

OPTİMAL AKTİF GÜÇ DAĞITIMI İÇİN KARŞIT ÖĞRENME TABANLI DİFERANSİYEL GELİŞİM ALGORİTMASI

Serdar ÖZYÖN *

Alınma: 22.10.2019; düzeltme: 14.01.2020; kabul: 09.03.2020

Öz: Elektrik enerji üretim sistemlerinin optimal işletimi problemi, içerdiği kısıtlar bakımından nümerik yöntemler ile çözümü zor bir problemdir. Bu tür problemlerin daha kısa sürelerde kabul edilebilir çözümlerinin elde edilebilmesi için çeşitli optimizasyon algoritmaları sıklıkla kullanılmaktadır. Son yıllarda bu tür algoritmaların, daha kararlı ve daha iyi çözümler elde edebilmek üzere geliştirilmesi oldukça yaygındır. Bu çalışmada daha önce birçok problemin çözümüne başarıyla uygulanmış diferansiyel gelişim algoritmasına (DE), karşıt tabanlı öğrenme kavramı iki farklı şekilde entegre edilmiştir. Geliştirilen algoritmaların performanslarının ve kararlılıklarının test edilmesi için iki farklı problem çözümü yapılmıştır. Bu problemlerden ilki altı adet multimodal test fonksiyonunun optimizasyonu, ikincisi ise optimal güç dağıtımı probleminin çözümüdür. Problem çözümü için IEEE 30 baralı 6 generatörlü sistem örnek olarak seçilmiştir. İletim hattı kayıpları Newton Raphson metodu ile AC yük akışı yapılarak hesaplanmıştır. Son olarak her iki problemin çözümlerinden elde edilen değerler ile algoritmaların performansları karşılaştırılmış ve karşıt tabanlı öğrenme kavramının optimizasyon algoritmaları üzerine etkileri tartışılmıştır.

Anahtar Kelimeler: Optimal Aktif Güç Dağıtımı, AC Yük Akışı, Karşıt Tabanlı Öğrenme, Diferansiyel Gelişim Algoritması.

Opposite-Based Learning Differential Evolution Algorithm for Optimal Active Power Dispatch

Abstract: The optimum operation problem of electrical energy generation systems is a difficult problem to solve with numeric methods in terms of the constraints it includes. Various optimization algorithms are frequently used in order to be able to obtain the acceptable solutions of these kinds of problems in short times. In recent years it is very common to improve these kinds of algorithms in order to be able to obtain more decisive and better solutions. In this study Opposite-based learning concept has been integrated into Differential Evolution Algorithm, which was applied to the solution of many problems successfully before, in two different ways. Two different problem solutions have been done in order to test the performances and the decisiveness of the developed algorithms. The first of these problems is the optimization of six multimodal test functions, and the second is the solution of the optimum power dispatch problem. IEEE 30 bus 6 generator system has been selected as the sample for the solution of the problem. The calculation of transmission line losses have been done by doing AC load flow with Newton Raphson method. Finally, the values obtained from the solutions of the two problems have been compared with the performances of the algorithms and the effects of the opposite-based learning concept on the optimization algorithms have been discussed.

Keywords: Optimum Active Power Dispatch, AC Load Flow, Opposite-based Learning, Differential Evolution Algorithm

* Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği, 43100, KÜTAHYA.
İletişim Yazarı: Serdar Özyön (serdar.ozyon@dpu.edu.tr)

1. GİRİŞ

Günümüzde ülkelerin gelişmişlikleri yaptıkları üretimle, dolayısıyla harcadıkları enerjiyle yakından ilişkilidir. Harcanan bu enerjinin, giderek artan üretim maliyetlerinden dolayı, en ucuz ve kararlı bir şekilde üretilmesi oldukça önemlidir. Bu işlem elektrik mühendislerini üretim birimlerinin optimal işletimi problemi ile karşı karşıya getirmiştir. Bu problemin temelini sistem tarafından talep edilen gücün, en ucuz ve en az kayıp ile elde edilebilmesi için sistemdeki üretim birimlerinin işletimi oluşturmaktadır. Bu işletim sırasında, üretimin devamlılığı için çeşitli kısıtların göz önüne alınması gereklidir. Bu kısıtlar genellikle güç-denge kısıtı, üretim birimlerinin minimum-maksimum üretim limitleri ve iletim hattı kayıplarıdır. Optimal aktif güç dağıtım problemi içerdiği kısıtlar bakımından kompleks bir problem olarak tanımlanır. Sistem tarafından talep edilen gücün sıklıkla değişebilmesinden dolayı, problemin kabul edilebilir bir çözümünün en kısa sürede yapılması gerekmektedir. Bu aşamada optimizasyon algoritmalarının kullanımı önemli olmaktadır (Wood ve diğ. 2013; Kothari ve diğ. 2007).

Optimizasyon algoritmaları literatürde çözümü zor ya da uzun süreler alan gerçek dünya problemlerinin çözümünde başarıyla kullanılmaktadır. Bu çalışmada ele alınan optimal güç dağıtım problemi literatürde birçok farklı algoritma ile başarıyla çözülmüştür. Bu algoritmalar genetik algoritma (GA) (Osman ve diğ. 2004), diferansiyel gelişim algoritması (DE) (Abou ve diğ. 2010; Özyön ve diğ. 2011), parçacık sürü optimizasyonu (PSO) (Abido, 2002), harmoni arama algoritması (HA) (Özyön ve diğ. 2011) ve yapay arı koloni optimizasyon algoritması (ABC) (Dinh ve diğ. 2013; Xuanhu ve diğ. 2015) şeklinde sayılabilir.

Kısıt sayısı fazla, daha karmaşık ve yüksek boyutlu problemlerin çözümleri için optimizasyon algoritmalarının çeşitli metotlar ile iyileştirilmesi ve geliştirilmesi ihtiyacı doğmuştur. Algoritmaya karşıt tabanlı öğrenme yapısının entegre edilmesi, algoritmalarının kaotik haritalama yöntemleriyle birlikte kullanılması, artırılmış sosyal öğrenme yapısının algoritmaya eklenmesi ve algoritma parametrelerinin optimizasyonu gibi yaklaşımlar algoritmaları iyileştirmek üzere literatürde sıklıkla kullanılmaktadır (Tizhoosh, 2005; Nouhi ve diğ. 2013; Montes de Oca ve diğ. 2008; Mohamed ve diğ. 2013).

Bu çalışmada literatürde başka algoritmalarla başarıyla uygulanmış karşıt tabanlı öğrenme kavramı DE'ye iki farklı şekilde entegre edilmiştir. Oluşturulan bu yeni yaklaşımlara karşıt öğrenme tabanlı diferansiyel gelişim algoritması (OblDE) adı verilmiştir. DE ve OblDE algoritmaları ilk olarak altı adet multimodal test fonksiyonuna uygulanarak analiz edilmiş daha sonra da optimal aktif güç dağıtım probleminin çözümü bu algoritmalar ile başarıyla yapılmıştır. Çalışmada hem yeni geliştirilen algoritma performansları karşılaştırılmış hem de karmaşık gerçek dünya mühendislik problemlerine örnek bir problem çözümü yapılarak literatüre katkı amaçlanmıştır. Çalışmanın bu bölümünde algoritma ve problem ile ilgili genel bilgiler anlatılmıştır. İkinci bölümde AC yük akışı analizi ve optimal aktif güç dağıtım probleminin tanım ve denklemleri verilmiştir. Üçüncü bölümde karşıt öğrenme tabanlı diferansiyel gelişim algoritmasının yapısı ve akış diyagramı verilmiş ve denklemleri tanımlanmıştır. Dördüncü bölümde iki adet sayısal örnek tanımlanmış ve çözümleri verilerek, sonuç bölümünde çalışma kısaca özetlenerek elde edilen sonuçlar tartışılmıştır.

2. AC YÜK AKIŞI ANALİZİ VE OPTİMAL AKTİF GÜÇ DAĞITIMI

2.1. AC Yük Akışı Analizi

Yük akışı çalışmaları, mevcut güç sistemlerinin en iyi çalışma şeklinin belirlenmesi ve güç sistemindeki her bir baranın gerilim genliğinin ve faz açısının hesaplanmasıdır. Baralar ile ilgili bu bilgiler hesaplandıktan sonra sistemdeki iletim hatlarında meydana gelen aktif ve reaktif güç akışları ile kayıplar hesaplanabilir. Güç akışı yapılmasındaki amaç sistemde, salınım barası olarak belirlenen bara dışındaki tüm baraların aktif ve reaktif güçlerinin belirlenmesidir. Ele alınan sistem içinde eğer gerilim kontrollü bara mevcutsa, bu bara için de sabit tutulacak bara gerilim

genliği belirlenir. Bu baradaki reaktif güç üretimi ve bara gerilim açısı çözümden elde edilir (Kurban ve diğ. 2007; Rossoni ve diğ. 2016; Yaşar ve diğ. 2017).

Sistemde yer alan bir k barasının geriliminin kutupsal koordinatlardaki ifadesi denklem (1)'de verilmiştir.

$$V_k = |V_k| \angle \delta_k = |V_k| (\cos \delta_k + j \sin \delta_k) \quad (1)$$

Y_{kn} bara matrisinin kutupsal koordinatlardaki ifadesi denklem (2)'deki gibi yazılır.

$$Y_{kn} = |Y_{kn}| \angle \theta_{kn} = |Y_{kn}| \cos \theta_{kn} + j |Y_{kn}| \sin \theta_{kn} = G_{kn} + jB_{kn} \quad (2)$$

Y_{bara} matrisi kullanılarak sistemdeki her bir k barası için enjekte edilen net akımlar aşağıdaki gibi yazılır.

$$I_k = Y_{k1}V_1 + Y_{k2}V_2 + \dots + Y_{kN}V_N = \sum_{n=1}^N Y_{kn}V_n \quad (3)$$

P_k ve Q_k , k barasından sisteme giren net aktif ve reaktif gücü gösterirken, k barasından sisteme enjekte edilen net aktif ve net reaktif güçler denklem (4) ve (5)'ten hesaplanır.

$$P_k = |V_k| \sum_{n=1}^N |V_n| (G_{kn} \cos \delta_{kn} + B_{kn} \sin \delta_{kn}) \quad (4)$$

$$Q_k = |V_k| \sum_{n=1}^N |V_n| (G_{kn} \sin \delta_{kn} - B_{kn} \cos \delta_{kn}) \quad (5)$$

Denklem (4) ve (5)'teki P_k ve Q_k durum değişkenleri, $|V_k|$ ve δ_k 'nin lineer olmayan fonksiyonlarıdır. Bu nedenle, güç akışı hesaplamaları lineer olmayan denklem sistemleri için iteratif çözüm yöntemlerinin kullanılmasını gerektirir. Dolayısıyla çalışmada Newton-Raphson metodunun kullanılması tercih edilmiştir. Newton-Raphson metodu güç akışı problemlerinin kutupsal formunu, her baradaki aktif ve reaktif güç farkları belli bir tolerans içinde kalana kadar çözümlemede kullanılır. Yöntemde düğüm gerilimleri yöntemi esas alınır.

AC yük akışı analizinde her k barası için potansiyel olarak bilinmeyen değerler aktif güç P_k , reaktif güç Q_k , gerilim açısı δ_k ve gerilim genliği $|V_k|$ 'dir. Her k barasının türüne göre P_k , Q_k , δ_k ve $|V_k|$ değerlerinden ikisi tanımlanır ve geri kalan diğer ikisi hesaplanır. Güç akışı problemlerinin çözümünde amaç, P_k ve Q_k değerleri ile hesaplanmış değerler arasındaki fark sıfıra yaklaştırılırken bilinmeyen iki değer bulunmasıdır (Kurban ve diğ. 2007; Rossoni ve diğ. 2016; Yaşar ve diğ. 2017).

Bara gerilim büyüklükleri $|V_k|$ ve açıları δ_k güç akışı çalışmalarında giriş bilinmeyenleridir, sahip oldukları değerlere göre sistemin durumlarını belirledikleri için durum ya da matematiksel açıdan bakılırsa bağımsız değişkenlerdir. Bu durumda güç akışı problemi, giriş verilerini esas alarak eşit miktarda güç akışı denklemi kullanarak tüm durum değişkenlerinin değerlerinin bulunması olarak da tanımlanabilir. Eğer N_g tane gerilim kontrollü bara (salınım barası dışında) varsa $(2N - N_g - 2)$ adet durum değişkeni için çözülmesi gereken $(2N - N_g - 2)$ adet denklem bulunmaktadır. Durum değişkenlerinin değerleri hesaplandıktan sonra sistemin tüm durumu bilinmektedir ve durum değişkenlerine bağlı tüm değerler hesaplanabilir.

Sistemde yer alan k . barayı n . baraya bağlayan iletim hattındaki aktif güç (P_{kn}), reaktif güç (Q_{kn}), baraların gerilim genlikleri ($|V_k|$, $|V_n|$) ve bara açılarının (δ_k , δ_n), Newton-Raphson yöntemi sonucunda elde edilen değerleri denklem (6) ve (7)'de yer alan formüllerle hesaplanır (Kurban ve diğ. 2007; Rossoni ve diğ. 2016; Yaşar ve diğ. 2017).

$$P_{kn} = G_{kn} |V_k|^2 - |V_k| |V_n| (G_{kn} \cos \delta_{kn} + B_{kn} \sin \delta_{kn}) \quad (6)$$

$$Q_{kn} = |V_k|^2 \left(\frac{B_{kn}}{2} - B_{kn} \right) + |V_k| |V_n| (B_{kn} \cos \delta_{kn} - G_{kn} \sin \delta_{kn}) \quad (7)$$

Burada P_{kn} ve Q_{kn} , n . baraya k . baradan gönderilen sırasıyla aktif ve reaktif güçlerin k . bara sınırındaki değerleridir.

2.2. Optimal Aktif Güç Dağıtımı

Çalışmada sistemdeki üretim birimlerinin konveks yakıt maliyeti fonksiyonu, her bir birim için aktif güç üretiminin 2. derece fonksiyonu olarak alınmıştır (Wood ve diğ. 2013; Özyön ve diğ. 2012).

$$F_n(P_{G,n}) = a_n + b_n P_{G,n} + c_n P_{G,n}^2, \quad (\$/h) \quad (8)$$

Denklem (1)'de ($P_{G,n}$)'in birimi MW olarak alınmaktadır. Amaç fonksiyonu olarak bilinen sistemdeki toplam yakıt maliyeti $F_T(P_{G,n})$ denklem (9) kullanılarak hesaplanmaktadır. Ekonomik güç dağıtım problemi çözümünü, sistem kısıtları altında amaç fonksiyonunun minimize edilmesi şeklinde bulunur.

$$F_T(P_{G,n}) = \sum_{n \in N_G} F_n(P_{G,n}), \quad (\$/h) \quad (9)$$

Kayıplı bir enerji sistemindeki güç denge kısıtı denklem (10)'daki gibi alınmıştır.

$$\sum_{n \in N_G} P_{G,n} - P_{yük} - P_{kayıp} = 0 \quad (10)$$

Termik üretim birimlerinin çalışma sınır değerleri ise denklem (11)'de verilmiştir.

$$P_{G,n}^{\min} \leq P_{G,n} \leq P_{G,n}^{\max}, \quad (n \in N_G) \quad (11)$$

Sistemin iletim hatlarında meydana gelen güç kayıpları ($P_{kayıp}$) ikinci bölümde anlatılan yük akışı analizi sonucunda hesaplanmaktadır (Wood ve diğ. 2013; Özyön ve diğ. 2012).

3. KARŞIT ÖĞRENME TABANLI DİFERANSİYEL GELİŞİM ALGORİTMASI

Genetik algoritma tabanlı ve popülasyon temelli bir optimizasyon tekniği olan DE, ilk kez 1995 yılında Price ve Storn tarafından önerilmiştir. Algoritmanın temelinde, her biri içinde bir çözüm barındıran kromozomların, tek tek operatörlere tabi tutularak yeni bir çözüm elde edilmesi yatmaktadır. Bu işlemler sırasında mutasyon ve çaprazlama operatörleri kullanılmaktadır. Yeni bireyin uygunluğu yani çözüme olan yakınlığı, eskisinden daha iyi ise yeni birey, değilse eski birey bir sonraki popülasyona aktarılır. DE'de kullanılan temel algoritma parametreleri, popülasyonun büyüklüğü (NP), değişken sayısı (D), maksimum iterasyon sayısı (g_{max}), çaprazlama oranı (CR) ve ölçekleme faktörü (F)'dir. Algoritmanın işlem basamakları değişken ataması ve başlangıç popülasyonunun oluşturulması, bireylerin uygunluklarının hesaplanması, seçim, mutasyon, çaprazlama ve algoritmanın durdurulması olarak belirtilebilir. DE'de yeni bir birey üretebilmek için en az üç kromozom gereklidir. Bu sebeple belirlenen popülasyon

büyükliğünün üçten büyük olması gerekir ($NP > 3$). Başlangıç popülasyonunun denklem (12)'ye göre oluşturulur (Abou ve diğ. 2010; Özyön ve diğ. 2011; Storn ve diğ. 1997; Makas ve diğ. 2016).

$$x_{ji,g=0} = x_j^{(l)} + rand_j[0,1].(x_j^{(u)} - x_j^{(l)}) \quad (12)$$

Denklemden yer alan $x_{ji,g}$, g . iterasyonda i . kromozomun j . boyuttaki değerini, $(x_j^{(l)}, x_j^{(u)})$ ise değişkenlere ait alt ve üst sınırları göstermektedir (Abou ve diğ. 2010; Özyön ve diğ. 2011; Storn ve diğ. 1997; Makas ve diğ. 2016).

Popülasyon oluşturulduktan sonra mutasyon işlemine geçilir. Mutasyon, seçilen kromozomun genleri üzerinde rastgele değişiklikler yapmaktır. DE'de mutasyon operatörü için, farklı üç kromozom belirlenir (r_1, r_2, r_3). İlk ikisinin farkı alınarak, belirlenen F katsayısı ile çarpılır. F katsayısı genellikle 0-2 arasında bir değer alınmaktadır. Ağırlıklandırılmış fark kromozomu ile üçüncü kromozom toplanır. Literatürde DE için farklı birçok mutasyon metodu kullanılmaktadır (Özyön, 2019). Bu çalışmada kullanılan mutasyon işlemi ($DE/rand/1/bin$) ise klasik DE'de ilk kullanıldığı şeklindedir ve denklem (13)'de gösterilmiştir. (Abou ve diğ. 2010; Özyön ve diğ. 2011; Storn ve diğ. 1997; Makas ve diğ. 2016).

$$n_{ji,g+1} = x_{jr_3,g} + F.(x_{jr_1,g} - x_{jr_2,g}) \quad (13)$$

Denklemden $n_{ji,g+1}$ mutasyon ve çaprazlaştırmaya tabi tutulmuş ara kromozom, r_1, r_2, r_3 yeni kromozom üretilmesinde kullanılacak rastgele seçilmiş kromozomları $r_{1,2,3} \in \{1, 2, 3, \dots, NP\}$, $r_1 \neq r_2 \neq r_3 \neq i$ göstermektedir.

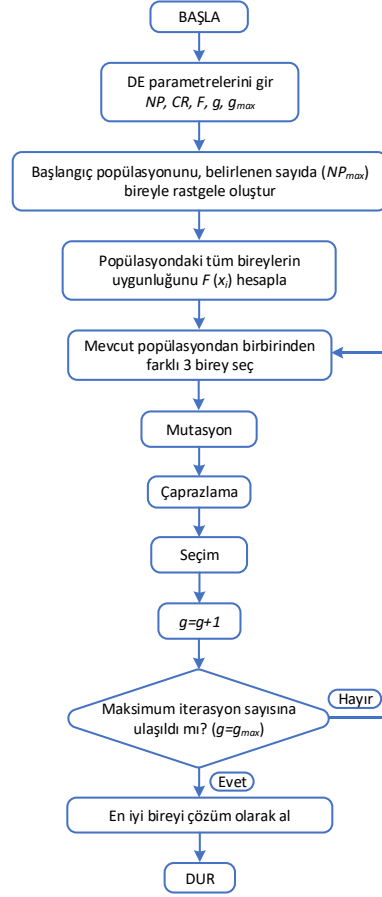
Mutasyon operatörünün uygulanması ile bulunan fark kromozomu ve $x_{i,g}$ kromozomu kullanılarak yeni bir kromozom ($u_{i,g+1}$) bulunur. Aday kromozomu için genler belirlenen CR olasılıkla fark kromozomundan, $(1-CR)$ olasılıkla o andaki kromozomdan seçilir. $j=j_{rand}$ koşulu, en az bir tane genin üretilen yeni kromozomdan alınmasını garanti etmek için kullanılmaktadır. Rastgele seçilen $j=j_{rand}$ noktasındaki bir gen, CR değerine bakılmaksızın $n_{ji,g+1}$ 'den seçilir (Abou ve diğ. 2010; Özyön ve diğ. 2011; Storn ve diğ. 1997; Makas ve diğ. 2016).

$$u_{ji,g+1} = \begin{cases} n_{ji,g+1} & \text{eğer } rand[0,1] \leq CR \text{ veya } j = j_{rand} \\ x_{ji,g} & \text{diğer durumlarda} \end{cases} \quad (14)$$

Mutasyon ve çaprazlama işlemleri kullanılarak hedeflenen kromozomla birlikte üç kromozom kullanılarak farklı bir kromozom elde edilmiştir. Sonraki popülasyona ($g=g+1$) aktarılacak kromozom uygunluk değerine bakılarak belirlenir. Problemin amaç fonksiyonu değeri uygunluk fonksiyonu olarak hesaplanır. Kromozomlardan uygunluğu yüksek olan kromozom yeni popülasyona aktarılır. Bu işlemler belirlenen maksimum iterasyon ($g=g_{max}$) sayısı tamamlanana kadar devam eder. Maksimum iterasyon sayısı tamamlandığında son popülasyondaki en iyi birey çözüm olarak belirlenir (Abou ve diğ. 2010; Özyön ve diğ. 2011; Storn ve diğ. 1997; Makas ve diğ. 2016).

$$x_{i,g+1} = \begin{cases} u_{i,g+1} & \text{eğer } f(u_{i,g+1}) \leq f(x_{i,g}) \\ x_{i,g} & \text{diğer durumlarda} \end{cases} \quad (15)$$

Algoritmada yapılan bütün bu işlemlerin amacı, her iterasyonda daha iyi uygunluk değerine sahip bireyler elde etmek ve optimum çözüm değerini yakalamak veya bu değere yaklaşımdır. Bu döngü belirlenen iterasyon sayısı tamamlanıncaya kadar devam eder. DE'ye ait akış diyagramı Şekil 1'de verilmiştir (Abou ve diğ. 2010; Özyön ve diğ. 2011; Storn ve diğ. 1997; Makas ve diğ. 2016).



Şekil 1:
DE'nin akış diyagramı (Özyön ve diğ. 2011)

Meta-sezgisel algoritmaların genelinde olduğu gibi DE algoritması da problemin çözümünü bulmak üzere bir başlangıç popülasyonu ile hesaplamaya başlar. Başlangıç popülasyonu oluşturulurken çözüm uzayında bireyler rastgele konumlandırılırlar. Tizhoosh tarafından 2005 yılında ortaya atılan karşıt konumlu öğrenme kavramına göre rastgele konumlandırma yerine, uygunluk değeri daha yüksek olan bireylerle ilk popülasyon oluşturulursa, en iyi çözüme ulaşma işlemi hızlandırılabilir. Bu yaklaşım kısaca şu şekilde tanımlanabilir, rastgele bir sayının karşıt konum durumu çözüme, yeniden oluşturulacak rastgele başka bir sayıdan daha yakındır. Bu nedenle, bir sayının karşıt değeriyle birlikte oluşturulan başlangıç popülasyonu, çözüme yakınsamak için daha küçük bir aramaya ihtiyaç duyacağı söylenebilir. Bu yakınsamayı hızlandırır. Karşıt öğrenme kavramı; karşıt konumlu sayı, nokta ve optimizasyon olarak geliştirilebilir (Tizhoosh, 2005; Temurtaş ve diğ. 2017).

Bu çalışmada DE'nin performansını da iyileştirebileceği öngörülerek iki farklı karşıt konumlu öğrenme kavramı, algoritmaya entegre edilmiştir. Bu iki farklı şekilde uygulanan karşıt konumlu öğrenme kavramı ile karşıt öğrenme tabanlı diferansiyel gelişim algoritmaları (Opposite-based Learning Differential Evolution Algorithm - ObLDE) elde edilmiştir. Bunlara ObLDE-1 ve ObLDE-2 adı verilmiş ve iki farklı durum alt başlığında incelenmiştir.

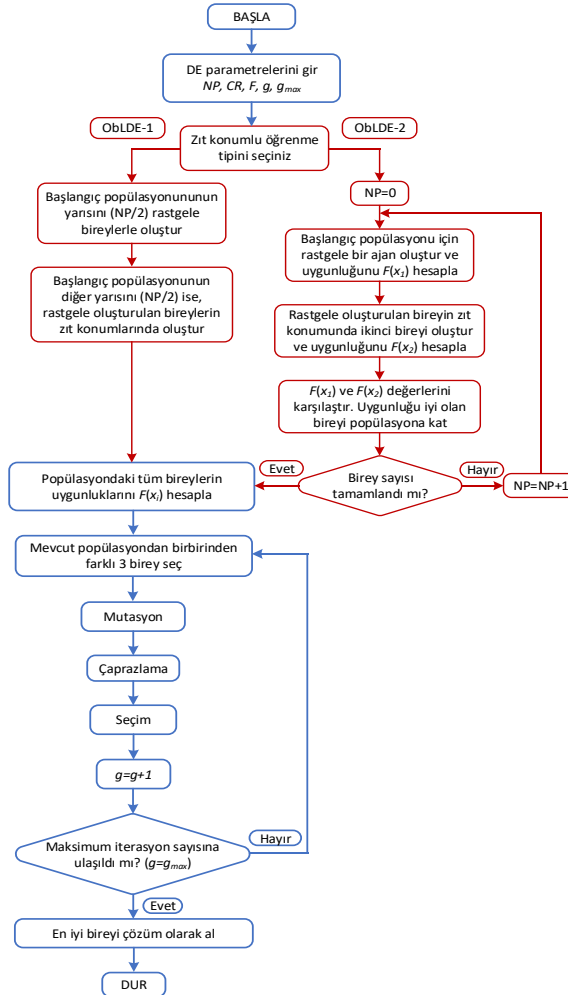
3.1. Yaklaşım-1 (OblLDE-1)

İlk yaklaşımda (OblLDE-1), ilk popülasyonunun oluşturulmasında bireylerin yarısı değişkenlerin maksimum ve minimum değerleri arasında rastgele atanırken, diğer yarısı bu bireylerin karşıt konumunda oluşturulması temeline dayanır (Temurtaş ve diğ. 2017).

3.2. Yaklaşım-2 (OblLDE-2)

Bu yaklaşımda (OblLDE-2) ise ilk popülasyonda, bütün bireyler rastgele oluşturulmuş ve oluşturulan bütün bireylerin karşıt konumları belirlenmiş ve bütün bireylerin uygunluk değerleri hesaplanmıştır. Daha sonra hesaplanan uygunluğu daha fazla olan bireyler ile popülasyon oluşturulmuştur. Bu işlem ile uygunluğu daha fazla olan bireylerle aramaya başlanarak algoritmanın yakınsama hızının artırılması amaçlanmıştır (Temurtaş ve diğ. 2017).

Çalışmada tasarlanan OblLDE-1 ve OblLDE-2 algoritmaları için akış diyagramı Şekil 3'te verilmiştir. Verilen diyagramda Şekil 1'de verilen klasik DE algoritmasına göre farklılıklar ise kırmızı renkte gösterilmiştir.



Şekil 3:
OblLDE-1 ve OblLDE-2 için akış diyagramı ve klasik DE'den farkı

4. SAYISAL ÖRNEKLER

Çalışmada geliştirilen algoritmalar ilk olarak, literatürde yer alan çeşitli test fonksiyonlarına uygulanmış, daha sonra elektrik mühendisliğinde önemli bir yere sahip, gerçek dünya problemlerinden biri olan ve önceki bölümlerde tanımı yapılan optimal aktif güç dağıtımı probleminin çözümünde kullanılmışlardır. Her iki uygulama içinde kullanılan parametre değerleri Tablo 1’de verilmiştir. Tabloda yer alan P1 ifadesi bu bölümde çözümü yapılan problem 1’i, P2 ifadesi ise problem 2’yi temsil etmektedir.

Tablo 1. DE ve ObLDE parametre değerleri

İterasyon Sayısı (g_{max})	Birey Sayısı (NP)	Fonksiyon Çağırımı (F_{Call})	Çaprazlama Oranı (CR)	Ölçekleme Faktörü (F)
P1:1000 P2:100	50	50000	0,8	0,4

Problemin çözümü MATLAB R2015b programı ve Intel Xeon E5-2637 v4 3.50 GHz işlemciye sahip, 128 GB RAM’li iş istasyonu kullanılarak yapılmıştır. Algoritmanın koşturulduğu makine özellikleri süre karşılaştırmaları bakımından önemlidir.

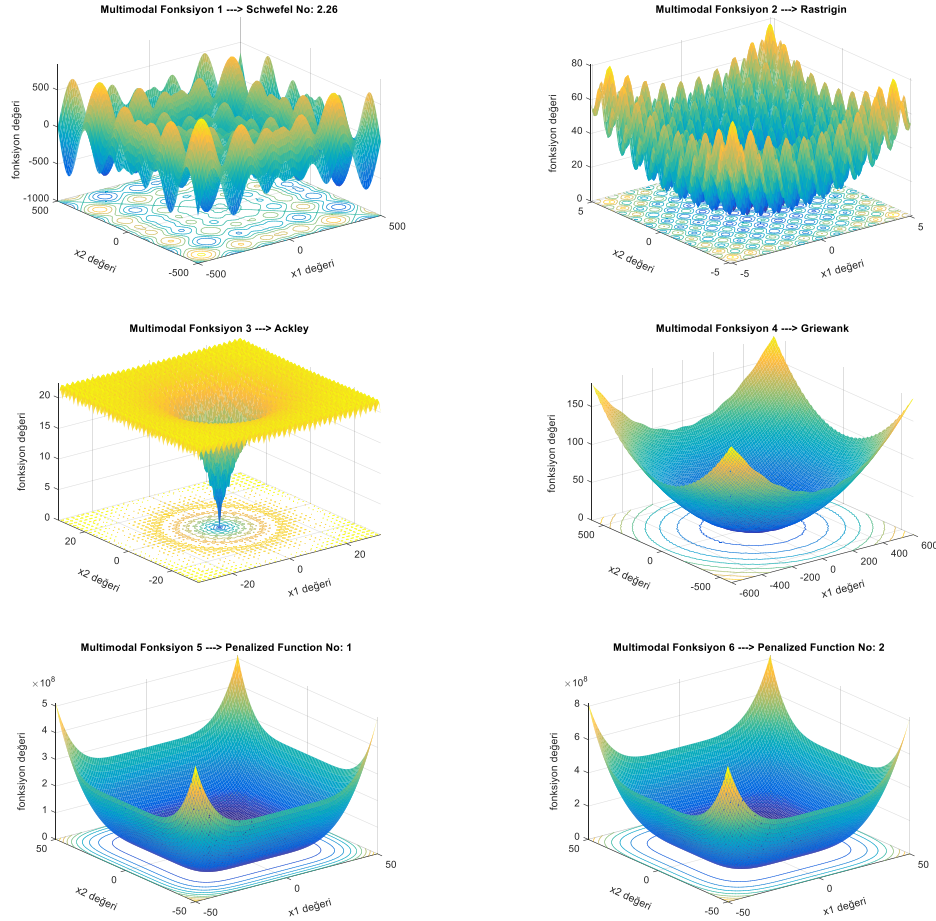
4.1. Problem-1: Multimodal Test Fonksiyonları

ObLDE-1 ve ObLDE-2 yaklaşımlarının performanslarının değerlendirilmesi için 6 adet test fonksiyonu belirlenmiştir. Bu fonksiyonlar Tablo 2’de verilmiştir. Bu fonksiyonlar birçok lokal minimum noktaları olan (multimodal) aynı zamanda yüksek boyutlu ve geniş arama uzayına sahip fonksiyonlardır (Temurtaş ve diğ. 2017). Tabloda yer alan bütün fonksiyonlar için boyut (n) 30 olarak belirlenmiştir.

Tablo 2. Multimodal test fonksiyonları (Temurtaş ve diğ. 2017)

Matematiksel İfade	Arama Aralığı (S)	f_{min}
$f_1(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	$[-500, 500]^n$	$(-418.9829) \times n$
$f_2(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	$[-5, 12, 5, 12]^n$	0
$f_3(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$	$[-32, 32]^n$	0
$f_4(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	$[-600, 600]^n$	0
$f_5(x) = \frac{\pi}{n} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] \right\} + \sum_{i=1}^{n-1} u(x_i, a, k, m)$ $y_i = 1 + \frac{x_i + 1}{4}, a = 10, k = 100, m = 4, u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 & -a < x_i < a \\ k(-x_i - a)^m & x_i < -a \end{cases}$	$[-50, 50]^n$	0
$f_6(x) = 0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] \right\} + \sum_{i=1}^n u(x_i, a, k, m), a = 5, k = 100, m = 4$	$[-50, 50]^n$	0

Tablo 2’de matematiksel ifadeleri ve tanımlamaları yapılan test fonksiyonlarına ait 2 boyut (2 değişken) durumu için arama uzayındaki grafikleri toplu olarak Şekil 4’de verilmiştir.



Şekil 4:
Multimodal test fonksiyonlarının 2-D grafikleri

Bu test fonksiyonlarının DE ve geliştirilen algoritmalar (ObLDE-1, ObLDE-2) ile 30 kez çözümlerinden elde edilen bütün sonuçlar Tablo 3’de verilmiştir. Tabloda yer alan süreler her bir çözüm için geçen ortalama süreleri ifade etmektedir.

Tablo 3. DE ve ObLDE-1 ve ObLDE-2 ile elde edilen sonuçlar


		DE	ObLDE-1	ObLDE-2
f_1	En kötü	-5,235931e+03	-5,231836e+03	-5,095567e+03
	Ortalama	-6,291986e+03	-6,112514e+03	-6,136837e+03
	En İyi	-7,587250e+03	-7,182990e+03	-7,611980e+03
	St. Sapma	7,353762e+02	5,430942e+02	5,766945e+02
	Süre (sn)	1,30862	1,33645	1,21476
f_2	En kötü	1,789917e+02	1,796852e+02	1,727121e+02
	Ortalama	1,539041e+02	1,545331e+02	1,519520e+02
	En İyi	1,366116e+02	1,155087e+02	1,250423e+02
	St. Sapma	1,069011e+01	1,617763e+01	1,129328e+01
	Süre (sn)	1,31478	1,26918	1,43019

Tablo 3. (devamı)

f_3	En kötü	3,719247e-11	5,185852e-11	2,583711e-11
	Ortalama	1,699788e-11	1,628816e-11	1,350616e-11
	En İyi	7,067680e-12	7,902567e-12	7,129852e-12
	St. Sapma	7,756366e-12	8,697831e-12	4,677131e-12
	Süre (sn)	1,43584	1,63529	1,47425
f_4	En kötü	1,231607e-02	9,857285e-03	9,857285e-03
	Ortalama	4,105358e-04	3,285762e-04	8,216455e-04
	En İyi	0,000000e+00	0,000000e+00	0,000000e+00
	St. Sapma	2,210803e-03	1,769437e-03	2,492093e-03
	Süre (sn)	2,27975	2,7063	2,40315
f_5	En kötü	1,036690e-01	2,693014e-21	3,963702e-21
	Ortalama	3,455634e-03	3,562217e-22	3,718196e-22
	En İyi	3,234012e-23	6,443437e-23	1,879387e-23
	St. Sapma	1,860916e-02	5,137788e-22	7,332914e-22
	Süre (sn)	2,33334	2,42218	2,36008
f_6	En kötü	3,331361e+00	3,331361e+00	2,012387e+00
	Ortalama	1,979155e-01	1,110454e-01	6,767285e-02
	En İyi	2,430646e-22	2,687890e-22	1,970917e-22
	St. Sapma	7,464275e-01	5,979976e-01	3,611386e-01
	Süre (sn)	2,06494	1,8569	2,10789

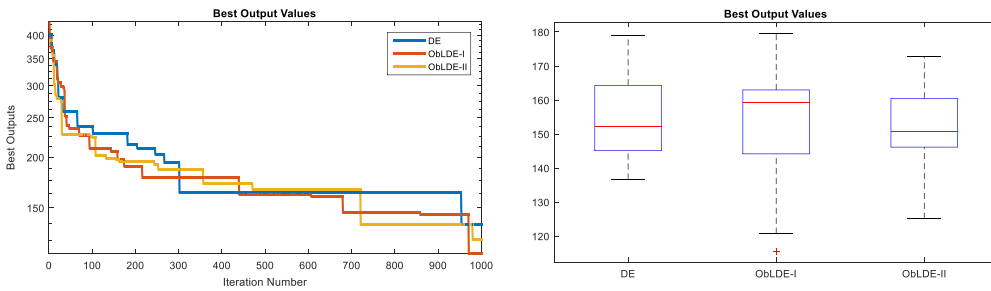
Tablo 3’deki sonuçlar incelendiğinde, OBLDE-1 ve OBLDE-2 ile elde edilen bazı sonuçların, DE ile elde edilen sonuçlardan daha iyi oldukları görülmektedir. OBLDE-1, 2 fonksiyonda DE’den daha iyi sonuç bulurken, OBLDE-2, 3 fonksiyonda, DE’den daha iyi sonuç bulmuştur. OBLDE-1 ve OBLDE-2 birbirleriyle karşılaştırıldığında, OBLDE-2 yaklaşımının OBLDE-1’e göre daha üstün olduğu belirlenmiştir.

Belirlenen test fonksiyonlarının 30 kez çözülmesiyle bulunan en iyi çözümlere ait, yakınsamayı gösteren grafikler ve kutu grafikleri sırasıyla Şekil 5-Şekil 10 arasında verilmiştir.



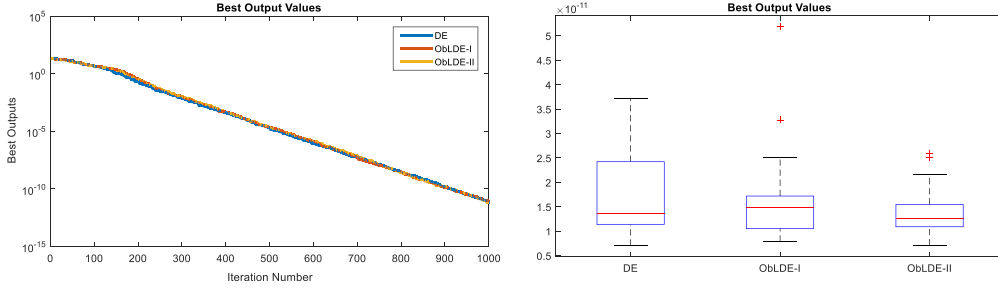
Şekil 5:

f_1 için yakınsama eğrileri ve kutu grafikleri




Şekil 6:


f_2 için yakınsama eğrileri ve kutu grafikleri




Şekil 7:
 f_3 için yakınsama eğrileri ve kutu grafikleri



Şekil 8:
 f_4 için yakınsama eğrileri ve kutu grafikleri



Şekil 9:
 f_5 için yakınsama eğrileri ve kutu grafikleri




Şekil 10:
 f_6 için yakınsama eğrileri ve kutu grafikleri

Çözümü yapılan multimodal fonksiyonlar için çizdirilen grafikler incelendiğinde, ObLDE-2 yaklaşımının hem DE hem de ObLDE-1 yaklaşımlarına yakınsama bakımından üstünlüğü görülmektedir. DE algoritması ise ObLDE-1 yaklaşımından daha iyi ve kararlı sonuçlar elde etmiştir. DE algoritmasına çalışmada ki ikinci yaklaşımla entegre edilen karşıt öğrenme

metodunun, algoritma üzerine olumlu etkileri olduğu söylenebilir. 30 kez yapılan çözümlerden elde edilen kutu grafiklerine bakıldığında ise karşıt öğrenme tabanlı metodun klasik algoritmayı kararlılık bakımından da geliştirdiği görülmektedir. Aynı fonksiyonlar için eniyi değerler karşıt öğrenme tabanlı yaklaşımlarla 30 çözümde daha az sayıda sapan değer ile bulunmuştur.

4.2. Problem-2: Optimal Güç Dağıtım Problemi

Önerilen algoritmaların (ObLDE-1 ve ObLDE-2), performanslarının daha karmaşık ve farklı kısıtlar içeren gerçek dünya problemlerindeki performanslarının değerlendirilebilmesi için elektrik mühendisliği için önemli bir problem olan optimal güç dağıtım problemi seçilmiştir. Probleme örnek olarak Şekil 11’de tek hat diyagramı verilen IEEE 30 baralı 6 generatörlü güç sistemi seçilmiştir. Bu güç sisteminde 30 adet bara, 6 adet güç üretim generatörü, 41 adet iletim hattı ve 21 adet yük barası bulunmaktadır. Sistemin çözümünde kullanılan bütün değerler ve elde edilen sonuçlar *pu* olarak alınmıştır. Belirlenen baz değerler $S_{baz}=100 \text{ MVA}$, $V_{baz}=230 \text{ kV}$ ve $Z_{baz}=529 \text{ Ohm}$ ’dur. Bu sistemde literatürdeki bütün çalışmalarda 1. baraya bağlı G_1 üretim birimi salınım barası olarak seçilmiştir. Salınım barası için sabit, bara gerilim değeri $U_1=1,05 \angle 0^\circ$ olarak alınmıştır. Örnek sisteme ait bütün veriler belirtilen kaynaktaki gibi alınmıştır (Özyön ve diğ. 2011; Özyön ve diğ. 2016). Bu çalışmada örnek sistem DE, ObLDE-1 ve ObLDE-2 algoritmaları ile iletim hattı kayıpları dikkate alınarak çözülmüştür. Literatürdeki birçok çalışma çözüm kolaylığı için B-kayıp matrisleri kullanarak iletim hattı kayıplarını yaklaşık hesaplamaktadır. Bu çalışmada iletim hattı kayıpları AC yük akışı yapılarak bulunmuştur.



Şekil 11:

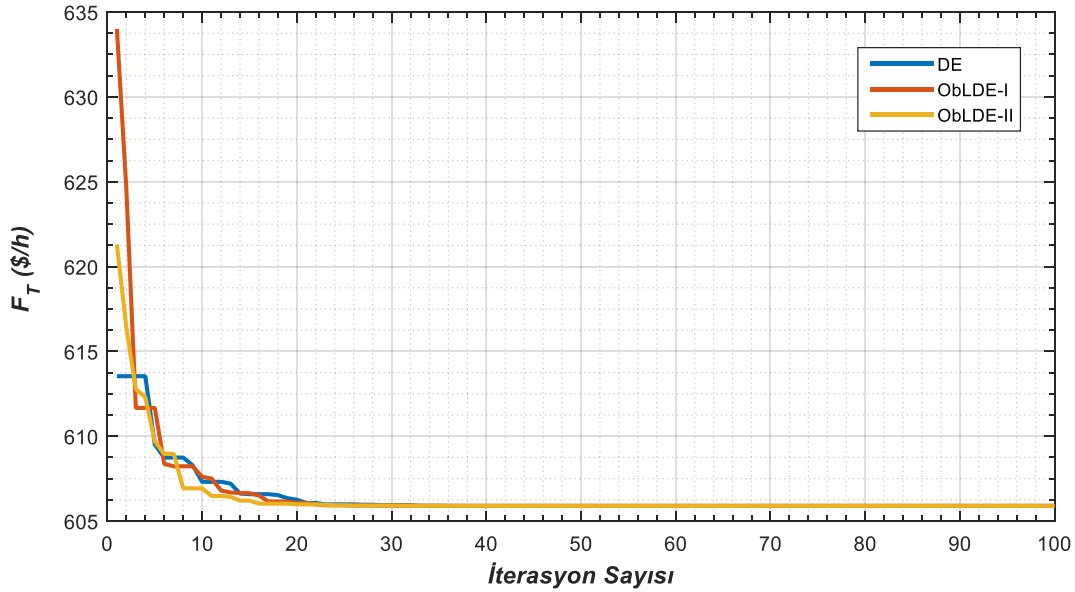
IEEE 30 bara 6 generatörlü örnek sistemin tek hat diyagramı (Özyön ve diğ. 2011)

Örnek sistem mevcut yük talebi için DE, ObLDE-1 ve ObLDE-2 algoritmaları ile ayrı ayrı 30'ar kez çözülmüştür. Bu çözümler sonucunda elde edilen en iyi termik yakıt maliyeti değerine sahip çözüm için bütün değerler Tablo 4'de verilmiştir.

Tablo 4. Sistemin çözümlerine ait sonuç değerleri

(pu)	DE	ObLDE-1	ObLDE-2
$P_{GT,1}$ (salınım)	0,108204	0,108201	0,108199
$P_{GT,2}$	0,302150	0,302137	0,302152
$P_{GT,5}$	0,596272	0,596270	0,596275
$P_{GT,8}$	0,989488	0,989487	0,989490
$P_{GT,11}$	0,509531	0,509557	0,509531
$P_{GT,13}$	0,353224	0,353218	0,353222
TYM (\$/h)	605,894887	605,894887	605,894887
$P_{kayıp}$	0,024870	0,024870	0,024870
Çözüm Süresi (sn)	14,650296	16,209728	14,862826

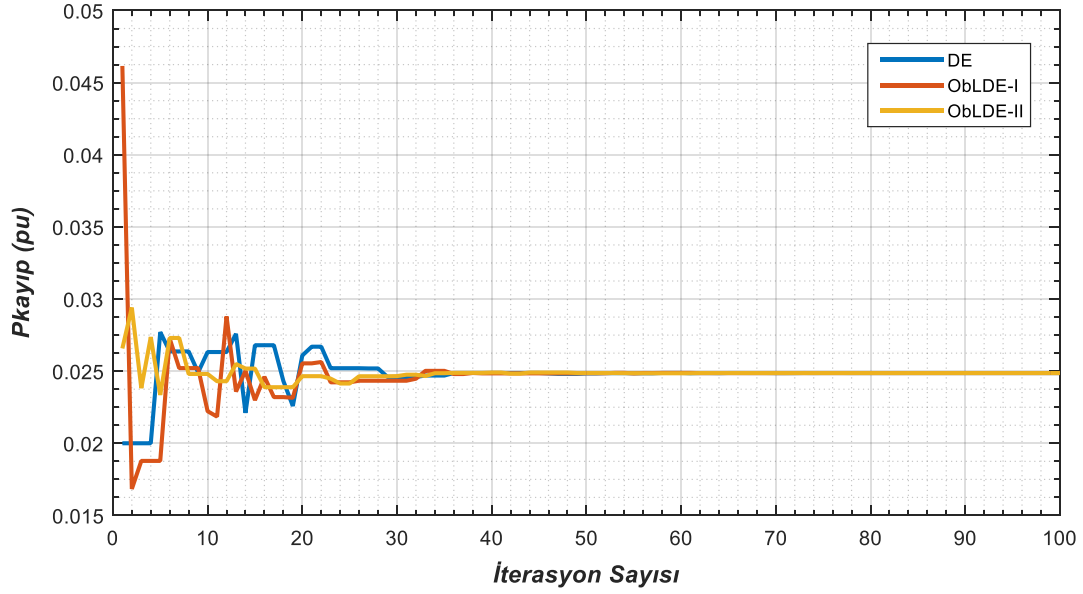
Yapılan çözümlerde toplam yakıt maliyeti değerlerinin iterasyon sayısına göre değişimleri Şekil 12'de, toplam iletim hattı kayıplarının iterasyon sayısına göre değişimleri Şekil 13'te ve 30 çalışma için kutu grafikleri Şekil 14'de verilmiştir.



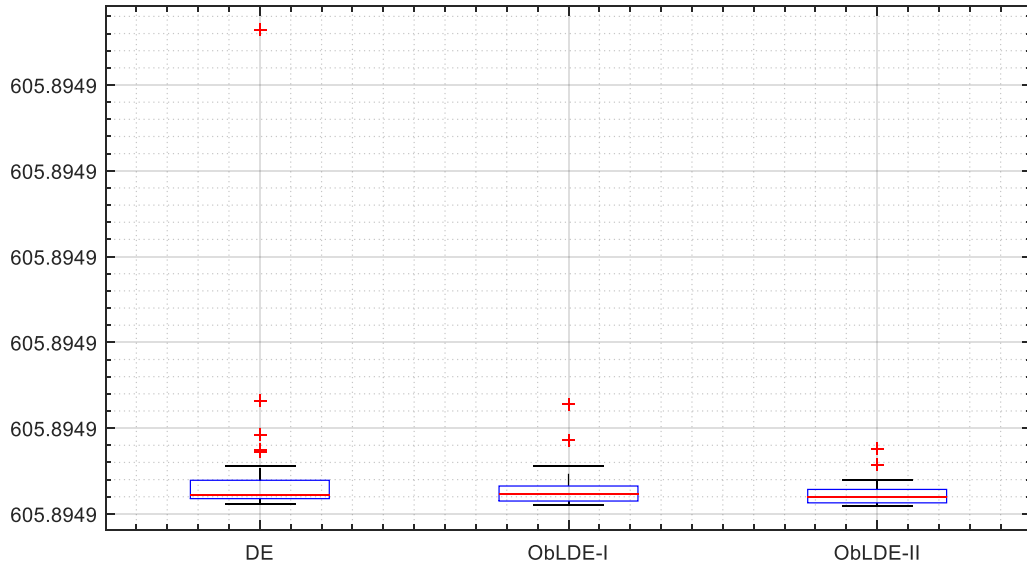
Şekil 12:

Toplam yakıt maliyetlerinin iterasyon sayısına göre değişimleri

Tablo 4'teki veriler incelendiğinde üç algortmada 30 denemenin en az birinde en iyi sonuca yakınsamasına rağmen, zıt konumlu algoritmalar süre açısından dezavantajlı oldukları görülmektedir. Sonraki çalışmalarda süre konusunda çalışmalar yapılabilir. Şekil 12'den DE'nin 26. iterasyonda, ObLDE-1'nin 22. iterasyonda ve ObLDE-2'nin 16. iterasyonda eniyi toplam termik yakıt maliyeti değerlerini yaklaşık yakaladığı görülmüştür. Eniyi sonuçlar için arama bu iterasyonlarda sağlanmasına rağmen generatör çıkışlarının bundan sonraki iterasyonlarda da farklı değerler alması nedeni ile Şekil 13'de verilen iletim hatlarındaki güç kaybının değişimi yaklaşık 36. iterasyondan sonra sabitlenmiş ve 0,024870 pu değerine oturmuştur.



Şekil 13:
Toplam iletim hattı kayıplarının iterasyon sayısına göre değişimleri



Şekil 14:
30 çalışma için kutu grafikleri

Problemin her algoritma ile 30'ar kez çözümünden elde edilen ve Şekil 14'de verilen kutu grafikleri incelendiğinde ise her üç algoritmada aynı eniyi toplam termik yakıt maliyetini yakalamasına rağmen, kararlılık bakımından sıralama ObLDE-2, ObLDE-1 ve DE şeklinde oluşmuştur. ObLDE-1 ve ObLDE-2 yaklaşımlarındaki iki adet sapan değere karşın DE'de beş adet sapan değer mevcuttur. Grafikteki sonuçlardan karşıt tabanlı öğrenme kavramının, klasik optimizasyon algoritmasını kararlılık bakımından daha iyi hale getirmiş olduğu söylenebilir.

5. SONUÇ

Çalışmada literatürde geniş bir kullanım alanına sahip, birçok problemin çözümüne başarıyla uygulanmış DE algoritmasının geliştirilmesi ve iyileştirilmesi amaçlanmıştır. Bu amaç doğrultusunda algoritmanın tasarlanan ilk haline karşıt tabanlı öğrenme kavramı iki farklı şekilde entegre edilerek ObLDE-1 ve ObLDE-2 isimli farklı DE yapıları oluşturulmuştur. İlk olarak yeni algoritmaların performanslarının gözlemlenebilmesi için altı adet yüksek boyutlu multimodal test fonksiyonunun çözümü yapılmıştır. Bu çözümler sonucunda elde edilen veri ve grafiklerden karşıt tabanlı öğrenme kavramının DE algoritması üzerinde olumlu etkilere yol açtığı görülmüştür. Elde edilen sonuçlardan algoritmaların performans sıralaması ise ObLDE-2, DE ve ObLDE-1 şeklinde oluşmuştur. Test fonksiyonlarının optimizasyonlarının ardından geliştirilen algoritmalar ile optimal güç dağıtım problemi çözülmüştür. Örnek sistem olarak seçilen IEEE 30 baralı 6 generatörlü ve iletim hattı kayıplı sistemin termik yakıt maliyeti DE ve geliştirilen algoritmalar ile başarıyla optimize edilmiştir. İleride yapılacak çalışmalarda, bu çalışmada ele alınan karşıt tabanlı öğrenme kavramı ve literatürde yer alan farklı algoritma geliştirme yöntemleri, çeşitli yapılarıdaki enerji problemlerinin daha kararlı ve kısa sürede çözümleri için farklı optimizasyon algoritmalarına uygulanacaktır.

KAYNAKLAR

1. Abido, M.A. (2002) Optimal power flow using particle swarm optimization, *International Journal of Electrical Power & Energy Systems*, 24, 563-571. doi: 10.1016/S0142-0615(01)00067-9
2. Abou A.A., Abido M.A., Spea S.R. (2010) Differential evolution algorithm for emission constrained economic power dispatch problem, *Electric Power Systems Research*, 80, 1286-1292. doi: 10.1016/j.epsr.2010.04.011
3. Dinh, L.L., Ngoc, D.V., Vasant, P. (2013), Artificial Bee Colony Algorithm for Solving Optimal Power Flow Problem, *The Scientific World Journal*, 1-9. doi: 10.1155/2013/159040
4. Kothari, D.P., Dhillon, J.S. (2007) *Power System Optimization*, PHI, New Delhi, 2007.
5. Kurban, M., Başaran Filik, Ü. (2007) Türkiye'deki 22 baralı 380 kV'luk güç sisteminin iki farklı yöntem kullanılarak ekonomik dağıtım analizi, *SAÜ Fen Bilimleri Dergisi*, 11(1), 78-86.
6. Makas, H., Yumuşak, N. (2016) System identification by using migrating birds optimization algorithm: a comparative performance analysis, *Turkish Journal of Electrical Engineering & Computer Sciences*, 24, 1879-1900. doi: 10.3906/elk-1311-45
7. Mohamed, A.W., Sabry, H.Z., Abd-Elaziz, T. (2013) Real parameter optimization by an effective differential evolution algorithm, *Egyptian Informatics Journal*, 14(1), 37-53. doi: 10.1016/j.eij.2013.01.001
8. Montes de Oca, M.A., Stützle, T. (2008) Towards incremental social learning in optimization and multiagent systems, *ECoMASS Workshop of the Genetic and Evolutionary Computation Conference (GECCO'08)*, 1939-1944, ACM Press, New York. doi: 10.1145/1388969.1389004
9. Nouhi, B., Talatahari, S., Kheiri, H., Cattani, C. (2013) Chaotic charged system search with a feasible-based method for constraint optimization problems, *Mathematical Problems in Engineering*, 1-8. doi: 10.1155/2013/391765
10. Osman, M.S., Abo-Sinna, M.A., Mousa, A.A. (2004) A solution to the optimal power flow using genetic algorithm, *Applied Mathematics and Computation*, 155, 391-405. doi: 10.1016/S0096-3003(03)00785-9

11. Özyön, S., (2019) Farklı mutasyon yapılarının diferansiyel gelişim algoritması performansına etkileri, *Erasmus International Academic Research Symposium in Science, Engineering and Architecture (Erasmus'19)*, 255-263, İzmir, Türkiye.
12. Özyön, S., Yaşar, C. (2016) Farklı salınım barası seçimlerinin optimal güç akışı üzerindeki etkilerinin incelenmesi, *2nd International Multidisciplinary Congree of Eurasia (IMCOFE'16)*, 40-50, Odessa, Ukrayna.
13. Özyön, S., Yaşar, C., Durmuş, B., Temurtaş, H., Kuvat, G. (2012) Solution to non-convex economic power dispatch problems with generator constraints by charged system search algorithm, *International Review of Electrical Engineering (I.R.E.E.)*, 7(5), 5840-5853.
14. Özyön, S., Yaşar, C., Özcan, G., Temurtaş, H. (2011) Çevresel ekonomik güç dağıtım problemlerine yapay arı koloni algoritması (ABC) yaklaşımı, *Ulusal Elektrik-Elektronik Bilgisayar Sempozyumu (FEEB2011)*, 222-228, Elâzığ, Türkiye.
15. Özyön, S., Yaşar, C., Temurtaş, H. (2011) Diferansiyel gelişim algoritmasının valf nokta etkili konveks olmayan ekonomik güç dağıtım problemlerine uygulanması, *6th International Advanced Technologies Symposium (IATS'11)*, Electrical & Electronics Technologies Papers 4, 181-186, Elâzığ, Turkey.
16. Özyön, S., Yaşar, C., Temurtaş, H. (2011) Harmoni arama algoritmasının çevresel ekonomik güç dağıtım problemlerine uygulanması, *Çukurova Üniversitesi, Mühendislik-Mimarlık Fakültesi Dergisi*, 26(2), 65-76.
17. Rossoni, P., Rosa, W.M., Belati, E.A. (2016) Linearized AC load flow applied to analysis in electric power systems, *IEEE Latin America Transactions*, 14(9), 4048-4053. doi: 10.1109/TLA.2016.7785932
18. Storn, R., Price, K. (1997) Differential evolution-A simple and efficient heuristic for global optimization over continuous spaces, *Journal of Global Optimization*, 11, 341-359.
19. 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, 922-937. doi: 10.5578/fmbd.66295
20. Tizhoosh, H.R. (2005) Opposition-based learning: A new scheme for machine intelligence, *International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06)*, 695-701, Vienna, Austria.
21. Wood, A.J., Wollenberg, B.F., Sheble, G.B. (2013) *Power Generation Operation and Control*, IEEE & Wiley, Third Edition, USA.
22. Xuanhu, H., Wang, W., Jiuchun, J., Lijie, X. (2015) An Improved Artificial Bee Colony Algorithm and Its Application to Multi-Objective Optimal Power Flow, *Energies*, 8, 2412-2437. doi: 10.3390/en8042412
23. Yaşar, C., Özyön, S., Temurtaş, H. (2017) A New Program Design Developed for AC Load Flow Analysis Problems, *Kırıkkale Üniversitesi Mühendislik Fakültesi Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 9(3), 207-222. doi: 10.29137/umagd.372979