

KARŞIT VE YARI-KARŞIT TABANLI ÖĞRENME İLE AKCİĞER PERFORMANSINA DAYALI OPTİMİZASYON

Serdar ÖZYÖN *

Alınma: 20.02.2025; düzeltme: 28.04.2025; kabul: 11.06.2025

Öz: Optimizasyon algoritmalarının sonraki süreçlerde geliştirilmesi ve iyileştirilmesi konusu birçok bilim dalında geniş bir çalışma alanını oluşturmaktadır. Bu algoritmaların ilk tasarımı ele alınamayan ya da değerlendirilemeyen birçok geliştirme metodu daha sonra algoritmalar ile birlikte kullanılarak yeni algoritmalar geliştirilmekte ve daha iyi yakınsama eğrileri ve süreleri elde edilebilmektedir. Bu çalışmada algoritma geliştirme metodlarından biri olan karşıt ve yarı-karşıt tabanlı öğrenme kavramı ele alınmıştır. Bu kavram, rastgele oluşturulan çözümler yerine, onların karşıt konumlarındaki bireyleri dikkate alarak daha hızlı ve kararlı sonuçlara ulaşmayı amaçlamaktadır. Karşıt tabanlı öğrenme kavramının temelinde algoritmanın ilk popülasyonunun yarısı rastgele oluşturulurken diğer yarısının ise karşıt konumlara yerleştirilmesi yatar. Bu işlem yarı-karşıt tabanlı öğrenmede ise rastgele birey ve bu bireyin karşıt konumu arasındaki bir bölgede başka bir birey oluşturularak, bu bireylerin uygunlukları karşılaştırılıp uygunluğu iyi olan bireyin popülasyona katılması şeklinde uygulanır. Bu iyileştirme yapılarının son yıllarda ortaya atılan akciğer performansına dayalı optimizasyon algoritması ile birlikte kullanılmasıyla, klasik algoritma üzerindeki etkileri kıyaslama fonksiyonları üzerinden tartışılmıştır. Önerilen OLPO (Opposite-based LPO) ve QOLPO (Quasi-opposite-based LPO) algoritmalarının performansı, 12 adet CEC 2022 kıyaslama fonksiyonu üzerinde 30 tekrar (run) ve 20 boyut (dimension) kullanılarak değerlendirilmiştir.

Anahtar Kelimeler: Optimizasyon, Meta-sezgisel algoritmalar, Akciğer performansına dayalı optimizasyon, Karşıt ve yarı-karşıt-tabanlı öğrenme.

Lungs performance-based optimization with opposite and quasi-opposite-based learning.

Abstract: Developing and improving optimization algorithms in later processes constitutes a wide field of study in many branches of science. Many development methods that could not be considered or evaluated in the initial design of these algorithms are later used together with the algorithms to develop new algorithms and obtain better convergence curves and times. This study discusses the concept of opposite and quasi-opposite-based learning, which aims to accelerate convergence by evaluating both candidate solutions and their opposite counterparts in the search space. The basis of the opposite-based learning concept is that half of the initial population of the algorithm is randomly generated while the other half is placed in opposing positions. This process is applied in quasi-opposite-based learning by creating another individual in a region between a random individual and the opposite position of this individual, comparing the suitability of these individuals, and adding the individual with better suitability to the population. Using these improvement structures and the lung performance-based optimization algorithm put forward in recent years, their effects on the classical algorithm are discussed through comparison functions. The performance of the proposed OLPO (Opposite-based LPO) and QOLPO (Quasi-opposite-based LPO) algorithms is evaluated on 12 CEC 2022 benchmark functions using 30 runs and 20 dimensions.

Keywords: Optimization, Meta-heuristic algorithms, Lungs performance-based optimization, Opposite and quasi-opposite-based learning.

* Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Elektrik elektronik Mühendisliği Bölümü, KÜTAHYA. İletişim Yazarı: Serdar ÖZYÖN (serdar.ozyon@dpu.edu.tr)

1. GİRİŞ

Optimizasyon, birçok bilim ve mühendislik alanında karmaşık problemlerin çözümünde kritik bir rol oynayan temel yaklaşımlardan biridir. Bunun yanında giderek karmaşıklaşan hesaplama problemleri karşısında, optimizasyon algoritmaları bilimsel araştırmaların ve mühendislik uygulamalarının vazgeçilmez araçları haline gelmiştir. Optimizasyon kavramının anlamı herhangi bir matematiksel fonksiyonunun ya da problemin farklı arama aralıklarındaki değişkenlerde amaca en yakın değerin elde edilmesi olarak tanımlanabilir. Çoğu zaman karmaşık yapıdaki amaç fonksiyonuna ait bu eniyi değerin kabul edilebilir sürelerde nümerik metotlarla elde edilebilmesi zor ya da imkânsız olabilmektedir. Bu amaç fonksiyonlarına ait kabul edilebilir eniyi çözümlerin makul sürelerde elde edilebilmesi için optimizasyon algoritmaları kullanılmaktadır. Bu algoritmalar birçok karmaşık problemin çözümünde başarıyla kullanılmaktadır (Ghasemi vd., 2024).

Literatürde birçok optimizasyon algoritması tasarımı yapılmış ve yapılmaya da devam etmektedir. Her geçen gün ortaya atılan bu optimizasyon algoritmalarındaki amaç problem özelinde daha iyi sonuçlar ve daha kararlı yapılar elde edebilmektir. Her optimizasyon algoritması yapısı gereği farklı amaç fonksiyonlarına sahip problemlerde başarı gösterebilmektedir. Bu çalışmada ele alınan Akciğer performansına dayalı optimizasyon algoritmasında (LPO), Ghasemi ve arkadaşları tarafından, 2024 yılında tasarlanmış ve CEC2005, CEC2014 test fonksiyonları ile çeşitli mühendislik problemleri üzerinde uygulanarak başarılı sonuçlar elde etmiş bir meta-sezgisel algoritmadır.

Bu çalışmanın temel amacı, yakın zamanda literatüre kazandırılan Akciğer Performansına Dayalı Optimizasyon (LPO) algoritmasının performansını artırmaktır. Bu doğrultuda, optimizasyon algoritmalarında yakınsama başarısını artırdığı bilinen karşıt ve yarı-karşıt tabanlı öğrenme yöntemleri LPO algoritmasına entegre edilmiştir. Tasarlanan iki yeni algoritma - OLPO (Opposite-based LPO) ve QOLPO (Quasi-opposite-based LPO) - CEC 2022 kıyaslama fonksiyonları üzerinde değerlendirilmiş, elde edilen sonuçlar klasik LPO ile karşılaştırılarak performans iyileştirmeleri ortaya konmuştur. Bu çalışma, Akciğer Performansına Dayalı Optimizasyon (LPO) algoritmasına ilk defa karşıt ve yarı-karşıt tabanlı öğrenme yapılarının entegre edilmesiyle literatüre katkı sunmaktadır. Önceki çalışmalarda LPO algoritmasının temel uygulamaları bulunmakla birlikte, bu algoritmanın yapısal performansının iyileştirilmesine yönelik bir geliştirme çalışması yapılmamıştır. Bu yönüyle çalışma, hem LPO algoritmasının geliştirilmesi hem de karşıt öğrenme yöntemlerinin yeni bir optimizasyon yapısında kullanımına dair özgün bir yaklaşım önermektedir.

1.1. Literatür Taraması

Çalışmada ele alınan meta-sezgisel algoritma ve algoritmanın geliştirilmesi için kullanılan karşıt ve yarı-karşıt öğrenme yapıları için iki farklı literatür taraması yapılmıştır.

İlk olarak LPO algoritması literatüre kazandırıldığı ana çalışmada test fonksiyonlarına ve çeşitli mühendislik problemlerine başarıyla uygulanmıştır (Ghasemi vd., 2024). Algoritma başka bir çalışmada elektrikli araçların hibrit enerji depolama sistemleri için kontrolör geliştirmede kullanılmıştır (Boyar vd., 2024). LPO'nun son yıllarda tasarlanmış olmasından dolayı hem geliştirilmesi hem de uygulama alanı bakımından literatürde oldukça büyük bir boşluk olduğu görülmektedir.

İkinci olarak bu çalışmada klasik algoritmanın geliştirilmesi için kullanılacak olan karşıt ve yarı-karşıt öğrenme yapıları için arama yapılmıştır. Bu metotların ilk tasarımları ve matematiksel modelleri için iki çalışma verilmiştir (Tizhoosh 2005; Rahnamayan vd., 2007). Ayrıca karşıt öğrenme için geniş bir inceleme makalesi de yayınlanmıştır (Mahdavi vd., 2018).

Bu yapıların birçok optimizasyon algoritmasının geliştirilmesinde de kullanıldığı görülmüştür. Bu algoritmalar yerçekimsel arama algoritması (Temurtaş vd., 2017), diferansiyel gelişim algoritması (Özyön 2020; Xu vd., 2019), jaya algoritması (Nasser vd., 2021), runge-kutta optimizasyonu (Turgut ve Turgut, 2024) sinüs-cosinüs algoritması (Chen vd., 2024) ve açlık oyunları optimizasyon algoritması (Ekinci vd., 2024) olarak sayılabilir. Bu çalışmalarda karşıt ya da yarı-karşıt öğrenme yapıları farklı şekillerde klasik algoritmayla birlikte kullanılarak algoritmanın çözüm hızı, kararlılık ve lokal minimumlardan kaçma özelliklerinde iyileştirilmeler elde edildiği görülmüştür.

2. AKCİĞER PERFORMANSINA DAYALI OPTİMİZASYON ALGORİTMASI (LPO)

Bu bölümde LPO'nun yapısı ve matematiksel modeli ayrıntılı olarak açıklanmıştır. İnsan akciğerlerinin düzenli çalışma esnasında ortaya çıkan birçok fonksiyonunun modellenmesiyle ortaya çıkan algoritma yapısı alt başlıklar halinde verilmiştir.


2.1. LPO tasarımı

Meta-sezgisel algoritmaların birçoğu bir olguyu modellemek ve mevcut meta-sezgisel yöntemlerden daha iyi performans gösteren yeni bir meta-sezgisel geliştirmeyi amaçlamaktadır. Ele alınan gerçek dünya olgusunu tam ve doğru olarak modellemek için bilimsel olarak birçok denkleme hâkim olmak gerekebilir. LPO algoritmasının tasarımına ilham olan akciğerler, çevremizdeki havadaki oksijeni filtrelemekten ve etkili bir şekilde dolaşım sistemine iletmekten sorumlu, insan vücudunda çok önemli bir organdır. Ayrıca vücuttaki gaz değişimi sürecinde karbondioksitin dolaşım sisteminden uzaklaştırılması ve havaya verilmesinden de sorumludur. Algoritmanın temel fikri, solunum sisteminin elektriksel olarak modellenenebilir olması ve akciğer fonksiyonunu değerlendirmek için en yaygın kullanılan yöntem olan zorlu salınım tekniği metoduna dayanmaktadır. Bu teknik, solunum sisteminin girişindeki hava basıncının ve hava akış hızının ölçülmesini içerir ve bu da sistemin elektriksel empedansının hesaplanmasına olanak sağlar. Darbe Osilometri Sistemi (IOS) ölçümlerinden elde edilen empedans eğrileri, karmaşık empedansın hem klinik hem de mühendislik perspektifinden analiz edilebilen gerçek kısmından (solunum direnci: Z_R) ve sanal kısmından (solunum reaktansı: Z_x) oluşur. Bu empedans eğrileri, solunum sistemine özgü dirençleri, uyumlulukları ve eylemsizlikleri taklit eden elektrikli bileşenlerden oluşan modellerle ilişkilendirilirler (Ghasemi vd., 2024). Matematiksel model aşağıdaki gibi özetlenebilir.

Difüzyon yoluyla bir doku tabakasından geçen gazın hacmi Fick yasası ile ifade edilir (Ghasemi vd., 2024).

$$\vec{V} = \frac{AK}{d} \overline{\Delta P} \quad (1)$$

Yukarıdaki denklemde $\overline{\Delta P}$ basınç gradyanı, A kesit alanı, d tabakanın kalınlığı ve K gaz difüzyon katsayısıdır. Solunum sistemi ve akciğerlerin fonksiyonu için birçok model tanıtılmıştır, Şekil 1'de gösterildiği gibi akciğer fonksiyonu basit bir RC elektriksel devresi olarak modellenenebilir. Burada bazı basitleştirmeler yapılmıştır. Birçok meta-sezgisel algoritmanın tasarımında ele alınan olgu birebir modellenemeyebilir.



Şekil 1:

Akciğer fonksiyonunu simüle etmek için kullanılan matematiksel model (Ghasemi vd., 2024)

Ele alınan modelde basınç değişiklikleri aşağıdaki gibi verilmiştir (Ghasemi vd., 2024).

$$\Delta P = V \times \left(\sqrt{R^2 + \left(\frac{1}{2\pi \times fr \times RC} \right)^2} \times \sin(2\pi \times fr \times t) \times \sin(2\pi \times fr \times t + \theta) \right) \quad (2)$$

$$\theta = \tan^{-1} \left(\frac{1}{2\pi \times fr \times RC} \right) \quad (3)$$

Burada; i . parçacık (X_i) damarların içinde alacağı konuma göre hareket etmektedir. Diğer taraftan bu parçacık optimizasyon için ya daha optimal bir konuma doğru ilerleyebilir ya da mevcut konumunda kalabilir. LPO için matematiksel modellemede kullanılan değişkenler Tablo 1’de verilmiştir (Ghasemi vd., 2024).

Tablo 1. Vücuttaki akciğerlerin performansı ve LPO algoritmasındaki eşdeğer kavramları

Akciğerlerdeki eleman veya fonksiyon	Algoritmadaki eşdeğer kavramlar
Hava ve kan kütlesi	Sürüdeki birey sayısı
Karbondioksitin havadan ayrılması ve damarlardaki kan hareketi	Problem aralığı içinde sürünün hareketi
Akciğerlerde daha iyi performans	Amaç fonksiyonu
Nefes alma ve nefes verme	Üretim
Kandan karbondioksitin ayrılması	Sürü bileşenleri ve çaprazlama
Devre teorisine göre modellenmiştir	LPO’da modellenmiştir
R	$f(X)$
C	$f(X) \times 0.5 \times \sin(\theta)$
t	Iter (iterasyon sayısı)
fr	D (boyut)
Değer	Konum

2.2. LPO algoritması

LPO, $i=1,2,\dots, N_{pop}$ olan bir başlangıç sürüsü veya hava kütlesi M_i ile başlayan ve vücudun işlevsel döngüsünde kana girerek yeni bir popülasyon oluşturan bir optimize edicidir. Bu başlangıç popülasyonu, amaç fonksiyonun iki maksimum (M_{max}) ve minimum (M_{min}) değeri arasında rastgele oluşturulur. Bu birincil sürü, kan kütleleri veya parçacıklarıyla aynı rolü oynar (Ghasemi vd., 2024).

2.2.1. Havanın akciğerlere girip çıkması

Akciğerler için RC devre modeli seçilmiştir. Modelleme parametreleri dikkate alınarak, akciğerlere giren hava kütlelerinin konumları Denklem (4)-(8)'ye göre arama alanında konumlandırılmış ve bu konumlar optimizasyon algoritmasının ilk popülasyonunun konumları olmuştur (Ghasemi vd., 2024).

$$M_i^{new,1} = M_i + M_i \times \left(\sqrt{R_i^2 + \left(\frac{1}{2\pi \times fr \times R_i C_i} \right)^2} \times \sin(2\pi \times fr \times t) \times \sin(2\pi \times fr \times t + \theta_i) \right) \quad (4)$$

$$\theta_i = \tan^{-1} \left(\frac{1}{2\pi \times fr \times R_i C_i} \right) \quad (5)$$

$$R_i = f(S_i) \quad (6)$$

$$C_i = \frac{f(S_i)}{2} \times \sin(\theta_i) \quad (7)$$

$$fr = D, \quad t = Iter \quad (8)$$

Yukarıdaki denklemlerde, D problem boyutu, $Iter$ ise algoritmanın mevcut iterasyonudur.

2.2.2. Karbondioksitin havadan ayrılması ve kanın damarlarda hareketi

Akciğerler tarafından havadan ayrıştırılan oksijen kütlesi kana getirilir. Bu kütle M_i , problem uzayındaki popülasyonun hareketine eşdeğerdir. Kana giren oksijenin hareketi Denklem (9)'a göre simüle edilir. Yani kan, üzerine uygulanan basınçla orantılı olarak hareket eder. Daha fazla basınç uygulanan, yani daha iyi bir uygunluk değeri olan taraftan, daha az kuvvet uygulanan tarafa, yani daha zayıf bir uygunluk değerine doğru hareket eder.

$$M_i^{new,2} = M_i^{new,1} + K_{i1} \times \alpha_i \times (M_i^{new,1} - M_1) + K_{23} \times \alpha_i \times (M_3 - M_2) \quad (9)$$

$$K_{ij} = \text{sign}(f(M_j) - f(M_i)) = \begin{cases} f(M_i) < f(M_j) & ise \quad +1 \\ f(M_i) > f(M_j) & ise \quad -1 \\ f(M_i) = f(M_j) & ise \quad 0 \end{cases} \quad (10)$$

Denklem (10)'da K_{ij} , arterler içindeki i . kan kütleinin, yani M_i 'nin hareket yönünü yönetir. Her dolaşım döngüsünde α_i , kayma değerini belirleyen ve daha iyi bir miktara yönelen θ ile I arasında bir sayıdır.

2.2.3. Kandan Karbondioksitin ayrılması

Tablo 1'de gösterildiği gibi, kandan karbondioksitin ayrılması sürü bileşenlerinin çaprazlanması olarak aşağıdaki gibi modellenir (Ghasemi vd., 2024).

$$\begin{aligned}
 & \text{for } j = 1 : D \\
 & \quad \text{if } s_i > rand \\
 & \quad \quad m_{ij}^{new,3} = m_{1j} + \alpha_i \times (m_{3j} - m_{2j}) \\
 & \quad \text{else} \\
 & \quad \quad m_{ij}^{new,3} = m_{ij}^{new,2} \\
 & \quad \text{end} \\
 & \text{end}
 \end{aligned}
 \quad M_i = [m_{i1}, m_{i2}, \dots, m_{ij}, \dots, m_{iD}] \quad (11)$$

Denklemde s_i , kanın akciğerler tarafından saflaştırılması nedeniyle, her nefes verilmesiyle azalan bir olasılık değeridir ve nefes alma ve nefes verme sayısı N_e ile ters ilişkiye sahiptir. Burada; N_e 'nin değeri kullanıcı tarafından belirlenir. Ana makalede N_e için en uygun değerin 8 olduğu belirtilmiştir.

$$s_i = \frac{rand}{N_e} \quad (12)$$


Daha önce belirtildiği gibi, nefes alma ve nefes verme her yineleme sırasında N_e defa gerçekleştirilir. İstenen kütle her bağlantı birleşme yerinde iyileşirse, mevcut konumun yerini alır. Yani, $M_{ij}^{new,3}$ konumu M_i 'den daha iyiye, değiştirilecektir. $M_{ij}^{new,3}$ ikinci nefes alma ve verme işleminden sonra Denklem (13)'de kullanılır. Bu optimizasyon döngüsü, belirlenen iterasyon sayısı kadar devam ettirilerek bu döngü sonunda elde edilen eniyi konum, çözüm olarak kabul edilir (Ghasemi vd., 2024).

$$M_i^{new,1} = M_i + M_{ij}^{new,3} \times \left(\sqrt{R^2 + \left(\frac{1}{2\pi \times fr \times R_i C_i} \right)^2} \times \sin(2\pi \times fr \times t) \times \sin(2\pi \times fr \times t + \theta_i) \right) \quad (13)$$

3. KARŞIT VE YARI-KARŞIT TABANLI ÖĞRENME

Bu bölümde, literatürde birçok çalışmada, klasik meta-sezgisel algoritmaların geliştirilmesi için kullanılan karşıt ve yarı-karşıt tabanlı öğrenme yapılarının matematiksel yapısı açıklanmıştır. Daha önceki bölümlerde de belirtildiği üzere ilk kez tasarımı yapılan birçok optimizasyon algoritması mevcut diğer bir optimizasyon algoritmasından daha iyi performans gösteren yeni bir meta-sezgisel geliştirmeyi amaçlamaktadır. Fakat çoğu kez klasik optimizasyon yapılarında bu iyileştirme kısıtlı düzeyde olmaktadır. Bu nedenle literatürde klasik optimizasyon algoritma yapılarının geliştirilmesi ve iyileştirilmesi için birçok metot önerilmiştir. Bu iyileştirme metotlarından biri de karşıt tabanlı öğrenme yapısının algoritmaya

entegre edilmesidir (Kaur vd., 2025). Karşıt ve yarı-karşıt tabanlı öğrenme kavramlarının temelinde ilk popülasyonda rastgele oluşturulan konumlar yerine, karşıt konumların veya uygunluk değeri daha iyi olan bireylere sahip bir ilk popülasyon ile hesaplamaya başlamak yer almaktadır. Bu düşünce yapısı popülasyonun en iyi çözüme ulaşırken geçirdiği süreci hızlandırabilir düşüncesiyle Tizhoosh tarafından 2005 yılında karşıt konumlu öğrenme kavramı olarak literatüre kazandırılmıştır. Bu yaklaşım şu şekilde tanımlanmaktadır, herhangi rastgele bir sayının karşıt konumlu durumu çözüme rastgele sayıdan daha yakındır (Tizhoosh, 2005; Temurtaş vd., 2017). Bu sebeple, bir sayının karşıt konumlu durumlarıyla birlikte oluşturulan başlangıç popülasyonunun, en iyi çözüme yakınsamak için daha küçük bir arama uzayına ihtiyaç duyacağı söylenmiştir. Bu işlem yakınsama hızını artırmaktadır. Karşıt tabanlı öğrenme kavramı literatürde birçok farklı şekilde optimizasyon algoritmalarının iyileştirilmesi için kullanılmıştır. Bu iyileştirme metodunun temelinde bir sayının tek, iki ve üç boyutlu uzaydaki karşıt konumları dikkate alınması yer almaktadır. Yapılacak arama için karşıt ve yarı-karşıt bölgeler bir boyut, iki boyut ve üç boyutlu aramalar için Şekil 2’de gösterilmiştir (Mahdavi 2018).



Şekil 2:

1D, 2D ve 3D arama alanları için karşıt ve yarı karşıt bölgeler (Mahdavi vd., 2018)

4. KARŞIT VE YARI KARŞIT TABANLI ÖĞRENME İLE AKCİĞER PERFORMANSINA DAYALI OPTİMİZASYON ALGORİTMASI (OLPO, QOLPO)

Klasik LPO algoritması karmaşık bir problemin eniyi çözümünü elde etmek için rastgele bir başlangıç popülasyonu ile hesaplamaya başlar. Birçok klasik optimizasyon algoritmasında olduğu gibi ilk popülasyon tanımlanırken, bireyler çözüm uzayında rastgele konumlarda oluşturulurlar. Bu çalışmada, LPO'nun performansını iyileştirebileceği öngörülerek, klasik algoritma için karşıt ve yarı-karşıt tabanlı öğrenme kavramı önerilmiştir. Önerilen bu yeni

algoritmalar, karşıt ve yarı-karşıt tabanlı akciğer performansına dayalı optimizasyon algoritmaları (Opposite and Quasi Opposite-based Learning Lungs performance-based optimization - OLPO, QOLPO) olarak isimlendirilmiştir. OLPO ve QOLPO algoritmalarının klasik LPO'ya uygulama şekilleri alt başlıklarda açıklanmış ve algoritma üzerindeki etkileri 10 boyutlu CEC 2022 test fonksiyonları ile elde edilen sonuçlar üzerinde tartışılmıştır.

4.1. OLPO

OLPO algoritmasında kullanılan karşıt tabanlı öğrenme yapısı, daha önce literatürde birçok çalışmada tanımlanan “classic opposite-based learning (COBL)” yapısına karşılık gelmektedir. Bu yapıda, bir çözüm uzayında rastgele oluşturulan bir bireyin karşıt konumu aşağıdaki matematiksel ifade ile elde edilir (Mahdavi vd., 2018).

$$\tilde{x}_i = a_i + b_i - x_i \quad (14)$$


Burada x_i , i . boyuttaki mevcut çözüm değerini; a_i ve b_i ise o boyuttaki çözüm uzayının alt ve üst sınırlarını ifade eder. Bu yapı, klasik karşıt konumun, orijinal değerin karşı tarafına simetrik olarak yansıtılması esasına dayanır. Kısaca algoritmanın ilk popülasyonunun oluşturulmasında bireylerin (olası çözüm değerleri) yarısı arama uzayında rastgele atanırken, diğer yarısı bu bireylerin arama uzayındaki karşıt konumlarına yerleştirilmiştir. Bu yaklaşım klasik karşıt tabanlı öğrenme kavramını oluşturmaktadır. Burada amaç arama uzayında karşıt konumlara yerleştirilen bireylerin, tamamen rastgele oluşturulacak bireylerden çözüme daha yakın konumlarda olacağının öngörülmesidir.

4.2. QOLPO

QOLPO algoritması için çalışmada kullanılan yarı-karşıt yapı ise “quasi-opposite-based learning (QOBL)” yapısıdır. Bu yapı aşağıdaki şekilde tanımlanmıştır (Mahdavi vd., 2018).

$$\tilde{x}_i^q = \left(\frac{a_i + b_i}{2} \right) + \left(x_i - \frac{a_i + b_i}{2} \right) \cdot r \quad (15)$$

Denklemden $\tilde{x}_i^q$ i . boyuttaki yarı-karşıt bireyi, $r \in [0,1]$ rastgele seçilen bir skala parametresidir. Bu yapı, klasik karşıt değer ile orijinal değer arasındaki aralıkta yeni bireyler üretmeyi amaçlar ve daha dengeli başlangıç popülasyonları oluşturulmasını sağlar. Bu çalışmada, QOLPO tasarımında $r=0.5$ alınarak, klasik değer ile karşıtı arasında tam ortalama noktaya yakın bireylerin seçilmesi hedeflenmiştir. Bu yapıda, ilk yapıdaki yaklaşımdan yola çıkılarak popülasyon oluşturulurken, bütün bireyler sırayla arama uzayında rastgele yerleştirilir ve bu bireylerin karşıt konumları ile bu konumlar arasında başka bir birey daha oluşturularak, oluşturulan normal ve yarı-karşıt konumdaki bireylerin uygunluk değerleri hesaplanır, daha sonra bu bireylerden uygunluk değeri daha yüksek (çözüme daha yakın) olan birey popülasyona eklenir. Bu işlem popülasyon sayısı tamamlanıncaya kadar devam eder. Bu işlem ile, problemin çözümüne daha yakın yani uygunluk değeri daha yüksek olan bireyler ile arama işlemine başlanarak LPO'nun yakınsama hızının artırılması amaçlanmıştır. Literatürde bu iki yapıdan başka birçok karşıt tabanlı öğrenme yapısı önerilmiştir. Karşıt ve yarı-karşıt öğrenme kavramlarının akış diyagramı Şekil 3'de verilmiştir.



Şekil 3:
OLPO ve QOLPO yapıları

4.3. CEC 2022 Test Fonksiyonları

Bu bölümde, klasik LPO algoritması ve çalışmada önerilen algoritmalar (OLPO, QOLPO) ile literatürde oldukça kompleks yapıda tanımlanmış ve birçok algoritma geliştirme çalışmasında kıyaslama fonksiyonları olarak kullanılmış olan 12 adet CEC 2022 fonksiyonunun çözümü yapılmıştır. Bu fonksiyonlar birçok lokal minimum noktasına sahip, yüksek boyutlu ve geniş arama uzayına sahip fonksiyonlardır. Bu fonksiyonlara ait bilgiler Tablo 2’de verilmiştir (Kumar vd., 2021, He vd., 2024).

Tablo 2. CEC 2022 kıyaslama fonksiyonları

Tip	No	Fonksiyon Adı	Boyut (D)	Aralık	f_{opt}
Unimodal	f_1	Kaydırılmış ve tam döndürülmüş Zakharov F.	20	[-100,100] ^D	300
Temel	f_2	Kaydırılmış ve tam döndürülmüş Rosenbrock’s F.			400
	f_3	Kaydırılmış ve tam döndürülmüş genişletilmiş Schaffer’s f_6 F.			600
	f_4	Kaydırılmış ve tam döndürülmüş sürekli olmayan Rastrigin’s F.			800
	f_5	Kaydırılmış ve tam döndürülmüş Levy F.			900
Hibrit	f_6	Hibrit Fonksiyon 1 (N=3)			1800
	f_7	Hibrit Fonksiyon 2 (N=6)			2000
	f_8	Hibrit Fonksiyon 3 (N=5)			2200
Kompozit	f_9	Kompozit fonksiyon 1 (N=5)			2300
	f_{10}	Kompozit fonksiyon 2 (N=4)			2400
	f_{11}	Kompozit fonksiyon 3 (N=5)			2600
	f_{12}	Kompozit fonksiyon 4 (N=6)			2700

Test fonksiyonlarının çözümü için MATLAB R2021b’de geliştirilen program Intel Xeon E5-2637 v4 3.50 GHz çift işlemcili ve 512 GB RAM bellekli iş istasyonunda koşturulmuştur. Algoritmanın koşturulduğu makine özellikleri yakınsama sürelerinin karşılaştırmaları bakımından önemlidir. Programda kullanılan başlangıç parametre değerleri Tablo 3’de verilmiştir.

Tablo 3. LPO, OLPO ve QOLPO parametre değerleri

<i>İterasyon Sayısı (IteN)</i>	<i>Birey Sayısı (NP_{max})</i>	<i>Fonksiyon Çağırımı (F_{Call})</i>	<i>LPO Kontrol Parametresi (N_e)</i>	<i>Koşturma Sayısı (Run)</i>
10000	100	1x10 ⁶	8	30

Kıyaslama fonksiyonlarının LPO, OLPO ve QOLPO ile 30 kez çözümlerinden elde edilen sonuçlara ait istatistiki değerler Tablo 4’de verilmiştir.











Tablo 4. LPO, OLPO ve QOLPO ile elde edilen sonuçlar (20D-30 Run)











		LPO	OLPO	QOLPO
<i>f₁</i>	En kötü	3,000000000e+02	3,000000000e+02	3,000000000e+02
	Ortalama	3,000000000e+02	3,000000000e+02	3,000000000e+02
	En iyi	3,000000000e+02	3,000000000e+02	3,000000000e+02
	St. sapma	0,000000000e+00	0,000000000e+00	0,000000000e+00
	Süre (sn)	55,8146	56,0021	57,2591
<i>f₂</i>	En kötü	4,490844790e+02	4,490844790e+02	4,490844790e+02
	Ortalama	4,489448453e+02	4,489448453e+02	4,489448453e+02
	En iyi	4,448954693e+02	4,448954693e+02	4,448954693e+02
	St. sapma	7,519502470e-01	7,519502470e-01	7,519502470e-01
	Süre (sn)	46,5556	51,3645	50,1149
<i>f₃</i>	En kötü	6,000000000e+02	6,000000000e+02	6,000000000e+02
	Ortalama	6,000000000e+02	6,000000000e+02	6,000000000e+02
	En iyi	6,000000000e+02	6,000000000e+02	6,000000000e+02
	St. sapma	8,302512735e-14	8,806144584e-14	8,038873388e-14
	Süre (sn)	75,7148	76,2393	62,6034
<i>f₄</i>	En kötü	8,867890335e+02	8,837167352e+02	8,835400720e+02
	Ortalama	8,759363413e+02	8,753642125e+02	8,747829711e+02
	En iyi	8,660105906e+02	8,650602682e+02	8,604751541e+02
	St. Sapma	5,313098885e+00	4,797437275e+00	5,828512774e+00
	Süre (sn)	59,2196	51,0662	53,4266
<i>f₅</i>	En kötü	9,000000000e+02	9,000000000e+02	9,000000000e+02
	Ortalama	9,000000000e+02	9,000000000e+02	9,000000000e+02
	En iyi	9,000000000e+02	9,000000000e+02	9,000000000e+02
	St. Sapma	0,000000000e+00	0,000000000e+00	0,000000000e+00
	Süre (sn)	58,2907	65,1288	65,0136
<i>f₆</i>	En kötü	4,986366800e+05	3,306096444e+05	5,560606287e+05
	Ortalama	8,483814733e+04	6,911738897e+04	7,730749768e+04
	En iyi	2,460856448e+04	6,613402001e+03	2,435598636e+04
	St. sapma	1,103454348e+05	7,384413750e+04	9,571478333e+04
	Süre (sn)	52,9573	49,7821	57,7053


f_7	En kötü	2,037188435e+03	2,036425660e+03	2,033295776e+03
	Ortalama	2,025689721e+03	2,026638915e+03	2,026411887e+03
	En iyi	2,002427440e+03	2,020312460e+03	2,020624575e+03
	St. sapma	6,048062209e+00	4,743065144e+00	3,737943953e+00
	Süre (sn)	95,8607	87,8967	94,7379
f_8	En kötü	2,233353932e+03	2,232986886e+03	2,232216829e+03
	Ortalama	2,230699083e+03	2,230906444e+03	2,230967275e+03
	En iyi	2,226017239e+03	2,228970966e+03	2,229235300e+03
	St. sapma	1,606513529e+00	9,829490061e-01	6,785509212e-01
	Süre (sn)	106,466	106,983	95,8538
f_9	En kötü	2,480781272e+03	2,480781272e+03	2,480781272e+03
	Ortalama	2,480781272e+03	2,480781272e+03	2,480781272e+03
	En iyi	2,480781272e+03	2,480781272e+03	2,480781272e+03
	St. sapma	0,000000000e+00	0,000000000e+00	0,000000000e+00
	Süre (sn)	86,3856	91,2223	95,0149
f_{10}	En kötü	2,500242933e+03	2,500234385e+03	2,500253057e+03
	Ortalama	2,500217429e+03	2,500213994e+03	2,500219318e+03
	En iyi	2,500187724e+03	2,500166087e+03	2,500183522e+03
	St. sapma	1,530349142e-02	1,633656416e-02	1,612318104e-02
	Süre (sn)	78,1603	82,1902	85,4345
f_{11}	En kötü	3,000000000e+03	2,900000000e+03	2,900000000e+03
	Ortalama	2,903333333e+03	2,900000000e+03	2,900000000e+03
	En iyi	2,900000000e+03	2,900000000e+03	2,900000000e+03
	St. sapma	1,795054936e+01	0,000000000e+00	0,000000000e+00
	Süre (sn)	111,708	107,046	90,5372
f_{12}	En kötü	2,942058068e+03	2,942114593e+03	2,943647685e+03
	Ortalama	2,939097169e+03	2,938239091e+03	2,939165293e+03
	En iyi	2,933974301e+03	2,933974301e+03	2,932609435e+03
	St. sapma	2,586608818e+00	2,727043693e+00	3,089706297e+00
	Süre (sn)	101,285	110,084	107,236

12 adet, CEC 2022 kıyaslama fonksiyonunun klasik LPO ve önerilen OLPO ve QLPO algoritmalarıyla çözümünden elde edilen sayısal değerler incelendiğinde, bazı fonksiyonlarda OLPO ve QOLPO ile daha iyi optimum değerlere ulaşıldığı görülmüştür. Bu fonksiyonlardan f_1 , f_2 , f_3 , f_5 ve f_9 'da hem klasik algoritma hem de karşıt tabanlı öğrenme algoritmaları benzer istatistikî değerler elde etmişlerdir. f_7 ve f_{10} fonksiyonlarında klasik LPO, f_6 fonksiyonunda OLPO ve f_4 , f_8 ve f_{12} fonksiyonlarında ise QOLPO yapıları, eniyi değer, standart sapma ve süre bakımından öne çıkmışlardır. Özellikle f_6 fonksiyonunda karşıt tabanlı öğrenme yapısının klasik algoritma yapısı üzerindeki olumlu etki, yerel minimumdan kurtarma yönünde olmuştur. Tablo 4'te sunulan sonuçlar incelendiğinde, yalnızca en iyi sonuçlar değil, aynı zamanda elde edilen ortalama uygunluk değerleri ve standart sapmalar da dikkate alındığında OLPO ve QOLPO algoritmalarının genel performansının klasik LPO algoritmasına göre daha kararlı ve güvenilir olduğu gözlemlenmektedir. Özellikle f_4 , f_6 , f_8 ve f_{12} gibi fonksiyonlarda, QOLPO algoritması hem daha düşük ortalama değerler hem de daha düşük standart sapma ile sonuçlar elde ederek daha tutarlı bir optimizasyon süreci sunmuştur. Bu durum, karşıt ve yarı-karşıt öğrenme yöntemlerinin yalnızca en iyi çözüme ulaşma potansiyelini değil, aynı zamanda çözüm uzayındaki arama süreçlerinin kararlılığını da artırdığını göstermektedir.

Bütün kıyaslama fonksiyonları için 30 çalışmada elde edilen en iyi çözümlere ait, iterasyon sayısına göre yakınsamayı gösteren grafikler ve en iyi değerlerin yayılımını gösteren kutu grafikleri ise bütün fonksiyonlar için toplu halde Şekil 4'de verilmiştir. Bu şekilde, f_1 - f_{12} kıyaslama fonksiyonları için LPO, OLPO ve QOLPO algoritmalarının yakınsama eğrileri (solda) ve kutu grafikleri (sağda) verilmiştir. Yakınsama eğrileri, her algoritmanın iterasyon sayısına göre en iyi çözüm değerlerine ulaşma hızını gösterirken, kutu grafikleri 30 tekrar üzerinden elde edilen çözüm dağılımlarının kararlılığını göstermektedir.







Şekil 4:
 f_1 - f_{12} için en iyi sonuçların elde edildiği yakınsama eğrileri ve kutu grafikleri

Çözümü yapılan fonksiyonlar için verilen grafikler incelendiğinde ise, OLPO ve QOLPO yapılarının klasik LPO algoritmasına hem kararlılık hem de yakınsama hızı bakımından bazı fonksiyonlarda iyileştirme yaptığı görülmektedir. f_6 hibrit fonksiyon yapısında, OLPO algoritmasının klasik LPO algoritması üzerindeki iyileştirme etkisi görülmektedir. LPO ve QOLPO algoritmaları 3500. iterasyondan sonra yakınsamamasına rağmen OLPO algoritması 7500. iterasyona kadar yakınsamaya devam etmiştir. Benzer durumlar f_4 ve f_{10} fonksiyonları için verilen kutu grafiklerinde görülmekte ve daha kararlı yapılar elde edildiği görülmektedir. Özellikle f_4 , f_6 ve f_{12} fonksiyonlarında OLPO ve QOLPO algoritmaları daha hızlı ve istikrarlı bir yakınsama performansı göstermiştir. QOLPO'nun düşük varyanslı kutu grafikleri, çözüm kararlılığının yüksek olduğunu ortaya koymaktadır. f_7 gibi bazı fonksiyonlarda ise LPO daha erken ve hızlı yakınsama eğilimi göstermiştir.

Klasik LPO, OLPO ve QOLPO algoritmalarının CEC 2022 test fonksiyonlara uygulanmasında elde edilen Tablo 4 ve Şekil 4'te verilen bütün sayısal sonuçlar ve grafikler incelendiğinde aşağıdaki değerlendirmeler yapılabilir:

- f_1, f_2, f_3, f_5, f_9 : Tüm algoritmalar benzer başarı göstermiştir; bu fonksiyonların yapısal olarak tek modal ve düşük karmaşıklıkta olması, LPO yapısının doğrudan yeterli olduğunu göstermektedir. OLPO/QOLPO ile belirgin bir fark gözlenmemiştir.

- f_4 : QOLPO algoritması, düşük ortalama değer ve kararlı standart sapma ile en iyi sonucu vermiştir. Yarı-karışt öğrenme sayesinde başlangıçta daha iyi bireylerin seçilmesi bu başarıda etkili olmuştur.

- f_6 : OLPO'nun en iyi sonucu verdiği fonksiyondur. Hibrit fonksiyon yapısı içinde karışt bireylerle daha geniş alanın taranması, yerel minimumlardan kurtulmayı kolaylaştırmıştır.

- f_7 : Klasik LPO algoritması burada daha başarılıdır. Karşıt/yarı-karşıt bireylerin bazı durumlarda arama sürecini zorlaştırabileceği, bu fonksiyonun dar optimum yapısı nedeniyle anlaşılmaktadır.

- f_8 : QOLPO daha düşük standart sapma ve daha iyi ortalama ile daha kararlı sonuçlar vermiştir. Yarı-karşıt yapıların popülasyon çeşitliliğini artırdığı düşünülmektedir.

- f_{10} : OLPO ile daha kararlı ve düşük ortalama sonuçlar elde edilmiştir. Karşıt bireylerin erken aşamalarda etkili pozisyonlara ulaşması bu farkı yaratmıştır.

- f_{11} : Her üç algoritma benzer sonuçlar vermiş, ancak LPO'da daha yüksek standart sapma gözlenmiştir. Bu da karşıt tabanlı yöntemlerin kararlılık sağladığını göstermektedir.

- f_{12} : QOLPO algoritması en düşük ortalama ve en iyi sonucu vermiştir. Bu karmaşık kompozit fonksiyonda yarı-karşıt birey seçimi en etkili yaklaşım olmuştur.

5. TARTIŞMA

Geliştirilen OLPO ve QOLPO algoritmaları, yalnızca kıyaslama fonksiyonları üzerinde değil, gerçek dünya problemlerinde de uygulanabilir potansiyele sahiptir. Özellikle akciğer işlevinden esinlenen LPO yapısının biyomedikal kaynaklı olması, bu algoritmaların sağlık teknolojilerinde kullanımı için güçlü bir zemin oluşturur. Örneğin:

Biyomedikal mühendisliği: Solunum verileriyle çalışan hasta izleme sistemlerinde sinyal optimizasyonu veya parametre ayarlama problemlerinde kullanılabilir.

Makine öğrenmesi/veri bilimi: Özellikle hiperparametre optimizasyonu, sınıflandırıcı parametre ayarı ve model seçimi gibi görevlerde alternatif meta-sezgisel yaklaşımlar olarak değerlendirilebilir.

Enerji sistemleri mühendisliği: Hibrit enerji depolama, yük dengeleme, üretim planlama ve ekonomik güç dağıtımı gibi çok değişkenli mühendislik problemlerinde OLPO/QOLPO'nun daha hızlı yakınsama potansiyeli sayesinde avantaj sağlanabilir.

Endüstriyel tasarım: Çok amaçlı optimizasyon gerektiren otomasyon, üretim planlaması ve yapay zekâ destekli kontrol sistemlerinde kullanılabilir.

Ayrıca, algoritmaların karşıt ve yarı-karşıt öğrenme temelli yapısı nedeniyle, çözüm uzayı geniş ve çok yerel minimum içeren problemlerde daha etkili performans göstereceği düşünülmektedir. Bu bağlamda OLPO ve QOLPO, klasik LPO algoritmasının ötesine geçen uygulama potansiyeline sahiptir.

6. SONUÇ

Meta sezgisel algoritmalar genel olarak tasarımları yapılırken belirli bir evrimsel, fiziksel ya da biyolojik bir olgunun modellenmesini temel alırlar. Bu nedenle tasarımı yapılan her algoritma farklı matematiksel yapılarıdaki problemlerin çözümlerinde daha iyi ya da daha kötü sonuçlar elde edebilir. Tasarlanan bütün klasik algoritmalar zaman içinde iyileştirmeye ve geliştirmeye uğrayabilirler. Bu çalışmada da literatürde çeşitli kıyaslama fonksiyonları için tasarımı yapılan LPO algoritması, karşıt-yarı karşıt tabanlı öğrenme kavramlarıyla birlikte kullanılarak geliştirilmiştir. Bu yeni algoritmalar OLPO ve QOLPO olarak isimlendirilerek, CEC 2022 kıyaslama fonksiyonlarına uygulanarak sayısal sonuçlar karşılaştırılmış ve farklı yapılarıdaki matematiksel fonksiyonlarda iyileştirmeler sağlanmıştır. Ortalama sonuçların değerlendirilmesi, algoritmaların genel başarısını daha sağlıklı biçimde ortaya koymaktadır. Bu

bağlamda, QOLPO algoritması hem istatistiksel olarak daha düşük ortalama değerler hem de daha küçük standart sapmalarla klasik LPO algoritmasına kıyasla daha istikrarlı bir performans göstermiştir. Yapılacak sonraki çalışmalarda burada oluşturulan yeni algoritmalar farklı bilim alanlarında yer alan optimizasyon fonksiyonlarının çözümüne uygulanarak, bu algoritmaların farklı optimizasyon problemleri üzerindeki etkileri de incelenebilir. Bunun yanında geliştirilen OLPO ve QOLPO algoritmaları, yalnızca teorik kıyaslama fonksiyonlarında değil, gerçek dünya problemlerinde de yüksek potansiyele sahiptir. Özellikle tıbbi cihaz teknolojilerinde (örneğin solunum cihazı optimizasyonu, biyomedikal veri analizi), giyilebilir sistemlerde (örn. solunum izleme sistemleri), enerji verimliliği optimizasyonu (örneğin hibrit enerji depolama sistemleri, akıllı şebekeler) gibi çok değişkenli ve karmaşık problemlerde uygulama alanı bulabilir. Gelecek çalışmalar için ise, geliştirilen algoritmaların daha farklı optimizasyon problemlerinde (çok amaçlı optimizasyon, zamanla değişken ortamlar gibi) performanslarının araştırılması ve algoritma parametrelerinin adaptif şekilde ayarlanabileceği hibrit modellerin geliştirilmesi önerilmektedir.

ÇIKAR ÇATIŞMASI

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

YAZAR KATKISI

Serdar ÖZYÖN, Araştırmanın kavram ve/veya tasarım sürecinin belirlenmesi, veri toplanması, verilerin analizi ve sonuçların yorumlanması, makalenin hazırlanması, fikri içeriğin eleştirel analizi, nihai onay ve tüm sorumluluğun üstlenilmesi.

TEŞEKKÜR

Kütahya Dumlupınar Üniversitesi, Akıllı Sistemler Tasarımı Uygulama ve Araştırma Merkezi (ASTAM)’a bu çalışma için gerekli bazı temel araştırma olanaklarını sağladığı için teşekkür ederim.

KAYNAKLAR

1. Basu, M. (2016). Quasi-oppositional differential evolution for optimal reactive power dispatch. *International Journal of Electrical Power & Energy Systems*, 78, 29-40. doi:10.1016/j.ijepes.2015.11.067
2. Boyar, A., Kabalcı, Y., & Kabalcı, E. (2024). Elektrikli araçların hibrit enerji depolama sistemleri için akciğer performansına dayalı optimizasyon algoritması temelli kontrolör geliştirilmesi. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 13(3), 948-955. doi:/10.28948/ngumuh.1449613
3. Chen, L., Ma, L., & Li, L. (2024). Enhancing sine cosine algorithm based on social learning and elite opposition-based learning. *Computing*, 106(5), 1475–1517. doi:10.1007/S00607-024-01256-3
4. Ekinci, S., Izci, D., Eker, E., Abualigah, L., Thanh, C.L., & Khatir, S. (2024). Hunger games pattern search with elite opposite-based solution for solving complex engineering design problems. *Evolving Systems*, 15(3), 939-964. doi:10.1007/s12530-023-09526-9
5. Ghasemi, M., Zare, M., Zahedi, A., Trojovský, P., Abualigah, L., & Trojovská, E. (2024). Optimization based on the performance of lungs in the body: Lungs performance-based optimization (LPO). *Computer Methods in Applied Mechanics and Engineering*, 419, 116582. doi:10.1016/J.CMA.2023.116582

6. He, K., Zhang, Y., Wang, Y., & Zhou, R. (2024). Solving power system economic emission dispatch problem under complex constraints via dimension differential learn butterfly optimization algorithm with FDC-based. *Computers & Industrial Engineering*, 197, 110568. doi:10.1016/j.cie.2024.110568
7. Kaur, A., Singh, M. & Dhillon, J.S. (2025). Oppositionally driven crisscross gravitational search approach for economic load dispatch. *Electrical Engineering*. doi:10.1007/s00202-024-02905-8
8. Kumar, A., Price, K. V., Mohamed, A. W., & Hadi, A. A. (2021). Problem definitions and evaluation criteria for the CEC 2022 special session and competition on single objective bound constrained numerical optimization. In IEEE congress on evolutionary computation: Tech. rep, Italy: Centro Congressi Padova. doi:10.13140/RG.2.2.32347.85284
9. Mahdavi, S., Rahnamayan, S., & Deb, K. (2018). Opposition based learning: A literature review. *Swarm and Evolutionary Computation*, 39, 1–23. doi:10.1016/j.swevo.2017.09.010
10. Nasser, A.B., Zamli, K.Z., Hujainah, F., Ghanem, W.A.H., Saad, A.M.H., & Alduais, N.A.M. (2021). An adaptive opposition-based learning selection: The case for Jaya algorithm. *IEEE Access*, 9, 55581-55594. doi:10.1109/ACCESS.2021.3055367
11. Özyön, S. (2020). Opposite-based learning differential evolution algorithm for optimal active power dispatch. *Uludağ University Journal of The Faculty of Engineering*, 25(1), 231-246. doi:10.17482/uumfd.635957
12. Rahnamayan, S., Tizhoosh, H.R., & Salama, M.M. (2007). Quasi-oppositional differential evolution. In 2007 IEEE congress on evolutionary computation (pp. 2229-2236). IEEE. doi:10.1109/CEC.2007.4424748
13. Temurtaş, H., Yaşar, C., & Özyön, S. (2017). Nümerik fonksiyonların optimizasyonu için karşıt tabanlı yeni bir meta-sezgisel algoritma. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 17(3), 922-937. doi:10.5578/fmbd.66295
14. Tizhoosh, H.R. (2005). Opposition-based learning: a new scheme for machine intelligence. In International conference on computational intelligence for modelling, control and automation and international conference on intelligent agents, web technologies and internet commerce (CIMCA-IAWTIC'06) (Vol. 1, pp. 695-701). IEEE. doi:10.1109/CIMCA.2005.1631345
15. Turgut, O.E., & Turgut, M.S. (2024). Quasi-dynamic opposite learning enhanced Runge-Kutta optimizer for solving complex optimization problems. *Evolutionary Intelligence*, 17(4), 2899–2962. doi:10.1007/S12065-024-00919-6
16. Xu, Q., Wang, N., Zou, F., & Yang, J. (2019). Exploring the reasons behind the good performance of opposition-based learning. *IEEE Access*, 7, 7259-7272. doi:10.1109/ACCESS.2018.2890402

