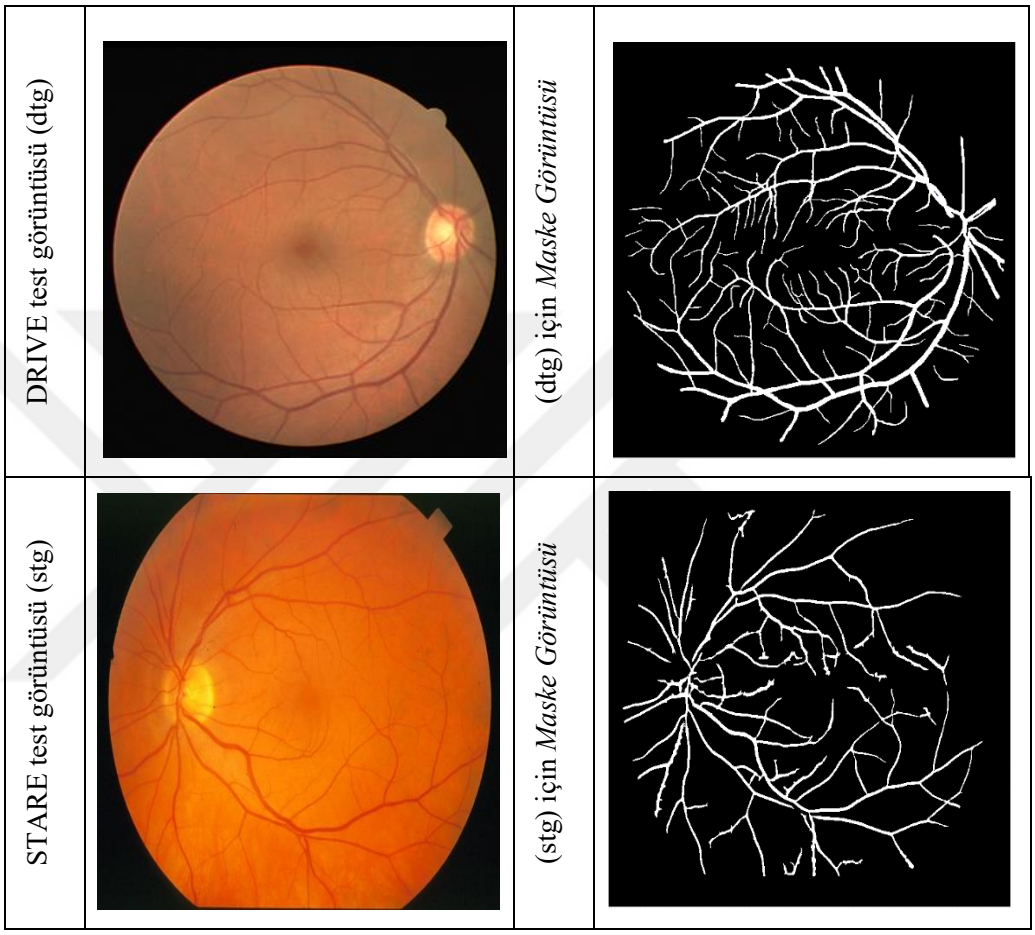

Şekil 1.2. DRIVE ve STARE veri tabanlarından alınan örnek retinal görüntüler ve bu görüntülere ait maske görüntüleri

Kontrast zenginleştirme ön işlemi ile retinal görüntünün Gri Skalada bölgesel olarak yoğunlaşmış piksel değerlerinin skalanın bütününe yani [0 255] piksel değer aralığına homojen olarak dağıtılması gerçekleştirilerek görüntü kontrastı artırılmaktadır. Eşitlik 1.1, en temel kontrast zenginleştirme yaklaşımını göstermektedir.

$$g\,(x,y) = \;\; a\,[\,f(x,y)] \tag{1.1}$$

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 [1]. Benzetimlerde kontrast zenginleştirme işlemi alt-şapka dönüşümünden sonra elde edilen görüntülere uygulanmış ve algoritmalara uygulanacak olan nihai görüntüler elde edilmiştir.



Şekil 1.3. DRIVE veri tabanından alınan örnek retinal görüntüye Alt-şapka dönüşümü uygulandıktan sonra elde edilen görüntü

Bu tez çalışması kapsamında, en güncel sürü zekâsına dayalı meta-sezgisel algoritmalardan olan *Vahşi At Optimizasyon (Wild Horse Optimization, WHO)* ve *Kel Kartal Araştırma (Bald Eagle Search, BES) Optimizasyon* algoritmaları kümeleme tabanlı olarak geliştirilmiş ve retinal görüntülerde damar piksellerinin yüksek doğrulukta tespitine yönelik uygulanmışlardır. Ayrıca, bu algoritmaların performansları literatürdeki en etkin sürü zekâsına dayalı meta-sezgisel algoritmalardan bir diğeri olan *Gri Kurt Optimizasyon (Grey Wolf Optimization, GWO)* algoritması ile mukayese edilmiştir.

1.2. Literatür Araştırması

Retinal hastalıklardaki önemli semptomların yüksek doğrulukta teşhis ve tedavisi için retinal damar bölütleme uygulamaları son derece önem arz etmektedir [5]. Literatürde retinal görüntü analizine yönelik geleneksel algoritmalar sıklıkla kullanılmasına karşın bu alana yönelik meta-sezgisel algoritmaların çok sınırlı sayıda kullanıldığı görülmektedir. Literatür taraması gerçekleştirildiğinde çalışmaların üç farklı ana başlık

altında toplandığı görülmektedir. Bunlar, *i.)* retinal damar bölütlemesine yönelik bilgisayar destekli yaklaşımların geliştirilmesi, *ii.)* retinal damar bölütlemesine yönelik sezgisel ve meta-sezgisel algoritmaların geliştirilmesi ve son olarak, *iii.)* görüntüler üzerinde çok seviyeli eşikleme yaklaşımına yönelik sezgisel ve meta-sezgisel algoritmaların geliştirilmesi olarak sınıflandırılabilir.

Retina tabakasında görülen Oftalmik Bozuklukların (ophthalmic disorders) teşhis ve tedavisinde geleneksel yaklaşımların yetersiz kalmasından dolayı son yıllarda bilgisayar destekli yöntemler geliştirilerek kullanılmaya başlanmıştır [6]. Bilgisayar destekli yöntemlerin ayrıca obezite [7], hipertansiyon [8], göz tansiyonu [9] ve diyabetik retinopati [10-12] gibi retinal hastalıklar için yüksek doğrulukta çözümler sunduğu da görülmüştür. [13] numaralı çalışmada, Heneghan ve arkadaşları tarafından prematüre retinopati hastalığının tedavisine yönelik etkin bir yaklaşım önerilmiştir. Lowell ve arkadaşları [14] numaralı çalışmalarında, önerdikleri 2-Boyutlu Modelleme yaklaşımının retinal damarların boyut analizinde başarılı bir şekilde kullanılabileceğini göstermişlerdir. Retinal görüntüler üzerinde bölgesel analizlerin araştırıldığı [15] numaralı çalışmada, Markov rastgele alanları kullanılarak retina anjiyogramlarında foveal avasküler bölgelerin yüksek doğrulukta tespiti gerçekleştirilmiştir. Grisan ve Ruggeri tarafından sunulmuş olan [16] numaralı çalışmada retina damarlarının arterler ve damarlar olarak otomatik sınıflandırılmasına yönelik bir strateji önerilmiştir. [17-19] numaralı çalışmalarda ise retinal hastalıklara yönelik farklı tedavi yaklaşımları önerilmiştir. Archer tarafından [17] numaralı çalışmasında bazı hücresel ve moleküler tedavi yaklaşımları önerilirken, Antal ve Hadju tarafından [18] numaralı çalışmalarında mikroanevrizma tespiti ve diyabetik retinopati derecelendirmesi için topluluk-tabanlı bir sistematik yaklaşım önerilmiştir. Abramoff ve arkadaşları ise yönlendirilebilen diyabetik retinopatinin tespiti için retina görüntülerinin otomatik analizini araştırmışlardır [19]. Retinal görüntülerde optik disk tespitine yönelik sunulmuş olan [20] numaralı çalışmada Foracchia ve arkadaşları tarafından damar yapısının geometrik bir modeli çıkartılmıştır. Retinal görüntü analizine yönelik detaylı bir literatür incelemesinin gerçekleştirildiği derleme makalelerinde [21] Patton ve arkadaşları, literatürde kullanılmakta olan mevcut teknikleri içeren çalışmaları derleyerek sunmuşlardır.

Literatürde ayrıca iyi bilinen sezgisel ve meta-sezgisel algoritmaların retinal damar bölütleme işlemine yönelik uygulamalarını içeren çalışmalar da bulunmaktadır. [22]

numaralı çalışmada sürü zekâsına dayalı, evrimsel tabanlı ve fizik tabanlı en güncel sekiz adet meta-sezgisel algoritma retinal damar bölütlemesine uygulanmış ve bu algoritmaların performansları literatürde iyi bilinen üç adet diğer meta-sezgisel algoritma ile mukayese edilmiştir. Xu ve arkadaşları tarafından [23] numaralı çalışmalarında, temel *Yusufçuk Algoritmasının* (*Dragonfly Algorithm*) performansı geliştirilerek renkli görüntülerin bölütlenmesine yönelik uygulanmış ve geliştirilen bu yeni algoritmanın performansı temel yusufçuk ve diferansiyel gelişim algoritmaları ile mukayese edilmiştir. [24] numaralı çalışmada yazarlar tarafından kenar algılama ve şekil analizi yöntemlerinin kademeli bağlantısından oluşan etkin bir retinal damar bölütleme yaklaşımı geliştirilmiştir.

Literatürde, görüntüler üzerinde *Çok Seviyeli Eşikleme* yaklaşımlarının geliştirilmesine yönelik çalışmalar da bulunmaktadır. Jia ve arkadaşları [25] numaralı çalışmalarında renkli görüntülerde çok seviyeli eşiklemeye yönelik *Kendini Uyarlayan Güve Alevi Optimizasyon* (*Self-Adaptive Moth-Flame Optimization*) algoritması olarak adlandırdıkları bir meta-sezgisel yaklaşım önermişlerdir. [26] numaralı çalışmada, renkli görüntülerde çok seviyeli eşikleme için performansı iyileştirilmiş *Guguk Kuşu Arama* (*Cuckoo Search*), *Yıldırım Arama* (*Lightning Search*) ve *Mürekkepbalığı* (*Cuttlefish*) algoritmaları önerilmiştir. [27] numaralı çalışma Zhang ve Yin tarafından çok seviyeli eşikleme işlemine yönelik geliştirilmiş bir *Arı Yiyecek Arama Algoritmasının* (*Bee Foraging Algorithm*) detaylı analizini içermektedir. [28] numaralı çalışmada Esparza ve arkadaşları tarafından çok seviyeli görüntü işlemine yönelik *Harris Hawks Optimizasyon (Harris Hawks Optimization)* algoritmasını temel alan yeni bir metodoloji önerilmiştir. [29]'de, Kurban ve arkadaşları literatürde yaygın olarak kullanılan bazı evrimsel ve sürü zekasına dayalı algoritmaları renkli görüntülerde çok seviyeli eşikleme amacıyla kullanarak performanslarını mukayese etmişlerdir.

2. BÖLÜM

YÖNTEM VE MATERYAL

Sürü zekâsına dayalı optimizasyon yaklaşımları, sürüler halinde hareket eden canlıların doğasında var olan ve sürekli tekrarladıkları zeki davranışların deterministik olarak modellenmesi ile geliştirilirler [30,31]. Sürü zekâsına dayalı meta-sezgisel algoritmalar farklı alanlarda mühendislik problemlerinin çözümünde ortaya koydukları yüksek başarımlardan dolayı literatürde çok sık tercih edilmektedirler. Bu algoritmalar; çok boyutlu araştırma uzaylarında küresel çözümleri yüksek doğrulukta bulabilme yetenekleri, yüksek yakınsama hızları, problemden ve problem boyutundan bağımsız optimizasyon yetenekleri gibi önemli avantajlara sahiptirler.

Bu tez çalışmasında, en güncel sürü zekâsına dayalı meta-sezgisel algoritmalardan olan WHO ve BES algoritmaları retinal damar bölütleme işlemine yönelik geliştirilerek detaylı performans analizleri gerçekleştirilmiştir.

2.1. Vahşi At Optimizasyon (WHO) Algoritması

Naruei ve Keynia tarafından önerilmiş olan Vahşi At Optimizasyon algoritması [32], vahşi atların sosyal hayatlarındaki davranışlarını modelleyen bir meta-sezgisel algoritmadır. Bu davranışlar liderlik etme (leading), hükmetme (dominating), otlama (grazing), kovalama (chasing) ve çiftleşme (mating) olarak gruplandırılabilirler [33].

WHO algoritmasının kod yapısı ve ilgili açıklamalar aşağıda detaylı bir şekilde açıklanmıştır.

Rastgele başlangıç popülasyonu oluştur, $i = 1, 2, ..., N$

Crossover percentage (PC) ve Stallions percentage (number of groups, PS) kontrol parametre değerlerini tanımla

Popülasyondaki her bir birey (At) için kalite (fitness) değerini hesapla,

Tay (Foal) gruplarını ve bu grupların lider atlarını (Stallions) belirle,

En yüksek kalite değerli At'ı en iyi çözüm olarak tanımla,

TDR adaptif kontrol parametre değerini hesapla (Eşitlik 2.1),

FOR *1:Lider sayısı,*

Z değerini hesapla (Eşitlik 2.2),

For *Herhangi bir gruptaki herhangi bir Tay için,*

İf *rand > PC*

İlgili Tay'ın pozisyonunu Eşitlik 2.3 ile güncelle,

Else

İlgili Tay'ın pozisyonunu Eşitlik 2.4 ile güncelle,

End

End

İf *rand > 0,5*

$Lider_{G_i}$ *pozisyonunu Eşitlik 2.5 ile güncelle,*

Else

$Lider_{G_i}$ *pozisyonunu Eşitlik 2.6 ile güncelle,*

End

İf $\text{cost}(\overrightarrow{Lider_{G_i}}) < \text{cost}(Lider)$

$Lider = \overrightarrow{Lider_{G_i}}$

End

Tay gruplarını kalite değerlerine göre sırala ve en iyi çözümleri seç

İf $\text{cost}(Tay) < \text{cost}(Lider)$

Tay ve Lider pozisyonlarını Eşitlik 2.6 ile güncelle,

End

End

En iyi sonucu güncelle

END

WHO algoritmasında *N* adet bireyden oluşan ve rastgele üretilmiş bir başlangıç popülasyonunu kendi içerisinde aşağıda Şekil 2.1'de gösterildiği gibi ayrıştırılır.

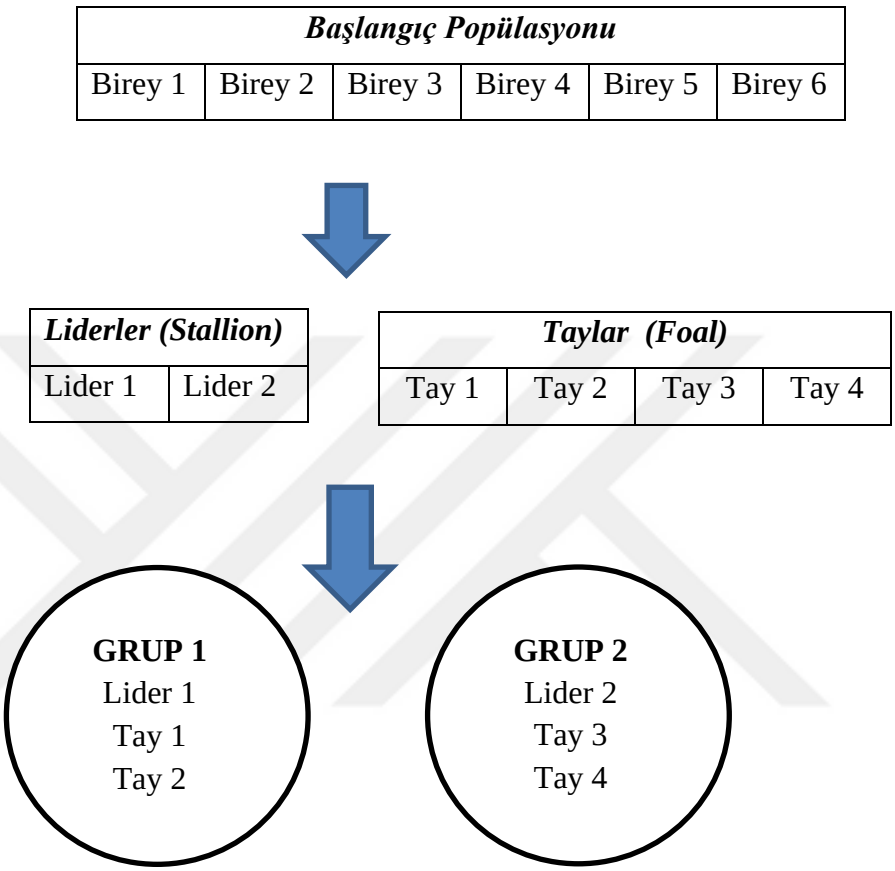

Şekil 2.1. WHO algoritması için başlangıç popülasyonu yapısı

Popülasyondaki her bir bireyin konumlarının farklı çözümleri temsil edecek şekilde adaptif olarak güncellenmesi işlemi, TDR parametresi olarak adlandırılan bir adaptif kontrol parametresi ile gerçekleştirilir.

$$TDR = 1 - Çevrim\, x\, (\frac{1}{Max\, Çevrim}) \tag{2.1}$$

TDR parametresinin başlangıç değeri 1 olarak atanır ve her bir Çevrim'de değeri Eşitlik 2.1'e göre güncellenerek son Çevrim'de değeri 0 olacaktır.

Tayların ve diğer atların, liderleri etrafındaki konum değişiklikleri aşağıda Eşitlik 2.2 ile verilmiş olan bir adaptif kontrol mekanizması ile gerçekleştirilir.

$$P = \overrightarrow{R_1} < TDR;\ IDX = (P == 0);\ Z = R_2 \Theta IDX + \overrightarrow{R_3} \Theta (\sim IDX) \tag{2.2}$$

burada; *P*, 0 veya 1 değerlerinden birisini alan ve problemin boyutuna eşit değerli bir vektördür; $\overrightarrow{R_1}$ ve $\overrightarrow{R_3}$, [0,1] aralığında bir uniform dağılımdan rastgele alınan sayılardır; son olarak, IDX indeksi ise $(P == 0)$ koşulunu karşılayan indeks değerleridir.

Eşitlik 2.2'de genel olarak verilmiş olan konum değiştirme stratejisi, otlama (Grazing) fazı için Eşitlik 2.3'te verildiği gibi ve çiftleşme (Mating) fazı için ise Eşitlik 2.4'te verildiği gibi tanımlanır.

$$\overrightarrow{X_{i,G}^{j}} = 2Z\cos(2\pi RZ)\ x(Lider^{j} - X_{i,G}^{j}) + Lider^{j} \tag{2.3}$$

$$X_{G,K}^{p} = Crossover(X_{G,i}^{q}\ ,\ X_{G,j}^{z}),\ i \neq j \neq k,\ \ p = q = end \tag{2.4}$$

bu eşitliklerde: $X_{i,G}^{j}$ ilgili bireyin mevcut konumunu; $Lider^{j}$ ilgili bireyin grup liderinin konumunu; ve R $\in$ [-2,2] parametresi ise her bir bireyin liderleri etrafında 360° açı altında konum değiştirmesini kontrol eden bir parametredir. (2.4) eşitliğinde ise: Crossover operatörü *Ortalama (Mean)* olarak ele alınırken; $X_{G,i}^{q}$, $X_{G,j}^{z}$ ifadeleri kendi gruplarını terk etmiş olan *q* ve *z* numaralı tayların konumlarını temsil etmektedir; ve son olarak *q* ve *z* numaralı tayların çiftleşmesi sonucunda oluşacak yeni bireyin konumu $X_{G,K}^{p}$ olacaktır. Yani, çiftleşme ile elde edilen yeni bireyin konumu *K* numaralı grupta bulunan ve grubu terk eden *G* numaralı bireyin konumu olarak atanacaktır.

Liderlik (Leadership) fazında, her bir grubun hareket alanı algoritma içerisinde *Water Hole* olarak tanımlanan bir rota içerisinde sınırlandırılmalıdır. Grubun bu rota dahilinde hareket ettirilerek optimum konumlara yerleştirilmesi görevi grup liderinindir. Lider tarafından gerçekleştirilen bu görev aşağıdaki (2.5) eşitliği ile simüle edilmektedir.

$$\overrightarrow{Lider_{G_i}} = \begin{Bmatrix} 2Z\cos(2\pi RZ)\,x(WH - Lider_{G_i}) + WH, & if\ R_3 > 0,5 \\ 2Z\cos(2\pi RZ)\,x(WH - Lider_{G_i}) - WH, & if\ R_3 \leq 0,5 \end{Bmatrix} \tag{2.5}$$

bu eşitliklerde: $\overrightarrow{Lider_{G_i}}$ ifadesi Lider'in bir sonraki pozisyonunu; WH ifadesi ise *Water Hole* pozisyonunu sembolize etmektedir.

Başlangıçta her bir grup için rastgele atanan Lider bireyler daha sonraki süreçte kalite (fitness) değerleri de dikkate alınarak değiştirilebilmektedir. Yüksek kalite değerli bireylerin yeni liderler olarak atanması Eşitlik 2.6 ile gerçekleştirilmektedir.

$$\overrightarrow{Lider_{G_i}} = \begin{cases} X_{G,i}, & if\ \cos t(X_{G,i}) < \cos t(Lider_{G_i}) \\ Lider_{G_i}, & if\ \cos t(X_{G,i}) > \cos t(Lider_{G_i}) \end{cases} \quad (2.6)$$

2.2. Kel Kartal Araştırma (BES) Optimizasyon Algoritması

H.A. Alsattar, A. A. Zaidan ve B. B. Zaidan tarafından geliştirilmiş olan Kel Kartal Optimizasyon algoritması [34], kel kartalların üç aşamalı avlanma stratejilerini modelleyen bir meta-sezgisel algoritmadır. Bu aşamalar, *i.) Bölge Seçme (selecting space), ii.) Seçilen Bölgeyi Araştırma (searching in space)* ve *iii.) Saldırma (swooping)* aşamaları olarak tanımlanmaktadır.

BES algoritması için kod yapısı ve ilgili açıklamalar aşağıda detaylı bir şekilde açıklanmıştır.

İlk aşama olan *Bölge Seçme* aşamasında Eşitlik 2.7. kullanılarak mevcut pozisyonlar güncellenir ve elde edilen yeni av pozisyonu mevcut pozisyon ile eşit veya daha yüksek kalite değerine sahipse mevcut pozisyonun yerine popülasyona dâhil edilir.

$$P_{new,i} = P_{best} + \alpha . r . (P_{mean} - P_i) \quad (2.7)$$

bu eşitlikte: $\alpha \in [1,5\ \ 2]$ parametresi pozisyon değişimlerini kontrol eden parametredir; $r \in [0\ \ 1]$ rastgele üretilen bir sayıdır; ve son olarak P_{mean} parametresi önceki kartallardan alınan tüm bilgilerin de yeni pozisyonlar üretilirken kullanılmasını sağlamaktadır.

n-adet konum içeren rastgele başlangıç popülasyonu oluştur, $P_i = P_1, P_2, ..., P_n$

Popülasyondaki her bir birey (P_i *) için kalite (fitness) değerini hesapla* $f(P_i)$,

WHILE *(sonlandırma kriteri sağlanıncaya kadar),*

FAZ 1. Bölge Seçme

For *(Popülasyondaki her bir birey (* P_i *) için : mevcut pozisyonları güncelle ve en iyi pozisyonları seç (Eşitlik 2.7),*

If $f(P_{new}) \leq f(P_i)$, *ise* $P_i = P_{new}$ *yani eski konum korunur.*

If $f(P_{new}) \leq f(P_{best})$, *ise* $P_{best} = P_{new}$ *en iyi konum popülasyona eklenir.*

End If

End If

End For

FAZ 2. Seçilen Bölgeyi Araştırma

For *(Popülasyondaki her bir birey (* P_i *) için : mevcut pozisyonları güncelle ve ava saldırmak için en iyi pozisyonu seç (Eşitlik 2.8),*

If $f(P_{new}) \leq f(P_i)$, *ise* $P_i = P_{new}$ *yani eski konum korunur.*

If $f(P_{new}) \leq f(P_{best})$, *ise* $P_{best} = P_{new}$ *en iyi konum popülasyona eklenir.*

End If

End If

End For

FAZ 3. Saldırma

For *(Popülasyondaki en iyi (* P_i *) pozisyonundan ava doğru saldırıya geç. Bu fazda popülasyondaki diğer bütün konumlar da en iyi konuma doğru hareket edecektir (Eşitlik 2.9),*

If $f(P_{new}) \leq f(P_i)$, *ise* $P_i = P_{new}$ *yani eski konum korunur.*

If $f(P_{new}) \leq f(P_{best})$, *ise* $P_{best} = P_{new}$ *en iyi konum popülasyona eklenir.*

End If

End If

End For

Cycle = Cycle +1;

END WHILE

İkinci aşama olan *Seçilen Bölgeyi Araştırma* aşamasında ilk aşamada seçilmiş olan bölge içerisinde en uygun av pozisyonu spiral bir araştırma uzayı içerisinde Eşitlik 2.8. kullanılarak araştırılmaktadır.

$$P_{i,new} = P_i + y(i).(P_i - P_{i+1}) + x(i).(P_i - P_{mean}) \tag{2.8}$$

burada, $\theta_i = a.\pi.r$ ve $r(i) = \theta(i) + R.r$ olmak üzere,

$$x(i) = \frac{r(i).\sin(\theta(i))}{\max(|xr|)} \quad \text{ve} \quad y(i) = \frac{r(i).\cos(\theta(i))}{\max(|yr|)}$$

eşitliklerinde: $x(i)$ ve $y(i)$ spiral araştırma uzayının oluştuğu düzlemin x ve y eksenleridir; $a \in [5\ 10]$ ve $R \in [0{,}5\ 2]$ parametreleri hareket düzlemindeki değişimleri oluşturmaktadır ve sırasıyla spiral hareket esnasında oluşabilecek herhangi bir düzlemden geçme sayısını ve araştırma döngü sayılarını tanımlamaktadır; ve son olarak $r \in [0\ 1]$ rastgele üretilen bir sayıdır.

Son olarak, *Saldırma* aşamasında popülasyondaki en iyi konumdan ava doğru saldırıya geçilmektedir. Bu hareket sırasında popülasyondaki diğer bütün konumlarda aynı zamanda en iyi konuma doğru hareket edecektir. Bu durum Eşitlik 2.9'da gösterildiği gibi modellenmektedir,

$$P_{i,new} = r.P_{best} + x1(i).(P_i - c1.P_{mean}) + y1(i).(P_i - c2.P_{best}) \tag{2.9}$$

burada, $\theta_i = a.\pi.r$, $xr(i) = r(i).\sinh[\theta(i)]$ ve $yr(i) = r(i).\cosh[\theta(i)]$ olmak üzere,

$$x1(i) = \frac{xr(i)}{\max(|xr|)} \quad \text{ve} \quad y1(i) = \frac{yr(i)}{\max(|yr|)}$$

eşitliklerinde: $c1, c2 \in [1\ 2]$ parametreleri kel kartalların hareket yoğunluğunun en iyi ve merkez noktalara doğru artırılmasını sağlayan parametrelerdir; ve son olarak $r \in [0\ 1]$ rastgele üretilen bir sayıdır.

3. BÖLÜM

BULGULAR

Bu tez çalışmasında, sürü zekâsına dayalı WHO, BES ve GWO algoritmaları kümeleme tabanlı olarak geliştirilmiş ve retinal görüntülerde damar piksellerinin yüksek doğrulukta tespitine yönelik uygulanmışlardır. Geliştirilmiş olan algoritmaların performansları ortalama karesel hata (MSE), CPU süresi, Duyarlılık, Kesinlik, Doğruluk ve Hassasiyet parametreleri için mukayese edilmiştir.

DRIVE ve STARE veri tabanlarından alınan retinal görüntüler üzerinde gerçekleştirilmiş olan benzetimlerde görüntüler öncelikle ve sırasıyla *Band Seçme*, *Alt-şapka Dönüşümü* ve *Kontrast Germe* ön işlemlerine tabi tutularak algoritmalara hazır hale getirilmiştir. Bu üç ön işlem uygulandıktan sonra elde edilen retinal görüntülerin damar pikselleri ile damar pikseli olmayan diğer pikselleri bu çalışmada geliştirilmiş olan kümeleme tabanlı WHO, BES ve GWO algoritmaları kullanılarak ayrıştırılmıştır.

3.1. Retinal Görüntülere Uygulanan Ön İşlemler

3.1.1. Band Seçme Ön İşlemi

Algoritmaların kümeleme performanslarını artırmak amacıyla uygulanan ilk görüntü zenginleştirme ön işlemi olan *Band Seçme* işlemi ile retinal görüntünün Kırmızı (R), Yeşil (G) ve Mavi (B) katmanlarından kümeleme işlemine en uygun olan katman belirlenir. Literatürde yapılmış olan çalışmalarda [1,22,35],

i.) kırmızı katman (R-katmanı) üzerinde kümeleme işlemi gerçekleştirildiğinde görüntünün belirli bölgelerinde aşırı saturasyon oluştuğu ve bu nedenle R katmanının kümeleme performansının düşük olduğu,

ii.) mavi katman (B-katmanı) üzerinde kümeleme işlemi gerçekleştirildiğinde görüntü üzerinde gürültü bileşenlerinin yoğun bir şekilde oluştuğu ve B katmanı için kümeleme performansının yetersiz olduğu,

iii.) yeşil katman (G-katmanı) üzerinde kümeleme işlemi gerçekleştirildiğinde ise damar pikselleri ile diğer pikseller arasında yüksek kontrast farklarının oluşturulabildiği ve bu nedenle kümeleme için en uygun katmanın G katmanı olduğu,

belirtilmiştir. Bu nedenle, bu tez çalışması kapsamında da kümeleme işlemi için G katmanı tercih edilmiştir.

Band Seçme ön işlemi ile G katmanı seçilmeden önce, her bir RGB retinal görüntünün G katmanının kontrast değerleri Eşitlik (3.1) uygulanmak suretiyle de ayrıca artırılmıştır [2].

$$G_{YENİ} = 0.1 * \mathrm{K} + 0.7 * \mathrm{Y} + 0.2 * \mathrm{M} \tag{3.1}$$

DRIVE veri tabanından alınmış olan iki adet retinal görüntü ve bu görüntülere *Band Seçme* ön işlemi uygulandıktan sonra elde edilen zenginleştirilmiş görüntüler Şekil 3.1 ile gösterilmiştir. Benzer şekilde, STARE veri tabanından alınan iki retinal görüntü ve bu görüntülere *Band Seçme* ön işlemi uygulandıktan sonra elde edilen zenginleştirilmiş görüntüler Şekil 3.2 ile aşağıda gösterilmiştir.

DRIVE ve STARE veri tabanları için Eşitlik 3.1 uygulanarak elde edilmiş olan bu zenginleştirilmiş görüntüler yine 3-katmanlı RGB görüntülerdir. *Band Seçme* ön işlemi kapsamında öncelikle bu görüntülerin G-katmanı seçildikten sonra bu katmanın Gri skala karşılığı elde edilerek görüntü işleme sürecine devam edilecektir. *Band Seçme* ön işlemi uygulandıktan sonra Gri skalada elde edilen retinal görüntüler benzetim sonuçları içerisinde ilgili şekillerde gösterilmiştir.

DRIVE Veri Tabanı İçin *Band Seçme* Sonrası Elde Edilen Retinal Görüntüler	DRIVE test görüntüsü 1 (dtg1)		Zenginleştirilmiş Görüntü (dtg1)	
	DRIVE test görüntüsü 2 (dtg2)		Zenginleştirilmiş Görüntü (dtg2)	

Şekil 3.1. DRIVE veri tabanından alınan test görüntüleri için Band Seçme Ön İşlemi sonrasında elde edilen zenginleştirilmiş retinal görüntüler

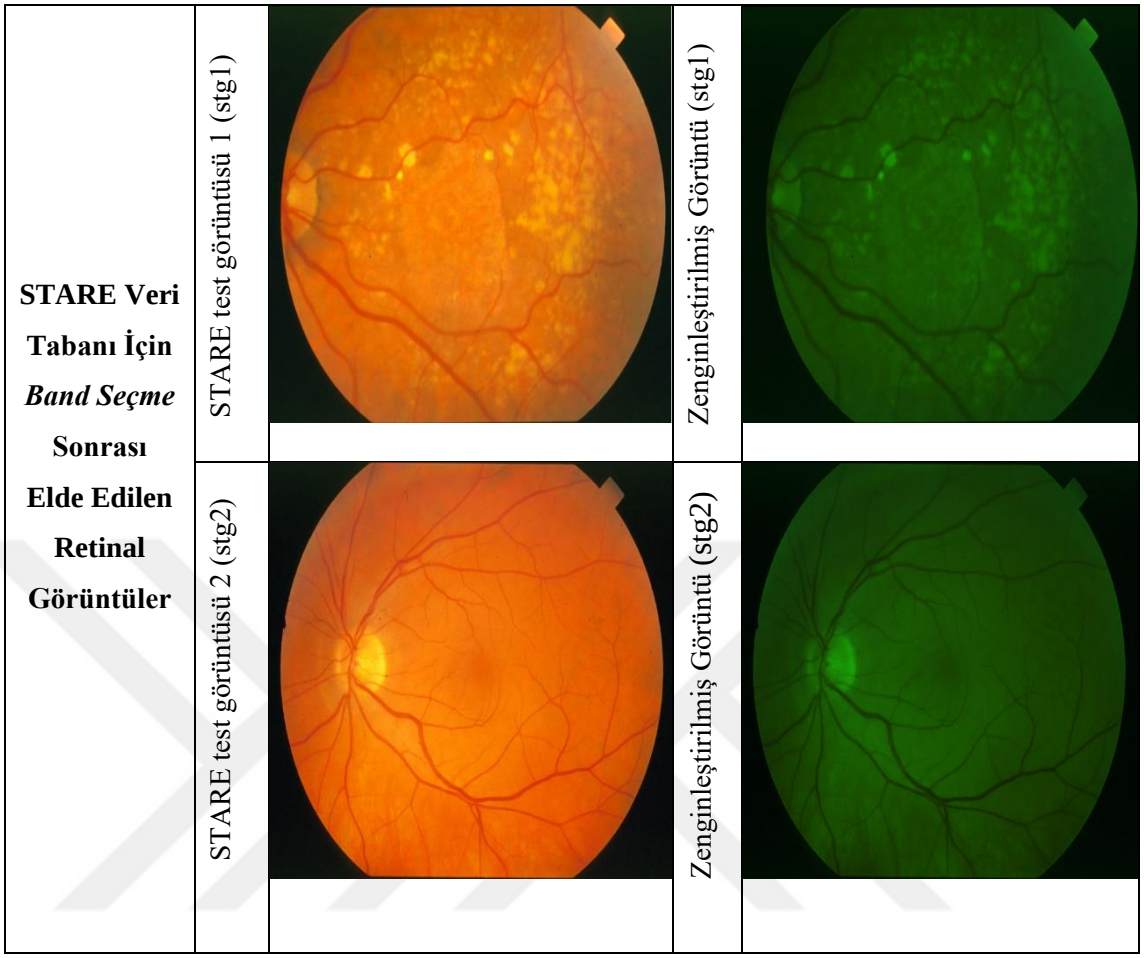

Şekil 3.2. STARE veri tabanından alınan test görüntüleri için Band Seçme Ön İşlemi sonrasında elde edilen zenginleştirilmiş retinal görüntüler

3.1.2. Alt-şapka Dönüşümü Ön İşlemi

Band Seçme ön işlemi ile retinal görüntülerde kontrast değerlerinin belirli bir oranda iyileştirildiği ancak damar pikselleri ile diğer pikseller arasında kontrast farkının yüksek performanslı kümeleme gerçekleştirebilmek için halen yetersiz olduğu görülmektedir. Bu nedenle bir sonraki adımda bir karşıtlık artırma işlemi olan *Alt-şapka Süzgeçleme* ön işlemi uygulanacaktır.

Karşıtlık artırma işlemi retinal görüntülerde yer alan öğelerin daha belirgin şekilde gözükmesi amacıyla gerçekleştirilir. İdeal olmayan görüntü çekim koşullarından kaynaklı olarak görüntülerde renk yoğunluk dağılımları homojen olarak oluşmazlar. Bu heterojen renk yoğunluk dağılımlarından kaynaklı olarak görüntü işleme yöntemleri uygulandığında genellikle düşük yoğunluklu renk bileşenlerinin kaybolma olasılığı

ortaya çıkmaktadır [36]. *Alt-şapka Süzgeçleme* ön işlemi ile retinal görüntüdeki renk yoğunluk dağılımları uniform bir hale getirilerek görüntünün kontrast değeri artırılmış olacaktır ve böylece farklı parlaklık seviyesine sahip bölgeler birbirinden daha başarılı bir şekilde ayırt edilebilecektir. Alt-şapka dönüşümü Eşitlik (3.2) ile aşağıda gösterilmiştir.

$$bottom - hat(g) = g - (g \bullet nB) \tag{3.2}$$

bu eşitlikte, g retinal görüntüyü, B kullanılacak olan yapı elemanını ve n ise Alt-şapka dönüşümünü tanımlamaktadır. Bu çalışmada, yapı elemanı olarak yarıçapı r=8 piksel yarıçaplı bir disk ve n = 8 Alt-şapka dönüşümü kullanılmıştır [1].

3.1.3. Kontrast Germe Ön İşlemi

Kümeleme öncesinde uygulanan son ön işlem ise *Kontrast Germe* ön işlemidir. *Kontrast Germe* ön işleminde, tüm piksel değerlerinin alt %1'i ve üst %1'i saturasyona götürülerek ilgili piksel değerleri daha yoğun piksel değerlerine yaklaştırılmış veya eşitlenmiş olur. Böylece, retinal görüntülerin kontrast değerleri de artırılmış ve görüntüler zenginleştirilmiş olacaktır.

Yukarıda tanımlanmış olan üç görüntü zenginleştirme işlemi sonrasında elde edilen ve algoritmalar tarafından kümeleme işlemi uygulanacak olan retinal görüntüler benzetim sonuçları içerisinde ilgili şekillerde gösterilmiştir.

Her bir algoritmanın kümeleme performansı Eşitlik (3.3) ile verilen Ortalama Karesel Hata (Mean Squared Error, MSE) hata fonksiyonu kullanılarak optimize edilmiştir.

$$MSE = \frac{1}{N}\sum_{i=1}^{N}(f_i - y_i)^2 \tag{3.3}$$

bu eşitlikte, N toplam piksel sayısını; f_i , i. piksele en yakın küme merkezinin değerini ve y_i ise i. pikselin temsil ettiği değeri tanımlamaktadır.

Benzetimlerde kullanılan her bir algoritma için kontrol parametre değerleri Tablo 3.1.'de gösterilmiştir.

Tablo 3.1. Algoritmalara ait parametre değerleri

Algoritma	**Kontrol Parametreleri**
WHO	• Popülasyon Boyutu = 10 • Birey Yüzdesi (Grup Sayısı), $PS = 0.2$ • Çaprazlama Yüzdesi, $PC = 0.13$ • Çevrim Sayısı=100
BES	• Popülasyon Boyutu = 10 • Spiral hareketin, yatay eksen ile (x-ekseni) kesişim sayısı, $a \in [5,10];\ a = 10$ • Pozisyon Değişim Kontrol Parametresi, $\alpha \in [1.5, 2];\ \alpha = 2$ • Araştırma Döngü Sayısı, $R \in [0.5, 2];\quad R = 1.5$ • Kartalın hareket yoğunluğunu optimum ve merkez noktalara doğru artıran rastgele adaptif atsayılar, $c_1, c_2 \in [1,2];\ c_1 = c_2 = 2$ • Çevrim Sayısı=100
GWO	• Popülasyon Boyutu = 10 • Gri Kurt ve Av pozisyonlarını optimize eden adaptif katsayı vektörleri, $\overrightarrow{A}$, $\overrightarrow{C}$ • Çevrim Sayısı=100

Bu tez çalışması kapsamında kümeleme tabanlı olarak geliştirilmiş olan sürü zekâsına dayalı meta-sezgisel WHO, BES ve GWO algoritmaları için elde edilmiş olan benzetim sonuçları ve istatistiksel analiz sonuçları DRIVE ve STARE veri tabanları için ve her bir meta-sezgisel algoritma için ayrı ayrı olmak üzere aşağıda verilmiştir.

DRIVE veri tabanından alınan test görüntüleri için WHO algoritmasına dayalı Retinal Damar Segmentasyonu benzetim sonuçları aşağıda Şekil 3.3 ile gösterilmiştir.

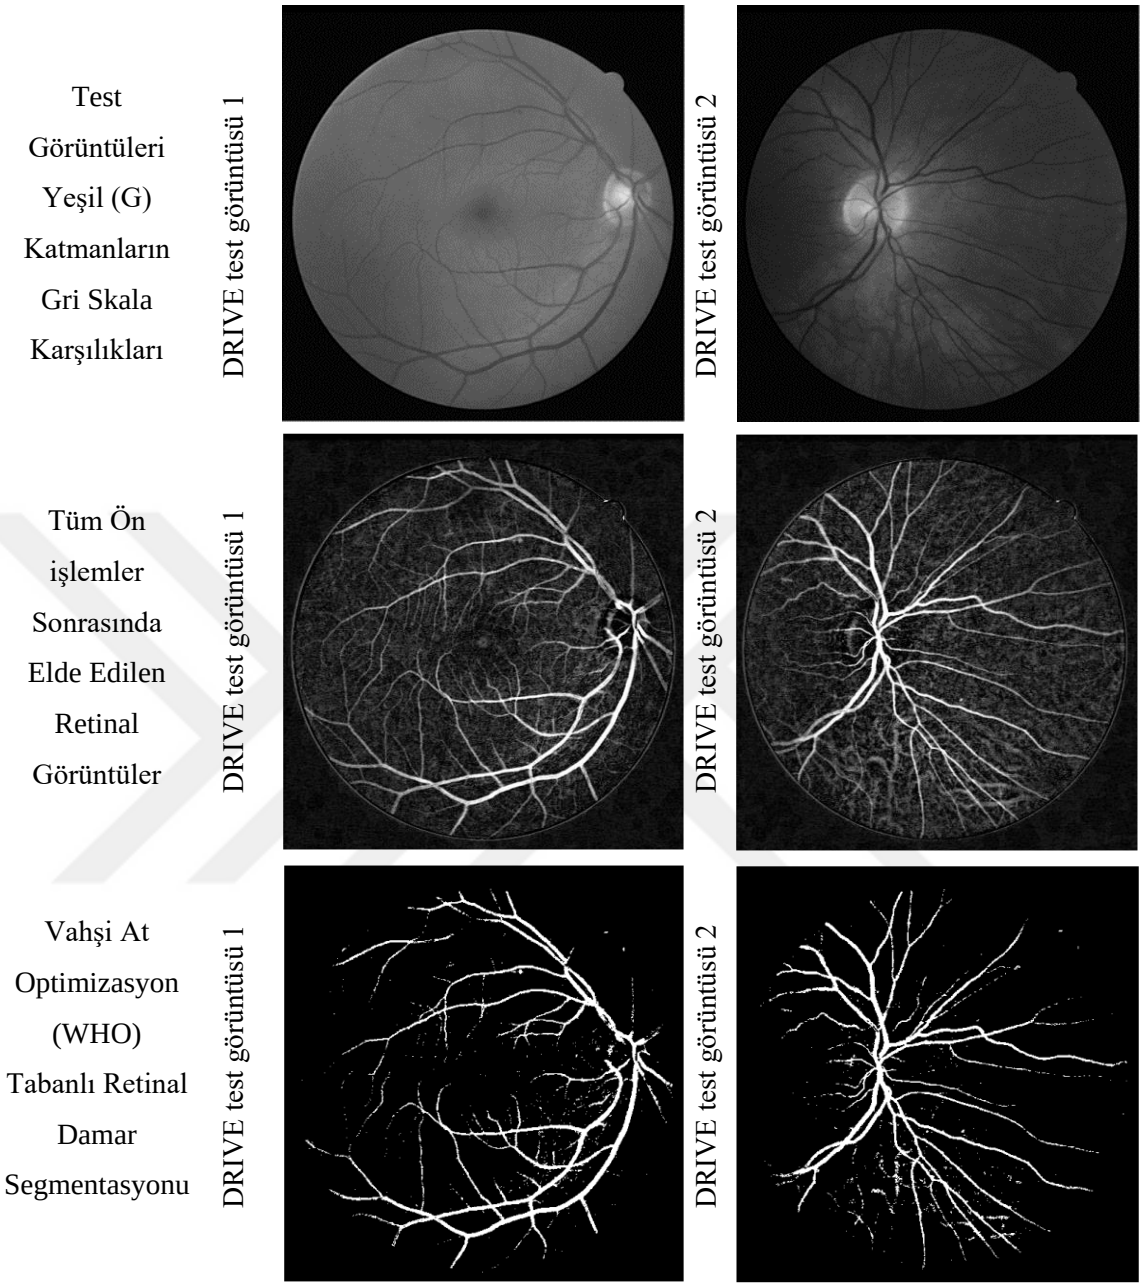

Şekil 3.3. DRIVE veri tabanından alınan test görüntüleri için WHO algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler

Kümeleme tabanlı BES algoritması ile DRIVE veri tabanı test görüntüleri üzerinde elde edilen Retinal Damar Segmentasyonu benzetim sonuçları Şekil 3.4'te verilmiştir.

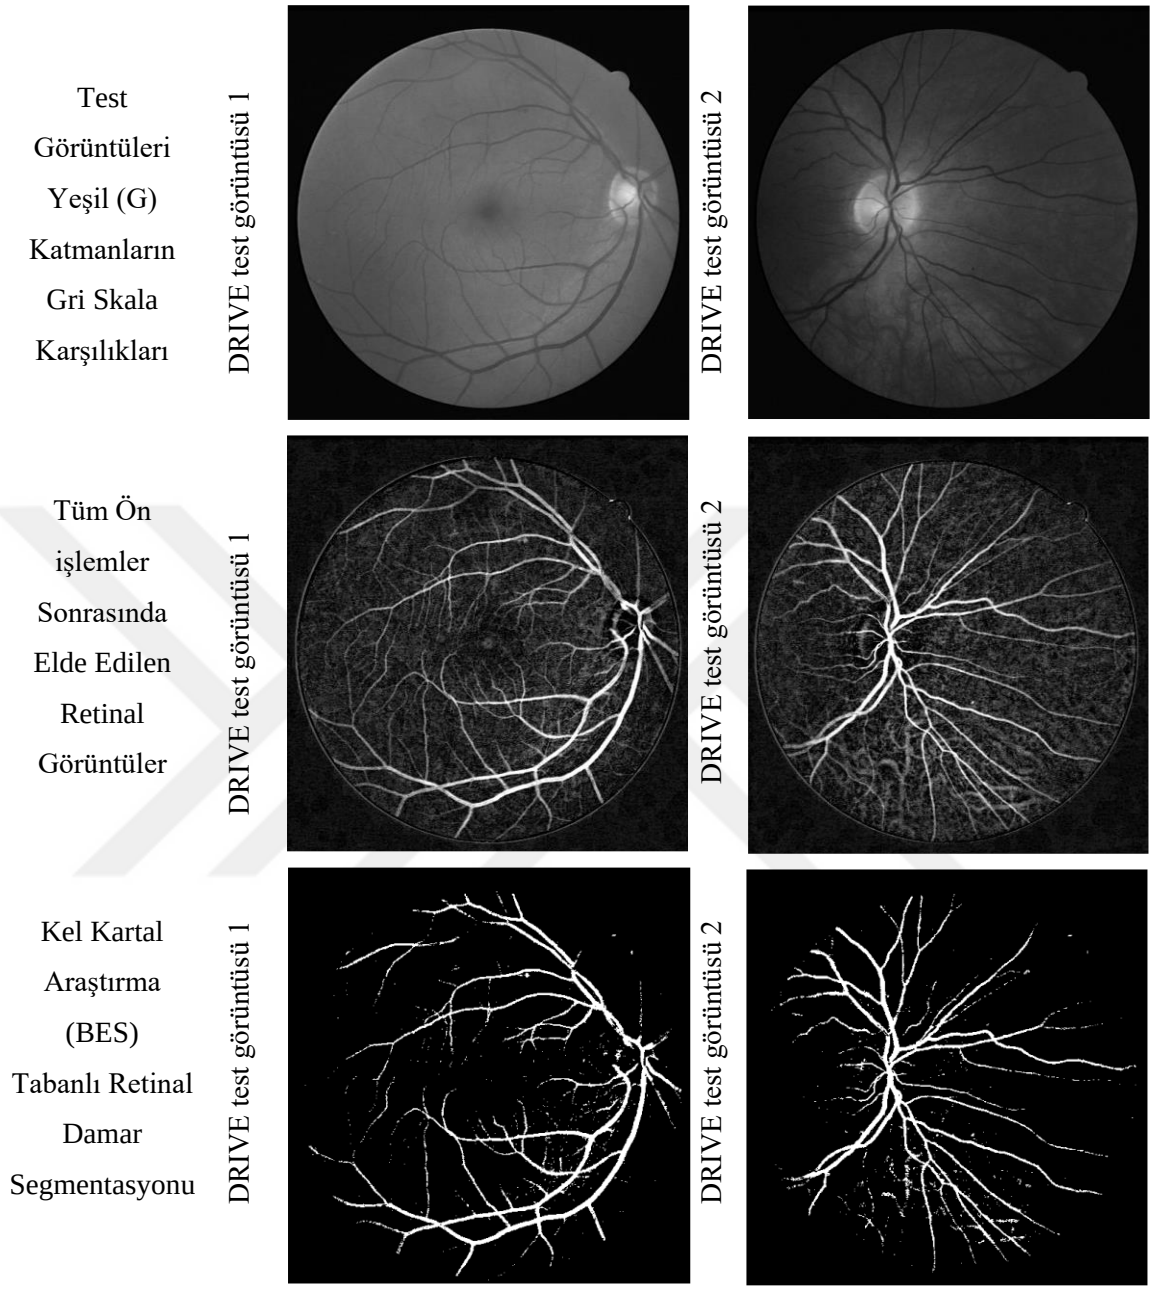

Şekil 3.4. DRIVE veri tabanından alınan test görüntüleri için BES algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler

GWO algoritması kullanılarak DRIVE veri tabanından alınan retinal görüntülere yönelik gerçekleştirilmiş olan benzetimlerde elde edilen sonuçlar ise aşağıda gösterilmiştir.

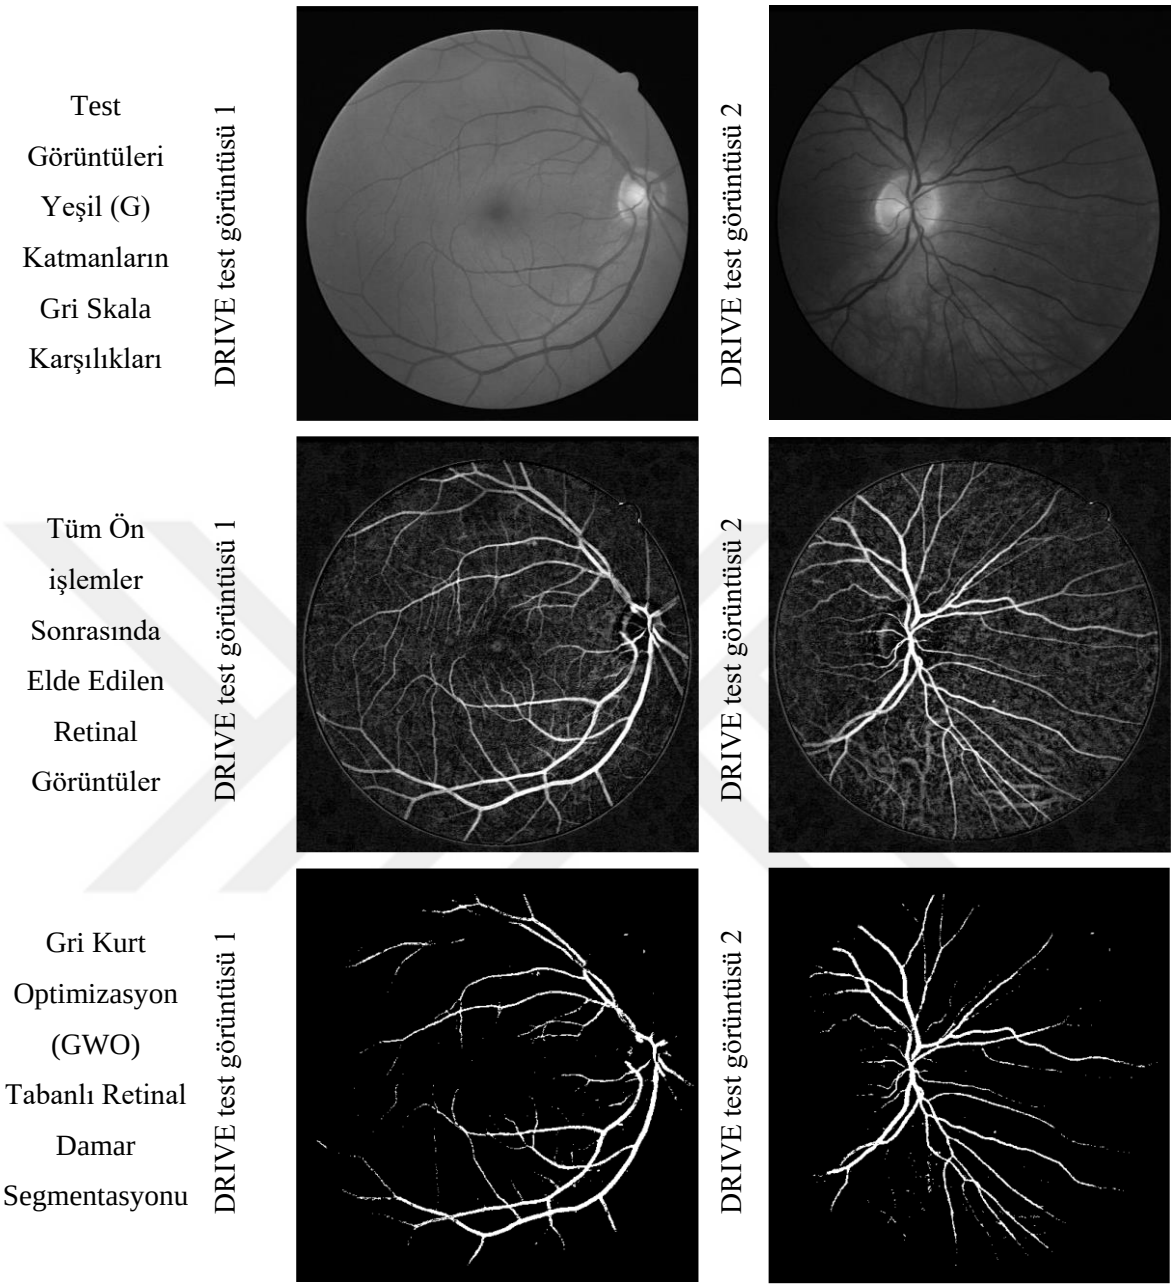

Şekil 3.5. DRIVE veri tabanından alınan test görüntüleri için GWO algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler

DRIVE veri tabanında WHO, BES ve GWO algoritmaları için elde edilen sonuçlar incelendiğinde, retinal görüntüler üzerindeki damar pikselleri ile art alan piksellerinin üç algoritmada da başarılı bir şekilde ayırt edilebildiği ve algoritmaların elde edilen nihai görüntüler açısından benzer performanslar gösterdiği görülmektedir.

STARE veri tabanından alınan test görüntüleri için WHO algoritmasına dayalı Retinal Damar Segmentasyonu benzetim sonuçları aşağıda Şekil 3.6 ile gösterilmiştir.

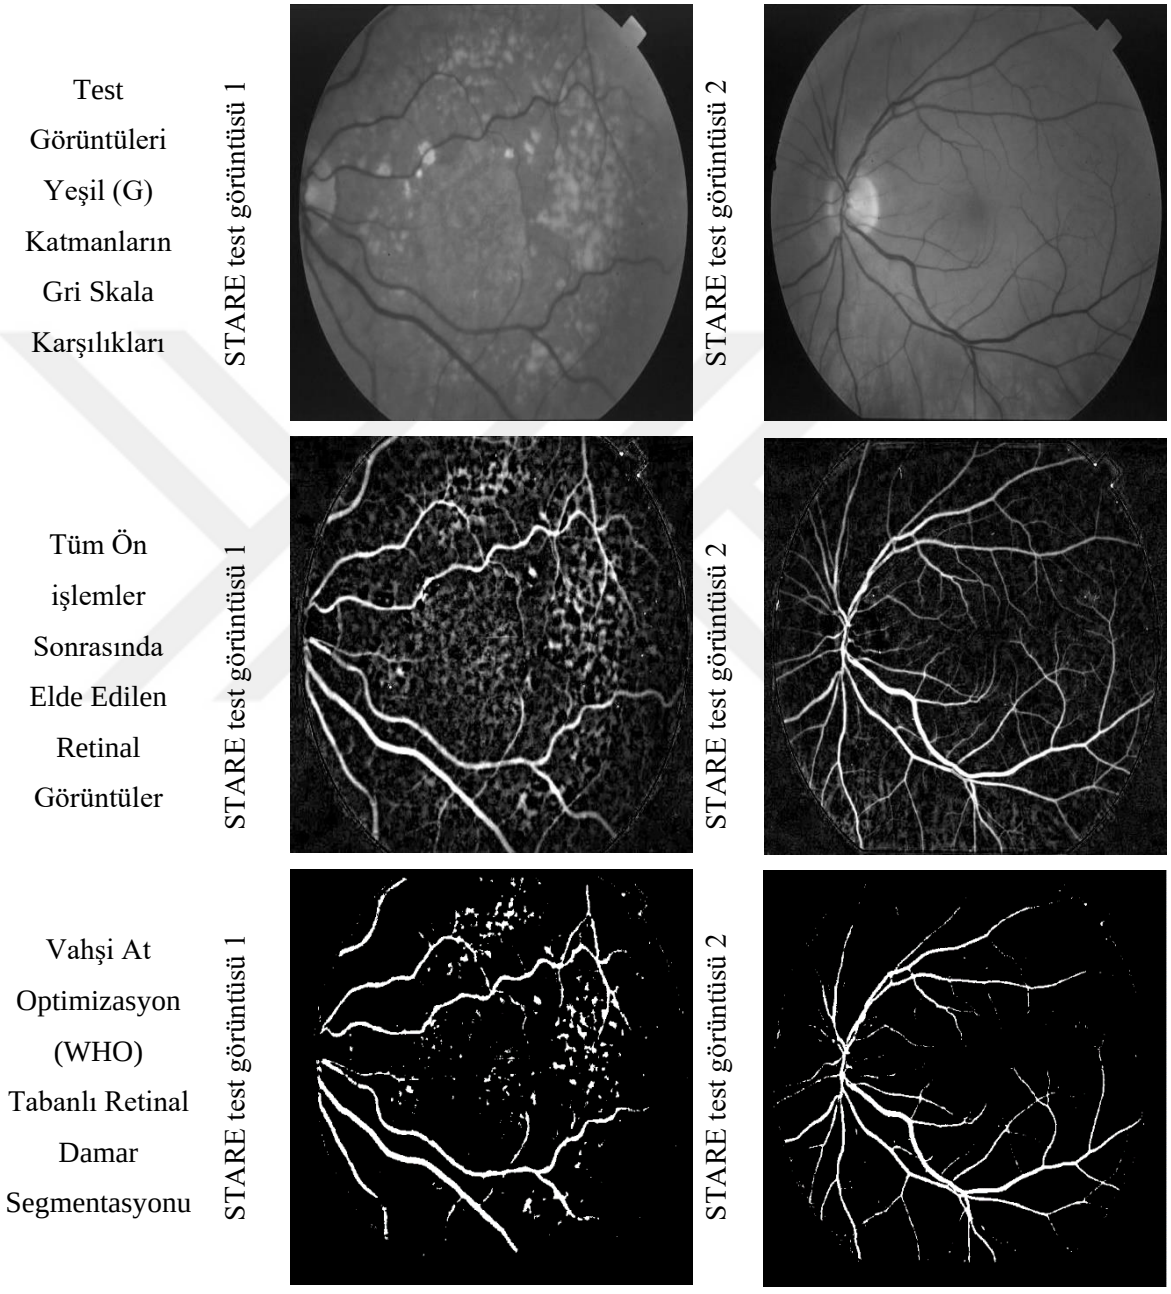

Şekil 3.6. STARE veri tabanından alınan test görüntüleri için WHO algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler

Kümeleme tabanlı BES algoritması ile STARE veri tabanı test görüntüleri üzerinde elde edilen Retinal Damar Segmentasyonu benzetim sonuçları Şekil 3.7'de verilmiştir.

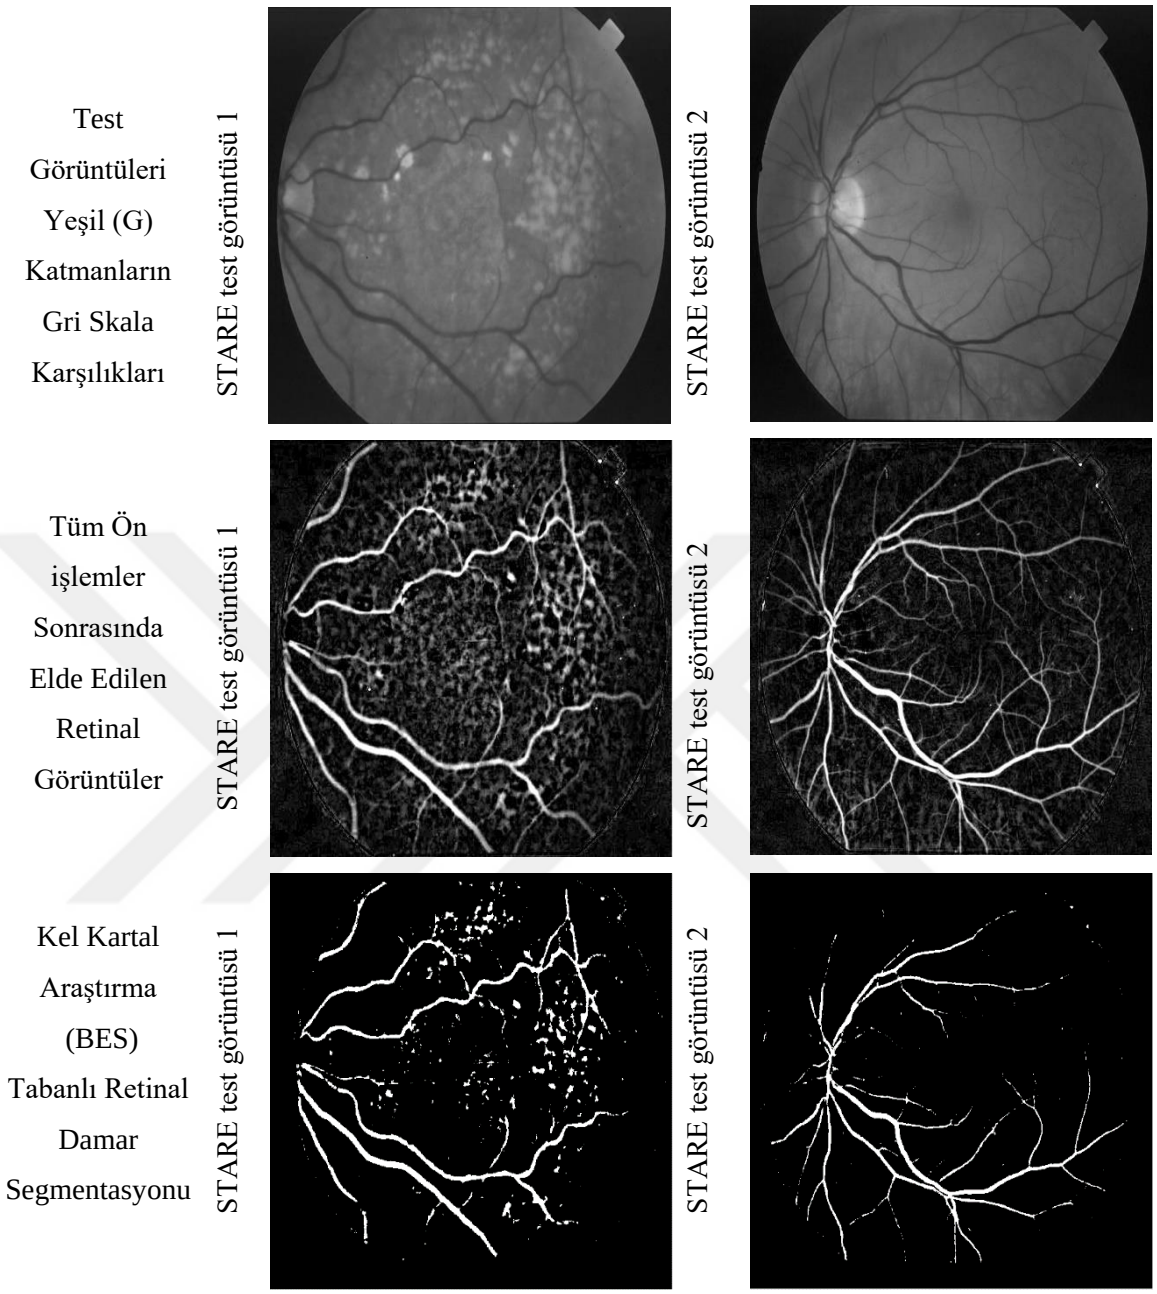

Şekil 3.7. STARE veri tabanından alınan test görüntüleri için BES algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler

GWO algoritması kullanılarak STARE veri tabanından alınan retinal görüntülere yönelik gerçekleştirilmiş olan benzetimlerde elde edilen sonuçlar ise aşağıda gösterilmiştir.

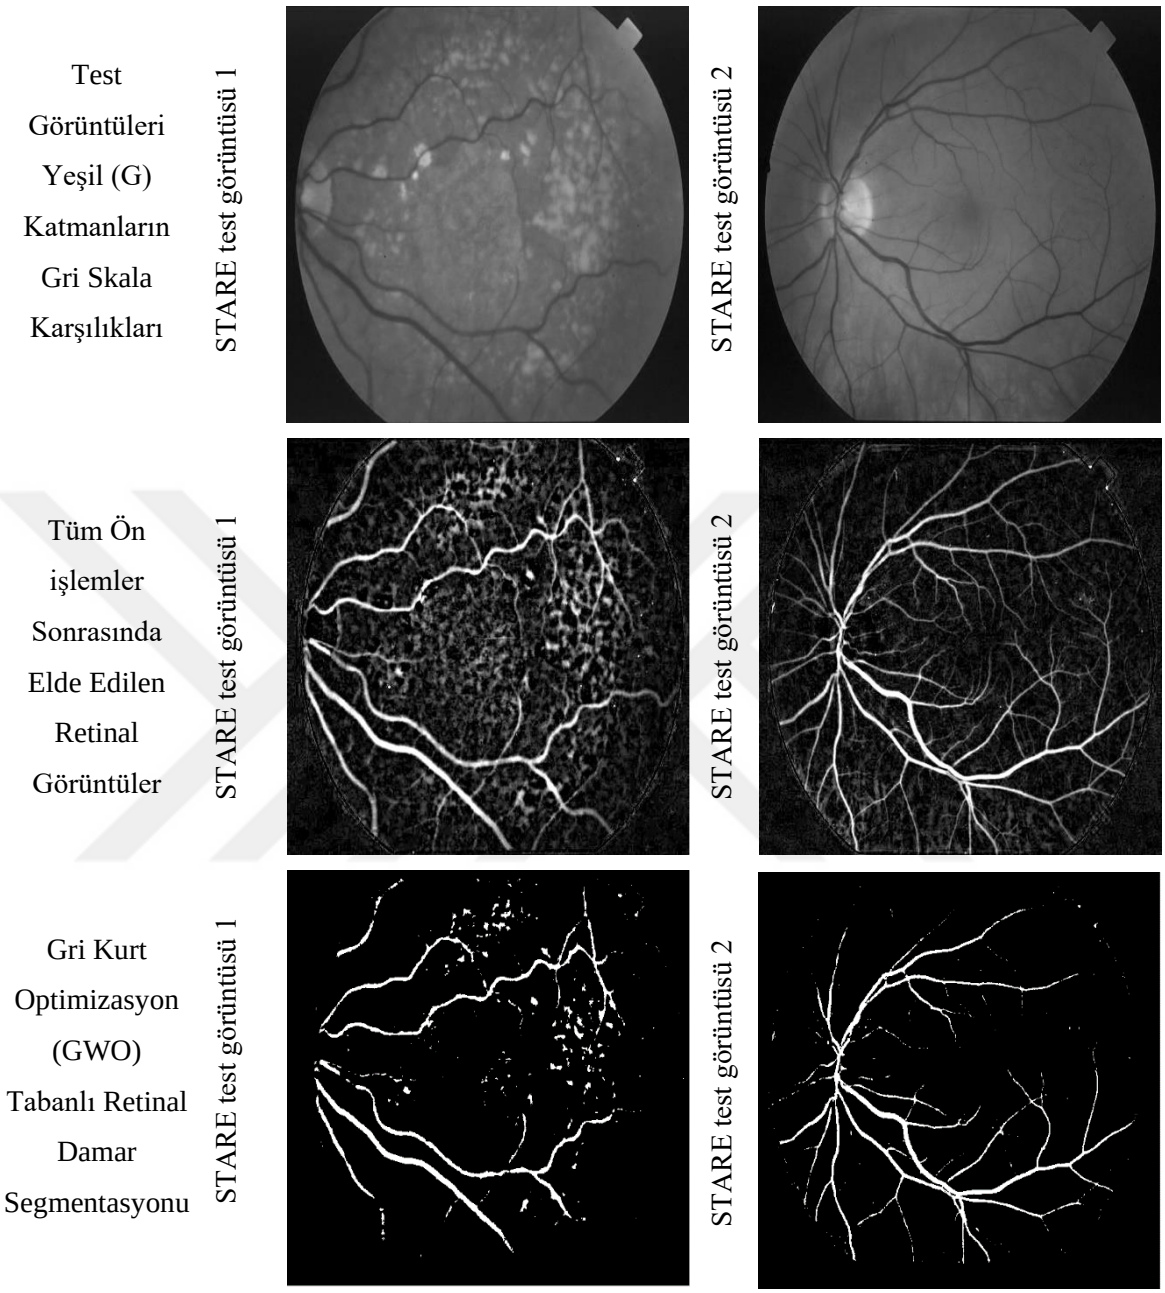

Şekil 3.8. STARE veri tabanından alınan test görüntüleri için GWO algoritmasına dayalı Retinal Damar Segmentasyonu aşamalarında elde edilen retinal görüntüler

WHO, BES ve GWO algoritmaları kullanılarak STARE veri tabanından alınan retinal görüntüler üzerinde gerçekleştirilmiş olan retinal damar segmentasyonu sonuçları incelendiğinde, damar pikselleri ile artalan piksellerinin bütün algoritmalar için başarılı bir şekilde ayırt edilebildiği ve benzer performansların elde edildiği görülmektedir.

Benzetim çalışmalarında her bir algoritma için elde edilen Ortalama Merkezi İşlemci Süresi (Ortalama CPU süresi), algoritma performanslarını tanımlamak için kullanılan önemli performans metriklerinden birisidir. *Intel i7-6700 / 3.40GHz / 16 GB RAM* donanımına sahip bir masaüstü bilgisayar ile gerçekleştirilen benzetimlerde WHO, BES ve GWO algoritmaları için 10 rastgele koşmanın ortalaması ile elde edilmiş olan ortalama merkezi işlemci süreleri Tablo 3.2 ile verilmiştir. Görüldüğü gibi, daha az sayıda kontrol parametresine sahip WHO ve GWO algoritmalarının birbirleri ile benzer fakat daha fazla sayıda kontrol parametresi içeren BES algoritmasına göre daha yüksek hızlarda optimizasyon gerçekleştirdikleri ifade edilebilir.

Tablo 3.2. WHO, BES ve GWO algoritmaları için ortalama merkezi işlemci süreleri

	Ortalama CPU süresi (saniye)		
	WHO	**BES**	**GWO**
DRIVE test görüntüsü 1	3.812530	10.695546	3.801234
DRIVE test görüntüsü 2	3.833657	10.750322	3.802039
STARE test görüntüsü 1	4.783289	13.470767	4.806597
STARE test görüntüsü 2	4.785272	13.791540	4.746616

Meta-sezgisel algoritmalar için bir diğer önemli performans kriteri ise *Yakınsama Hızı* olarak tanımlanmaktadır. *Yakınsama Hızı*, algoritmanın optimum hata değerine ulaşması için gereken *Çevrim* sayısını ve ayrıca toplam *Çevrim* sayısı süresince MSE hatasının gelişimini temsil eder. WHO, BES ve GWO algoritmalarının her birisinde en düşük hata değerine ulaşılan en iyi koşmalarda elde edilmiş olan yakınsama grafikleri, DRIVE ve STARE veri tabanları için sırasıyla Şekil 3.9 ve Şekil 3.10'da gösterilmiştir.

DRIVE test görüntüsü 1 ve DRIVE test görüntüsü 2 için elde edilmiş olan yakınsama grafiklerinden her üç algoritmanın da benzer MSE değerlerine benzer *Çevrim* sayısında yakınsadıkları görülmektedir. Diğer taraftan, her iki retinal görüntü için de en iyi hata performansının WHO algoritması tarafından elde edildiği ifade edilebilir.

STARE test görüntüleri için en iyi MSE performansının ise GWO algoritması ile elde edildiği görülmektedir. Diğer taraftan, her iki retinal görüntü için de BES algoritmasının kendi optimum hata değerine diğer iki algoritmaya göre daha az *Çevrim* sayısında ulaştığı ifade edilebilir.

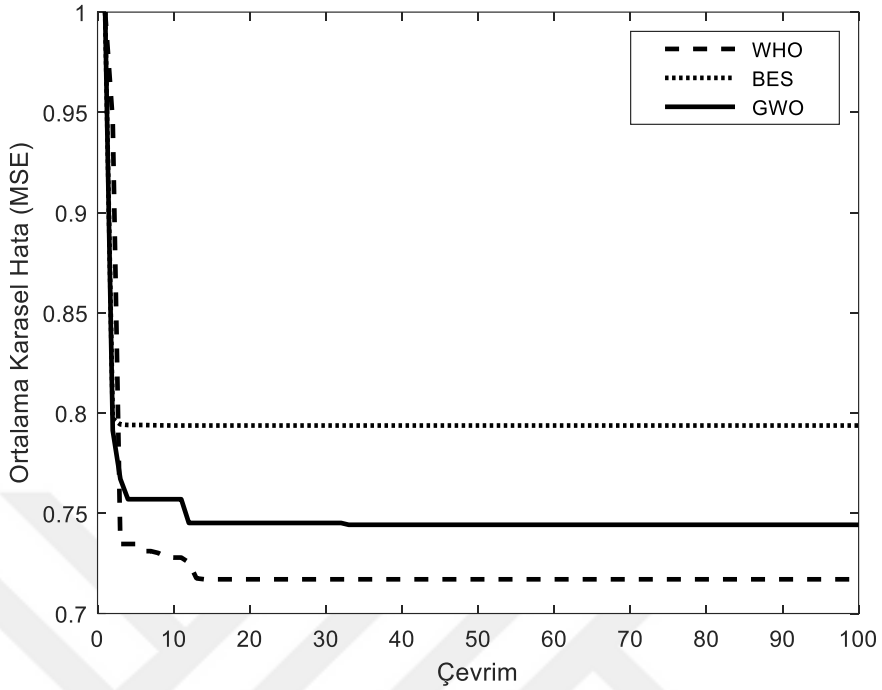

(a) DRIVE test görüntüsü 1

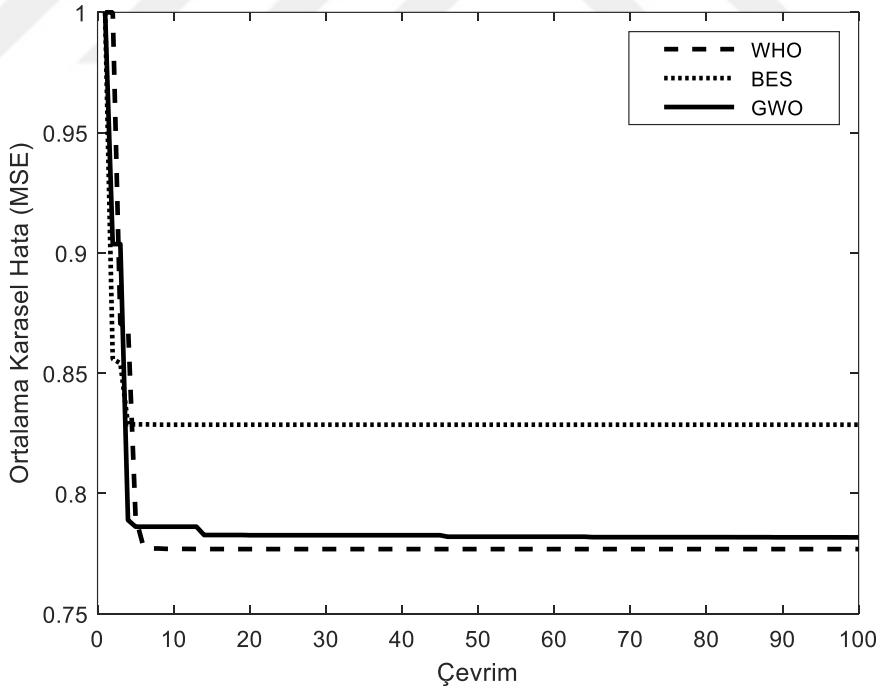

(b) DRIVE test görüntüsü 2

Şekil 3.9. DRIVE veri tabanından alınan retinal görüntüler için kümeleme tabanlı WHO, BES ve GWO algoritmalarının yakınsama performans mukayeseleri

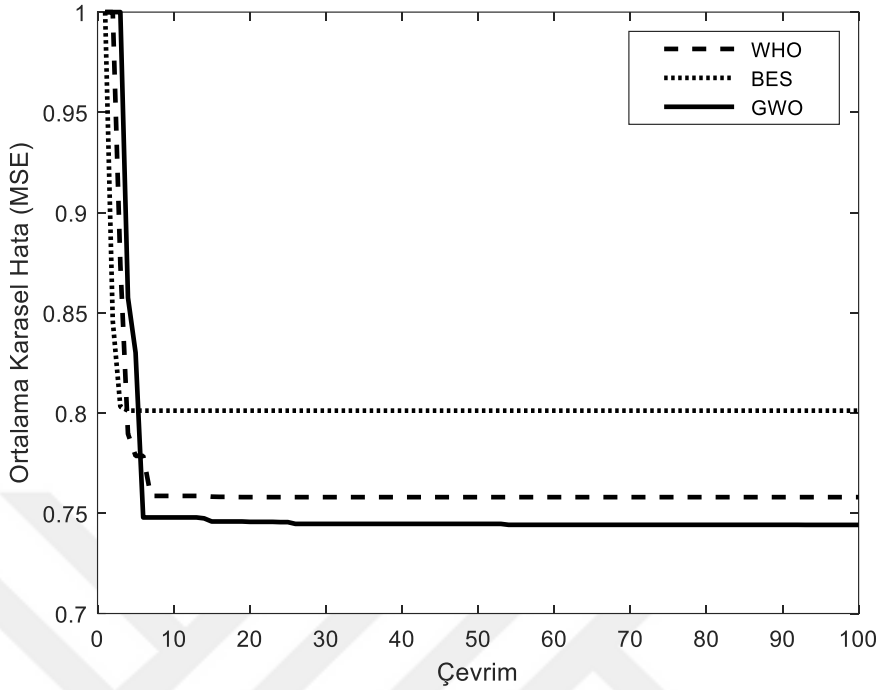

(a) STARE test görüntüsü 1

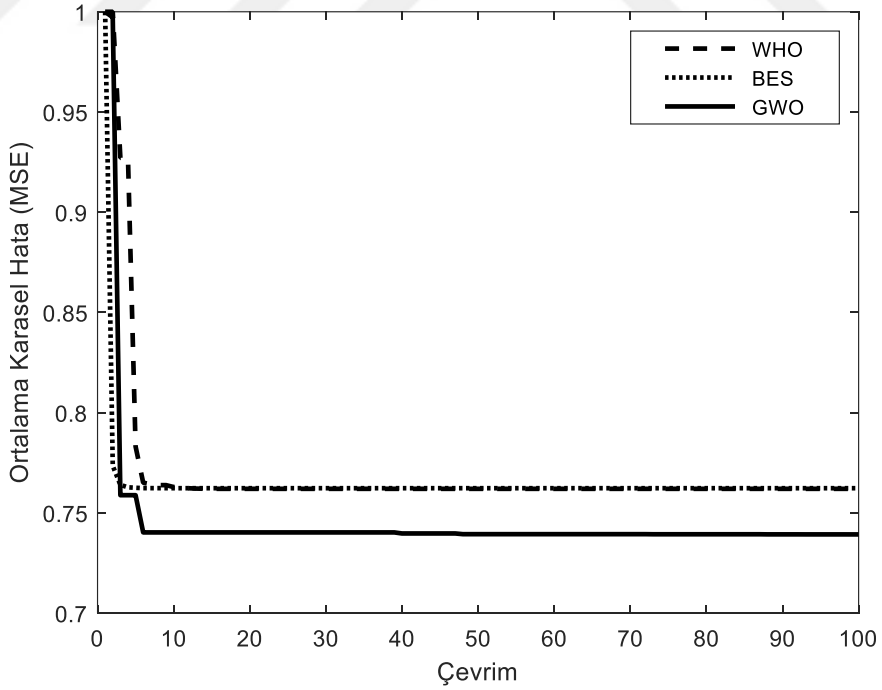

(b) STARE test görüntüsü 2

Şekil 3.10. STARE veri tabanından alınan retinal görüntüler için kümeleme tabanlı WHO, BES ve GWO algoritmalarının yakınsama performans mukayeseleri

Bu tez çalışması kapsamında analiz edilen diğer üç önemli performans kriteri ise, *i.)* algoritmalar için 10 rastgele koşmanın her birisinde ulaşılan *En Düşük MSE Değerleri*, *ii.)* 10 rastgele koşma için elde edilen *Ortalama MSE Değerleri,* ve *iii.)* algoritmaların *Standart Sapma* değerleri şeklinde belirlenmiştir. Bu üç performans kriterine yönelik olarak elde edilen sonuçlar DRIVE veri tabanı için Tablo 3.3 ve STARE veri tabanı için Tablo 3.4 ile aşağıda gösterilmiştir.

Tablo 3.3. DRIVE veritabanına yönelik benzetimlerde WHO, BES ve GWO algoritmaları için elde edilen En Düşük MSE, Ortalama MSE ve Standart Sapma değerleri

	DRIVE test görüntüsü 1			**DRIVE test görüntüsü 2**		
Koşma	**WHO**	**BES**	**GWO**	**WHO**	**BES**	**GWO**
1	0,7364	0,8115	0,7521	0,7861	0,8492	0,7896
2	0,7262	0,7928	0,7461	**0,7809**	0,8422	0,7941
3	0,7321	0,7968	**0,7442**	0,7822	0,8461	0,7895
4	**0,7204**	0,7935	0,7501	0,7917	**0,8386**	0,7939
5	0,7225	**0,792**	0,7519	0,7834	0,8394	0,7883
6	0,7361	0,7945	0,7464	0,7839	0,8478	0,7886
7	0,7271	0,8129	0,7565	0,7862	0,8399	**0,7875**
8	0,7367	0,7949	0,7477	0,7877	0,8394	0,79
9	0,7242	0,8007	0,7465	0,7816	0,8437	0,7886
10	0,7337	0,8038	0,7478	0,7819	0,8396	0,7895
Ortalama	**0,72954**	**0,79934**	**0,74893**	**0,78456**	**0,84259**	**0,78996**
Standart Sapma	**0,00618**	**0,00770**	**0,00369**	**0,00337**	**0,00390**	**0,00255**

DRIVE veri tabanı için elde edilmiş olan benzetim sonuçları incelendiğinde, BES algoritması için elde edilen en düşük hata ve ortalama hata değerlerinin WHO ve GWO algoritmalarına göre daha yüksek olduğu görülmektedir. Benzer şekilde, BES algoritmasının her iki retinal görüntü için de standart sapma değerlerinin diğer iki algoritmaya göre daha yüksek olduğu görülmektedir. Yani, BES algoritmasında her bir koşmada elde edilen hata değerlerinin ortalama değer etrafında daha geniş bir spektrumda yayıldığı ve bunun bir sonucu olarak da BES algoritmasının WHO ve GWO algoritmalarına göre biraz daha kararsız olduğu ifade edilebilir.

Tablo 3.4. STARE veri tabanına yönelik benzetimlerde WHO, BES ve GWO algoritmaları için elde edilen En Düşük MSE, Ortalama MSE ve Standart Sapma değerleri

	STARE test görüntüsü 1			**STARE test görüntüsü 2**		
Koşma	**WHO**	**BES**	**GWO**	**WHO**	**BES**	**GWO**
1	0,7709	0,8048	0,7482	0,7637	0,7687	0,7404
2	0,7658	**0,8012**	0,7543	0,7655	0,7709	0,7486
3	0,7669	0,8064	0,7498	**0,762**	0,7632	0,7426
4	0,7692	0,8123	0,7518	0,7703	0,7715	0,7413
5	0,7667	0,8025	0,7535	0,7631	0,7686	0,7489
6	**0,7632**	0,8074	0,7504	0,7628	**0,7623**	0,7412
7	0,7654	0,8046	**0,7462**	0,7663	0,7647	0,7461
8	0,7702	0,81	0,7495	0,7638	0,7709	0,7415
9	0,7728	0,8032	0,7485	0,7679	0,7689	**0,7393**
10	0,7672	0,8097	0,7475	0,7707	0,7661	0,7413
Ortalama	**0,76783**	**0,80621**	**0,74997**	**0,76561**	**0,76758**	**0,74312**
Standart Sapma	**0,00289**	**0,00361**	**0,00259**	**0,00312**	**0,00331**	**0,00345**

STARE veri tabanına yönelik elde edilen benzetim sonuçları incelendiğinde, STARE test görüntüsü 1 için BES algoritmasında elde edilen en düşük hata ve ortalama hata değerlerinin WHO ve GWO algoritmalarına göre daha yüksek olduğu görülmektedir. STARE test görüntüsü 2 için ise üç algoritmanın da birbirine çok yakın hata performansları sergilediği ifade edilebilir. STARE test görüntüsü 1 için gerçekleştirilen benzetimlerde algoritmalarda 10 rastgele koşma sonucunda oluşan standart sapma değerleri, en kararlı algoritmanın GWO algoritması en kararsız algoritmanın ise BES algoritması olduğunu göstermektedir. STARE test görüntüsü 2 için ise en yüksek standart sapma değerinin GWO algoritmasında ortaya çıktığı görülmektedir. Sonuç olarak, WHO, BES ve GWO algoritmalarının En Düşük MSE, Ortalama MSE ve Standart Sapma açısından genel anlamda performanslarının ise benzer olduğu ifade edilebilir.

Bu tez çalışması kapsamında istatistiksel analize yönelik olarak Standart Sapmanın yanı sıra hem DRIVE hem de STARE veri tabanları için algoritmaların *Duyarlılık (Sensitivity, Se)* ve *Kesinlik (Specifity, Sp)* açısından performansları da mukayese edilmiştir.

Duyarlılık ve *Kesinlik* analizi için kullanılmış olan temel tanımlamalar aşağıdaki gibidir,

- Doğru Pozitif (True Positive, TP) doğru sınıflandırılmış damar pikselleri sayısı,
- Doğru Negatif (True Negative, TN) doğru sınıflandırılmış art alan pikselleri sayısı,
- Yanlış Pozitif (False Positive, FP) damar pikseli olarak yanlış bir şekilde sınıflandırılmış art alan pikselleri sayısı,
- Yanlış Negatif (False Negative, FN) artalan pikseli olarak yanlış bir şekilde sınıflandırılmış damar pikselleri sayısı.

Buna göre, Se ve Sp değerleri literatürde aşağıdaki gibi ifade edilmektedir,

$$Duyarlılık = TP / (TP + FN) \tag{3.4}$$

$$Kesinlik = TN / (TN + FP) \tag{3.5}$$

Benzetimlerde *Duyarlılık* ve *Kesinlik* açısından elde edilen istatistiksel sonuçlar aşağıda Tablo 3.5 ile verilmiştir.

Tablo 3.5. Meta-sezgisel algoritmaların Duyarlılık ve Kesinlik açısından İstatistiksel analizi

	Duyarlılık			**Kesinlik**		
	WHO	**BES**	**GWO**	**WHO**	**BES**	**GWO**
DRIVE test görüntüsü 1	0.8956	0.9273	0.8461	0.9547	0.9498	0.9599
DRIVE test görüntüsü 2	0.7257	0.7816	0.8275	0.9746	0.9714	0.9682
STARE test görüntüsü 1	0.4885	0.5492	0.6057	0.9755	0.9725	0.9696
STARE test görüntüsü 2	0.7396	0.7701	0.7005	0.9765	0.9734	0.9796

Doğru sınıflandırılmış damar piksel sayılarını oransal olarak tanımlayan *Duyarlılık* parametre değerleri incelendiğinde, algoritmaların DRIVE ve STARE veri tabanlarının her ikisinde de ilgili görüntüler için benzer performanslar ürettikleri görülmektedir. Bununla birlikte, algoritmaların STARE veri tabanından alınan görüntüler için performanslarının düştüğü de görülmektedir.

Doğru sınıflandırılmış art alan piksel sayılarını oransal olarak tanımlayan *Kesinlik* parametre değerleri incelendiğinde, algoritmaların DRIVE ve STARE veri tabanlarının

her ikisinde de ilgili görüntüler için benzer performanslar ürettikleri görülmektedir. Ayrıca, her iki veritabanı için üç algoritmanın da yüksek *Kesinlik*'te piksel sınıflandırmaları yapabildikleri ifade edilebilir.

4. BÖLÜM

SONUÇ VE DEĞERLENDİRME

Retinal görüntü analizinde görüntüyü oluşturan piksellerin yüksek doğrulukta sınıflandırılması teşhis ve tedavi süreci açısından önem arz etmektedir. Bu nedenle, çok boyutlu hata yüzeylerinde küresel optimum çözümlere ulaşabilme yeteneklerinden dolayı meta-sezgisel algoritmalara dayalı kümeleme tabanlı yaklaşımların geliştirilmesi önemli bir araştırma alanı haline gelmiştir.

Bu tez çalışmasında, en güncel sürü zekâsına dayalı meta-sezgisel algoritmalar arasında olan WHO ve BES algoritmaları kümeleme tabanlı olarak retinal damar bölütleme uygulamasına yönelik geliştirilmiştir. Ayrıca, literatürdeki en etkin meta-sezgisel yaklaşımlardan olan GWO algoritması da kümeleme tabanlı geliştirilerek WHO, BES ve GWO algoritmaları arasında detaylı performans mukayeseleri gerçekleştirilmiştir.

Tez çalışmasının ilk bölümünde, diyabetik retinopati hastalığına yönelik temel bilgiler verilerek ilgili retinal görüntüler sunulmuş ve görüntü piksellerinin yüksek doğrulukta sınıflandırılmasına yönelik Kümeleme (Clustering) Yaklaşımı anlatılmıştır. Retinal damar bölütleme çalışmaları kapsamında literatürde en yaygın kullanılan iki veri tabanı olan DRIVE ve STARE veri tabanları hakkında detaylı açıklamalar verildikten sonra bu tez çalışması kapsamında kullanılmış olan görüntü zenginleştirme yaklaşımları açıklanmıştır. Ayrıca retinal görüntü analizi ve damar bölütleme uygulamalarına yönelik detaylı bir literatür çalışması da bu bölümde yer almaktadır.

İkinci bölümde, bu tez çalışmasında kullanılan temel WHO ve BES algoritmaları detaylı kod yapıları ve ilgili açıklamaları verilerek ayrıntılı bir şekilde anlatılmıştır.

Tez çalışmasının üçüncü bölümünde ise benzetim sonuçları ve bulgular sunulmuştur. İlk olarak Band Seçme, Alt-şapka Dönüşümü ve Kontrast Germe ön işlemlerinin detaylı anlatımları gerçekleştirilmiş ve bu ön işlemler sonucunda elde edilen retinal görüntüler benzetim sonuçları içerisinde gösterilmiştir. Meta-sezgisel algoritmalar ile hem DRIVE

hem de STARE veri tabanları için elde edilen sonuçlar incelendiğinde WHO, BES ve GWO algoritmalarının yüksek doğrulukta kümeleme performansı sağlayarak art alan ve damar piksellerini başarılı bir şekilde ayırt edebildikleri gözlemlenmiştir. Ortalama merkezi işlemci süreleri için elde edilmiş olan sonuçlar incelendiğinde WHO ve GWO algoritmalarının benzer sürelerde ve yüksek hızlarda optimal çözümlere ulaşabildikleri, BES algoritmasının ise bu algoritmalara göre yaklaşık üç kat daha yavaş olduğu görülmüştür. Algoritmalar yakınsama hızları açısından mukayese edildiklerinde ise her bir algoritmanın optimal sonuçlara yaklaşık benzer çevrimlerde ulaştıkları ve yakınsama hızı açısından algoritmaların benzer performanslara sahip oldukları ifade edilebilir. En Düşük MSE Değerleri ve Ortalama MSE Değerleri için elde edilmiş olan sonuçlar incelendiğinde BES algoritmasının her iki veri tabanı içinde performansının diğer algoritmalara göre biraz daha kötü olduğu görülmektedir. Standart sapma açısından algoritmaların istatistiksel performansları analiz edildiğinde ise GWO algoritmasının diğer iki algoritmaya göre genel olarak daha düşük veya benzer standart sapma değerlerine ulaştığı görülmektedir. Buna göre, GWO algoritmasının genel anlamda diğer algoritmalara göre nispeten daha kararlı olduğu BES algoritmasının ise en kararsız algoritma olduğu ifade edilebilir. İstatistiksel analize yönelik gerçekleştirilmiş olan *Duyarlılık* ve *Kesinlik* analiz sonuçları incelendiğinde ise her üç algoritmanın da hem DRIVE hem de STARE veri tabanları için piksel sınıflandırması açısından benzer performanslar ürettiği görülmektedir. Genel olarak ise STARE veri tabanından alınan görüntülerde algoritmaların piksel sınıflandırma performanslarının DRIVE veri tabanına göre daha düşük olduğu gözlemlenmektedir.

Sonuç olarak, en güncel sürü zekâsına dayalı meta-sezgisel algoritmalardan olan WHO ve BES algoritmalarının retinal damar bölütleme işleminde ve genel olarak biyomedikal görüntü analizinde başarılı bir şekilde kullanılabileceği görülmüştür.

KAYNAKÇA

1. Duran, H., 2018. Sezgisel Algoritmalar ile Biyomedikal Görüntü Analizi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kayseri, 138 s.
2. High-Resolution fundus image database. (Web sayfası: **http://www5.cs.fau.de**), (Erişim tarihi: Mart 2023).
3. Alonso-Montes, C., Vilari˜no, D. L., Dudek, P., Penedo, M. G., 2008. Fast retinal vessel tree extraction: A pixel parallel approach. **International Journal of Circuit Theory and Applications**, **36** (5-6): 641-651.
4. Hoover, A., Kouznetsova, V., Goldbaum, M., 2000. Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response. **IEEE Transactions on Medical Imaging**, **19** (3): 203–210.
5. Fong, D.S., Aiello, L.P., Gardner, T.W., King, G.L., Blankenship, G., Cavallerano, J.D., Ferris, F.L., Klein, R., 2004. Retinopathy in diabetes. **Diabetes Care, 27**(1): 84-87.
6. Fraz, M.M., Remagnino, P., Hoppe, A., Uyyanonvara, B., Rudnicka, A.R., Owen, C.G., Barman, S.A., 2012. Blood vessel segmentation methodologies in retinal images: A survey. **Computer Methods and Programs in Biomedicine 108**(1): 407–433.
7. Wang, J.J., Taylor, B., Wong, T.Y., Chua, B., Rochtchina, E., Klein, R., Mitchell, P., 2006. Retinal vessel diameters and obesity: A population-based study in older persons. **Obesity (Silver Spring) 14**(2): 206–214.
8. Foracchia, M., Grisan, E., Ruggeri, A., 2001. Extraction and quantitative description of vessel features in hypertensive retinopathy fundus images. *Book Abstracts of 2nd International Workshop on Computer Assisted Fundus Image Analysis*, October 2001, Copenhagen, Denmark.
9. Mitchell, P., Leung, H., Wang, J.J., Rochtchina, E., Lee A.J., Wong, T.Y., Klein, R., 2005. Retinal vessel diameter and open-angle glaucoma: The blue mountains eye study. **Ophthalmology 112**(2): 245–250.
10. Goatman, K., Charnley, A., Webster, L., Nussey, S., 2011. Assessment of automated disease detection in diabetic retinopathy screening using two-field photography. **PLoS One 6**(12): 275–284.

11. Asad, A.H., Elamry, E., Hassanien, AE., Tolba, M.F., 2013. New global update mechanism of ant colony system for retinal vessel segmentation, 221-227. *13th International Conference on Hybrid Intelligent Systems*, 04-06 December 2013, Tunisia, IEEE.
12. Verma, K., Deep, P., Ramakrishnan, A.G., 2011. Detection and classification of diabetic retinopathy using retinal images flight, 1-6. Annual *IEEE India Conference: Engineering Sustainable Solutions*, 16-18 December 2011, Hyderabad, India, IEEE.
13. Heneghan, C., Flynn, J., O'Keefe, M., Cahill, M., 2002. Characterization of changes in blood vessel width and tortuosity in retinopathy of prematurity using image analysis. **Medical Image Analysis, 6**(4): 407-429.
14. Lowell, J., Hunter, A., Steel, D., Basu, A., Ryder, R., Kennedy, R.L., 2004. Measurement of retinal vessel widths from fundus images based on 2D modeling. **IEEE Transactions on Medical Imaging, 23**(10): 1196–1204.
15. Haddouche, A., Adel, M., Rasigni, M., Conrath, J., Bourennane, S., 2010. Detection of the foveal avascular zone on retinal angiograms using markov random fields. **Digital Signal Processing, 20**(1):149–154.
16. Grisan, E., Ruggeri, A., 2003. A divide etimpera strategy for automatic classification of retinal vessels into arteries and veins, 890-893. *Proceedings of the 25th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, 17-21 September 2003, Cancun, Mexico, IEEE.
17. Archer, D.B., 1999. Diabetic retinopathy: Some cellular, molecular and therapeutic considerations. **Eye, 13**: 497–523.
18. Antal, B., Hajdu, A., 2012. An ensemble-based system for microaneurysm detection and diabetic retinopathy grading. **IEEE Transaction Biomedical Engineering, 59**(6): 1720–1726.
19. Abramoff, M.D., Folk, J.C., Han, D.P., 2013 Automated analysis of retinal images for detection of referable diabetic retinopathy. **JAMA Ophthalmology, 131**(3):351–7.
20. Foracchia, M., Grisan, E., Ruggeri, A., 2004. Detection of optic disc in retinal images by means of a geometrical model of vessel structure**. IEEE Transactions on Medical Imaging, 23**(10): 1189–1195.

21. Patton, N., Aslam, T.M., MacGillivray, T., Deary, I.J., Dhillon, B., Eikelboom, R.H., Yogesan, K., Constable, I.J., 2006. Retinal image analysis: Concepts, applications and potential. **Progress in Retinal and Eye Research, 25**(1): 99–127.

22. Çetinkaya, M.B., Duran, H., 2020. A detailed and comparative work for retinal vessel segmentation based on the most effective heuristic approaches. **Biomedical Engineering–Biomedizinische Technik 66**(2):181-200.

23. Xu, L., Jia, H., Lang, C., Peng, X., Sun, K., 2019. A novel method for multilevel color image segmentation based on dragonfly algorithm and differential evolution. **IEEE Access, 7**: 19502-19538.

24. Braovic´, M., Stipanicev, D., Šeric´, L., 2019. Retinal blood vessel segmentation based on heuristic image analysis. **Computer Science and Information Systems, 16**(1): 227-245.

25. Jia, H., Ma, J., Song, W., 2019. Multilevel thresholding segmentation for color image using modified moth-flame optimization. **IEEE Access, 7**: 44097-44134.

26. Bhandari, A.K., Kumar, I.V., Srinivas, K., 2019. Cuttlefish algorithm-based multilevel 3-D otsu function for color image segmentation. **IEEE Transactions on Instrumentation Measurement, 69**(5):1871-1880.

27. Zhang, Z., Yin, J., 2020. Bee foraging algorithm based multi-level thresholding for image segmentation. **IEEE Access, 8**:16269-16280.

28. Esparza, E.R., Calzada, L.Z., Oliva, D., Heidari, A.A., Zaldivar, D., Cisneros M.P., Foong L.K., 2020. An efficient Harris Hawks-inspired image segmentation method. **Expert Systems with Applications, 155**(1): 1-29.

29. Kurban, T., Civicioglu, P., Kurban, R., Besdok, E., 2014. Comparison of evolutionary and swarm based computational techniques for multilevel color image thresholding. **Applied Soft Computing, 23**: 128-143.

30. Kennedy, J., Eberhart, R., 1995. Particle Swarm Optimization, 1942-1945. *IEEE International Conference on Neural Networks*, 27 November 1995 - 01 December 1995, New Jersey, USA, IEEE.

31. Karaboga, D., 2005. An idea based on honey bee swarm for numerical optimization. (Web sayfası: **http:// mf.erciyes.edu.tr/abc/pub/tr06_2005.pdf**), (Erişim tarihi: Eylül 2017).

32. Naruei, I., Keynia, F., 2021. Wild horse optimizer: A new meta-heuristic algorithm for solving engineering optimization problems. **Engineering with Computers, 38**: 3025-3056.

33. Ali, M.H., Kamel, S., Hassan, M.H., Veliz, M.T., Zawbaa, H.M., 2022. An improved wild horse optimization algorithm for reliability based optimal DG planning of radial distribution networks, **Energy Reports, 8**: 582-604.

34. Alsattar, H.A., Zaidan, A.A., Zaidan, B.B., 2020. Novel meta-heuristic bald eagle search optimisation algorithm. **Artificial Intelligence Review, 53**: 2237-2264.

35. Meier, J., Bock, R., Michelson, G., Nyúl L.G., Hornegger, J., 2007. Effects of preprocessing eye fundus images on appearance based glaucoma classification, 165-172. *Proceeding of the 12th International Conference on Computer Analysis of Images and Patterns (CAIP'07)*, August 27-29 2007, Vienna, Austria.

36. Birdal, R.G., 2014. Diş Radyograflarinin Bilgisayar Destekli Analizi, İstanbul Üniversitesi Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul, 37 s.

ÖZGEÇMİŞ

KİŞİSEL BİLGİLER

Adı Soyadı: Kader TAŞKIRAN

Uyruğu: Türkiye (T.C)

EĞİTİM

Derece	**Kurum**	**Mezuniyet Tarihi**
Yüksek Lisans	Erciyes Üniversitesi, Mekatronik Mühendisliği	2023
Lisans	Erciyes Üniversitesi, Mekatronik Mühendisliği	2018
Lise	Atatürk Anadolu Lisesi, SİİRT	2013

YABANCI DİL

İngilizce

YAYINLAR

1. Çetinkaya, M.B., Taşkıran, K., (2022). *Journal of Materials and Mechatronics: A, 3*(1), ss 79-90