ZORLU VE TAM AYRIŞTIRILAMAZ BİR PROBLEM ÜZERİNDE GENETİK ALGORİTMA DAVRANIŞININ ANALİZİ: CEC 2013 F15 ÖRNEĞİ

Zeynep Sarı
Kocaeli Üniversitesi, Teknoloji Fakültesi, Bilişim Sistemleri Mühendisliği
zeynep.sari@kocaeli.edu.tr, ORCID: 0000-0003-2834-3745

Prof. Dr. Mehmet Yıldırım
Kocaeli Üniversitesi, Teknoloji Fakültesi, Bilişim Sistemleri Mühendisliği
myildirim@kocaeli.edu.tr, ORCID: 000-0003-1676-1560

Özet

Büyük ölçekli küresel optimizasyon problemleri, yüksek boyutlu karar uzayları ve değişkenler arası güçlü etkileşimler nedeniyle evrimsel hesaplama alanında önemli bir araştırma konusudur. Bu problemlerin yapısal zorluklarını kontrollü bir şekilde yansıtan benchmark test fonksiyonları, algoritmaların adil ve kapsamlı bir şekilde değerlendirilmesinde önemli bir rol oynamaktadır. Bu çalışma, CEC2013 büyük ölçekli optimizasyon test fonksiyonlarından tam ayrıştırılamaz F15 problemini ele almaktadır. F15, Schwefel Problem 1.2 tabanlı, 1000 boyutlu ve kaydırılmış bir test fonksiyonudur. Çalışmanın amacı, bu zor fonksiyon üzerinde gerçel sayılı bir genetik algoritmanın arama davranışını ve fonksiyon değerlendirme bütçesi boyunca gösterdiği ilerlemeyi sistematik olarak incelemektir. Kullanılan yöntem; gerçel sayılı kromozom temsili, turnuva seçimi, segment tabanlı çaprazlama, polinomsal mutasyon ve elitist hayatta kalma mekanizmasını içermektedir. Çalışma, yeni bir algoritma önermekten ziyade, güçlü değişken bağımlılığı içeren bir benchmark probleminde algoritmik akışı ve yakınsama davranışını şeffaf bir şekilde belgelemeyi hedeflemektedir.

Anahtar Kelimeler: Büyük Ölçekli Küresel Optimizasyon, Genetik Algoritmalar, Ayrıştırılamaz Problemler, CEC Test Fonksiyonları

ANALYZING GENETIC ALGORITHM BEHAVIOR ON A CHALLENGING AND FULLY NONSEPARABLE PROBLEM: THE CASE OF CEC 2013 F15

Abstract

Large-scale global optimization problems are a significant research area in evolutionary computation due to their high-dimensional decision spaces and strong intervariate interactions. Benchmark test functions, which reflect the structural challenges of these problems in a controlled manner, play a crucial role in the fair and comprehensive evaluation of algorithms. This study addresses the F15 problem, one of the fully nonseparable test functions in the CEC2013 large-scale global optimization benchmark suite. F15 is a 1000-dimensional shifted test function based on Schwefel Problem 1.2. The aim of this study is to systematically examine the search behavior of a real-number genetic algorithm on this challenging function and its progress throughout the function evaluation budget. The methodology used includes real-number chromosome representation, tournament selection, segment-based crossover, polynomial mutation, and elitist survival mechanisms. Rather than proposing a new algorithm, the study aims to transparently document the algorithmic flow and convergence behavior in a benchmark problem with strong variable dependency.

Keywords: Large Scale Global Optimization, Genetic Algortihms, Nonseparable Problems, CEC Benchmark Functions.

1. GİRİŞ

Çağdaş hesaplamalı bilim ve mühendislikte optimizasyon problemleri, mühendislik tasarımı, finans ve makine öğrenimine kadar çeşitli alanlarda karşılaşılan önemli bir konudur. Bu problemlerde parametre sayısı büyüdükçe ve kısıtlamaların karmaşıklığı arttıkça çözümün makul bir zaman dilimi içerisinde çözümü de zorlaşmaktadır.

Bilgisayar bilimi alanında ve özellikle optimizasyon alanında, büyük ölçekli küresel optimizasyon problemlerini (Large Scale Global Optimization - LSGO) ele almada algoritmaların karmaşıklığı büyük rol oynamaktadır. Enerji depolama teknolojilerinde parametre ayarlaması (Wang vd. 2019), (An vd. 2025) araç rotası optimizasyon problemleri (Buyukozdemir vd. 2021) fiyat tahmin analizi (Jovanovic vd. 2025) ve çok oyunculu oyunların optimizasyonu (Zhong ve Yu 2024) gibi birçok problem, gerçek dünya problemleri olarak ele alınmaktadır. Bu problemler, yüksek boyutlu, birden fazla yerel optimum içerebilen ve çoğu zaman NP-zor karakter taşıyan karmaşık optimizasyon problemleridir (Nadimi-Shahraki ve Zamani 2022).

LSGO, genellikle yüzlerce veya binlerce olmak üzere, çok sayıda karar değişkenine sahip problemleri optimize etmeyi içerir (Chen vd. 2022). (Mahdavi, Shiri, ve Rahnamayan 2015a) tanımına göre LSGO problemlerinin uzay karar değişkeni sayısı n ise ve n>100 ise bu problem bir LSGO problemidir. LSGO'nun asıl amacı, yüksek boyutlu problemlerin karmaşıklıklarını aşmak için küresel optimizasyon algoritmalarının gelişimine odaklanarak ölçeklenebilirliklerini artırmaktır ve özellikle popülasyon tabanlı meta-sezgisel yöntemler üzerinde yoğunlaşmaktadır (Omidvar, Li, ve Yao 2021). LSGO problemlerinin çözmek için bugüne kadar pek çok algoritma önerilmiştir (Potter 1997; Potter ve De Jong 1994; Suganthan vd. 2005; Zoppoli, Sanguineti, ve Parisini 2001). LSGO alanında karşılaştırılabilir ve standart bir değerlendirme çerçevesi sunması açısından önemli kaynaklardan biri, (Li, Omidvar, vd. 2013) CEC 2013 özel oturumu için geliştirilen 15 fonksiyonlu benchmark setidir. Bu set, CEC 2010 (Ke vd. 2010) temelli olarak kısmen ayrışabilir, örtüşen ve tamamen ayrıştırılamaz yapıları içermekte; ayrıca kaydırma (shift), döndürme (rotation), T*osz* ve T*asym* gibi gerçekçi dönüşümler ekleyerek problem karmaşıklığını artırmaktadır. Tüm fonksiyonlar $D = 1000$ boyutunda tasarlanmış olup, standart değerlendirme protokolü olarak her fonksiyon için 25 bağımsız çalıştırma ve maksimum 3×10^6 fonksiyon değerlendirmesi (FEs) önerilmiştir. Literatürde, CEC 2013 seti üzerinde diferansiyel evrim (DE), parçacık sürüsü optimizasyonu (PSO), kooperatif eşevrim (CC) ve memetik algoritma gibi gelişmiş yöntemlerle gerçekleştirilmiş pek çok çalışma mevcuttur (Abdollahzadeh vd. 2013; Abualigah, Almotairi, ve Elaziz 2023; A.J. ve P.D. 2015; Hadi, Mohamed, ve Jambi 2019a). Ancak, klasik ve herhangi bir gelişmiş mekanizma içermeyen standart Genetik Algoritma (GA)'nın, özellikle setin en zorlu kategorisi olan tamamen ayrıştırılamaz F15 fonksiyonu üzerindeki sistematik performansının incelendiği çalışmalar oldukça sınırlıdır.

LSGO problemlerinin zorluğu yalnızca yüksek boyutlu karar uzayları nedeniyle artan hesaplama yükünden değil, aynı zamanda değişken etkileşimleri, modüler yapıları, örtüşen/çakışan alt bileşenleri ve ayrıştırılamama gibi yapısal özelliklerinden gelmektedir. Bu nedenle standart meta-sezgisel yöntemlerin küçük ve orta boyutlu problemler üzerindeki başarısı, büyük ölçekli problemlere doğrudan taşınamamaktadır. Literatürdeki çalışmalar incelendiğinde, büyük ölçekli evrimsel optimizasyonun son yıllarda hem yöntem geliştirme hem de benchmark değerlendirme bakımından hızla büyüyen bir araştırma alanı olduğunu ortaya koymaktadır (Cabrera 2016; Liu vd. 2024; Mahdavi, Shiri, ve Rahnamayan 2015b).

GA'lar, seçilim, çaprazlama ve mutasyon operatörleriyle nüfus temelli arama gerçekleştiren temel evrimsel yöntemler arasında yer almaktadır. Özellikle sürekli değişkenli problemlerde gerçel sayılı gösterim, ikili kodlamaya göre daha doğal bir temsil sunduğu için tercih edilmektedir (Eb ve Kumar 1995). Gerçel sayılı GA'larda çaprazlama operatörünün ana arama mekanizması olarak güçlü bir rol oynadığı, mutasyonun ise çeşitliliği sürdürme ve yerel bölgelerde ince ayar yapma işlevi gördüğü çeşitli çalışmalarda ortaya konmuştur (Herrera, Lozano, ve Sánchez 2003).

Bu bağlamda, bu çalışmanın amacı, F15 gibi zor bir ayrıştırılamaz benchmark fonksiyonu üzerinde gerçel sayılı bir genetik algoritmanın işleyişini, operatör akışını ve fonksiyon değerlendirme bütçesi boyunca gösterdiği ilerlemeyi incelemektir. Çalışmanın katkısı, yeni bir meta-sezgisel önermekten ziyade, zor bir benchmark fonksiyonu üzerinde şeffaf ve tekrarlanabilir bir deney düzeniyle algoritma davranışını sistematik biçimde belgelemektir. Bu nedenle çalışma, tam benchmark karşılaştırması yerine odaklı bir deneysel durum çalışması olarak değerlendirilmelidir.

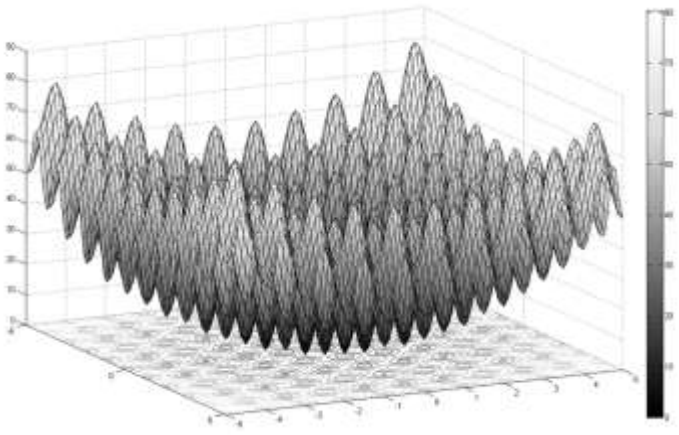
2. MATERYAL VE METOD

2.1. Problemin Tanımı

CEC 2013 test fonksiyonları, LSGO problemlerini dört ana kategori altında toplamaktadır: tam ayrışabilir (fully-separable) fonksiyonlar, kısmen ayrışabilir (partially separable) fonksiyonlar, örtüşen (overlapping) fonksiyonlar ve tam ayrıştırılamaz (fully-nonseparable) fonksiyonlar (Li, Tang, vd. 2013). Bu çalışmada, CEC2013 test fonksiyonlarının tam ayrıştırılamaz fonksiyonlar sınıfında yer alan F15 fonksiyonu ele alınmaktadır. F15 test fonksiyonu, teknik raporda Schwefel Problem 1.2 tabanlı, kaydırılmış ve 1000 boyutlu bir test fonksiyonu olarak tanımlanmaktadır.

$$f_{15}(z) = \sum_{i=1}^{D}(\sum_{j=1}^{i} x_i)^2 \quad (1)$$

Denklem (1)'de Kaydırılmış Schwefel's Problemi verilmektedir. Bütün değişkenler ($D = 1000$) tek bir büyük Schwefel 1.2 bloğu halinde ele alınmaktadır. Kaydırma ve Tosz, Tasym dönüşümlerinin ardından fonksiyon Denklem (1)'deki şekilde hesaplanmakta ve tamamen ayrıştırılamaz, tek modlu bir yapı oluşturmaktadır. Şekil 1'de gösterildiği üzere Schwefel Problem 1.2 fonksiyonunun temel biçimi, her değişkenin yalnızca kendi değerine değil, kendisinden önce gelen değişkenlerin toplamına da bağlı olması nedeniyle güçlü bir değişken bağımlılığı üretmektedir.



Şekil 13. Schwefel fonksiyonu (Kovačevi´kovačevi´c vd. 2013)

Kullanılan benchmark çağrı yapısında benchmark_func(x, func_num) fonksiyonu, fonksiyon numarasına göre uygun benchmark fonksiyonuna yönlendirme yapmaktadır. func_num == 15 olduğunda çağrı f15 fonksiyonuna aktarılmaktadır. $f_{15}(x)$ ise veri dosyasından kaydırma vektörünü yüklemekte, sınır kontrolünü yapmakta, karar vektöründen x_{opt} vektörünü çıkarmakta ve ardından Schwefel Problem 1.2 değerini hesaplamaktadır. Bu nedenle çalışma kapsamında kullanılan F15 değerlendirmesi, CEC2013 benchmark implementasyonuyla doğrudan uyumludur.

F15'in bu yapısı, problemi özellikle gerçel sayılı genetik algoritmalar açısından anlamlı kılmaktadır. Çünkü bu tür tam ayrıştırılamaz fonksiyonlarda değişkenler arası etkileşim yüksektir; dolayısıyla yalnızca boyut sayısı değil, değişkenler arasındaki bağımlılık yapısı da optimizasyon güçlüğünü artırmaktadır (LaTorre, Muelas, ve Pena 2011). Büyük ölçekli optimizasyon literatürü, bu tür yapıların hem ayrıştırma temelli yöntemler hem de klasik popülasyon temelli yöntemler için özel zorluklar taşıdığını vurgulamaktadır (Tarraq vd. 2021).

2.2. Genel Algoritmik Akış

Bu çalışmada kullanılan yöntem, gerçel sayılı kromozom temsiline sahip bir genetik algoritmadır. Ana akış; başlangıç popülasyonunun oluşturulması, amaç fonksiyonu değerlendirmesi, uygunluk dönüştürmesi, ebeveyn seçimi, çaprazlama, mutasyon, yeni nesil değerlendirmesi ve elitist hayatta kalma adımlarından oluşmaktadır. Bu akış, klasik gerçel sayılı genetik algoritma yapısıyla uyumlu olup, sürekli karar uzaylarında doğrudan temsil avantajından yararlanmaktadır (Eshelman ve Schaffer 1993).

Kod düzeyinde başlangıç popülasyonu, karar değişkenlerinin alt ve üst sınırları arasında düzgün rastgele dağılımla üretilmektedir. Ardından popülasyondaki her birey benchmark_func üzerinden değerlendirilmektedir. Bu noktada kullanılan çağrı yapısı, karar vektörlerini sütun bazlı benchmark biçimine dönüştürerek CEC2013 implementasyonuna göndermektedir. Böylece algoritmik yapı kullanıcı tarafında korunurken, benchmark değerlendirmesi resmi fonksiyon tanımları üzerinden yürütülmektedir.

2.3. Gerçel Sayılı Gösterim ve Başlatma

Gerçel sayılı genetik algoritmalarda kromozom, sürekli uzaydaki karar değişkenlerini doğrudan temsil eden kayan noktalı bir vektördür (Wright 1991). Bu çalışmadaki başlatma adımında her birey, ilgili benchmark fonksiyonunun sınır aralığında düzgün dağılımla üretilmektedir. F15 fonksiyonu için bu sınırlar benchmark tanımına uygun biçimde belirlenmektedir. Başlangıç popülasyonunun amacı, arama uzayına geniş bir ilk yayılım sağlayarak erken nesillerde keşif kapasitesini artırmaktır. Bu çalışma içerisinde popülasyon büyüklüğü 200 olarak seçilmiştir.

2.4. Uygunluk Dönüştürmesi ve Seçilim

Amaç fonksiyonundan elde edilen değerler doğrudan seçilimde kullanılmamaktadır; bunun yerine sıralama tabanlı bir uygunluk dönüştürmesi uygulanmaktadır. Böylece küçük amaç değeri daha yüksek uygunluk değerine karşılık gelmekte ve uygunluk dağılımı sayısal olarak daha kararlı hale getirilmektedir. Bu tercih, özellikle büyük ölçekli problemlerde çok geniş amaç değeri aralıklarının seçilim üzerinde bozucu etki üretmesini azaltmaktadır.

Seçilim aşamasında turnuva seçimi kullanılmaktadır. Bu yöntemde rastgele seçilen adaylar arasından daha yüksek uygunluk değerine sahip olan birey ebeveyn olarak belirlenmektedir. Çalışmada seçilmiş indeksler iki ebeveyn grubuna ayrılarak çaprazlama aşamasına aktarılmaktadır.

2.5. Çaprazlama Operatörü

GA'da sonucun başarısının büyük bölümünü etkili çaprazlama operatörlerinin kullanılmasına bağlıdır (Herrera vd. 2003). Bu çalışmada çaprazlama operatörü altı noktalı segment çaprazlama operatörüdür. Altı noktalı çaprazlama yapısında daha fazla segment değişimi gerçekleştirilerek ebeveynler arası bilgi karışımının artırılması hedeflenmiştir. Operatör amaç fonksiyonu değerlendirmesi yapmadan yalnızca yeni çözümler üretmektedir. Bu nedenle çaprazlama aşaması, standart benchmark muhasebesinde ek FEs maliyeti oluşturmamaktadır.

2.6. Mutasyon Operatörü

Mutasyon, genetik algoritmalarda çeşitliliği korumak ve aramanın erken yakınsamaya takılmasını engellemek için temel bir operatördür (Herrera vd. 2003). (Deb ve Deb t.y.) çalışmalarında mutasyonun yalnızca rastgele bozulma mekanizması olarak değil, uygun parametrelerle kullanıldığında arama davranışını önemli ölçüde etkileyen bir operatör olarak değerlendirilmesi gerektiğini göstermektedir.

Bu çalışmada polinomsal mutasyon tercih edilmiştir. Mutasyon adımı, bireyin belirli sayıda boyutunda kontrollü pertürbasyon oluşturarak yeni aday çözümler üretmektedir. Uygulanan mutasyon, jenerasyon ilerledikçe mutasyon oranını ve etkin boyut sayısını ayarlayan bir yapı ile kullanılmaktadır; böylece erken aşamalarda daha geniş keşif (exploration), geç aşamalarda ise daha yerel sömürü (exploitation) eğilimi hedeflenmektedir. Bu mutasyon operatörü de kendi içerisinde amaç fonksiyonu değerlendirmesi yapmadığı için, standart benchmark FEs muhasebesinde doğrudan ek maliyet üretmez; FEs artışı ancak mutasyon sonrası oluşan çocukların amaç fonksiyonunda değerlendirilmesi sırasında ortaya çıkar.

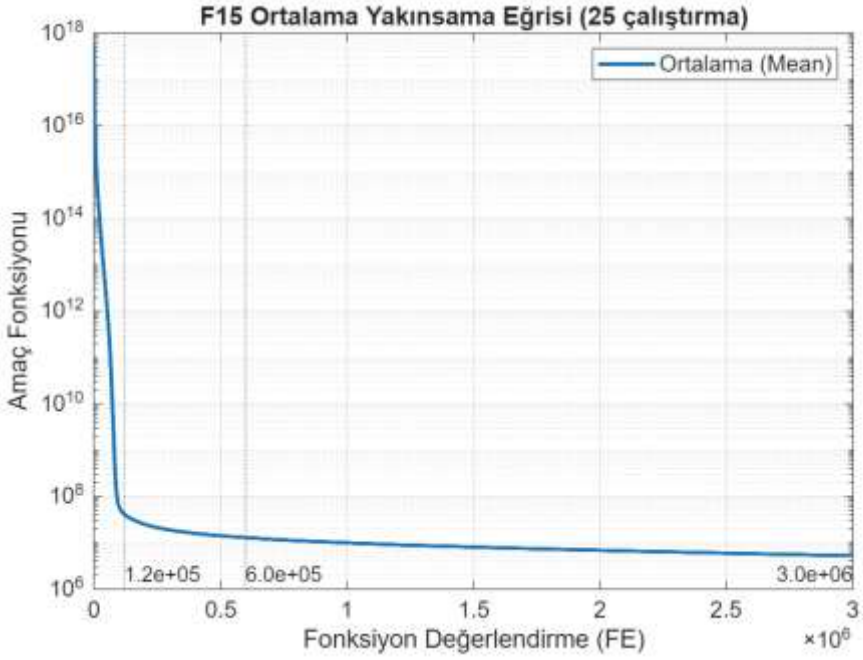
2.7. Elitist Hayatta Kalma ve FE Muhasebesi

Çalışmada, ebeveyn ve çocuk popülasyonları birlikte değerlendirilmekte, ardından en iyi bireyler seçilerek bir sonraki nesil oluşturulmaktadır. Bu yapı, elitizmin doğal olarak korunmasını sağlamaktadır. Böylece mevcut en iyi çözümün, daha kötü çocuklar nedeniyle kaybolması önlenmektedir.

Çalışmanın önemli bir yönü, performansın FEs bütçesi üzerinden izlenmesidir. Benchmark değerlendirmesi yalnızca amaç fonksiyonu çağrıları üzerinden sayılmakta; seçilim, çaprazlama ve mutasyon gibi operatörler FEs hesabına dahil edilmemektedir.

3. SONUÇLAR ve ANALİZ

Bu çalışmadaki deneysel analiz, Windows 10 işletim sistemi üzerinde çalışan ve AMD Ryzen 9 5900X 12-Core Processor işlemcisine sahip bir bilgisayarda, MATLAB R2025a ortamında yürütülmüştür. Çalışmada kullanılan F15 fonksiyonu, tüm değişkenlerin birbirleriyle etkileşimli olduğu tam ayrıştırılamaz yapısı nedeniyle büyük ölçekli optimizasyon problemleri arasında zorlayıcı bir test fonksiyonu olarak öne çıkmaktadır. Değişkenlerin bağımsız alt problemlere ayrıştırılmasını güçleştiren bu yapı, klasik GA'ların arama performansını sınayan önemli bir problemdir. Teknik raporda da F15 fonksiyonunun bu özelliği açıkça vurgulanmış ve deneylerin 25 bağımsız çalıştırma ile, en fazla 3E+06 FEs sınırı altında gerçekleştirilmesi önerilmiştir (Li, Tang, vd. 2013).



Şekil 14. F15 Fonksiyonu Ortalama Yakınsama Eğrisi

Şekil 2'de sunulan F15 fonksiyonuna ait ortalama yakınsama eğrisi, algoritmanın arama süreci boyunca çözüm kalitesini düzenli olarak iyileştirdiğini göstermektedir. Başlangıçta gözlenen yüksek hata değerleri, fonksiyon değerlendirme sayısındaki artışa paralel olarak azalmakta; bu durum, algoritmanın rastgele aramadan uzaklaşarak çözüm uzayının daha nitelikli bölgelerine yöneldiğine işaret etmektedir. Yakınsama

eğrisinin ilerleyen aşamalarda yatay seyir izlemesi ise iyileştirme hızının zamanla azaldığını ve algoritmanın son aşamalarda sınırlı düzeyde kazanım sağladığını ortaya koymaktadır. Bu davranış, özellikle tam ayrıştırılamaz nitelikteki ve kümülatif bağımlılık yapısı sergileyen Schwefel 1.2 türü problemlerde beklenen bir özellik olup, erken aşamalarda hızlı iyileşmelerin mümkün olduğu, buna karşın son aşamalarda yüksek hassasiyette iyileştirme yapmanın sınırlı kaldığı bir yapıyı yansıtmaktadır. Elde edilen bulgular, genetik algoritmanın istikrarlı bir yakınsama davranışı sergilediğini, ancak yerel sömürü mekanizmasının belirli bir düzeyde sınırlı kaldığını göstermektedir.

Tablo 9. F15 Fonksiyonu Sonuçları

FE	En İyi (Best)	En Kötü (Worst)	Ortanca (Median)	Ortalama (Mean)	Standart Sapma (StDev)
1.2E+05	3.23E+07	4.87E+07	4.04E+07	4.10E+07	5.19E+06
6E+05	1.11E+07	1.56E+07	1.29E+07	1.29E+07	1.04E+06
3E+06	4.49E+06	6.17E+06	5.35E+06	5.24E+06	3.69E+05

Tablo 1 incelendiğinde, F15 fonksiyonunda çözüm kalitesinin FEs bütçesi arttıkça belirgin ölçüde iyileştiği görülmektedir. 1.2E+05 FE seviyesinde ortalama değer 4.10E+07 iken, 6E+05 FE'de bu değer 1.29E+07'ye, 3E+06 FE sonunda ise 5.24E+06'ya düşmüştür. Bu bulgular, algoritmanın tüm değerlendirme süreci boyunca etkin bir öğrenme yeteneği sergilediğini ve erken yakınsamaya kapılmadığını göstermektedir. Ortalama uygunluk değerindeki bu düzenli düşüş, popülasyonun zaman içinde çözüm uzayının daha nitelikli bölgelerine yöneldiğini ve aramanın yalnızca başlangıç aşamalarında değil, orta ve geç evrelerde de verimli bir şekilde sürdüğünü ortaya koymaktadır. Bu durum, genetik algoritmanın arama-sömürü dengesini başarılı şekilde koruduğuna işaret etmektedir.

Aynı tablo üzerindeki en iyi (best), ortanca (median), en kötü (worst), ortalama (mean) ve standart sapma (std) değerlerinin birlikte değerlendirilmesi, algoritmanın yalnızca ortalama performans açısından değil, aynı zamanda çalıştırmalar arası tutarlılık bakımından da olumlu bir profil sergilediğini göstermektedir. 1.2E+05 FE düzeyinde 5.19E+06 olan standart sapma, 6E+05 FE'de 1.04E+06'ya, son aşamada ise 3.69E+05'e gerilemiştir. Bu azalış, ilerleyen iterasyonlarla birlikte bağımsız çalıştırmalar arasındaki dağılımın daraldığını ve algoritmanın daha kararlı sonuçlar ürettiğini ortaya koymaktadır. Son FE düzeyinde en iyi değerin 4.49E+06, en kötü değerin 6.17E+06 ve ortanca değerin 5.35E+06 olması, en iyi ile en kötü sonuç arasındaki farkın makul sınırlarda kaldığını; medyan ile ortalamanın birbirine yakın olması ise dağılımın dengeli olduğunu göstermektedir. Bu bulgular, elde edilen performansın yalnızca birkaç uç çalıştırmanın etkisiyle değil, 25 bağımsız çalıştırma boyunca sergilenen tutarlı davranışla ortaya çıktığını desteklemektedir.

Tablo 10. F15 Fonksiyonun 25 Bağımsız Çalıştırma Sonunda Çalışma Süreleri

Fonksiyon	Boyut	Mean (s)	StDev (s)	Toplam Zaman (saat)
F15	1000	2980.84	96.33	20.70

Tablo 2'de sunulan çalışma süreleri incelendiğinde, F15 fonksiyonu için 25 bağımsız çalıştırmanın ortalama süresi 2980,84 saniye, standart sapması ise 96,33 saniye olarak raporlanmıştır; toplam deney süresi 20,70 saat düzeyindedir. Bu sonuç iki açıdan önem taşımaktadır. Birincisi, süreye ilişkin standart sapmanın düşük olması, algoritmanın yalnızca çözüm kalitesi bakımından değil, çalışma zamanı bakımından da tutarlı olduğunu göstermektedir. İkincisi, toplam sürenin yüksekliği, F15'in hesaplama açısından maliyetli bir fonksiyon olduğunu ortaya koymaktadır. Nitekim CEC 2013 teknik raporunda F15, 10.000 FE başına yaklaşık 24,40 saniye ile en maliyetli fonksiyonlar arasında gösterilmektedir. Bu bağlamda elde edilen süre sonuçları, söz konusu yapısal zorlukla uyumlu olup F15'in hem algoritmik hem de hesaplama maliyeti açısından zorlu bir test problemi olduğunu doğrulamaktadır.

Tablo 11. F15 Fonksiyonu Sonuç Karşılaştırma (FEs= $3x10^6$)

Kalite / Algoritmalar	**GA**	**MOS (LaTorre, Muelas, ve Peña 2011)**	**DMDE (Nadimi-Shahraki ve Zamani 2022)**	**APSO (Sheng vd. 2023)**	**MLSHADE-SPA (Hadi, Mohamed ve Jambi 2019b)**
Ortalama (Mean)	5.24E+06	2.35E+06	1.31E+07	6.11E+06	2.76E+07
Standart Sapma (StDev)	3.69E+05	1.94E+05	1.81E+06	4.12E+05	9.01E+06

Tablo 3'te yer alan algoritmalar arası karşılaştırma, F15 fonksiyonu üzerindeki GA performansını daha net konumlandırmaktadır. Son FE düzeyinde GA için ortalama sonuç 5.24E+06, standart sapma ise 3.69E+05 olarak verilmiştir. Bu değerler, MOS yönteminin 2.35E+06 ortalamasından daha kötü, ancak APSO'nun, DMDE ve MLSHADE-SPA'nın sonuçlarından daha iyi durumdadır. Diğer bir ifadeyle GA, bu problemde en iyi yöntem olmamakla birlikte tamamen başarısız da değildir; karşılaştırılan yöntemler arasında orta-üst düzey bir performans sergilemektedir. MOS'un daha iyi sonuç vermesi, F15 gibi tam ayrıştırılamaz yapılarda daha gelişmiş arama stratejilerinin avantaj sağladığını gösterirken, GA'nın APSO, DMDE ve MLSHADE-SPA karşısında daha iyi performans göstermesi, kullanılan GA yapılandırmasının zorlu bir problemde dahi rekabetçi bir temel yöntem oluşturduğunu ortaya koymaktadır.

Genel olarak değerlendirildiğinde, F15 fonksiyonu üzerindeki sonuçlar üç temel noktaya işaret etmektedir. İlk olarak GA, bu problemde FE bütçesi boyunca düzenli bir yakınsama sergilemiş ve anlamlı düzeyde hata azaltımı sağlamıştır. İkinci olarak, bağımsız çalıştırmalar arasındaki düşük sapma değerleri, yöntemin kararlı ve tekrarlanabilir olduğunu göstermektedir. Üçüncü olarak, algoritmanın ulaştığı nihai çözüm kalitesi, tam ayrıştırılamaz büyük ölçekli yapılarda temel GA yaklaşımının belirli bir başarı sağlayabildiğini, ancak literatürdeki en iyi yöntemlerle rekabet edebilmek için daha gelişmiş mekanizmalarla desteklenmesi gerektiğini ortaya koymaktadır. Bu yönüyle F15 fonksiyon sonuçları, GA'nın güçlü yönünü istikrarlı yakınsama, zayıf yönünü ise nihai çözüm kalitesindeki sınırlı derinlik olarak tanımlamaktadır.

4. TARTIŞMA

Bu çalışmada elde edilen bulgular, standart GA'nın CEC2013 F15 fonksiyonu üzerinde düzenli bir yakınsama davranışı sergilediğini göstermektedir. Uygunluk değerlendirmesi sayısı arttıkça hata değerlerinin azalması, algoritmanın arama süreci boyunca çözüm kalitesini istikrarlı biçimde iyileştirdiğini

ortaya koymuştur. Bununla birlikte, yakınsama eğrisinin son aşamalarda yavaşlaması, yöntemin optimuma yüksek hassasiyetle yaklaşmada sınırlı kaldığını göstermektedir. Bu durum, F15 fonksiyonunun tam ayrıştırılamaz yapısıyla ilişkilidir. Değişkenler arasındaki güçlü etkileşimler, standart GA'nın arama sürecini zorlaştırmakta ve çözüm uzayında daha derin iyileştirmeler elde edilmesini güçleştirmektedir. Buna rağmen, elde edilen düşük standart sapma değerleri, algoritmanın bağımsız çalıştırmalar arasında tutarlı ve kararlı sonuçlar ürettiğini göstermektedir.

Literatürde yer alan yöntemlerle karşılaştırıldığında, kullanılan GA yapısının en iyi sonucu veren yöntem olmadığı, ancak tamamen yetersiz de kalmadığı görülmektedir. Özellikle bazı gelişmiş yöntemlerin gerisinde kalmasına rağmen, karşılaştırılan bazı algoritmalardan daha iyi sonuçlar üretmesi, bu yaklaşımın F15 gibi zor bir problem üzerinde rekabetçi bir temel yöntem olarak değerlendirilebileceğini göstermektedir. Genel olarak değerlendirildiğinde, bu çalışma klasik bir genetik algoritmanın F15 fonksiyonu üzerinde anlamlı bir iyileşme sağlayabildiğini ortaya koymaktadır.

KAYNAKLAR

Abdollahzadeh, A., Christie, M., Corne, D., Davies, B., & Elliott, M. (2013). An adaptive evolutionary algorithm for history-matching. *75th European Association of Geoscientists and Engineers Conference and Exhibition 2013 Incorporating SPE EUROPEC 2013: Changing Frontiers*, 5749-5762. https://doi.org/10.2118/164824-ms

Abualigah, L., Almotairi, K. H., & Elaziz, M. A. (2023). Multilevel thresholding image segmentation using meta-heuristic optimization algorithms: comparative analysis, open challenges and new trends. Içinde *Applied Intelligence* (C. 53, Sayı 10). Applied Intelligence. https://doi.org/10.1007/s10489-022-04064-4

A.J., U., & P.D., S. (2015). Crossover Operators in Genetic Algorithms: a Review. *ICTACT Journal on Soft Computing*, *06*(01), 1083-1092. https://doi.org/10.21917/ijsc.2015.0150

An, Q., Li, Y., Zhang, X., & Rao, L. (2025). Fast equalization of lithium battery energy storage system based on large-scale global optimization. *Journal of Power Sources*, *627*(September 2024), 235783. https://doi.org/10.1016/j.jpowsour.2024.235783

Buyukozdemir, K., Bas, A., Yildiz, K., & Uslu, B. C. (2021). A Review of Heuristic Approaches to Vehicle Routing Problems. *2021 IEEE Asia-Pacific Conference on Computer Science and Data Engineering, CSDE 2021*, 1-5. https://doi.org/10.1109/CSDE53843.2021.9718378

Cabrera, D. M. (2016). Evolutionary algorithms for large-scale global optimisation: a snapshot, trends and challenges. *Progress in Artificial Intelligence*, *5*(2), 85-89. https://doi.org/10.1007/s13748-016-0082-4

Chen, M., Du, W., Song, W., Liang, C., & Tang, Y. (2022). An improved weighted optimization approach for large-scale global optimization. *Complex and Intelligent Systems*, *8*(2), 1259-1280. https://doi.org/10.1007/s40747-021-00596-3

Deb, K., & Deb, D. (t.y.). *Analyzing Mutation Schemes for Real-Parameter Genetic Algorithms*.

Eb, K. D., & Kumar, A. (1995). Real-coded Genetic Algorithms with Simulated Binary Crossover: Studies on Multimodal and Multiobjective Problems. Içinde *Com plex Systems* (C. 9).

Eshelman, L. J., & Schaffer, J. D. (1993). *Real-Coded Genetic Algorithms and Interval-Schemata*. Foundations of Genetic Algorithms.

Hadi, A. A., Mohamed, A. W., & Jambi, K. M. (2019a). LSHADE-SPA memetic framework for solving large-scale optimization problems. *Complex and Intelligent Systems*, *5*(1), 25-40. https://doi.org/10.1007/s40747-018-0086-8

Hadi, A. A., Mohamed, A. W., & Jambi, K. M. (2019b). LSHADE-SPA memetic framework for solving large-scale optimization problems. *Complex and Intelligent Systems*, *5*(1), 25-40. https://doi.org/10.1007/s40747-018-0086-8

Herrera, F., Lozano, M., & Sánchez, A. M. (2003). A taxonomy for the crossover operator for real-coded genetic algorithms: An experimental study. *International Journal of Intelligent Systems*, *18*(3), 309-338. https://doi.org/10.1002/int.10091

Jovanovic, A., Jovanovic, L., Zivkovic, M., & Bacanin, N. (2025). Journal of Network and Computer Applications Particle swarm optimization tuned multi-headed long short-term memory networks approach for fuel prices forecasting. *Journal of Network and Computer Applications*, *233*(July 2024), 104048. https://doi.org/10.1016/j.jnca.2024.104048

Ke, T., Xiaodong, L., P. N., S., Zhenyu, Y., & Thomas, W. (2010). Benchmark Functions for the CEC'2013 Special Session and Competition on Large-Scale Global Optimization. *Technical report, Univ. of Science and Technology of China*, (1), 1-21. http://goanna.cs.rmit.edu.au/~xiaodong/cec13-lsgo/competition/cec2013-lsgo-benchmark-tech-report.pdf

Kovačevi´kovačevi´c, D., Mladenovi´c, N. M., Miloševi´c, P. M., Petrovi´c, B. P., & Dobri´cdobri´c, V. (2013). *Les Cahiers du GERAD Comparative Analysis of Continuous Global Optimization Methods*.

LaTorre, A., Muelas, S., & Peña, J. M. (2011). A MOS-based dynamic memetic differential evolution algorithm for continuous optimization: A scalability test. *Soft Computing*, *15*(11), 2187-2199. https://doi.org/10.1007/s00500-010-0646-3

LaTorre, A., Muelas, S., & Pena, J.-M. (2011). *A comprehensive comparison of large scal global optimizers* (ss. 517-549). Information Sciences.

Li, X., Omidvar, M. N., Qin, K., Tang, K., Omidvar, M. N., & Yang, Z. (2013). *Benchmark Functions for the CEC'2013 Special Session and Competition on Large-Scale Global Optimization*. http://goanna.cs.rmit.edu.au/˜xiaodong

Li, X., Tang, K., Omidvar, M. N., Yang, Z., & Qin, K. (2013). *Benchmark Functions for the CEC ' 2013 Special Session and Competition on Benchmark Functions for the CEC ' 2013 Special Session and Competition on Large-Scale Global Optimization*. (January).

Liu, J., Sarker, R., Elsayed, S., Essam, D., & Siswanto, N. (2024). Large-scale evolutionary optimization: A review and comparative study. *Swarm and Evolutionary Computation*, *85*(December 2023), 101466. https://doi.org/10.1016/j.swevo.2023.101466

Mahdavi, S., Shiri, M. E., & Rahnamayan, S. (2015a). *Mahdavi_Metaheuristics in large-scale global continues optimization A survey.pdf*. Information Sciences. https://doi.org/https://doi.org/10.1016/j.ins.2014.10.042

Mahdavi, S., Shiri, M. E., & Rahnamayan, S. (2015b). Metaheuristics in large-scale global continues optimization: A survey. *Information Sciences*, *295*, 407-428. https://doi.org/10.1016/j.ins.2014.10.042

Nadimi-Shahraki, M. H., & Zamani, H. (2022). DMDE: Diversity-maintained multi-trial vector differential evolution algorithm for non-decomposition large-scale global optimization. *Expert Systems with Applications*, *198*. https://doi.org/10.1016/j.eswa.2022.116895

Omidvar, M. N., Li, X., & Yao, X. (2021). A Review of Population-Based Metaheuristics for Large-Scale Black-Box Global Optimization—Part I. *IEEE Transactions on Evolutionary Computation*, *26*(5), 802-822. https://doi.org/10.1109/tevc.2021.3130838

Potter, M. A. (1997). *The Design and Analysis of a Computational Model of Cooperative Coevolution*.

Potter, M. A., & De Jong, K. A. (1994). A cooperative coevolutionary approach to function optimization. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, *866 LNCS*, 249-257. https://doi.org/10.1007/3-540-58484-6_269

Sheng, M., Wang, Z., Liu, W., Wang, X., Chen, S., & Liu, X. (2023). A swarm optimizer with attention-based particle sampling and learning for large scale optimization. *Journal of Ambient Intelligence and Humanized Computing*, *14*(7), 9329-9341. https://doi.org/10.1007/s12652-022-04432-5

Suganthan, P. N., Hansen, N., Liang, J. J., Deb, K., Chen, Y. P., Auger, A., & Tiwari, S. (2005). Problem definitions and evaluation criteria for the CEC 2005 special session on real-parameter optimization. *Technical Report, Nanyang Technological University, Singapore, May 2005 AND KanGAL Report 2005005, IIT Kanpur, India*, (May), 1-50.

Tarraq, A., Elmariami, F., Belfqih, A., & Haidi, T. (2021). Meta-heuristic optimization methods applied to renewable distributed generation planning: A review. *E3S Web of Conferences*, *234*, 1-10. https://doi.org/10.1051/e3sconf/202123400086

Wang, Z., Xiong, B., Tang, J., Li, Y., Huang, Y., Zhang, G., & Chen, J. (2019). Multi-parameter optimization strategy for vanadium redox flow battery operation based on genetic algorithm. *PEDG 2019 - 2019 IEEE 10th International Symposium on Power Electronics for Distributed Generation Systems*, 717-721. https://doi.org/10.1109/PEDG.2019.8807477

Wright, A. H. (1991). *Genetic Algorithms for Real Parameter Optimization* (ss. 205-218). Foundations of Genetic Algorithms.

Zhong, R., & Yu, J. (2024). Gene-targeting multiplayer battle game optimizer for large-scale global optimization via cooperative coevolution. *Cluster Computing*, *27*(9), 12483-12508. https://doi.org/10.1007/s10586-024-04600-6

Zoppoli, R., Sanguineti, M., & Parisini, T. (2001). Can we cope with the curse of dimensionality in optimal control by using neural approximators? *Proceedings of the IEEE Conference on Decision and Control*, *4*, 3540-3545. https://doi.org/10.1109/cdc.2001.980408