
Araştırma Makalesi / Research Article

Meta-Sezgisel Algoritmalarla Dayalı Retinal Damar Bölütlemesi

Mehmet Bahadır ÇETİNKAYA^{1*}, Kader TAŞKIRAN²

¹ Erciyes Üniversitesi, Mühendislik Fakültesi, Mekatronik Mühendisliği Bölümü, Kayseri, Türkiye,
ORCID ID: <https://orcid.org/0000-0003-3378-4561>, cetinkaya@erciyes.edu.tr

² Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Mekatronik Mühendisliği Anabilim Dalı, Kayseri, Türkiye,
ORCID ID: <https://orcid.org/0000-0001-7727-1544>, kader.tskiran@gmail.com

Geliş/ Received: 09.03.2022;

Kabul / Accepted: 20.04.2022

ÖZET: Diyabet hastalığına bağlı olarak retina tabakasına kan taşıyan kılcal damarlarda fonksiyon kayıpları oluşmakta ve Diyabetik Retinopati (Diabetic Retinopathy, DR) hastalığı ortaya çıkmaktadır. İlk aşamalarında gözde belirli oranlarda görme kayıplarına yol açan DR hastalığı doğru bir şekilde teşhis ve tedavi edilmez ise görme fonksiyonunun tamamen yok olmasına sebep olabilmektedir. DR hastalığının yüksek doğrulukta teşhis ve tedavi edilebilmesi için retinal damar yapısının bölütleme işlemi ile retina görüntüsünden ayrıştırılması ve analiz edilmesi gerekmektedir. Bu çalışmada, en güncel meta-sezgisel algoritmalarla olan Vahşi At Optimizasyon (Wild Horse Optimization, WHO) ve Kel Kartal Araştırma (Bald Eagle Search, BES) algoritmaları retinal damar bölütlemeye yönelik olarak kümeleme tabanlı geliştirilmiş ve performansları yaygın olarak kullanılan Gri Kurt Optimizasyon (Grey Wolf Optimization, GWO) algoritması ile mukayese edilmiştir.

Anahtar Kelimeler: Retinal damar bölütlemesi, Vahşi at optimizasyon algoritması, Kel kartal optimizasyon algoritması, Gri kurt optimizasyon algoritması.

*Sorumlu yazar / Corresponding author: cetinkaya@erciyes.edu.tr

Bu makaleye atıf yapmak için / To cite this article

Çetinkaya, M. B., Taşkıran, K. (2022). Meta-Sezgisel Algoritmalarla Dayalı Retinal Damar Segmantasyonu. Journal of Materials and Mechatronics: A (JournalMM), 3(1), 79-90.


Retinal Vessel Segmentation Based on Meta-Heuristic Algorithms

ABSTRACT: The functional losses due to the diabetes disease occurring in the vessels that carry blood to the retina layer causes the Diabetic Retinopathy (DR) disease. The DR which causes vision loss at certain rate in its initial stages, can lead to complete destruction of visual function if it is not correctly diagnosed and treated. In order to diagnose and treat DR with high accuracy, retinal vessel structure should be separated from the retinal image by segmentation and then to be analyzed in detail. In this work, Wild Horse Optimization (WHO) and Bald Eagle Search (Bald Eagle Search, BES) algorithms which are among the most recently proposed meta-heuristic algorithms have been improved as clustering based for retinal vessel segmentation and then their performances have been compared to that of well-known Gray Wolf Optimization (Grey Wolf Optimization, GWO) algorithm.

Keywords: Retinal vessel segmentation, Wild horse optimization algorithm, Bald eagle search optimization algorithm, Grey wolf optimization algorithm.

1. GİRİŞ

Diyabet hastalığı uzuvlar üzerinde fonksiyon zayıflamalarına veya kayıplarına yol açan önemli bir hastalıktır (Shuangling ve ark., 2015; Soares ve ark., 2006; Uyen ve ark., 2013). Bu hastalığın en önemli etkilerinden birisi ise retina tabakası üzerinde görülmektedir. Retina tabakası üzerinde meydana gelen ve diyabetik retinopati olarak adlandırılan bu hastalık sonucunda damarlarda daralma, genişleme, yırtılma veya pıhtı oluşumu gibi istenmeyen yapısal bozulmalar ortaya çıkmaktadır. Retinal damarlarda oluşan bu yapısal ve konum değişimleri retinal damar bölütleme işlemi ile yüksek doğrulukta tespit edilebilmektedir (Frame ve ark., 1998; Larsen ve ark., 2003). Sağlıklı ve DR hastalıklı retina görüntülerine ait örnek görseller aşağıda Şekil 1 ile verilmiştir.



Şekil 1. Retinal görüntüler, a) Sağlıklı retinal görüntü, b) DR hastalıklı retinal görüntü

Son yıllarda, diyabetik retinopati hastalığının teşhisine türeve dayalı geleneksel algoritmalar ve yapay sinir ağları kullanılarak yapılmış olan çalışmalar incelendiğinde; eksuda lezyonlarının tespitine yönelik analizlerin gerçekleştirildiği (Karegowda ve ark., 2011; Kaur ve Kaur, 2016; Jayakumari ve Santhanam, 2008; Somasundaram ve Prabhu, 2013), rasgele yürüyüş (random walk) algoritması ile retinal damar bölütlemenin gerçekleştirildiği (Gao ve ark., 2020), retinal damar bölütlemeye yönelik kenar kestirim süzgeçleri ve yapay sinir ağlarının kullanıldığı (Tchiotsop ve ark., 2021), retinal hastalık tespitine yönelik yapay sinir ağı tabanlı yaklaşımların geliştirildiği (Yağmur, 2008), retinal damar bölütleme işlemine yönelik derin yapay sinir ağı yapılarının önerildiği (Melinscak ve ark., 2015; Khanal ve Estrada, 2020), retinal damar bölütleme işlemine yönelik yeni bir evrişimli sinir ağı modelinin ve yama tabanlı yeni bir öğrenme stratejisinin önerildiği (Budak ve ark., 2020), retinal


görüntülerde optik disk bölgelerinin tespitine yönelik yüksek hızlı bölgesel evrişimli sinir ağ yapılarının geliştirildiği (Budak ve ark., 2018), Shearlet dönüşümü ve Indeterminacy süzgeçleme işlemlerine dayalı yeni bir retinal damar bölütleme yaklaşımının önerildiği (Guo ve ark., 2017) ve artık konvolüsyon yapay sinir ağlarının (residual convolution neural network) retinal bölütleme için kullanılmasını temel alan (Xu ve ark., 2021) çalışmaların bulunduğu görülmektedir. Bununla birlikte, literatürde meta-sezgisel algoritmaları temel alan çok sınırlı sayıda çalışma bulunmaktadır. Bu çalışmalar incelendiğinde; güncel meta-sezgisel algoritmaların retinal damar bölütleme işlemine yönelik kümeleme tabanlı geliştirildiği ve bilinen meta-sezgisel yaklaşımlar ile performans mukayeselerinin gerçekleştirildiği (Cetinkaya ve Duran, 2020; Cetinkaya ve Duran, 2022), parçacık sürüsü optimizasyon algoritması kullanılarak retinal damar bölütlemeye yönelik çok ölçekli damar kestirim yönteminin geliştirildiği (Khomri ve ark., 2018) ve ateş böceği meta-sezgisel algoritmasına dayalı retinal damar bölütlemeye yönelik (Keerthana ve ark., 2017) çalışmaların bulunduğu görülmektedir.

Bu çalışmada retinal görüntü analizi iki temel aşamada gerçekleştirilmiştir. Bunlar, *i.*) ön-işlemler ve *ii.*) sezgisel algoritmalara dayalı bölütleme aşamalarıdır. Bölütleme performansını artırmak için retinal görüntüler süzgeçleme, bottom-hat dönüşümü ve kontrast zenginleştirme ön-işlemlerine tabi tutulmuştur. Süzgeçleme işleminde, retinal görüntünün Kırmızı (R), Yeşil (G) ve Mavi (B) katmanları kontrast ve parlaklık açısından ayrı ayrı analiz edilerek en yüksek performansın G katmanı için elde edildiği görülmüştür ve sonraki aşamalarda yalnızca G katmanının gri-skala karşılığı üzerinden işlemler gerçekleştirilmiştir. Daha sonra, Eşitlik 1 kullanılarak bottom-hat dönüşümü uygulanmış ve görüntü art alanı içerisindeki koyu nesnelere yapısal elemanlar yani süzgeçler kullanılarak belirginleştirilmiştir.

$$\text{bottom-hat}(g) = g - (g \bullet nB) \quad (1)$$

burada, g ifadesi gri katmanda bir Öklid uzayından alınan eşleme noktalarını temsil etmektedir, (\bullet) operatörü morfolojik kapama işlemi, B ifadesi kullanılacak yapısal elemanı ve son olarak n ise bottom-hat dönüşümünü temsil etmektedir. Son ön-işlem olan kontrast zenginleştirmede ise gri-skala bölgesel olarak yoğunlaşmış piksel değerlerinin skalanın bütününe yani $[0 \ 255]$ piksel değer aralığına homojen olarak dağıtılması işlemi gerçekleştirilir.

Bu çalışmada, retinal damar bölütleme için DRIVE veri tabanından (Alonso-Montes ve ark., 2008) alınmış olan retinal görüntü ve bu görüntüye uygulanan ön-işlemler sonrası elde edilen görüntüler aşağıda Şekil 2 ile gösterilmiştir.



Şekil 2. Retinal görüntüler, a) DRIVE veritabanından alınan retinal görüntü, b) Süzgeçleme ön-işlemi sonrası elde edilen G katmanının gri skala karşılığı, c) Bottom-hat dönüşümü sonrası elde edilen retinal görüntü, d) Kontrast zenginleştirme ön-işlemi sonrası elde edilen retinal görüntü

2. MATERYAL VE YÖNTEM

Tabiatta sürüler halinde hareket eden canlı topluluklarının gösterdiği zeki davranışları modelleyen algoritmalar, *Sürü Zekasına Dayalı* optimizasyon algoritmaları olarak adlandırılırlar (Kennedy ve Eberhart, 1995). Bu algoritmalar yerel minimumlara takılmadan küresel çözümleri bulabilme yetenekleri, yüksek yakınsama oranları ve problemde bağımsız optimizasyon başarımlarından dolayı literatürde çok farklı alanlarda yaygın bir şekilde kullanılmaktadır. Bu çalışmada, en güncel sürü zekâsına dayalı meta-sezgisel algoritmalar arasında bulunan WHO ve BES algoritmaları retinal damar bölütleme üzerine uygulanmış ve performansları GWO algoritması ile mukayese edilmiştir.

2.1 Vahşi At Optimizasyon Algoritması

Naruei ve Keynia tarafından (Naruei ve Keynia, 2021) önerilmiş olan WHO algoritması için aşağıda verilen detaylı kod incelendiğinde, vahşi atların sergilediği liderlik, beslenme, kovalama ve çiftleşme davranışlarının matematiksel olarak modellendiği görülmektedir (Ali ve ark., 2022).

Rasgele başlangıç popülasyonu oluştur.

Çaprazlama ve Tay yüzdesi (PC ve PS) kontrol parametre değerlerini tanımla.

TDR adaptif kontrol parametre değerini hesapla, $TDR = 1 - \text{Çevrim} \cdot \left(\frac{1}{\text{Max Çevrim}}\right)$

FOR 1:Lider sayısı,

Z değerini hesapla,

$$P = \overline{R_1} < TDR; \text{IDX} = (P == 0); Z = R_2 \ominus \text{IDX} + \overline{R_3} \ominus (\square \text{IDX})$$

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

PC değerine göre Tay konumlarını aşağıdaki gibi güncelle,

$$\overline{X_{i,G}^j} = 2Z \cos(2\pi RZ) \cdot (\text{Lider}^j - X_{i,G}^j) + \text{Lider}^j, \text{rand} > PC$$

$$X_{G,K}^p = \text{Crossover}(X_{G,i}^q, X_{G,j}^z), i \neq j \neq k, p = q = \text{end}, \text{rand} < PC$$

burada; $X_{i,G}^j$ mevcut konum, Lider^j grup liderinin konumu, $R \in [-2,2]$ lider etrafında 360° açı altında konum değiştirme kontrol parametresi, $X_{G,i}^q$ ve $X_{G,j}^z$ gruplarını terketmiş q ve z numaralı tayların yeni konumları, $X_{G,K}^p$ bu tayların çiftleşmesi ile oluşan yeni bireyin konumu ve Crossover operatörü ise *Ortalama (Mean)* olarak tanımlanmaktadır.

Rasgele üretilen bir rand değerine göre Lider konumlarını aşağıdaki gibi güncelle,

$$\overline{\text{Lider}_{G_i}} = \begin{cases} 2Z \cos(2\pi RZ) \cdot (\text{WH} - \text{Lider}_{G_i}) + \text{WH}, & \text{if } R_3 > 0,5 \\ 2Z \cos(2\pi RZ) \cdot (\text{WH} - \text{Lider}_{G_i}) - \text{WH}, & \text{if } R_3 \leq 0,5 \end{cases}, \text{rand} > 0.5$$

$$\overline{\text{Lider}_{G_i}} = \begin{cases} X_{G,i}, & \text{if } \text{cost}(X_{G,i}) < \text{cost}(\text{Lider}_{G_i}) \\ \text{Lider}_{G_i}, & \text{if } \text{cost}(X_{G,i}) > \text{cost}(\text{Lider}_{G_i}) \end{cases}, \text{rand} \leq 0.5$$

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

if $\text{cost}(\overline{Lider}_{G_i}) < \text{cost}(Lider)$

$Lider = \overline{Lider}_{G_i}$

End

Tay gruplarını kalite değerlerine göre sırala ve en iyi çözümleri seç

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

Tay ve Lider pozisyonlarını güncelle,

$$\overline{Lider}_{G_i} = \begin{cases} X_{G,i}, & \text{if } \text{cost}(X_{G,i}) < \text{cost}(Lider_{G_i}) \\ Lider_{G_i}, & \text{if } \text{cost}(X_{G,i}) > \text{cost}(Lider_{G_i}) \end{cases}$$

End

En iyi sonucu güncelle

END

2.2 Kel Kartal Araştırma Optimizasyon Algoritması

Alsattar ve arkadaşları tarafından geliştirilen BES algoritması (Alsattar ve ark., 2020), kel kartalların avlanma sürecinde uyguladıkları bölge seçme, seçilen bölgeyi araştırma ve saldırma davranışlarını modelleyen meta-sezgisel bir algoritmadır. Üç avlanma stratejisini de içeren temel bir BES algoritmasının detaylı açıklamalı kodu aşağıda verilmiştir.

Rasgele başlangıç popülasyonu oluştur.

α, c_1 ve c_2 pozisyon değişim kontrol parametre değerlerini tanımla.

WHILE (sonlandırma kriteri sağlanıncaya kadar),

FAZ 1. Bölge Seçme

For (Popülasyondaki her bir birey için mevcut pozisyonları güncelle ve en iyi

iyi pozisyonları seç, $P_{new,i} = P_{best} + \alpha \cdot r \cdot (P_{mean} - P_i)$

$f(P_{new}) \leq f(P_i)$, ise $P_i = P_{new}$ eski konumu koru.

$f(P_{new}) \leq f(P_{best})$, ise $P_{best} = P_{new}$ en iyi konumu popülasyona ekle.

bu eşitliklerde; $\alpha \in [1,5 \ 2]$ pozisyon değişimlerini kontrol eden parametre, $r \in [0 \ 1]$ rasgele üretilen bir sayı ve P_{mean} önceki kartallardan alınan tüm bilgilerin yeni pozisyonlar üretilirken kullanılmasını sağlayan parametrelerdir.

End For

FAZ 2. Seçilen Bölgeyi Araştırma

For (Popülasyondaki her bir birey için mevcut pozisyonları güncelle ve ava saldırmak

için en iyi pozisyonu seç, $P_{i,new} = P_i + y(i) \cdot (P_i - P_{i+1}) + x(i) \cdot (P_i - P_{mean})$

$f(P_{new}) \leq f(P_i)$, ise $P_i = P_{new}$ eski konumu koru.

$f(P_{new}) \leq f(P_{best})$, ise $P_{best} = P_{new}$ en iyi konumu popülasyona ekle.

burada; $\theta_i = a \cdot \pi \cdot r$, $xr(i) = r(i) \cdot \sinh[\theta(i)]$, $yr(i) = r(i) \cdot \cosh[\theta(i)]$ ve $c1, c2 \in [1 \ 2]$ parametreleri hareket yoğunluğunun en iyi ve merkez noktalara

hareket düzlemindeki değişimleri oluşturmaktadır.

End For

FAZ 3. Saldırma

For (Popülasyondaki diğer bütün konumları ava saldırıya geçilen en iyi konuma doğru

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

$$f(P_{new}) \leq f(P_i), \text{ ise } P_i = P_{new} \text{ eski konumu koru.}$$

$$f(P_{new}) \leq f(P_{best}), \text{ ise } P_{best} = P_{new} \text{ en iyi konumu popülasyona ekle.}$$

burada; $\theta_i = a.\pi.r$, $xr(i) = r(i).\sinh[\theta(i)]$, $yr(i) = r(i).\cosh[\theta(i)]$ ve $c1, c2 \in [1, 2]$ parametreleri hareket yoğunluğunun en iyi ve merkez noktalara doğru yönlendirilmesini sağlayan parametrelerdir.

End For

$Cycle = Cycle + 1;$

END WHILE

WHO, BES ve GWO algoritmaları için benzetimlerde kullanılan kontrol parametre değerleri Çizelge 1'de gösterilmiştir. WHO, BES ve GWO algoritmaları için en uygun kontrol parametre değerleri sırasıyla (Naruei ve Keynia, 2021), (Alsattar ve ark., 2020) ve (Mirjalili ve ark., 2014) tarafından önerilmiştir. Ayrıca, belirli bir aralıkta değer alan parametreler için ilgili aralıkta çok sayıda farklı değer için benzetimler gerçekleştirilmiş ve en iyi sonuçların elde edildiği değer ilgili kontrol parametresi için en uygun değer olarak tanımlanmıştır. Ayrıca, her bir algoritma için bütün benzetimlerde Popülasyon Boyutu=10 ve Maksimum Çevrim Sayısı=100 olarak alınmıştır.

Çizelge 1. WHO, BES ve GWO algoritmaları için benzetimlerde kullanılan kontrol parametre değerleri

Algoritma	Kontrol Parametresi	Kontrol Parametre Değeri
WHO	Birey Yüzdesi (Grup Sayısı), PS	0.2
	Çaprazlama Yüzdesi, PC	0.13
BES	Pozisyon Değişim Kontrol Parametresi, $\alpha \in [1.5, 2]$	2
	Araştırma Döngü Sayısı, $R \in [0.5, 2]$	1.5
	Spiral hareketin, yatay eksen ile kesişim sayısı, $a \in [5, 10]$	10
	Hareket yoğunluğu yönlendirme parametreleri, $c_1, c_2 \in [1, 2]$	$c_1 = c_2 = 2$
GWO	Gri Kurt ve Av pozisyonlarını optimize eden adaptif katsayı vektörleri,	\vec{A} , \vec{C}

Optimizasyon sürecinde, retinal görüntüyü oluşturan her bir piksel değeri kümeleme işlemine yönelik optimize edilmektedir. Elde edilen uygunluk değerlerine göre her bir piksel değeri en yakın kümeleme merkezlerine atanır. Her olası küme merkezinin uygunluk değeri, aşağıdaki verilen Ortalama Karesel Hata (Mean Squared Error, MSE) fonksiyonu kullanılarak hesaplanabilir.

$$MSE = \frac{1}{M} \sum_{i=1}^M (f_i - y_i)^2 \quad (2)$$

burada, M toplam piksel sayısını, f_i ifadesi i . piksele en yakın küme merkezi değerini ve y_i ise i . pikselin piksel değeri olarak tanımlanmaktadır. Herhangi bir k . çözüme ait hata değeri MSE_k olmak üzere çözümlere ait fit_k kalite değerleri aşağıdaki gibi hesaplanmaktadır,

$$fit_k = \frac{1}{1 + MSE_k} \quad (3)$$

Algoritmalarda kullanılan kodlama stratejisinin optimizasyon performansı üzerinde doğrudan etkisi bulunmaktadır. Bu çalışma kapsamında geliştirilmiş olan kümeleme tabanlı meta-sezgisel algoritmalarda aşağıda gösterildiği gibi *Reel Değerli Kodlama Stratejisi* (Real-Valued Encoding Strategy) kullanılmıştır.

Reel-Değerli Kodlama

CC_1	CC_2	...	CC_k
--------	--------	-----	--------


burada, CC_k ifadesi $[0,255]$ aralığında reel değerler alan optimize edilmiş bir küme merkezini temsil etmektedir.

Kümeleme işlemi gerçekleştirilirken tercih edilen küme merkezi sayısı (k) bölütleme performansını etkileyen bir diğer önemli parametredir. Bu çalışmada retinal görüntüler *damar pikselleri* ve *artalan pikselleri* olmak üzere ayrıştırılmış ve küme merkezi sayısı $k=2$ olarak belirlenmiştir. Damar pikselleri için piksel değeri aralığı $[Küme\ Merkezi\ 1\ Küme\ Merkezi\ 2]$ şeklinde tanımlanmış ve bu aralık dışında kalan tüm piksel değerleri artalan pikselleri olarak bölütlenmiştir. *Küme Merkezi 1* ve *Küme Merkezi 2* için en uygun değerler ise meta-sezgisel algoritmalar tarafından elde edilmiştir.


3. BULGULAR VE TARTIŞMA

Retinal damar bölütleme işlemine yönelik kümeleme tabanlı geliştirilmiş olan sürü zekâsına dayalı meta-sezgisel WHO, BES ve GWO algoritmaları Şekil 2.a.'da verilen retinal görüntüye uygulandığında elde edilen bölütleme sonuçları aşağıda sırasıyla Şekil 3, Şekil 4 ve Şekil 5 ile gösterilmiştir.


Algoritmalar arasında adil bir mukayese gerçekleştirebilmek amacıyla her bir algoritma 10 kez koşturulmuş ve algoritmaların yakınsama hızları ve ulaştıkları minimum hata değerleri bu 10 rasgele koşmanın ortalamasına göre elde edilmiştir.



Şekil 3. WHO algoritması ile retinal damar bölütleme, a) DRIVE veritabanından alınan retinal görüntü, b) Tüm ön işlemler sonrasında elde edilen retinal görüntü, c) Retinal damar bölütleme sonucunda elde edilen bölütlenmiş görüntü



Şekil 4. BES algoritması ile retinal damar bölütleme, a) DRIVE veritabanından alınan retinal görüntü, b) Tüm ön işlemler sonrasında elde edilen retinal görüntü, c) Retinal damar bölütleme sonucunda elde edilen bölütlenmiş görüntü



Şekil 5. GWO algoritması ile retinal damar bölütleme, a) DRIVE veritabanından alınan retinal görüntü, b) Tüm ön işlemler sonrasında elde edilen retinal görüntü, c) Retinal damar bölütleme sonucunda elde edilen bölütlenmiş görüntü


Kümeleme tabanlı geliştirilmiş olan WHO, BES ve GWO algoritmaları ile elde edilen bölütlenmiş retinal görüntüler incelendiğinde, damar pikselleri ile artalan piksellerinin her üç algoritma için de başarılı bir şekilde ayırt edilebildiği ve algoritmaların elde edilen nihai görüntüler açısından benzer performanslar gösterdiği görülmektedir.

Benzetimlerde, 10 rasgele koşmanın her birisi için ulaşılan *Minimum MSE Değerleri* ile *Ortalama MSE Değerleri* aşağıda Çizelge 2 ile verilmiştir. Görüldüğü gibi, her üç algoritma da hata performansı açısından benzer sonuçlar üretmekle birlikte BES algoritması ulaşılan en düşük ve ortalama MSE hataları açısından diğer algoritmalara göre nispeten daha kötü performans sergilemektedir.

Çizelge 2. WHO, BES ve GWO algoritmaları için elde edilen Minimum ve Ortalama MSE değerleri

Koşma	WHO	BES	GWO
1	0,7764	0,8655	0,8141
2	0,7862	0,7988	0,7561
3	0,8171	0,8768	0,7442
4	0,7784	0,8695	0,7761
5	0,8025	0,8712	0,7839
6	0,8361	0,7938	0,8164
7	0,7171	0,8229	0,7965
8	0,7867	0,8049	0,8097
9	0,8142	0,8477	0,7465
10	0,7637	0,8738	0,7418
Minimum MSE	0,7171	0,7938	0,7442
Ortalama MSE	0,7878	0,8424	0,7785

WHO, BES ve GWO algoritmalarında 10 rasgele koşmanın ortalaması için elde edilen yakınsama grafikleri Şekil 6’da verilmiştir. Yakınsama grafiklerinden her üç algoritmanın da benzer MSE değerlerine benzer Çevrim sayısında yakınsadıkları görülmektedir. Diğer taraftan, en iyi hata performansının WHO algoritması tarafından elde edildiği ifade edilebilir.



Şekil 6. WHO, BES ve GWO algoritmalarının yakınsama performans mukayeseleri

Algoritmaların istatistiksel performans mukayeseleri için elde edilen F-score ve Standart Sapma parametre değerleri Çizelge 3 ile verilmiştir. Damar pikseli olarak doğru tahmin edilen piksel sayısı TP, artalan pikseli olarak yanlış tahmin edilen damar piksel sayısı FN ve damar pikseli olarak yanlış tahmin edilen artalan piksel sayısı FP olmak üzere F-score ifadesi aşağıdaki gibi tanımlanır,

$$F - score = TP / [TP + \frac{1}{2} (FP + FN)] \quad (4)$$

F-score parametresi için elde edilen sonuçlar değerlendirildiğinde her üç algoritmanın da doğru tahmin edilen piksel sayısı açısından benzer performanslar gösterdiği ancak GWO algoritmasının nispeten biraz daha iyi sonuçlar ürettiği görülmektedir. Benzer şekilde, her üç algoritmanın da standart sapma değerleri çok yakın olmakla birlikte en kararlı sonuçlar üreten algoritmanın GWO algoritması olduğu görülmektedir.

Çizelge 3. WHO, BES ve GWO algoritmaları için elde edilen F-score ve Standart Sapma değerleri

	WHO	BES	GWO
F-score	0,7055	0,6765	0,7246
Standart Sapma	0,0331	0,0339	0,0299

4. SONUÇ

Bu çalışma kapsamında kümeleme tabanlı geliştirilmiş olan WHO, BES ve GWO algoritmaları kullanılarak gerçekleştirilen retinal damar bölütleme benzetimleri sonucunda;

- Retinal görüntülerde çok yakın piksel değerlerine sahip olan artalan pikselleri ile damar piksellerinin WHO, BES ve GWO algoritmaları tarafından başarılı bir şekilde ayırt edebildikleri görülmüştür.
- WHO, BES ve GWO algoritmalarının benzer MSE hata değerlerine yakınsadıkları yani hata performanslarının benzer olduğu gözlemlenmiştir.
- WHO, BES ve GWO algoritmalarının benzer F-score ve Standart Sapma değerlerine yakınsadıkları yani istatistiksel performanslarının benzer olduğu gözlemlenmiştir.
- WHO, BES ve GWO algoritmalarının en düşük hata değerlerine yaklaşık olarak benzer çevrimlerde ulaştıkları yani benzer yakınsama performanslarına sahip oldukları görülmüştür.
- Meta-sezgisel algoritmaların biyomedikal görüntü analizinde ve kümeleme tabanlı çözüm gerektiren diğer mühendislik problemlerinde başarılı bir şekilde kullanılabileceği görülmüştür.

5. ÇIKAR ÇATIŞMASI

Yazarlar, bilinen herhangi bir çıkar çatışması veya herhangi bir kurum/kuruluş ya da kişi ile ortak çıkar bulunmadığını onaylamaktadırlar.

6. YAZAR KATKISI

Mehmet Bahadır ÇETİNKAYA çalışmanın algoritma kodlama ve geliştirme, algoritmaların retinal damar bölütleme işlemine uygulanması, ana metnin oluşturulması, kavramsal ve benzetim süreçlerinin belirlenmesi, kontrolü ve yönetimi.

Kader TAŞKIRAN literatür taramasının gerçekleştirilmesi, ana metnin oluşturulması ve düzenlenmesi, benzetimlerin gerçekleştirilmesi.

7. KAYNAKLAR

- Ali M. H., Kamel S., Hassan M. H., Veliz M. T., An Improved Wild Horse Optimization Algorithm for Reliability Based Optimal DG Planning of Radial Distribution Networks. *Energy Reports* 8, 582-604, 2022.
- Alsattar H. A., Zaidan A. A., Zaidan B. B., Novel Meta-Heuristic Bald Eagle Search Optimization Algorithm. *Artificial Intelligence Review* 53, 2237-2264, 2020.
- Alonso-Montes C., Vilariño D. L., Dudek P., Penedo M. G., Fast Retinal Vessel Tree Extraction: A Pixel Parallel Approach. *International Journal of Circuit Theory and Applications* 36 (5-6), 641-651, 2008.
- Budak Ü., Cömert Z., Şengür A., DCCMED-Net: Densely connected and concatenated multi-Encoder-Decoder CNNs for retinal vessel extraction from fundus images. *Medical Hypotheses* 134(109426), 2020.
- Budak Ü., Alçın Ö. F., Aslan M., Şengür A., Optic Disc Detection in Retinal Images via Faster Regional Convolutional Neural Networks. 1st International Engineering and Technology Symposium, Batman/Turkey, May 03-05, 2018, pp: 731-734.

- Çetinkaya M. B., Duran H., A Detailed and Comparative Work for Retinal Vessel Segmentation Based on The Most Effective Heuristic Approaches. *Biomedical Engineering / Biomedizinische Technik* 66(2), 181-200, 2021.
- Çetinkaya M. B., Duran H., Performance Comparison of Most Recently Proposed Evolutionary, Swarm Intelligence, and Physics-Based Metaheuristic Algorithms for Retinal Vessel Segmentation. *Mathematical Problems in Engineering* 2022(4639208), 1-25, 2022.
- Frame A. J., Undrill P. E., Cree M. J., Olson J. A., McHardy K. C., Sharp P. F., Forrester J. V., A Comparison of Computer Based Classification Methods Applied to The Detection of Microaneurysms in Ophthalmic Fluorescein Angiograms. *Computers in Biology and Medicine* 28(3), 225-238, 1998.
- Gao J., Chen G., Lin W., An Effective Retinal Blood Vessel Segmentation by Using Automatic Random Walks Based on Centerline Extraction. *BioMed Research International* 2020(7352129), 1-11, 2020.
- Guo Y., Budak Ü., Şengür A., Smarandache F., A Retinal Vessel Detection Approach based on Shearlet Transform and Indeterminacy Filtering on Fundus Images. *Symmetry* 9(10), 1-10, 2017.
- Jayakumari C., Santhanam T., An Intelligent Approach to Detect Hard and Soft Exudates Using Echo State Neural Network. *Information Technology Journal* 7(2), 386-395, 2008.
- Karegowda A. G., Bhattacharyya S., Jayaram M. A., Manjunath A. S., Exudates Detection in Retinal Images Using KNNFP And WKNNFP Classifiers. *Artificial Intelligent Systems and Machine Learning* 3(7), 419-425, 2011.
- Kaur A., Kaur P., A Comparative Study of Various Exudate Segmentation Techniques for Diagnosis of Diabetic Retinopathy. *International Journal of Current Engineering and Technology* 46(1), 142-146, 2016.
- Kennedy J., Eberhart R., Particle Swarm Optimization. *IEEE International Conference on Neural Networks* 4, 1942-1948, 1995.
- Keerthana K., Jayasuriya T. J., Raja N. S. M., Rajinikanth V., Retinal Vessel Extraction Based on Firefly Algorithm Guided Multi-Scale Matched Filter. *International Journal of Modern Science and Technology* 2(2), 74-80, 2017.
- Khanal A., Estrada R., Dynamic Deep Networks for Retinal Vessel Segmentation. *Frontiers in Computer Science* 2(35), 1-13, 2020.
- Khomri B., Christodoulidis A., Djerou L., Babahenini M. C., Cheriet F., Particle Swarm Optimization Method for Small Retinal Vessels Detection on Multiresolution Fundus Images. *Journal of Biomedical Optics* 23(5) 056004, 2018.
- Larsen M., Godt J., Larsen N., Lund-Andersen H., Sjølie A. K., Agardh E., Kalm H., Grunkin M., Owens D. R., Automated Detection of Fundus Photographic Red Lesions in Diabetic Retinopathy. *Investigative Ophthalmology and Visual Science* 44(2), 761-766, 2003.
- Melinscak M., Prentasic, P., Loncarik S., Retinal Vessel Segmentation using Deep Neural Networks. *10th International Conference on Computer Vision Theory and Applications* 1, 577-582, 2015.
- Mirjalili S., Mirjalili S. M., Lewis A., Grey Wolf Optimizer. *Advances in Engineering Software* 69,46-61, 2014.
- Naruei I., Keynia F., Wild Horse Optimizer: A New Meta-Heuristic Algorithm for Solving Engineering Optimization Problems. *Engineering With Computers*, <https://doi.org/10.1007/s00366-021-01438-z>, 2021.

- Shuangling W., Yilong Y., Guibao C., Benzeng W., Yuanjie Z., Gongping Y., Hierarchical Retinal Blood Vessel Segmentation Based on Feature and Ensemble Learning. *Neurocomputing* 149(Part B), 708-717, 2015.
- Soares J. V. B., Leandro J. J. G., Cesar J. R. M., Jelinek H. F., Cree M. J., Retinal Vessel Segmentation Using The 2-D Gabor Wavelet and Supervised Classification. *IEEE Medical Imaging* 25(9), 1214-1222, 2006.
- Somasundaram A., Prabhu J., Detection of Exudates for The Diagnosis of Diabetic Retinopathy. *International Journal of Innovation and Applied Studies* 3(1), 116-120, 2013.
- Tchinda B. S., Tchiosop D., Noubom M., Dorr V. L., Wolf D., Retinal Blood Vessels Segmentation Using Classical Edge Detection Filters and The Neural Network. *Informatics in Medicine Unlocked* 23(100521), 1-8, 2021.
- Uyen T. V., Nguyen A. B., Laurence A. F. P., Kotagiri R., An Effective Retinal Blood Vessel Segmentation Method Using Multi-Scale Line Detection. *Pattern Recognition* 46(3), 703-715, 2013.
- Yağmur F. D., Yapay sinir ağları ile retinada hastalık teşhisi. Haliç Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 2008.
- Xu S., Chen Z., Cao W., Zhang F., Tao B., Retinal Vessel Segmentation Algorithm Based on Residual Convolution Neural Network. *Frontiers in Bioengineering and Biotechnology* 9 (786425), 1-15, 2021.