



Derleme Makalesi

OPTİMAL GÜÇ AKIŞI PROBLEM ÇÖZÜMLERİNDE META-SEZGİSEL YÖNTEMLERİN İNCELENMESİ

INVESTIGATION OF META-HEURISTIC METHODS IN OPTIMAL POWER FLOW PROBLEM SOLVING

Mustafa SIRAĞAYA^{1*}  0000-0002-7964-4399,
Bahtiyar TAŞDEMİR²  0000-0001-7335-5185

Makale Bilgileri	ÖZET
Anahtar Kelimeler: Optimal güç akışı, meta-sezgisel algoritmalar, güç sistemleri, çok amaçlı optimizasyon, yapay zekâ.	Günümüz elektrik enerji sistemlerinin artan karmaşıklığı ve optimum işletme ve planlama gereksinimleri, optimal güç akışı (OGA) problemlerinin çözümünde daha etkin ve esnek yaklaşımların kullanılmasını zorunlu kılmaktadır. Geleneksel deterministik yöntemler, özellikle doğrusal olmayan, çok amaçlı ve kısıtlı problemlerde küresel optimuma ulaşmada yetersiz kalabilmektedir. Bu bağlamda, son yıllarda meta-sezgisel (metaheuristic) algoritmalar, OGA problemlerinin çözümünde güçlü alternatifler olarak öne çıkmıştır. Bu çalışmada, elektrik güç sistemlerinde OGA problemlerine yönelik olarak geliştirilen başlıca meta-sezgisel yöntemler kapsamlı bir şekilde incelenmiştir. Genetik algoritma (GA), parçacık sürü optimizasyonu (PSO), yapay arı kolonisi (ABC), Öğretme-Öğrenme tabanlı optimizasyon (ÖÖTO), farklı evrim (FE), Jaya ve hibrit algoritmalar gibi yaklaşımlar, performans kriterleri, avantajları, sınırlılıkları ve uygulama alanları açısından değerlendirilmiştir. Ayrıca bu yöntemlerin karşılaştırmalı analizleriyle sağladığı iyileştirme düzeyleri de detaylı biçimde ele alınmıştır. Ayrıca, çok amaçlı optimizasyon, yenilenebilir enerji entegrasyonu ve belirsizlik altında OGA gibi güncel araştırma eğilimlerine de yer verilmiştir. Bu derleme araştırması, meta-sezgisel tabanlı çözüm yöntemlerinin güç sistemleri alanındaki potansiyelini ortaya koymakta ve gelecekteki çalışmalar için yol gösterici olmayı amaçlamaktadır.
Article Info	ABSTRACT
Keywords: Optimal power flow, meta-heuristic algorithms, power systems, multi-objective	The increasing complexity of today's electric power systems and the requirements for optimal operation and planning necessitate the use of more efficient and flexible approaches to solve optimal power flow (OPF) problems. Traditional deterministic methods may be insufficient to reach the global optimum, especially for nonlinear, multi-objective and constrained problems. In this context, in recent years, metaheuristic

^{1*} Kırşehir Ahi Evran Üniversitesi, mustafa.sirakaya@ahievran.edu.tr

² T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Çankırı İl Müdürlüğü, bahtiyartasdemir1830@gmail.com
Sorumlu yazar: mustafa.sirakaya@ahievran.edu.tr

Başvuru tarihi:18.06.2025; Düzeltme Tarihi 30.07.2025; Kabul Tarihi 29.08.202

optimization,
intelligence.

artificial algorithms have emerged as powerful alternatives for solving OGA problems. In this study, the main meta-heuristic methods developed for OGA problems in electric power systems are comprehensively reviewed. Approaches such as genetic algorithm (GA), particle swarm optimization (PSO), artificial bee colony (ABC), Teaching-Learning based optimization (TLBA), differential evolution (FE), Jaya and hybrid algorithms are evaluated in terms of their performance criteria, advantages, limitations and application areas. In addition, the comparative analysis of these methods and the level of improvement they provide are also discussed in detail. Current research trends such as multi-objective optimization, renewable energy integration and OGA under uncertainty are also included. This review research demonstrates the potential of meta-heuristic-based solution methods in the power systems domain and aims to provide guidance for future work.

1. GİRİŞ

Elektrik güç sistemlerinin güvenli, ekonomik ve sürdürülebilir bir şekilde işletilmesi, modern enerji yönetiminin temel hedeflerinden biridir (Dommel & Tinney, 1968). Bu hedeflere ulaşabilmek için sistemdeki üretim birimlerinin uygun şekilde koordinasyonu, gerilim düzeylerinin sınırlar içinde tutulması ve enerji kayıplarının en aza indirilmesi gerekmektedir. Bu bağlamda, Optimal Güç Akışı (OGA) problemi, sistemin belirli kısıtlar altında işletme koşullarını optimize etmeyi amaçlayan kritik bir mühendislik problemidir (Sulaiman ve ark., 2021).

OGA problemleri genellikle doğrusal olmayan, çok değişkenli ve çok kısıtlı yapıları nedeniyle çözüm açısından oldukça karmaşıktır. Geleneksel çözüm yöntemleri (Newton-Raphson, Lagrange çarpanları, doğrusal programlama vb.), bazı özel durumlar dışında yerel çözümlere takılabilmekte veya yüksek boyutlu problemlerde yetersiz kalabilmektedir (Abou El Ela, Abido, & Spea, 2010; Gao ve ark., 2017). Ayrıca, bu yöntemlerin türev bilgisi gerektirmesi, sistemde belirsizliklerin artması ve yenilenebilir enerji kaynaklarının entegrasyonu gibi günümüz güç sistemlerindeki yeni dinamikler karşısında etkinliğini sınırlamaktadır (Zamzam & Baker, 2020).

Bu sorunların aşılması amacıyla son yıllarda meta-sezgisel algoritmalar, OGA çözümlerinde yaygın olarak kullanılmaya başlanmıştır. Meta-sezgisel yöntemler; rastgelelik, popülasyon temelli arama ve doğadaki çeşitli mekanizmalardan esinlenen yapılarına dayanarak, karmaşık optimizasyon problemlerinde küresel çözüme yakın sonuçlar elde etme potansiyeline sahiptir (Devarapalli, Bhattacharyya, & Sinha, 2020). Genetik algoritma (GA), parçacık sürü optimizasyonu (PSO), yapay arı kolonisi (ABC), farklı evrim (DE), Jaya, öğretmen-öğrenci temelli algoritmalar (TLBO) ve çeşitli hibrit yaklaşımlar, literatürde sıklıkla OGA çözümünde uygulanmış ve başarılı sonuçlar vermiştir.

Bu derleme çalışmasının amacı, OGA problemlerinde kullanılan başlıca meta-sezgisel yöntemleri sistematik bir şekilde incelemek, yöntemlerin güçlü ve zayıf yönlerini değerlendirmek ve gelecekteki araştırmalara ışık tutacak kapsamlı bir bakış açısı sunmaktır. Çalışma kapsamında hem tek amaçlı hem de çok amaçlı OGA problemleri ele alınmış, ayrıca yenilenebilir enerji entegrasyonu, belirsizlik modellemeleri ve dinamik yük değişimleri gibi güncel uygulama alanlarına da değinilmiştir.

2. OGA PROBLEMİ FORMÜLASYONU

Optimal Güç Akışı (OGA) problemi, elektrik enerji sistemlerinin güvenli, ekonomik ve verimli şekilde işletilmesini amaçlayan önemli bir optimizasyon problemidir (Cain, O'Neill, & Castillo, 2012). OGA, sistemin fiziksel ve operasyonel kısıtlarını dikkate alarak belirli bir amaç fonksiyonunu (örneğin üretim maliyeti, güç kaybı veya emisyon miktarı) optimize etmeyi hedefler. Bu bağlamda OGA problemi, hem sürekli hem de ayrık karar değişkenleri içeren doğrusal olmayan kısıtlı bir optimizasyon problemi olarak formüle edilir (Niu, Wan, & Xu, 2014).

2.1.Amaç Fonksiyonu

OGA probleminin temel amacı, aşağıda örneklenen kriterlerden biri veya birkaçının optimize edilmesidir:

- Toplam üretim maliyetinin minimizasyonu
- Aktif güç kayıplarının minimizasyonu

Sırakaya¹ ve ark.

- Çevresel emisyonların minimizasyonu
- Gerilim profilinin iyileştirilmesi

Genel bir amaç fonksiyonu aşağıdaki gibi ifade edilebilir:

$$\text{Minimize} : f(x, u) \quad (1)$$

Burada, $f(x, u)$, seçilen optimizasyon hedefini temsil eden amaç fonksiyonu, x , durum değişkenleri (örneğin gerilim büyüklükleri ve açıları, reaktif güçler), u , kontrol değişkenleri (örneğin jeneratör çıkışları, gerilim seviyeleri, transformatör kademe oranları)

2.1.1 Durum değişkenleri

Güç sisteminde belirli sınırlar altında mevcut durumu hakkında bilgi vermek için optimize edilen değerlerdir. Durum değişkeni x olarak tanımlanmış ve Eş. 2 ile belirtilmiştir.

$$x = [P_{G1}, V_{L1} \dots V_{LNL}, Q_{G1} \dots Q_{GNG}, S_{l1} \dots S_{lnl}] \quad (2)$$

Burada, P_{G1} seçilen slack bara, Q_G generatörlerin reaktif güç değeri, V_L yük baralarının gerilim değeri, and S_l iletim hattının yükü olarak tanımlanmıştır.

2.1.2. Kontrol değişkenleri

Güç sisteminde amaç fonksiyonuna uygun olarak optimize edilmesi için değişkenlere sahip karar değerleridir. Durum değişkeni u olarak tanımlanmış ve Eş. 3 ile belirtilmiştir.

$$u^T = [P_{G2} \dots P_{GNG}, V_{G1} \dots V_{GNG}, Q_{C1} \dots Q_{CNC}, T_1 \dots T_{NT}] \quad (3)$$

Burada, taransformatör tap ayarları T , paralel reaktif güç kompanzatörleri Q_C olarak tanımlanmıştır.

2.1.3 Kısıtlamalar

OGA çalışmalarında, güç sisteminin güvenli ve verimli çalışması için bazı kısıtlamaların belirlenmesi gerekmektedir. bu kısıtlamaları eşitlik ve eşitsizlik kısıtlamaları olarak sınıflandırılmaktadır. Kısıtlamalar sistemin çalışma sınırlarını belirler.

Eşitlik kısıtlamaları: burada amaç sistemdeki güç üretimi, tüketimi ve kayıplar arasında oluşturulan dengeyi belirleyen kısıtlamalardır. Güç sistemlerinde aktif ve reaktif güç kısıtlamaları Eş. 4ve 5’de verilmiştir.

$$P_{Gi} - P_{Di} - V_i \sum_{j=1}^{NB} V_j [G_{ij} \cos(\delta_i - \delta_j) + B_{ij} \sin(\delta_i - \delta_j)] = 0, \quad (4)$$

$$Q_{Gi} - Q_{Di} - V_i \sum_{j=1}^{NB} V_j [G_{ij} \sin(\delta_i - \delta_j) + B_{ij} \cos(\delta_i - \delta_j)] = 0 \quad (5)$$

Burada, P_{Gi} , i . baradaki jeneratörlerin ürettiği aktif güç. P_{Di} , i . baradaki aktif güç talebi. Q_{Gi} , i . baradaki jeneratörlerin ürettiği reaktif güç. Q_{Di} , i . baradaki reaktif güç talebidir. G_{ij} ve B_{ij} i . ve j . baralar arasındaki iletim hattının iletkenlik ve susceptance değerleridir.

Eşitsizlik kısıtlamaları: burada generatörlerin, baraların, trafoların güç gerilim gibi değerlerinin belirli sınırlar içinde kalması belirlenir.

$$P_{Gi}^{min} \leq P_{Gi} \leq P_{Gi}^{max}, \quad 1 \leq i \leq N_G \quad (6)$$

$$Q_{Gi}^{min} \leq Q_{Gi} \leq Q_{Gi}^{max}, \quad 1 \leq i \leq N_G \quad (7)$$

$$V_{Gi}^{min} \leq V_{Gi} \leq V_{Gi}^{max}, \quad 1 \leq i \leq N_G \quad (8)$$

$$Q_{Ci}^{min} \leq Q_{Ci} \leq Q_{Ci}^{max}, \quad 1 \leq i \leq N_C \quad (9)$$

$$T_i^{min} \leq T_i \leq T_i^{max}, \quad 1 \leq i \leq N_T \quad (10)$$

$$V_{Li}^{min} \leq V_{Li} \leq V_{Li}^{max}, \quad 1 \leq i \leq N_L \quad (11)$$

$$S_{li} \leq S_{li}^{max}, \quad 1 \leq i \leq N_l \quad (12)$$

3. KLASİK OGA ÇÖZÜM YÖNTEMLERİ

Optimal Güç Akışı (OGA) problemi, karmaşık, doğrusal olmayan ve kısıtlı bir optimizasyon problemidir. Bu problemin çözümü için uzun yıllardır geliştirilen klasik (deterministik) çözüm yöntemleri, özellikle sistemin kararlılığını ve güvenilirliğini sağlamak amacıyla yaygın olarak kullanılmaktadır. Klasik yöntemler, genellikle türev bilgisi gerektiren matematiksel tekniklere dayalı olup, hızlı yakınsama özelliklerine sahiptir. Ancak, yerel optimuma saplanma eğilimleri ve çok amaçlı hedeflere sınırlı uyumlulukları nedeniyle bazı kısıtlamaları da beraberinde getirirler.

Klasik OGA çözüm yöntemleri genel olarak aşağıdaki başlıklar altında sınıflandırılabilir:

3.1. Newton-Raphson Tabanlı Yöntemler

Newton-Raphson (NR) yöntemi, güç sistemleri analizinde sıklıkla kullanılan hızlı yakınsayan bir nümerik yöntemdir. OGA'ye uyarlanmış haliyle bu yöntem, Lagrange çarpanları ile amaç fonksiyonunu ve kısıtları birleştirerek çözüm üretir (Sun ve ark., 1984). Denklem sistemi şu şekilde oluşturulur:

$$L(x, \lambda) = f(x) + \lambda^T g(x) \quad (13)$$

Burada $f(x)$ amaç fonksiyonunu, $g(x)$ ise güç akış denklemlerini temsil eder. NR tabanlı yöntemlerde doğrusal olmayan denklem sistemi Jacobian matrisi yardımıyla çözülür. Bu yöntem özellikle küçük ve orta ölçekli sistemlerde yüksek doğruluk sağlar, ancak başlangıç noktasına duyarlıdır.

3.2. Doğrusal Programlama (LP)

Doğrusal programlama, hem amaç fonksiyonunun hem de kısıtların doğrusal olduğu problemlerde kullanılır. OGA problemleri genellikle doğrusal olmadığından, LP ancak bazı varsayımlar altında (örneğin sabit gerilim büyüklükleri, doğrusal kayıplar) yaklaşık çözümler sunabilir (Stott & Marinho, 1979). Hızlı ve kararlı çalışmasına rağmen, gerçekçi OGA problemleri için sınırlı bir uygulama alanına sahiptir (Capitanescu, 2016).

3.3. Doğrusal Olmayan Programlama (NLP)

Doğrusal olmayan programlama, hem amaç fonksiyonunun hem de kısıtların doğrusal olmayan fonksiyonlarla ifade edildiği durumları kapsar (Frank, Steponavice, & Rebennack, 2012). Lagrange çarpanları veya Karush-Kuhn-Tucker (KKT) koşulları kullanılarak çözüm elde edilir. NLP yöntemleri, problem boyutuna göre etkili sonuçlar üretebilir ancak çözüm süresi uzayabilir ve yerel minimuma saplanma riski vardır (Wei, ve ark. 1998).

3.4. Artırılmış Lagrange Yöntemi (Augmented Lagrangian Method)

Bu yöntem, klasik Lagrange yaklaşımının bir uzantısı olup, ceza terimleriyle güç akış denklemlerini daha etkili şekilde uygular. Amaç fonksiyonuna eklenen ceza terimleri sayesinde kısıtların ihlal edilmesi engellenir:

$$L_a(x, \lambda, \rho) = f(x) + \lambda^T g(x) + \frac{\rho}{2} \|g(x)\|^2 \quad (14)$$

Burada ρ , ceza katsayısıdır. Bu yöntem, kısıtların daha hassas kontrolünü sağlar.

3.5. İç Nokta Yöntemleri (Interior Point Methods)

İç nokta yöntemleri, büyük ölçekli optimizasyon problemlerinde etkili performans sergileyen modern klasik yöntemlerdendir (Yan & Quintana, 1999). Kısıtlı optimizasyon problemlerinde bariyer fonksiyonları kullanarak çözüm uzayında iç noktalardan ilerlenmesini sağlar. Özellikle yüksek boyutlu OGA problemlerinde tercih edilmektedir (Momoh & Zhu, 1999).

İç nokta yöntemiyle amaç fonksiyonu genellikle şu şekilde formüle edilir:

$$\text{Min } f(x) = \mu \sum_i \ln(s_i) \quad (15)$$

Burada μ , bariyer parametresi; s_i , eşitsizlik kısıtlarına ilişkin boşluk değişkenleridir. Hem çözüm hassasiyeti hem de algoritmik verimlilik açısından ileri düzey avantajlar sunar.

3.6. Kuadratik Programlama (QP)

Amaç fonksiyonunun kuadratik, kısıtların ise doğrusal olduğu durumlarda kuadratik programlama kullanılabilir. Özellikle ikinci dereceden üretim maliyet fonksiyonlarının optimize edilmesinde etkilidir. Ancak, güç akış denklemlerinin doğrusal hale getirilmesi gerektiğinden, çözüm hassasiyeti bazı durumlarda azalabilir (Reid & Hasdorff, 2007).

Tablo 1. Klasik Yöntemlerin Avantaj ve Dezavantajları

Özellik	Avantaj	Dezavantaj
Newton-Raphson	Hızlı yakınsama	Başlangıç noktasına duyarlılık
LP	Hızlı ve kararlı	Gerçekçilikten uzaklaşabilir
NLP	Doğrusal olmayan sistemlerde etkili	Yerel minimuma saplanabilir
İç Nokta	Büyük sistemlerde güçlü performans	Karmaşık algoritma yapısı
QP	Maliyet fonksiyonlarında uygundur	Kısıt doğrusal varsayımı gerekir

Sonuç olarak, klasik çözüm yöntemleri, OGA probleminin deterministik yapısını temel alarak yüksek çözüm doğruluğu ve hızlı hesaplama avantajları sunmaktadır. Ancak, bu yöntemlerin karmaşık, çok amaçlı ve çok modlu yapıya sahip modern enerji sistemlerinde bazı sınırlamaları bulunmaktadır. Tablo 1’de klasik yöntemlerin avantaj ve dezavantajları tablo halinde gösterilmiştir. Bu nedenle son yıllarda klasik yöntemler, evrimsel algoritmalar ve yapay zeka tabanlı yaklaşımlarla tamamlanarak daha esnek OGA çözümleri elde edilmektedir.

4. META-SEZGİSEL YÖNTEMLERİN SINIFLANDIRILMASI

Meta-sezgisel algoritmalar, genel olarak doğadan ilham alan ve deterministik olmayan arama mekanizmaları kullanan sezgisel yaklaşımlar olarak tanımlanabilir. OGA problemi bağlamında kullanılan başlıca meta-sezgisel yöntemler aşağıdaki başlıklar altında sınıflandırılabilir:

4.1 Evrimsel Algoritmalar

- **Genetik Algoritma (GA):** Evrim teorisine dayalı, kromozom temelli arama yöntemidir. Çaprazlama ve mutasyon operatörleri ile çözüm uzayında dolaşır.
- **Farklı Evrim (DE):** Vektör tabanlı mutasyon ve yeniden kombinasyon süreçleri ile çözümleri geliştirir. Sürekli değerli problemler için uygundur.

4.2 Sürü Zekâsı Tabanlı Yöntemler

- **Parçacık Sürü Optimizasyonu (PSO):** Kuş ve balık sürülerinin hareketinden ilham alan, çözüm adaylarını hız ve konum vektörleri ile güncelleyen bir yöntemdir.
- **Yapay Arı Kolonisi (ABC):** Arıların nektar arama davranışına dayanır. Çalışan, gözlemci ve keşifçi arı fazları ile çözüm geliştirilir.

4.3 Fiziksel ve Sosyal Davranış Tabanlı Yöntemler

- **Çekimsel Arama Algoritması (GSA):** Kütle çekimi yasasına dayanarak ajanlar arası etkileşimle çözüm aranır.
- **Jaya Algoritması:** En iyi çözüme yaklaşma ve en kötü çözümden uzaklaşma prensibine dayalı sade bir algoritmadır.
- **Öğretme-Öğrenme Temelli Optimizasyon (TLBO):** Bir öğretmen ve öğrenciler arasında bilgi transferi modeliyle çalışır. Parametre ayarı gerektirmemesi avantaj sağlar.

4.4 Hibrit ve Uyarlanabilir Yöntemler

- **GA-PSO, DE-ABC, TLBO-Jaya** gibi hibrit yöntemler, birden fazla algoritmanın güçlü yönlerini birleştirerek daha dengeli bir arama süreci sunmayı hedefler.
- Uyarlanabilir algoritmalar ise parametrelerini probleme göre otomatik olarak ayarlayarak esneklik kazandırır.

5. ÇOK AMAÇLI OPTİMİZASYON VE PARETO YAKLAŞIMI

Güç sistemlerinde optimal güç akışı (OGA) problemleri genellikle tek bir hedefle sınırlı değildir. Minimum üretim maliyeti, minimum güç kaybı, voltaj kararlılığı, çevresel emisyonlar ve güvenilirlik gibi birçok kriter aynı anda optimize edilmek istenir. Bu nedenle çok amaçlı optimizasyon (Multi-Objective Optimization - MOO) yaklaşımları, OGA problemlerinin çözümünde daha gerçekçi ve etkili bir alternatif sunar.

Meta-sezgisel algoritmaların çok amaçlı versiyonları, Pareto optimalite prensibini esas alarak birden fazla hedef fonksiyon arasında denge kurmayı amaçlar. Bir çözümün Pareto optimal olması, başka bir çözümün tüm hedeflerde daha iyi olamayacağı anlamına gelir. Bu yaklaşımla elde edilen Pareto ön cepheleri (Pareto fronts), karar vericilere farklı tercihleri değerlendirme olanağı sağlar.

Literatürde en çok kullanılan çok amaçlı meta-sezgisel yöntemler arasında NSGA-II (Non-dominated Sorting Genetic Algorithm II), MOPSO (Multi-Objective Particle Swarm Optimization), MOABC, MODE, MOJaya ve MO-TLBO yer almaktadır. Bu yöntemler ile yakıt maliyeti vs. kayıplar, emisyon vs. gerilim saptması gibi farklı hedef çiftleri dengeli şekilde optimize edilmiştir. Pareto tabanlı analizler, sistem planlamacıları için çok kıymetli karar destek araçları sunmaktadır.

6. META-SEZGİSEL YÖNTEMLERİN GÜÇ SİSTEMLERİNE UYGULANMASINDAKİ ZORLUKLAR

Meta-sezgisel yöntemlerin OGA çözümlerinde sunduğu avantajlara rağmen, uygulamada çeşitli zorluklar da mevcuttur:

- **Küresel optimum garantisi yoktur:** Meta-sezgisel yöntemler, küresel optimuma yakın çözümler üretebilse de, çözümün gerçekten küresel optimum olup olmadığı garanti edilemez.
- **Parametre hassasiyeti:** Birçok algoritma, uygun parametre ayarı yapılmadığında düşük performans gösterebilir. Bu durum kullanıcı deneyimine bağlıdır.
- **Yavaş yakınsama ve hesap yükü:** Özellikle büyük ölçekli sistemlerde, çözümün hesaplama süresi artabilir. Yüksek işlem gücü gereksinimi söz konusu olabilir.
- **Kısıtların ele alınması:** Karmaşık kısıt setlerinin (voltaj, reaktif güç, hat kapasiteleri vb.) algoritmalara entegrasyonu bazen zordur.
- **Gerçek zamanlı uygulama kısıtları:** Meta-sezgisel algoritmaların doğası gereği iteratif yapıları, bazı gerçek zamanlı uygulamalarda kullanımını sınırlayabilir.

7. GELECEK ÇALIŞMALAR İÇİN ÖNERİLER

Meta-sezgisel yöntemlerin güç sistemlerinde daha etkin kullanılabilmesi ve mevcut sınırlamaların aşılması için aşağıdaki öneriler dikkate alınabilir:

- **Uyarlanabilir ve parametresiz algoritmalar:** Kullanıcı müdahalesini azaltan, algoritma içi öğrenmeye dayalı yapılar geliştirilebilir (örneğin Jaya, TLBO gibi).
- **Hibrit yaklaşımlar:** Birden fazla algoritmanın güçlü yönlerini birleştiren yapılarla çözüm kalitesi ve yakınsama süresi iyileştirilebilir.
- **Veri temelli yöntemlerle bütünleşme:** Yapay sinir ağları, derin öğrenme ve makine öğrenmesi teknikleriyle algoritmalar desteklenerek daha akıllı optimizasyon yapıları geliştirilebilir.
- **Gerçek zamanlı ve dağıtık çözümler:** Özellikle mikro şebekeler ve akıllı şebekelerde kullanılabilecek, dağıtık ve hızlı çalışan versiyonlar tasarlanabilir.
- **Enerji dönüşüm teknolojileri ile entegrasyon:** Yenilenebilir enerji, enerji depolama, elektrikli araçlar gibi yeni sistem unsurlarının dahil edildiği OGA modelleriyle çalışmalar genişletilmelidir.
- **Benchmark test sistemleriyle karşılaştırmalı analiz:** IEEE 14, 30, 57, 118 gibi yaygın test sistemlerinde standartlaştırılmış karşılaştırmalar yapılması önerilir.

Tablo 2’de yıllar içinde OGA problemlerinin çözümünde kullanılan meta-sezgisel algoritmalar seçilen test sistemlerine göre incelenmiş, amaç fonksiyonları, tekli veya çoklu amaç fonksiyonlarına göre sıralanmıştır. İncelenen çalışmalarda test sistemi olarak IEEE 30 baralı test sistemi yaygın olarak kullanılmıştır. Hemen hemen tüm çalışmalarda maliyet amaç fonksiyonu optimize edilmiştir. Klasik GA, PSO gibi yöntemlerden biyolojik ve sosyal davranış temelli (Krill, Squirrel, Goose, Manta ray vb.) yöntemlere geçiş olmuş. 2010 sonrası Çok Amaçlı

Sırakaya¹ ve ark.

OGA (MO-OGA) modelleri ön plana çıkmış. 2024 yılı itibarıyla DRL (Deep Reinforcement Learning), QIGA gibi yapay zekâ ve kuantum esinli modeller de kullanılmaya başlanmıştır.

Tablo 2. Literatürdeki OGA çalışmalarında kullanılan meta-sezgisel algoritmalar.

YIL	Ref.	Algoritma	Amaç Fonksiyonu				Amaç	Test Sistemi
			F ₁	F ₂	F ₃	F ₄		
2002	(Bakirtzis, Biskas, Zoumas, & Petridis, 2002)	Enhanced genetic algorithm (EGA)	x				T	IEEE 30
2006		Particle swarm optimization (PSO)		x	x		T	IEEE 30-118
2010	(Vlachogiannis & Lee, 2006)	Genetic Algorithm (GA)	x	x	x		T	IEEE 30
2010		Differential evolution (DE)	x		x		T	IEEE 30
2010	(Todorovski & Rajicic, 2006)	Enhanced Genetic Algorithm (EGA)	x	x	x		T	IEEE 30
2011		Particle swarm optimization (PSO)	x			x	T/Ç	IEEE 30-118
2011	(Abou El Ela ve ark., 2010)	Particle swarm optimization (PSO)	x	x		x	T	IEEE 30-118
2011		Biogeography-based optimisation (BBO)	x		x		T	IEEE 30
2011	(Kumari & Maheswarapu, 2010)	Harmony search (HS)	x	x	x		T/Ç	IEEE 30
2011		Honey Bee Mating Optimisation (HBMO)	x	x		x	T	IEEE 14-30-118
2012	(Hazra & Sinha, 2011)	Genetic Algorithm (GA)	x		x		T	IEEE 30
2012		Particle swarm optimization (PSO)	x	x	x	x	T	IEEE 30-118
2012	(Liang ve ark., 2011)	Bacterial foraging (BF)	x		x		T	IEEE 30-118
2013		Artificial bee colony (ABC)	x	x	x	x	T	IEEE 30-118
2013	(Bhattacharya & Chattopadhyay, 2011)	Harmony search method (HS)	x		x		T	IEEE 6-14-30-57-118
2014		Artificial bee colony (ABC)	x	x		x	T/Ç	IEEE 30
2014	(Sivasubramani & Swarup, 2011)	Teaching-learning based optimization (TLBO)	x		x		T	IEEE 30-118
2014		Teaching-learning based optimization (TLBO)	x			x	T	IEEE 30-57
2014	(Niknam ve ark., 2011)	Modified imperialist competitive algorithm-teaching learning algorithm (MICA-TLBO)	x		x		T	IEEE 30-57
2014		Krill herd algorithm (KHA)	x	x	x		T/Ç	IEEE 9-30-57
2015	(Attia, Al-Turki, & Abusorrah, 2012)	Differential evolution (DE)	x	x	x		T/Ç	IEEE 30-118
2015		Artificial bee colony (ABC)	x	x	x	x	T	IEEE 30-57

Sırakaya¹ ve ark.

2015	(Niknam, ve ark., 2012)	Biogeography-based optimization (BBO)	x		x		T	IEEE 30-57
2015		Teaching-learning based optimization (TLBO)	x		x		T	IEEE 30-57
2015	(Amjady, Fatemi, & Zareipour, 2012)	Krill herd algorithm (KHA)	x	x	x		T	IEEE 57
2016		Particle swarm optimization (PSO)	x	x			T	IEEE 30
2016	(Khorsandi, Hosseinian, & Ghazanfari, 2013)	Differential evolution (DE)	x	x	x		T/Ç	IEEE 30-57
2016		Harmony search algorithm (HSA)	x				T	IEEE 30-57-118
2016	(Sinsuphan, Leeton, & Kulworawanichpong, 2013)	Grenade explosion method (GEM)	x	x	x	x	T/Ç	IEEE 30
2016		Glowworm Swarm Optimization (GSO)	x			x	T/Ç	IEEE 30
2017	(Chen, Bo, & Zhu, 2014)	Differential evolution (DE)	x			x	T	IEEE 30
2017		Differential evolution (DE)	x	x	x		T/Ç	IEEE 57
2017	(Boucekara, Abido, & Boucherma, 2014)	Artificial bee colony (ABC)	x	x			T	IEEE 30-118
2018		Modified Sine-Cosine algorithm (MSCA)	x	x	x		T	IEEE 30-118
2019	(Shabanpour-Haghighi, Seifi, & Niknam, 2014)	Moth Swarm Algorithm (MSA) ve Gravitational Search Algorithm (GSA)	x	x			T	IEEE 30-57-118
2019		JAYA	x	x		x	T	IEEE 30, 118-bus
2019	(Ghasemi, ve ark., 2014)	Novel improved social spider optimization algorithm (NISSO)	x	x	x	x	T	IEEE 30-57-118
2019		Grasshopper optimization algorithm (GOA)	x	x	x	x	T/Ç	IEEE 30-57-118
2019	(Roy & Paul, 2015)	Artificial bee colony (ABC), Wind Driven Optimization (WDO), Gravitational Search Algorithm (GSA)	x	x	x		T	IEEE 9-30-57
2020		Particle swarm optimization (PSO)	x	x		x	T/Ç	IEEE 30
2020	(El-Fergany & Hasanien, 2015)	Differential-based harmony search algorithm (DH)	x			x	T	IEEE 57-118
2020		JAYA	x	x	x		T	IEEE 30-118
2021	(He, ve ark., 2015)	Improved Wind-Driven Algorithm (IWDA)	x	x			T	14-124
2021		GOA Grasshopper Optimization Algorithm (GOA),	x	x		x	T	IEEE 30
2022	(Kumar & Premalatha, 2015)	Manta ray foraging optimizer (MRF)	x			x	T/Ç	IEEE 30
2023		Teaching-learning based optimization (TLBO)	x	x	x		T/Ç	IEEE 30-57

Sırakaya¹ ve ark.

2023	(Ghasemi, ve ark., 2015)	Wild Horse Optimizer (WHO)	x	x	x	x	T	IEEE 30
2023		Turbulent flow of water-based optimization) TFWO	x	x	x	x	T/Ç	IEEE 30
2024	(Mukherjee & Mukherjee, 2015)	Deep Reinforcement Learning (DRL) ve Quantum Inspired Genetic Algorithm (DRL-QIGA).	x	x	x		T/Ç	IEEE 30
2024		Self-adaptive wild goose algorithm (SAWGA)	x	x	x	x	T	IEEE 30-118
2024	(Ravi, 2016)	Squirrel search algorithm (SSA)	x		x	x	T/Ç	IEEE 30
2024		Democratic political algorithm (DPA)	x			x	T/Ç	IEEE 30

F₁: Maliyet Optimizasyonu, F₂: Güç Kaybı Optimizasyonu, F₁: Gerilim Sapması Optimizasyonu, F₁: Emisyon Optimizasyonu, T: Tekli Amaç Fonksiyonu, Ç: Çoklu Amaç Fonksiyonu

8. SONUÇ

Bu derleme çalışmasında, elektrik güç sistemlerinde optimal güç akışı (OGA) probleminin çözümünde meta-sezgisel yöntemlerin kullanımı detaylı bir şekilde incelenmiştir. Meta-sezgisel algoritmalar, geleneksel yöntemlerin karşılaştığı hesaplama zorluklarını aşmak ve karmaşık sistem koşullarında küresel çözüme yakın sonuçlar elde etmek için etkili araçlar sunmaktadır. Genetik algoritma, parçacık sürü optimizasyonu, yapay arı kolonisi, Jaya ve TLBO gibi algoritmaların tek başına veya hibrit yapılarla kullanımı sayesinde hem tek hem çok amaçlı OGA problemlerinde başarılı uygulamalar gerçekleştirilmiştir. Literatürden elde edilen bulgular, bu yöntemlerin çözüm kalitesi, esneklik ve çok amaçlılık konularında önemli avantajlar sunduğunu ortaya koymaktadır. Ancak, parametre bağımlılığı, uzun hesaplama süreleri ve gerçek zamanlı uygulama sınırlamaları gibi bazı zorlukların da var olduğu görülmektedir. Bu bağlamda, gelecekte geliştirilecek araştırmaların parametresiz algoritmalar, yapay zekâ destekli hibrit çözümler, dağıtık ve uyarlanabilir yapılar gibi alanlara yönelmesi önerilmektedir. Sonuç olarak, meta-sezgisel yöntemlerin OGA çözümlerinde sunduğu yüksek potansiyel, bu alanda sürdürülebilir, güvenilir ve ekonomik enerji yönetimi stratejileri geliştirmek isteyen araştırmacılar ve mühendisler için güçlü bir araç olmaya devam etmektedir.

Yazar Katkısı

Fikir ve tasarım, B.T.; Makale yazımı, M.S.; Veri toplama, B.T., Veri analizi, M.S.; Yazılım, M.S; Kaynak sağlama, B.T.

Çıkar Çatışması

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

KAYNAKÇA

- Abbasi, M., Abbasi, E., & Mohammadi-Ivatloo, B. (2021). Single and multi-objective optimal power flow using a new differential-based harmony search algorithm. *Journal of Ambient Intelligence and Humanized Computing*, 12(1), 851-871.
- Abou El Ela, A., Abido, M., & Spea, S. (2010). Optimal power flow using differential evolution algorithm. *Electric Power Systems Research*, 80(7), 878-885.
- Ahmadipour, M., Ali, Z., Othman, M. M., Bo, R., Javadi, M. S., Ridha, H. M., & Alrifay, M. (2024). A high-performance democratic political algorithm for solving multi-objective optimal power flow problem. *Expert systems with applications*, 239, 122367.
- Alghamdi, A. S. (2023). Optimal power flow of hybrid wind/solar/thermal energy integrated power systems considering costs and emissions via a novel and efficient search optimization algorithm. *Applied Sciences*, 13(8), 4760.
- Amjady, N., Fatemi, H., & Zareipour, H. (2012). Solution of optimal power flow subject to security constraints by a new improved bacterial foraging method. *IEEE Transactions on Power Systems*, 27(3), 1311-1323.
- Attia, A.-F., Al-Turki, Y. A., & Abusorrah, A. M. (2012). Optimal power flow using adapted genetic algorithm with adjusting population size. *Electric Power Components and Systems*, 40(11), 1285-1299.
- Attia, A.-F., El Sehiemy, R. A., & Hasanien, H. M. (2018). Optimal power flow solution in power systems using a novel Sine-Cosine algorithm. *International Journal of Electrical Power & Energy Systems*, 99, 331-343.

Sırakaya¹ ve ark.

- Bai, W., Eke, I., & Lee, K. Y. (2017). An improved artificial bee colony optimization algorithm based on orthogonal learning for optimal power flow problem. *Control Engineering Practice*, 61, 163-172.
- Bakirtzis, A. G., Biskas, P. N., Zoumas, C. E., & Petridis, V. (2002). Optimal power flow by enhanced genetic algorithm. *IEEE Transactions on Power Systems*, 17(2), 229-236.
- Bhattacharya, A., & Chattopadhyay, P. (2011). Application of biogeography-based optimisation to solve different optimal power flow problems. *IET generation, transmission & distribution*, 5(1), 70-80.
- Biswas, P. P., Suganthan, P., & Amaratunga, G. A. (2017). Optimal power flow solutions incorporating stochastic wind and solar power. *Energy conversion and management*, 148, 1194-1207.
- Boucekara, H., Abido, M., & Boucherma, M. (2014). Optimal power flow using teaching-learning-based optimization technique. *Electric Power Systems Research*, 114, 49-59.
- Boucekara, H., Chaib, A., & Abido, M. (2016). Multiobjective optimal power flow using a fuzzy based grenade explosion method. *Energy systems*, 7, 699-721.
- Cain, M. B., O'Neill, R. P., & Castillo, A. (2012). History of optimal power flow and formulations. *Federal Energy Regulatory Commission*, 1, 1-36.
- Capitanescu, F. (2016). Critical review of recent advances and further developments needed in AC optimal power flow. *Electric Power Systems Research*, 136, 57-68.
- Chen, H., Bo, M. L., & Zhu, Y. (2014). Multi-hive bee foraging algorithm for multi-objective optimal power flow considering the cost, loss, and emission. *International Journal of Electrical Power & Energy Systems*, 60, 203-220.
- Devarapalli, R., Bhattacharyya, B., & Sinha, N. K. (2020). An intelligent EGWO-SCA-CS algorithm for PSS parameter tuning under system uncertainties. *International Journal of Intelligent Systems*, 35(10), 1520-1569.
- Dommel, H. W., & Tinney, W. F. (1968). Optimal power flow solutions. *IEEE Transactions on power apparatus and systems*(10), 1866-1876.
- El-Fergany, A. A., & Hasanien, H. M. (2015). Single and multi-objective optimal power flow using grey wolf optimizer and differential evolution algorithms. *Electric Power Components and Systems*, 43(13), 1548-1559.
- Elattar, E. E., & ElSayed, S. K. (2019). Modified JAYA algorithm for optimal power flow incorporating renewable energy sources considering the cost, emission, power loss and voltage profile improvement. *Energy*, 178, 598-609.
- Ermis, S., Yesilbudak, M., & Bayindir, R. (2019). *Optimal power flow using artificial bee colony, wind driven optimization and gravitational search algorithms*. Paper presented at the 2019 8th International Conference on Renewable Energy Research and Applications (ICRERA).
- Ermiş, S. (2023). Multi-objective optimal power flow using a modified weighted teaching-learning based optimization algorithm. *Electric Power Components and Systems*, 51(20), 2536-2556.
- Frank, S., Steponavice, I., & Rebennack, S. (2012). Optimal power flow: A bibliographic survey I: Formulations and deterministic methods. *Energy systems*, 3, 221-258.
- Gao, H., Liu, J., Wang, L., & Liu, Y. (2017). Cutting planes based relaxed optimal power flow in active distribution systems. *Electric Power Systems Research*, 143, 272-280.
- Ghasemi, M., Ghavidel, S., Gitizadeh, M., & Akbari, E. (2015). An improved teaching-learning-based optimization algorithm using Lévy mutation strategy for non-smooth optimal power flow. *International Journal of Electrical Power & Energy Systems*, 65, 375-384.
- Ghasemi, M., Ghavidel, S., Rahmani, S., Roosta, A., & Falah, H. (2014). A novel hybrid algorithm of imperialist competitive algorithm and teaching learning algorithm for optimal power flow problem with non-smooth cost functions. *Engineering Applications of Artificial Intelligence*, 29, 54-69.
- Gurumoorthi, G., Senthilkumar, S., Karthikeyan, G., & Alsaif, F. (2024). A hybrid deep learning approach to solve optimal power flow problem in hybrid renewable energy systems. *Scientific Reports*, 14(1), 19377.
- Hassan, M. H., Kamel, S., & Hussien, A. G. (2023). Optimal power flow analysis considering renewable energy resources uncertainty based on an improved wild horse optimizer. *IET generation, transmission & distribution*, 17(16), 3582-3606.
- Hazra, J., & Sinha, A. (2011). A multi-objective optimal power flow using particle swarm optimization. *European transactions on electrical power*, 21(1), 1028-1045.
- He, X., Wang, W., Jiang, J., & Xu, L. (2015). An improved artificial bee colony algorithm and its application to multi-objective optimal power flow. *Energies*, 8(4), 2412-2437.
- Ilyas, M. A., Abbas, G., Alquthami, T., Awais, M., & Rasheed, M. B. (2020). Multi-objective optimal power flow with integration of renewable energy sources using fuzzy membership function. *IEEE Access*, 8, 143185-143200.
- Kahraman, H. T., Akbel, M., & Duman, S. (2022). Optimization of optimal power flow problem using multi-objective manta ray foraging optimizer. *Applied Soft Computing*, 116, 108334.

Sırakaya¹ ve ark.

- Khorsandi, A., Hosseini, S., & Ghazanfari, A. (2013). Modified artificial bee colony algorithm based on fuzzy multi-objective technique for optimal power flow problem. *Electric Power Systems Research*, 95, 206-213.
- Kumar, A. R., & Premalatha, L. (2015). Optimal power flow for a deregulated power system using adaptive real coded biogeography-based optimization. *International Journal of Electrical Power & Energy Systems*, 73, 393-399.
- Kumari, M. S., & Maheswarapu, S. (2010). Enhanced genetic algorithm based computation technique for multi-objective optimal power flow solution. *International Journal of Electrical Power & Energy Systems*, 32(6), 736-742.
- Liang, R.-H., Tsai, S.-R., Chen, Y.-T., & Tseng, W.-T. (2011). Optimal power flow by a fuzzy based hybrid particle swarm optimization approach. *Electric Power Systems Research*, 81(7), 1466-1474.
- Momoh, J. A., & Zhu, J. (1999). Improved interior point method for OPF problems. *IEEE Transactions on Power Systems*, 14(3), 1114-1120.
- Mukherjee, A., & Mukherjee, V. (2015). Solution of optimal power flow using chaotic krill herd algorithm. *Chaos, Solitons & Fractals*, 78, 10-21.
- Nguyen, T. T. (2019). A high performance social spider optimization algorithm for optimal power flow solution with single objective optimization. *Energy*, 171, 218-240.
- Niknam, T., Narimani, M., Aghaei, J., & Azizpanah-Abarghoee, R. (2012). Improved particle swarm optimisation for multi-objective optimal power flow considering the cost, loss, emission and voltage stability index. *IET generation, transmission & distribution*, 6(6), 515-527.
- Niknam, T., Narimani, M., Aghaei, J., Tabatabaei, S., & Nayeripour, M. (2011). Modified honey bee mating optimisation to solve dynamic optimal power flow considering generator constraints. *IET generation, transmission & distribution*, 5(10), 989-1002.
- Niu, M., Wan, C., & Xu, Z. (2014). A review on applications of heuristic optimization algorithms for optimal power flow in modern power systems. *Journal of Modern Power Systems and Clean Energy*, 2(4), 289-297.
- Pandiarajan, K., & Babulal, C. (2016). Fuzzy harmony search algorithm based optimal power flow for power system security enhancement. *International Journal of Electrical Power & Energy Systems*, 78, 72-79.
- Ravi, K. (2016). Optimal power flow considering intermittent wind power using particle swarm optimization. *International Journal of Renewable Energy Research (IJRER)*, 6(2), 504-509.
- Reddy, S. S., & Rathnam, C. S. (2016). Optimal power flow using glowworm swarm optimization. *International Journal of Electrical Power & Energy Systems*, 80, 128-139.
- Reid, G. F., & Hasdorff, L. (2007). Economic dispatch using quadratic programming. *IEEE Transactions on power apparatus and systems*(6), 2015-2023.
- Roy, P. K., & Paul, C. (2015). Optimal power flow using krill herd algorithm. *International transactions on electrical energy systems*, 25(8), 1397-1419.
- Shabanpour-Haghighi, A., Seifi, A. R., & Niknam, T. (2014). A modified teaching-learning based optimization for multi-objective optimal power flow problem. *Energy conversion and management*, 77, 597-607.
- Shaheen, A. M., El-Sehiemy, R. A., & Farrag, S. M. (2016). Solving multi-objective optimal power flow problem via forced initialised differential evolution algorithm. *IET generation, transmission & distribution*, 10(7), 1634-1647.
- Shaheen, A. M., Farrag, S. M., & El-Sehiemy, R. A. (2017). MOPF solution methodology. *IET generation, transmission & distribution*, 11(2), 570-581.
- Shilaja, C., & Arunprasath, T. (2019). Optimal power flow using moth swarm algorithm with gravitational search algorithm considering wind power. *Future generation computer systems*, 98, 708-715.
- Sinsuphan, N., Leeton, U., & Kulworawanichpong, T. (2013). Optimal power flow solution using improved harmony search method. *Applied Soft Computing*, 13(5), 2364-2374.
- Sivasubramani, S., & Swarup, K. (2011). Multi-objective harmony search algorithm for optimal power flow problem. *International Journal of Electrical Power & Energy Systems*, 33(3), 745-752.
- Stott, B., & Marinho, J. (1979). Linear programming for power-system network security applications. *IEEE Transactions on power apparatus and systems*(3), 837-848.
- Sulaiman, M. H., & Mustaffa, Z. (2021). Optimal power flow incorporating stochastic wind and solar generation by metaheuristic optimizers. *Microsystem Technologies*, 27(9), 3263-3277.
- Sulaiman, M. H., Mustaffa, Z., Mohamad, A. J., Saari, M. M., & Mohamed, M. R. (2021). Optimal power flow with stochastic solar power using barnacles mating optimizer. *International transactions on electrical energy systems*, 31(5), e12858.
- Sun, D. I., Ashley, B., Brewer, B., Hughes, A., & Tinney, W. F. (1984). Optimal power flow by Newton approach. *IEEE Transactions on power apparatus and systems*(10), 2864-2880.

Sırakaya¹ ve ark.

- Syed, M. S., Chintalapudi, S. V., & Sirigiri, S. (2021). Optimal power flow solution in the presence of renewable energy sources. *Iranian Journal of Science and Technology, Transactions of Electrical Engineering*, 45, 61-79.
- Taher, M. A., Kamel, S., Jurado, F., & Ebeed, M. (2019). Modified grasshopper optimization framework for optimal power flow solution. *Electrical Engineering*, 101, 121-148.
- Todorovski, M., & Rajicic, D. (2006). An initialization procedure in solving optimal power flow by genetic algorithm. *IEEE Transactions on Power Systems*, 21(2), 480-487.
- Trojovský, P., Trojovská, E., & Akbari, E. (2024). Economical-environmental-technical optimal power flow solutions using a novel self-adaptive wild geese algorithm with stochastic wind and solar power. *Scientific Reports*, 14(1), 4135.
- Vlachogiannis, J. G., & Lee, K. Y. (2006). A comparative study on particle swarm optimization for optimal steady-state performance of power systems. *IEEE Transactions on Power Systems*, 21(4), 1718-1728.
- Warid, W. (2020). Optimal power flow using the AMTPG-Jaya algorithm. *Applied Soft Computing*, 91, 106252.
- Wei, H., Sasaki, H., Kubokawa, J., & Yokoyama, R. (1998). An interior point nonlinear programming for optimal power flow problems with a novel data structure. *IEEE Transactions on Power Systems*, 13(3), 870-877.
- Yan, X., & Quintana, V. H. (1999). Improving an interior-point-based OPF by dynamic adjustments of step sizes and tolerances. *IEEE Transactions on Power Systems*, 14(2), 709-717.
- Zamzam, A. S., & Baker, K. (2020). *Learning optimal solutions for extremely fast AC optimal power flow*. Paper presented at the 2020 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm).
- Zhu, L., Zhou, Y., Jiang, R., & Su, Q. (2024). Surgical cases assignment problem using a multi-objective squirrel search algorithm. *Expert systems with applications*, 235, 121217.