

Gerçek Parametre Optimizasyonu İçin Kara Dul Örümceği Optimizasyon Algoritması

Yasin BEKTAŞ^{1*}, Necibe Füsün OYMAN SERTELLER²

^{1*}Elektrik-Enerji Bölümü, Aksaray Üniversitesi, Aksaray

²Elektrik Elektronik Mühendisliği, Marmara Üniversitesi, İstanbul

*yasinbektas@aksaray.edu.tr

(Geliş Tarihi: 04 Aralık 2023, Kabul Tarihi: 11 Aralık 2023)

(2nd International Conference on Frontiers in Academic Research ICFAR 2023, December 4-5, 2023)

ATIF/REFERENCE: Bektaş, Y. & Serteller, N. F. O (2023). Gerçek Parametre Optimizasyonu İçin Kara Dul Örümceği Optimizasyon Algoritması. *International Journal of Advanced Natural Sciences and Engineering Researches*, 7(11), 78-86.

Özet –Kara Dul Örümceği Optimizasyon Algoritması (BWOA), örümceklerin avlarını yakalama stratejilerinden esinlenerek geliştirilmiş bir meta-sezgisel optimizasyon algoritmasıdır. Bu algoritma, özellikle makina mühendisliği, elektrik-elektronik mühendisliği, inşaat mühendisliği, enerji-mühendisliği, endüstri mühendisliği ve görüntü işleme, ağ, çevre, robotik, planlama ve programlama, sağlık gibi araştırma konularında optimizasyon problemlerini çözmek için kullanılmaktadır. Bu çalışmada BWOA'nın performansı, çeşitli özelliklere sahip on iki farklı optimizasyon problemi üzerinde detaylı bir şekilde incelenmiş, elde edilen sonuçlar, literatürde kullanılan Genetik Algoritma (GA), Parçacık Sürüşü Optimizasyonu (PSO), Gri Kurt Optimizasyonu (GWO), Harris Şahinleri Optimizasyonu (HHO), Serçe Arama Algoritması (SSA) ve Balina Optimizasyon Algoritması (WOA) gibi altı farklı meta-sezgisel algoritmalar ile elde edilen sonuçlarla karşılaştırılmıştır. Sonuçlar, BWOA'nın diğer algoritmalara göre üstün bir performans sergilediğini açıkça ortaya koymuştur.

Anahtar Kelimeler – Kara Dul Örümceği Optimizasyon Algoritması, optimizasyon teknikleri, Meta-sezgisel algoritma, global optimizasyon

I. GİRİŞ

Optimizasyon, bir durumun veya kaynağın en verimli biçimde kullanılması amacını taşıyan bir eylem olarak tanımlanır. Son on yılda, optimizasyon hemen hemen her alanda yaygın bir şekilde kullanılmıştır [1]. Doğadaki çeşitli prensipler ve mekanizmalar, bir dizi stokastik yöntemin geliştirilmesine öncülük etmiş ve bu yöntemler, farklı optimizasyon problemlerini oldukça etkili bir biçimde çözmek için kullanılmıştır.

Literatürdeki teorik çalışmalar genellikle stokastik yöntemlere odaklanır ve bu çalışmalar genellikle üç ana başlık altında incelenebilir: mevcut algoritmaların geliştirilmesi, çeşitli

tekniklerin birleştirilmesi ve yeni algoritmaların tanıtılması. Bu kategorilerin ilk sırasında, araştırmacılar genellikle mevcut algoritmaların performansını artırmak için değiştirilmiş veya tamamen yeni stokastik operatörler kullanmaya çalışırlar. Bu operatörler arasında evrimsel operatörler [2], arama uzayını azaltma teknikleri [3] ve yeniden başlatma stratejileri [4] bulunmaktadır ve bunlar sıkça tercih edilen tekniklerdir. İkinci kategoride, çeşitli stokastik yöntemler, belirli bir türdeki problemleri çözmek için genel performansı artırmak amacıyla birleştirilir. Son kategori ise çeşitli araştırmacılar tarafından önerilen yeni meta-sezgisel algoritmaların tanıtılmasıyla ilgilidir. Bu

yeni algoritmaların motivasyonu, biyolojik evrim sistemlerinden, canlı varlıkların sürü davranışlarından, insanların yaşam tarzlarına ilişkin kavramlardan ve çeşitli doğa olaylarından ilham alabilir.

Biyolojik evrimden ilham alan bir dizi evrimsel algoritma geliştirilmiştir; bu örnekler arasında Genetik Algoritma (GA) [6] ve Diferansiyel Evrim (DE) [7] bulunmaktadır. Ayrıca, parçacık sürüsü mantığına dayalı olarak geliştirilen Parçacık Sürüsü Optimizasyonu (PSO) [8,9], Yarasa Algoritması (BA) [9] gibi çeşitli parçacık sürüsü tabanlı optimizasyon algoritmaları da öne çıkmıştır. Bu algoritmalar, farklı türlerden canlıların sürü veya kolektif davranışlarını taklit etmektedir; örneğin, kuşlar, balıklar, bakteriler vb. Bu tür algoritmaların, problem çözme stratejilerini taklit edenlerin, diğer yaşayan varlıkların sürü davranışlarını modelleyenlerden daha üstün olduğu gösterilmiştir [10]. Bu nedenle, Beyin Fırtınası Optimizasyonu (BSO) [10], Öğrenme Temelli Algoritma (TLBO) [11] gibi algoritmalar, araştırmacılardan daha fazla ilgi görmüştür ve bu algoritmalar genellikle büyük ölçekli problemlere başarıyla uygulanmıştır.

Literatürde çeşitli meta-sezgisel algoritmalar çeşitli optimizasyon problemlerini çözmek için kullanılmıştır. Bu durum göz önüne alındığında, temel bir soru ortaya çıkmaktadır: Daha fazla optimizasyon algoritmasına ihtiyaç duyuyor muyuz ve eğer öyleyse, neden? Birçok meta-sezgisel algoritmanın genellikle adaptif olmayan kontrol parametrelerine sahip olduğu gözlemlenmiştir. Algoritmaya özgü parametreler, algoritmanın evrim sırasında duruma bağlı olarak değerlerini değiştirmelidir, örneğin, Genetik Algoritma'da (GA) mutasyon olasılığını sağlayan değerler değiştirilmesi gibi. Bu parametrelerin optimal değerleri problem ve evrim durumuna bağlı olarak değiştirilebilir. Bu konuda bazı çalışmalar yapılmış olsa da [12], daha fazla araştırmaya ihtiyaç vardır. Ayrıca, "Bedava Öğle Yemeği Yok (NFL)" olarak adlandırılan ve tüm optimizasyon problemlerini eşit kolaylık ve verimlilikle çözebilecek bir genel algoritmanın olamayacağını iddia eden iyi bilinen bir teorem vardır [13]. Bu teorem, bir algoritmanın belirli bir problemde üstün performans sergilemesinin, aynı performansı farklı türde

optimizasyon problemlerine çözüm bulma garantisi olmadığını ortaya koymaktadır. Bu teorem, araştırmacılara yeni optimizasyon teknikleri önerme veya mevcut algoritmaları farklı sektörlere ait problemler üzerinde geliştirme olanağı sağlamaktadır.

Yukarıda belirtilen gerçekler, bu çalışmanın motivasyonunu oluşturan temel unsurlardır. Bu araştırmada, temelde kara dul örümceklerin avlanma ve hayatta kalma stratejilerine dayalı olarak geliştirilmiş, basit ancak etkili bir optimizasyon algoritması açıklanmıştır. Bu algoritma, örümceklerin doğadaki avlanma davranışlarından ilham alarak tasarlanmıştır.

Çalışmanın devamı aşağıdaki gibidir: Bölüm II, BWOA'nın matematik modeliyle ilgilenir. Bölüm III'te, BWOA'nın on iki farklı test fonksiyonu üzerinde yapılan detaylı performans analizi sunulmaktadır. Son olarak, elde edilen bazı sonuçlar Bölüm IV'te açıklanmıştır.

II. KARA DUL ÖRÜMCEĞİ OPTİMİZASYON ALGORİTMASI

Kara Dul Örümceği Optimizasyon Algoritması (BWOA), örümceklerin avlarını yakalamak ve kaynakları optimize etmek amacıyla geliştirilmiş bir meta-sezgisel optimizasyon algoritmasıdır. Bu algoritma, örümceklerin doğadaki avlanma ve hayatta kalma stratejilerinden esinlenerek tasarlanmıştır. Örümceklerin avlanma davranışları genellikle hızlı, etkili ve stratejiktir. Bu algoritma örümcek türlerinden olan Kara Dul Örümceklerinin avlarını yakalama ve kaynakları daha etkili bir şekilde kullanma yeteneklerini taklit eder.

BWOA'nın ana stratejileri şunlardır:

Avcılık Stratejisi: Örümcekler avlarını yakalamak için stratejik bir şekilde bekler ve avlarına saldırır. BWOA, bu stratejiyi optimizasyon problemlerinde çözüm alanında etkili bir şekilde arama yapmak için kullanır.

Üreme Stratejisi: Örümcekler, çeşitli üreme stratejilerini kullanarak nesillerini sürdürür. BWOA, bu stratejileri çeşitlilik sağlamak ve yeni çözümler üretmek için kullanır.

Kara Dul Örümcek Optimizasyon Algoritması, kullanıcılarına bir dizi avantaj sunar ve bu algoritma çeşitli optimizasyon problemlerine başarılı bir şekilde uyarlanabilir. Bu avantajlar şu şekildedir:

Basitlik ve kullanım kolaylığı: Algoritma, basit bir tasarıma sahiptir ve kullanımı kolaydır. Kullanıcılar, algoritmanın temel prensiplerini hızla

öğrenip uygulayabilir, bu da pratikte kullanımı kolay bir optimizasyon aracı haline getirir.

Etkililik ve büyük ölçekli problemlere uygunluk: Bu algoritma özellikle karmaşık ve büyük ölçekli optimizasyon problemleri için özel olarak tasarlanmıştır. Bu özelliği sayesinde, gerçek dünya problemlerinin karmaşıklığıyla başa çıkabilir ve etkili sonuçlar üretebilir.

Çeşitli optimizasyon problemlerine uyarlanabilirlik: Kara Dul Örümcek Optimizasyon Algoritması, farklı problem tipleri ve endüstrilerde geniş bir uygulama yelpazesine uyarlanabilir. Bu esneklik, algoritmanın çeşitli optimizasyon senaryolarında kullanılabilmesini sağlar. Kara dul örümceklerinin davranışlarıyla ilgili daha fazla detay için [14, 15]'de bulunan bilgilere başvurulabilir.

A. Matematiksel Model

Örümceklerin kur yapma ve çiftleşme davranışlarına ilişkin farklı hareket stratejilerinin ve feromon oranının matematiksel modeli aşağıda sunulmuştur:

1. Hareket stratejisi: Örümceğin ağ içindeki hareketleri Şekil 1'de gösterildiği doğrusal ve sarmal olarak iki farklı şekilde modellenmiştir [17].

$$\bar{x}_i(t+1) = \begin{cases} \bar{x}^*(t) - m\bar{x}_{r_1}(t), & \text{eğer } \text{rand}() \leq 0.3 \\ \bar{x}^*(t) - \cos(2\pi\beta)\bar{x}_i(t), & \text{diğer durumda} \end{cases} \quad (1)$$

Burada $\bar{x}_i(t+1)$ bir arama ajanının yeni pozisyonunu, yani örümceğin hareketini temsil eder.

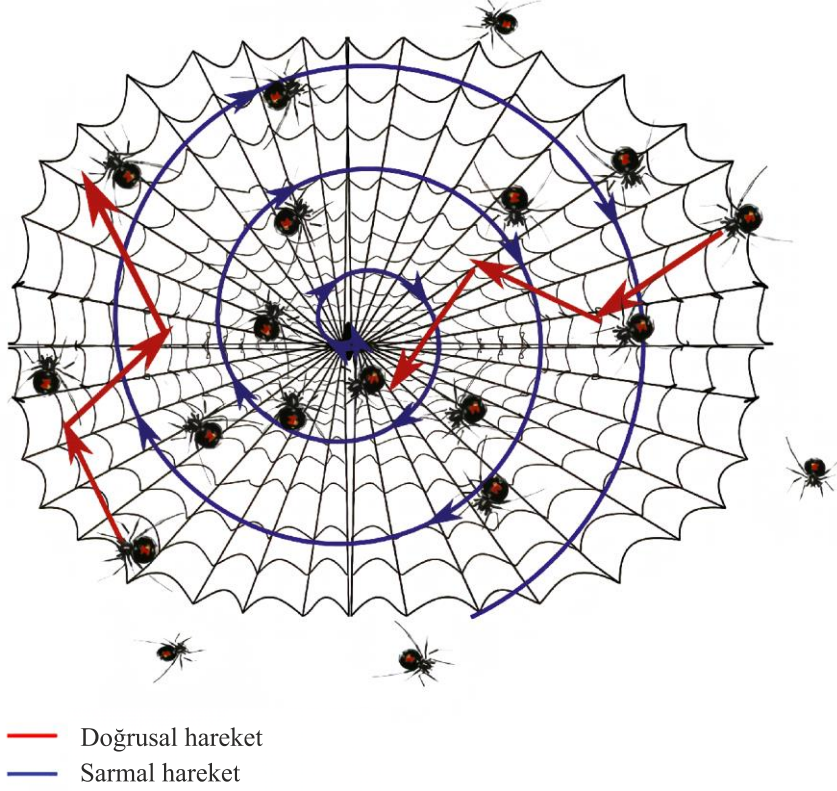
$\bar{x}^*(t)$ ise önceki iterasyonda bulunan en iyi arama ajanını temsil eder. m değişkeni [0.4, 0.9] aralığında rastgele oluşturulan bir ondalık sayıdır.

r_1 değişkeni 1 ile maksimum arama ajanı boyutu arasında rastgele oluşturulan bir tamsayıdır. $\bar{x}_{r_1}(t)$

r_1 'inci arama ajanını temsil eder, burada $i \neq r_1$ 'dir.

Son olarak β , [-1.0, 1.0] aralığında rastgele oluşturulan bir ondalık sayıdır ve $\bar{x}_i(t)$ ise mevcut arama ajanını temsil eder.

2. Feromonlar: Feromonlar, örümceklerinin kur yapma-çiftleşme sürecinde çok önemli bir rol oynar. Örümceklerin diyeti ile feromon sinyallerinin değişimi arasındaki bağlantı Denklem 2'de gösterilmiştir [14]; bu değişim, ipek kalitesini ve miktarını etkiler. Başka bir deyişle, iyi beslenmiş dişiler, aç dişilere kıyasla daha fazla ipek üretir. Erkek örümcekler, iyi beslenmiş dişilerden gelen cinsel feromona daha duyarlıdır, çünkü bu, daha yüksek verimliliğe sahip olmanın yanı sıra muhtemelen aç bir dişiyiyle riskli çiftleşme girişimlerinin maliyetinden kaçınma avantajını sağlar. Yani, erkek kara dul örümcekleri, daha verimli dişiler aramak yerine, genellikle aç bir dişiyiyle olan riskli çiftleşmelerden kaçınmayı tercih eder.



Şekil 1. Ağ içindeki tipik örümcek hareketi [16].

Kara dul örümceklerin feromon oranı, tercih edilen dişi örümcekleri belirlemek için kullanılan bir değerdir ve aşağıdaki denklemle tanımlanmaktadır:

$$feromon(i) = \frac{uygunluk_{maksimum} - uygunluk(i)}{uygunluk_{maksimum} - uygunluk_{minimum}} \quad (2)$$

Burada, $uygunluk_{maksimum}$ ve $uygunluk_{minimum}$ sırasıyla mevcut neslin en kötü ve en iyi uygunluk değerleridir, $uygunluk(i)$ ise i 'inci arama ajanının mevcut uygunluk değeridir. Denklem (2) 'deki feromon vektörü, $[0, 1]$ aralığında normalize edilmiş uygunluk değerlerini içerir. Düşük feromon oranları, 0.3'e eşit veya daha düşük değerlere sahipse, Denklem (3) Algoritma 1'de uygulanır. Dişi bir örümceğin düşük feromon seviyeleri, aç bir yırtıcı örümcek temsil eder. Bu nedenle, varlarsa, söz konusu dişi örümcekler seçilmeyecek, başka biriyle değiştirilecektir:

$$\bar{x}_i(t) = \bar{x}^*(t) + \frac{1}{2} \left[\bar{x}_{r_1}(t) - (-1)^\sigma * \bar{x}_{r_2}(t) \right] \quad (3)$$

Burada, $\bar{x}_i(t)$, güncellenecek düşük feromon oranına sahip arama ajanını (dişi örümcek) temsil eder. r_1 ve r_2 , 1 ile arama ajanlarının (örümceklerin) maksimum boyutu arasında üretilen rastgele tam sayıdır, $r_1 \neq r_2$ olup, $\bar{x}_{r_1}(t)$ ve $\bar{x}_{r_2}(t)$ sırasıyla seçilen r_1 'inci ve r_2 'inci arama ajanlarıdır. $\bar{x}^*(t)$, önceki iterasyonda bulunan en iyi arama ajanını temsil eder ve σ , Algoritma 2'de rastgele üretilen $\{0, 1\}$ arasındaki ikili bir sayıdır. Bu değer ya sıfırdır ya da 1'dir.

3. BWOA Algoritmasının Pseudo kodu: BWOA'nın Pseudo kodu Algoritma 3'te açıklanmıştır. Algoritma hakkında belirtilmesi gereken önemli noktalardan biri, çalıştırmak için popülasyonun boyutundan ve iterasyon sayısından daha fazla parametre gerektirmemesidir. Her iterasyonda, m (doğrusal hareket) ve β (sarmal hareket) değerleri, Algoritma 3'ün ana while döngüsündeki satır 4'te açıklandığı gibi değişir, burada rastgele üretilen her iki değişken de ana while döngüsünün içindedir. Tüm popülasyonu güncellemek için düşük feromon kriteri (satır 10 ve 11) algoritmanın, bir sonraki iterasyondan

önce uygunluk değerinin kalitesini iyileştirmek için ikinci bir şans elde etmesine yardımcı olur. Örümceklerin biyolojik davranışı açısından, bu, dişi örümceklerde yamyamlık veya düşük feromon seviyeleri nedeniyle erkek örümcekler tarafından dişilerin seçilmemesini temsil etmek için kullanılır. Bu stratejiler ve kurallar, arama uzayı üzerinde yoğunlaşma (eksploitasyon) ile çeşitlenme (keşif) arasında ince bir denge sağlar (Algoritma 3).

4. Zaman Karmaşıklığı: Optimizasyon problemleri genellikle bir fonksiyon olan f üzerinden tanımlanır. Bu fonksiyonun optimize edilmesi, yani en iyi (genellikle minimum veya maksimum) değer bulunması, birçok algoritmaya dayanır. BWOA'nın hesaplamalı zaman karmaşıklığı, algoritmanın maksimum iterasyon sayısı (**Tmaksimum**), popülasyon büyüklüğü (**Spn**), ve optimizasyon probleminin fonksiyon değerini değerlendirmenin hesaplamalı zaman karmaşıklığı (**O(f)**) ile ilişkilidir. Matematiksel olarak, BWOA'nın hesaplamalı zaman karmaşıklığı aşağıdaki gibi ifade edilir:

$$O(T_{maksimum} * Spn * f) \quad (4)$$

Tablo 3. ALGORİTMA 3: Kara dul örümceği optimizasyon algoritması (BWOA) [16]

- (1). Prosedürü başlat.
- (2). Başlangıç popülasyonunu oluştur.
- (3). **while** iterasyon < maksimum iterasyon **do**
- (4). m ve β parametrelerinin rastgele başlat, burada $0,4 \leq m \leq 0,9$ ve $-1,0 \leq \beta \leq 1,0$
- (5). **if** random < 0.3 **then**
- (6). $x_{yeni_i} = \bar{x} * (t) - m\bar{x}_1(t)$
- (7). **else**
- (8). $x_{yeni_i} = \bar{x} * (t) - \cos(2\pi\beta)\bar{x}_i(t)$
- (9). **end if**
- (10). Her arama ajanı için feromonu denklem (2)'ye göre hesapla.
- (11). Düşük feromon değerine sahip arama ajanını Denklem (3)'e göre güncelle, Algoritma 1.
- (12). x_{yeni_i} yeni arama ajanının uygunluk değerini hesapla
- (13). **if** $x_{yeni_i} < x_*$ **then**
- (14). $x_* = x_{yeni_i}$
- (15). **end if**
- (16). iterasyon = iterasyon + 1
- (17). **end while**
- (18). x_* en iyi çözümü görüntüle
- (19). **end** prosedür

Zaman karmaşıklığı, algoritmanın performansını değerlendirmek ve çeşitli optimizasyon problemlerine uygulanabilirliğini anlamak için kullanılır.

Tablo 1. ALGORİTMA 1: Feromon prosedürü [16]

- (1). Prosedürü başlat.
- (2). **for** $i = 1$ nüfusu boyutlandır **do**
- (3). **if** feromon(i) ≤ 0.3 **then**
- (4). $\bar{x}_i(t)$ arama ajanını denklem (3)'e göre güncelle
- (5). **end if**
- (6). **end for**
- (7). Prosedürü durdur.

Tablo 2. ALGORİTMA 2: σ prosedürü [16]

- (1). Prosedürü başlat.
- (2). **if** rand ≤ 0.3 **then**
- (3). return 0
- (4). **else**
- (5). return 1
- (6). **end if**
- (7). Prosedürü durdur.

Tablo 4. Unimodal benchmark fonksiyonları

Fonksiyon	Dim	Range	f_{\min}
$f_1(x) = \sum_{i=1}^n x_i^2$	30,100,500	[-100,100]	0
$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30,100,500	[-10,10]	0
$f_3(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2$	30,100,500	[-100,100]	0
$f_4(x) = \max \{ x_i , 1, i, n\}$	30,100,500	[-100,100]	0
$f_5(x) = \sum_{i=1}^{n-1} \left[100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2 \right]$	30,100,500	[-30,30]	0
$f_6(x) = \sum_{i=1}^n ([x_i + 0.5])^2$	30,100,500	[-100,100]	0
$f_7(x) = \max \{ x_i , 1, i, n\}$	30,100,500	[-1.28,1.28]	0

III. SONUÇLAR VE TARTIŞMA

Bu bölüm, Kara Dul Örümcek Optimizasyon Algoritması'nın (BWOA), Genetik Algoritma (GA), Parçacık Sürüsü Optimizasyonu (PSO), Gri Kurt Optimizasyonu (GWO), Harris Şahinleri Optimizasyonu (HHO), Serçe Arama Algoritması (SSA) ve Balina Optimizasyon Algoritması (WOA) gibi altı farklı algoritma ile karşılaştırıldığı 12 kriter fonksiyonu (30 boyut) değerlendirmelerini içermektedir. Bu klasik fonksiyonlar, literatürde yaygın olarak kullanılan ve mevcut meta-sezgisel algoritmaların sonuçlarıyla karşılaştırmak amacıyla seçilmiştir.

Tablo 4 ve 5'te gösterilen standart fonksiyonlar, boyutlarını temsil eden Dim, arama uzayının sınırlarını temsil eden Range ve optimal değeri gösteren f_{\min} ile temsil edilmiştir. Benchmark fonksiyonları, bilgisayar algoritmalarının performansını değerlendirmek ve karşılaştırmak amacıyla kullanılan standart matematiksel fonksiyonlardır. Bu fonksiyonlar, genellikle belirli özelliklere sahip olup, algoritmaların belirli zorluk derecelerini test etmelerini sağlar.

Her bir benchmark fonksiyonunun matematiksel ifadesi, belirli bir optimizasyon problemi veya test senaryosunu temsil eder. Bu ifadeler, genellikle algoritmaların ne kadar iyi performans gösterdiğini

belirlemek için kullanılan hedef fonksiyonlarıdır. Bu test fonksiyonları doğalarına göre farklılık gösterir; örneğin, tek modlu (örneğin, F01, F02, F03 ve diğerleri) ve çok modlu (örneğin, F04, F06, F09 ve diğerleri).

Tek modlu bir problemde yalnızca tek bir global optimum nokta bulunur ve başka bir yerel optimum havuz yoktur. Bir algoritmanın sömürü yeteneği ve yakınsama hızı bu tür fonksiyonlar üzerinde iyi bir şekilde test edilebilir. Aksine, çok modlu bir problem, global optimum noktasının yanı sıra birkaç yerel optimum havuzdan oluşur. Bu nedenle, bir optimizasyon algoritmasının keşif gücü, algoritmanın bu tür test problemlerine uygulanmasıyla kontrol edilebilir.

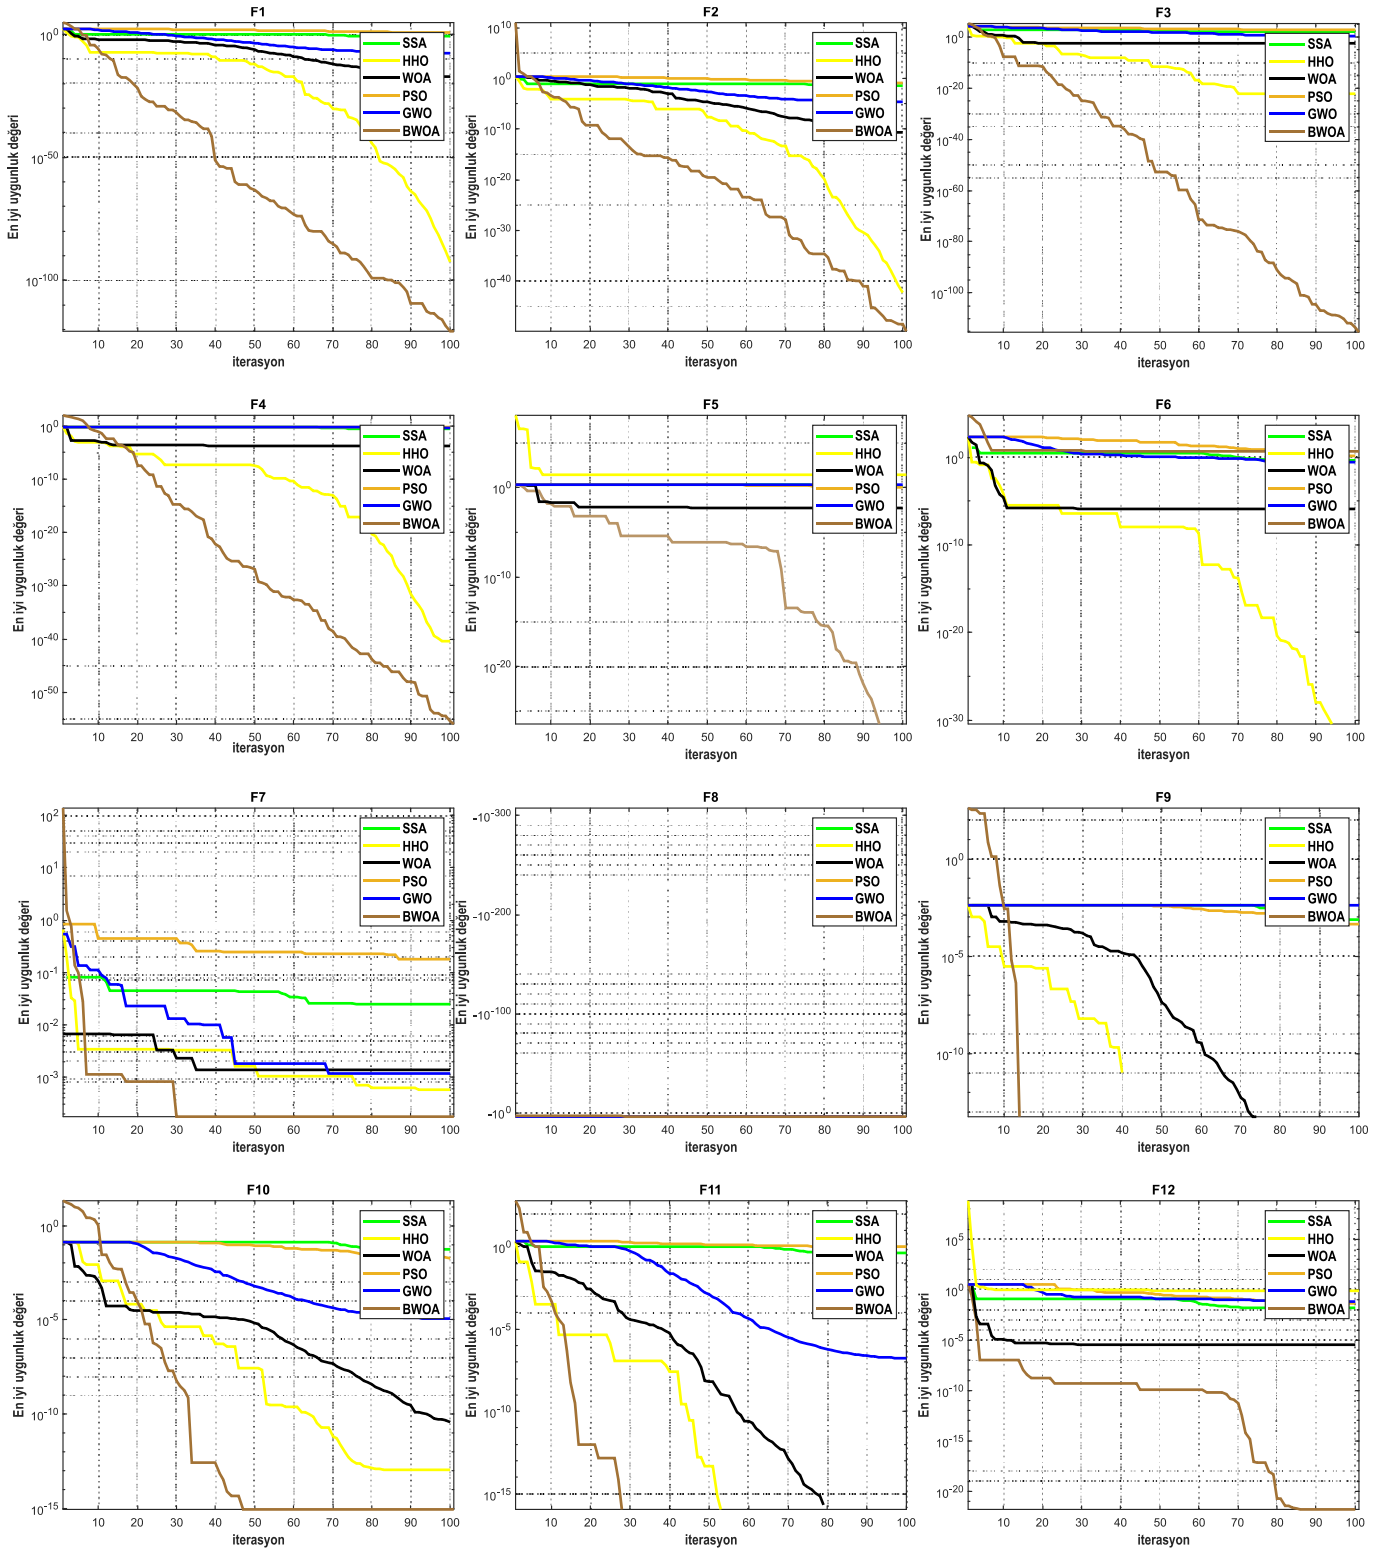
Bu makalede, aynı deneysel koşullarda BWOA'nın bu ön üç test fonksiyonu üzerindeki performansı değerlendirilmiş ve elde edilen sonuçlar diğer algoritmaların sonuçları ile karşılaştırılmıştır. Her bir algoritma beşer defa çalıştırılmış, en iyi sonuçlar Tablo 6'da verilmiştir. Görüldüğü gibi, BWOA sadece F6 fonksiyonunda diğerlerinden başarısız olmuştur. Şekil 2'de ise standart test fonksiyonları için algoritmaların yakınsama eğrisi verilmiştir.

Tablo 5. Multimodal benchmark fonksiyonları

Fonksiyon	Dim	Range	f_{min}
$F_8(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	30,100,500	[-500,500]	0
$F_9(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30,100,500	[-5.12,5.12]	0
$F_{10}(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	30,100,500	[-32,32]	0
$F_{11}(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30,100,500	[-600,600]	0
$F_{12}(x) = \frac{\pi}{n} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \right\}$ $+ \sum_{i=1}^n u(x_i, 10, 100, 4) + \sum_{i=1}^n u(x_i, 10, 100, 4) \quad y_i = 1 + \frac{x_i + 1}{4}$ $u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 & -a < x_i < a \\ k(-x_i - a)^m & x_i < -a \end{cases}$	30,100,500	[-50,50]	0

Tablo 6. Test fonksiyonlarının sonuçları.

	BWOA	SSA	HHO	WOA	PSO	GWO	GA
F1	3.238e ⁻¹²⁴	0.8024	1.781e ⁻⁸⁰	1.346e ⁻¹⁸	4.359	1.243e ⁻⁰⁷	1.678e ⁰³
F2	2.927e ⁻⁵⁶	0.5172	3.2705e ⁻³⁹	1.407e ⁻¹¹	0.317	6.363e ⁻⁰⁵	1.046e ⁴⁰
F3	2.693e ⁻¹²²	225.1473	2.4266e ⁻¹⁹	0.4695	46.4420	0.8614	8.127e ⁰³
F4	6.041e ⁻⁶³	0.1607	7.4927e ⁻⁴⁰	0.0521	2.0823	1.1957	1.878e ⁰¹
F5	0	3.6011	1.7628e ⁻⁰⁹	5.1138	7.0728	12.6098	3.158e ⁰⁵
F6	5.3372	0	0	0	0	0	5.758e ⁰¹
F7	1.244e ⁻⁰⁵	0.0018	0.0001	0.0008	0.0066	0.0004	5.858e ⁰⁰
F8	-0.4000	-1.2322	-1.2569	-1.2569	-1.1988	-0.9231	-1.2371
F9	0	0.1048	0	0	30.2636	39.2498	5.137e ⁰³
F10	8.818e ⁻¹⁶	0.1349	7.9019e ⁻¹⁵	1.2088e ⁻¹²	0.3769	4.9019e ⁻¹²	5.963e ⁰³
F11	0	1.0663	0	0	0.4846	1.612e ⁻⁷	9.887e ⁰⁷
F12	1.378e ⁻¹⁴	0.0013	9.8252e ⁻¹³	0.0001	0.0081	0.0497	6.457e ⁰³



Şekil 2. Algoritmaları tek-modal test fonksiyonları (F1-F7) üzerindeki ve çoklu-modal test fonksiyonları (F8-F12) üzerindeki yakınsama eğrileri.

IV. SONUÇLAR

Bu çalışmanın sonuçları, Kara Dul Örümcek Optimizasyonu Algoritması'nın (BWOA) performansını değerlendirmek amacıyla elde edilmiştir. Matematiksel model, örümceklerin

çiftleşme ve feromon oranları için farklı hareket stratejilerini tanımlayan bir yapı içermektedir.

Analiz, önerilen BWOA'nın on iki farklı test fonksiyonu üzerinde gerçekleştirilmiş ve diğer popüler meta-sezgisel algoritmalarla (GA, PSO, GWO, HHO, SSA ve WOA) karşılaştırılmıştır. BWOA, on iki test fonksiyonunun on birinde etkili

bir şekilde performans göstermiştir ($F1=3.238e-124$, $F2=2.927e-56$, $F3=2.693e-122$, $F4=6.041e-63$, $F5=0$, $F7=1.244e-05$, $F8=-0.4000$, $F9=0$, $F10=8.818e-16$, $F11=0$, $F12=1.378e-14$). Ancak, sadece F6 fonksiyonunda diğer algoritmalarından düşük performans sergilemiştir ($F6=5.3372$).

BWOA'nın zaman karmaşıklığı, maksimum iterasyon sayısı ve popülasyon boyutu gibi faktörler temel alınarak başka optimizasyon algoritmaları ile karşılaştırılmıştır. Elde edilen sonuçlar, özellikle belirlenmiş aynı optimizasyon problemleri üzerinde BWOA'nın etkili bir çözüm sunabileceğini ve diğer algoritmalarla rekabet avantajına sahip olduğunu göstermiştir (Tablo 6).

Ancak, algoritmanın genel kullanılabilirliği ve performansı konusunda daha geniş kapsamlı değerlendirmeler ve uygulamalar gerekmektedir. Kara Dul Örümcek Optimizasyonu Algoritması'nın belirli problem tiplerine ait sınırlamalara sahip olabileceği ve her problem tipinde en iyi çözümü sunamayabileceği unutulmamalıdır. Bu nedenle, algoritmanın farklı problemler üzerindeki performansını daha ayrıntılı bir şekilde anlamak için ileri araştırmalara ihtiyaç vardır.

KAYNAKLAR

- [1] C.-L. Liao, S.-J. Lee, Y.-S. Chiou, C.-R. Lee, and C.-H. Lee, "Power consumption minimization by distributive particle swarm optimization for luminance control and its parallel implementations," *Expert Systems with Applications*, vol. 96, pp. 479-491, 2018.
- [2] A. K. Das and D. K. Pratihar, "A directional crossover (DX) operator for real parameter optimization using genetic algorithm," *Applied Intelligence*, 2018.
- [3] A. K. Das and D. K. Pratihar, "A New Search Space Reduction Technique for Genetic Algorithms," in *Contemporary Advances in Innovative and Applicable Information Technology*, ed: Springer, 2019, pp. 111-119.
- [4] A. K. Das and D. K. Pratihar, "A Novel Restart Strategy for Solving Complex Multi-modal Optimization Problems Using Real-Coded Genetic Algorithm," in *17th International conference on Intelligent Systems Design and Applications (ISDA)*, Delhi, India, 2018, pp. 32-41.
- [5] Y. Yun, H. Chung, and C. Moon, "Hybrid genetic algorithm approach for precedence-constrained sequencing problem," *Computers & Industrial Engineering*, vol. 65, pp. 137-147, 2013.
- [6] J. H. Holland, *Adaptation in natural and artificial systems. An introductory analysis with application to biology, control, and artificial intelligence*. Cambridge, MA, USA: MIT Press, 1992.
- [7] R. Storn and K. Price, "Differential evolution—a simple and efficient heuristic for global optimization over continuous spaces," *Journal of global optimization*, vol. 11, pp. 341-359, 1997.
- [8] J. Kennedy and R. Eberhart, "Particle swarm optimization," in *Proceedings of International Conference on Neural Networks (ICNN'95)*, 1995, pp. 1942-1948.
- [9] Kumru, E., Serteller, N.F.O. (2023). DC motor Analysis Based on Improvement of PID Coefficients Using PSO Algorithm for Educational Use. In: Auer, M.E., Pachatz, W., Rüttemann, T. (eds) *Learning in the Age of Digital and Green Transition*. ICL 2022. *Lecture Notes in Networks and Systems*, vol 633. Springer, Cham. https://doi.org/10.1007/978-3-031-26876-2_85
- [10] X.-S. Yang, "A new metaheuristic bat-inspired algorithm," in *Nature inspired cooperative strategies for optimization (NICSO 2010)*, ed: Springer, 2010, pp. 65-74.
- [11] Y. Shi, "An optimization algorithm based on brainstorming process," *Emerging Research on Swarm Intelligence and Algorithm Optimization*, pp. 1-35, 2015.
- [12] R. V. Rao, V. J. Savsani, and D. Vakharia, "Teaching-learning-based optimization: a novel method for constrained mechanical design optimization problems," *Computer-Aided Design*, vol. 43, pp. 303-315, 2011.
- [13] L. dos Santos Coelho, H. V. H. Ayala, and V. C. Mariani, "A self-adaptive chaotic differential evolution algorithm using gamma distribution for unconstrained global optimization," *Applied Mathematics and Computation*, vol. 234, pp. 452459, 2014.
- [14] D. H. Wolpert and W. G. Macready, "No free lunch theorems for optimization," *IEEE transactions on evolutionary computation*, vol. 1, pp. 67-82, 1997.
- [15] L. Baruffaldi and M. C. B. Andrade, "Contact pheromones mediate male preference in black widow spiders: avoidance of hungry sexual cannibals?" *Animal Behaviour*, vol. 102, pp. 25-32, 2015.
- [16] E. C. MacLeod and M. C. B. Andrade, "Strong, convergent male mate choice along two preference axes in field populations of black widow spiders," *Animal Behaviour*, vol. 89, pp. 163-169, 2014.
- [17] Peña-Delgado, A. F., Peraza-Vázquez, H., Almazán-Covarrubias, J. H., Torres Cruz, N., García-Vite, P. M., Morales-Cepeda, A. B., & Ramirez-Arredondo, J. M. (2020). A novel bio-inspired algorithm applied to selective harmonic elimination in a three-phase eleven-level inverter. *Mathematical Problems in Engineering*, 2020, 1-10.