



## Meta-Sezgisel Algoritmalarla Kümeleme: MetaCluster Platformu ile Farklı Hedef Fonksiyonların Karşılaştırmalı Analizi

*Clustering with Meta-Heuristic Algorithms: Comparative Analysis of Different Objective Functions with MetaCluster Platform*

Münevver Bahar<sup>1\*</sup> , Murat Karakoyun<sup>2</sup> 

<sup>1</sup>Aydın Adnan Menderes Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Aydın, Türkiye

<sup>2</sup>Necmettin Erbakan Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Konya, Türkiye

### Öz

Veri kümeleme, denetimsiz öğrenme yöntemleri arasında yer alan ve veri setlerinde doğal grupların keşfedilmesini amaçlayan temel bir analiz yöntemidir. Geleneksel kümeleme algoritmaları, özellikle karmaşık yapıları veri setlerinde yeterli başarıyı sağlayamamaktadır. Bu nedenle, meta-sezgisel algoritmalar son yıllarda veri kümeleme problemlerinde etkili bir alternatif olarak ön plana çıkmıştır. Bu çalışmada, Python tabanlı MetaCluster platformu kullanılarak toplam 13 farklı meta-sezgisel algoritmanın üç ayrı hedef fonksiyon (BHI, MIS, XBI) altında circles, moons ve blobs olmak üzere üç farklı yapay veri seti üzerindeki kümeleme performansları karşılaştırılmıştır. Değerlendirme, BRI, DBI, DRI, CHI ve KDI metrikleri ile yapılmıştır. Sonuçlar, veri setlerinin geometrisine ve hedef fonksiyonlara bağlı olarak algoritmaların performanslarının anlamlı biçimde farklılaştığını göstermektedir. Blobs veri setinde, BHI ve MIS hedef fonksiyonları altında 12 algoritma (ALO, AOA, BBO, FBIO, GCO, GWO, HGSO, HHO, ICA, SMA, TLO, WOA) aynı optimum DBI değerine ( $\approx 0.2804$ ) ulaşırken, XBI hedef fonksiyonu altında bu grubun tamamı ile birlikte BMO'nun da yer aldığı 13 algoritma  $\approx 0.2612$  düzeyinde, neredeyse aynı kümeleme kalitesini üretmiştir. Circles veri setinde ise XBI hedef fonksiyonu altında FBIO algoritması en düşük DBI değerini ( $\approx 0.6444$ ) sağlamış; SMA, HHO ve BMO algoritmaları benzer fakat daha yüksek değerlerle onu takip etmiştir. HGSO ve ICA bu veri setinde hem DBI ortalamaları hem de varyansları açısından en zayıf ve en dengesiz performans sergilemiştir. Moons veri setinde ise BHI hedef fonksiyonu altında WOA ve GCO algoritmaları  $\approx 0.8093$  DBI değeri ile en iyi sonucu vermiş, diğer algoritmaların büyük kısmı yaklaşık 0.8094 civarında yoğunlaşmış; ICA ise tüm kombinasyonlar içinde nispeten daha yüksek DBI değerleri ile ayrılmıştır. DBI'ye göre genel sıralama incelendiğinde, FBIO, HHO, ALO ve TLO algoritmaları en başarılı grubun içinde yer alırken, ICA tüm veri setleri ve hedef fonksiyonlar dikkate alındığında son sırada konumlanmıştır. Bu çalışma, meta-sezgisel algoritmaların esnek yapıları sayesinde geleneksel yöntemlere kıyasla daha başarılı ve uygulanabilir kümeleme çözümleri sunabileceğini ortaya koymaktadır. Elde edilen bulgular, araştırmacılara algoritma ve hedef fonksiyon seçiminde yol gösterici niteliktedir.

**Anahtar Kelimeler:** Meta-sezgisel algoritmalar, metaCluster, veri kümeleme.

### Abstract

Data clustering is a basic analysis method among unsupervised learning methods that aims to discover natural groups within data sets. Traditional clustering algorithms cannot provide sufficient success especially in complex structured data sets. For this reason, metaheuristic algorithms have come to the forefront as an effective alternative in data clustering problems in recent years. In this study, the clustering performances of a total of 13 different metaheuristic algorithms on three different artificial data sets, circles, moons and blobs, under three different objective functions (BHI, MIS, XBI) were compared using the Python-based MetaCluster platform. The evaluation was made with BRI, DBI, DRI, CHI and KDI metrics. The results show that the performances of the algorithms

\*Sorumlu yazarın e-posta adresi: [munevverbahar@adu.edu.tr](mailto:munevverbahar@adu.edu.tr)

Münevver Bahar  [orcid.org/0009-0009-0489-0884](https://orcid.org/0009-0009-0489-0884)

Murat Karakoyun  [orcid.org/0000-0002-0677-9313](https://orcid.org/0000-0002-0677-9313)



differ significantly depending on the geometry of the datasets and the objective functions. On the Blobs dataset, 12 algorithms (ALO, AOA, BBO, FBIO, GCO, GWO, HGSO, HHO, ICA, SMA, TLO, WOA) achieved the same optimal DBI value ( $\approx 0.2804$ ) under the BHI and MIS objective functions. On the XBI objective function, the entire group, including BMO, produced almost the same clustering quality at  $\approx 0.2612$ . On the Circles dataset, the FBIO algorithm achieved the lowest DBI value ( $\approx 0.6444$ ) under the XBI objective function, followed by the SMA, HHO, and BMO algorithms with similar but higher values. HGSO and ICA exhibited the weakest and most unstable performance on this dataset in terms of both DBI means and variances. On the Moons dataset, the WOA and GCO algorithms performed best with a DBI value of  $\approx 0.8093$  under the BHI objective function, while the majority of the other algorithms concentrated around 0.8094; ICA distinguished itself with relatively higher DBI values across all combinations. When examining the overall ranking by DBI, the FBIO, HHO, ALO, and TLO algorithms were among the most successful, while ICA ranked last when considering all datasets and objective functions. This study reveals that metaheuristic algorithms can provide more successful and applicable clustering solutions compared to traditional methods thanks to their flexible structures. The findings are guiding for researchers in the selection of algorithms and target functions.

**Keywords:** Meta-heuristic algorithms, metaCluster, data clustering.

## 1. Giriş

Veri kümeleme, denetimsiz öğrenme yöntemleri arasında yer alan ve veri setlerinde doğal grupların ortaya çıkarılmasını amaçlayan temel bir veri madenciliği tekniğidir. Yapılandırılmamış ve yüksek boyutlu veri kaynaklarının sayısının artmasıyla birlikte, kümeleme yöntemleri hem akademik dünyada hem de endüstride büyük önem kazanmıştır (Xu & Wunsch, 2005). Bu teknik, örnekler arasındaki benzerlikleri kullanarak veri kümesini anlamlı alt gruplara ayırmakta ve böylece daha etkili analizlerin yapılabilmesini mümkün kılmaktadır (Jain, 2008). Kümeleme, görüntü işleme (Hart vd., 2000), biyoinformatik (Ng & Han, 2002), müşteri segmentasyonu (Wedel & Kamakura, 2000), sosyal ağ analizi (Fortunato, 2010), belge sınıflandırma (Steinbach vd., 2000) ve anomali tespiti gibi pek çok uygulama alanında yaygın olarak kullanılmaktadır. Ancak geleneksel kümeleme algoritmaları ön kabullere dayandığından dolayı, veri dağılımı kompleks yapılar içerdiğinde performans açısından yetersiz kalabilmektedir. Bu algoritmalar genellikle küme sayısının önceden bilinmesini, kümelerin konveks ve küresel biçimde dağılmasını veya belirli mesafe ölçütlerinin kullanılmasını varsayar (Ester vd., 1996). Bu varsayımlar, özellikle iç içe geçmiş veya düzensiz şekilli kümelerin bulunduğu veri setlerinde düşük başarı oranlarına yol açabilmektedir (Ertöz vd., 2003).

Bu sınırlamaları aşmak ve daha esnek yapılarla çalışmak amacıyla son yıllarda doğadan esinlenen meta-sezgisel algoritmalar veri kümeleme problemlerine entegre edilmeye başlanmıştır. Meta-sezgisel algoritmalar, arama uzayını daha geniş kapsayarak yerel optimumlara takılma riskini azaltır ve daha genel çözümler üretme potansiyeline sahiptir (Yang, 2010). Bu algoritmalar, sürü zekâsı (örn. Particle Swarm Optimization - PSO (Kennedy & Eberhart, 1995), Ant Colony Optimization - ACO (Shelokar vd., 2004)),

evrimsel stratejiler (örn. Genetic Algorithms - GA (Holland, 1992)), fizik temelli optimizasyonlar (örn. Simulated Annealing - SA) ve insan davranışına dayalı modeller (örn. Teaching-Learning-Based Optimization - TLBO) gibi çok çeşitli alt yapıya sahiptir.

Özellikle çok amaçlı optimizasyon yapıları ile desteklenen bu algoritmalar, kümeleme işlemlerinde aynı anda birden fazla değerlendirme kriterini optimize edebilmeleri sayesinde daha dengeli çözümler sunmaktadır (Zitzler vd., 2001). Klasik tekli hedef fonksiyonlarının (örneğin sadece kümeler arası uzaklıkların maksimize edilmesi ya da kümeler içi varyansın minimize edilmesi) yetersiz kaldığı durumlarda, çok amaçlı optimizasyon hem küme içi tutarlılığı hem de küme dışı ayrışmayı dikkate alarak daha genel geçer sonuçlar elde edilmesine olanak tanımaktadır (Yang vd., 2022).

Bu çalışmada, Python tabanlı çoklu hedef fonksiyonlu analiz ortamı sunan MetaCluster (Van Thieu vd., 2023) platformu kullanılarak, üç farklı yapay veri seti üzerinde 13 farklı meta-sezgisel algoritmanın üç ayrı hedef fonksiyonu doğrultusunda kümeleme başarımı karşılaştırmalı olarak analiz edilmiştir. Çalışmanın temel amacı, farklı algoritma ve fonksiyon kombinasyonlarının çok boyutlu ve yapay zorluklara sahip veri setleri üzerindeki etkilerini karşılaştırmalı olarak ortaya koymak ve araştırmacılara algoritma seçimi konusunda yön göstermektir.

Bu çalışmanın temel katkıları aşağıda özetlenmiştir:

- Python tabanlı MetaCluster platformu kullanılarak 13 farklı meta-sezgisel algoritma ve üç hedef fonksiyonun (BHI, MIS, XBI) sistematik karşılaştırması gerçekleştirilmiştir.
- Tüm algoritmalar aynı parametrelerde çalıştırılarak tekrarlanabilirlik sağlanmıştır.
- Her algoritma-fonksiyon kombinasyonu için ortalama

ve standart sapma değerleri hesaplanmış, Friedman ve Nemenyi testleriyle istatistiksel anlamlılık analiz edilmiştir.

- Bulgular, farklı hedef fonksiyonların veri kümesi geometrisine göre performans değişimini ortaya koymuştur.
- MetaCluster platformunun istatistiksel analizlerle genişletilerek çok amaçlı kümeleme araştırmalarında referans bir çerçeve sunduğu gösterilmiştir.

### 1.1. Literatür

Son yıllarda yapılan araştırmalar, meta-sezgisel algoritmaların kümeleme problemlerine uygulanmasında önemli gelişmeler sağlandığını göstermektedir. Liu vd. (2025), Geliştirilmiş PSO-Tabanlı Kümeleme (HPE-PSOC) isimli çalışmalarında Particle Swarm Optimization iyileştirerek boş küme oluşumu sorununu gideren bir algoritma sunmuşlardır. Boş küme problemini incelemek amacıyla çeşitli yapay veri setleri üzerinde testler yapmışlar ve önerilen PSO tabanlı hibrit yöntem, karşılaştırılan algoritmalarından istatistiksel olarak anlamlı derecede daha iyi sonuçlar vermiş; özellikle sentetik veriler üzerinde boş küme oluşmadan tutarlı kümeler elde etmişlerdir. El Habib Kahla vd. (2024), balıkların kolektif hareket davranışından esinlenen K-Level adında yenilikçi bir hiyerarşik kümeleme algoritması geliştirilmiştir. Bu yöntem, ağaçlı yaklaşım ile kademeli olarak yakın kümeleri birleştirerek hiyerarşik bir yapı oluşturmaktadır. Circles, Moons, Blobs ve Spiral gibi yapay dağılımlara (her biri binlerce nokta içeren) uygulanmış; ayrıca UPGMA, SLINK gibi klasik yöntemlerle de karşılaştırılmıştır. Silhouette skoru, Davies–Bouldin indeksi ve Calinski–Harabasz indeksi gibi iç geçerlik metrikleri ile değerlendirme yapılmıştır. K-Level algoritması, iyi ayrılmış belirgin kümeler içeren veri setlerinde yüksek Silhouette ve düşük DBI değerleriyle güçlü performans sergilemiştir. Örneğin Circles veri setinde Silhouette  $\approx 0.38$  ve DBI  $\approx 0.66$  ile klasik yöntemlere yakın bir performans sağlarken, Spiral ve Blobs gibi karmaşık şekillerde daha belirgin üstünlük göstermiştir. Genel olarak K-Level, UPGMA ve CLINK gibi geleneksel hiyerarşik algoritmalarından Calinski–Harabasz değeri bakımından sürekli daha iyi çıkararak daha tutarlı kümeler üretmiştir, bu da algoritmanın farklı yapıda kümelere uyum sağladığını ve ölçeklenebilir olduğunu ortaya koymaktadır. Gang vd. (2025), Quantum Walk Artificial Bee Colony (QWABC) algoritmasını K-modes kümeleme ile birleştirerek yüksek boyutlu veri kümeleri üzerinde başarılı sonuçlar elde etmiştir. El Haouari vd. (2025), ise hibrit bir Artificial Bee Colony (ABC) ve K-Means Algoritması

geliştirerek görüntü kümeleme uygulamalarında doğruluğu artırmışlardır. Pektaş & İnan (2022), yeni bir doğa-esinli optimizasyon yöntemi olan Tree Seed Algorithm 17 farklı kümeleme problemi üzerinde deneysel olarak test etmiş ve geleneksel yöntemlere kıyasla üstün sonuçlar elde etmiştir. Çok amaçlı optimizasyon temelli yaklaşımlar da son yıllarda dikkat çekmektedir. Zhou vd. (2024), adaptif çoklu popülasyonlara dayalı bir ABC algoritması (ABC-AMP) ile kümeleme başarısını artırmayı başarmışlardır. Yang vd. (2022), kısa dönemli bellek ve K-Means entegrasyonu ile desteklenen MOPSO-SMK algoritmasıyla, Davies–Bouldin ve Silhouette indekslerinde iyileşme sağlamıştır. Bununla birlikte, Sharma vd. (Sharma vd., 2022), çok amaçlı Gray Wolf Optimization (GWO) algoritmasını kullanarak yüksek boyutlu veri kümelerinde etkili kümeleme performansı elde etmişlerdir. Ayrıca Karakoyun & Özkış (2021), Moth-Flame Optimization (MFO) algoritmasını ikili problemlere uyarlamak amacıyla sekiz farklı transfer fonksiyonu kullanarak varyasyonlar oluşturmuş ve bu algoritmaların performansını karşılaştırmalı olarak değerlendirmiştir.

Bu çalışmalara ek olarak; Ananthi vd. (2025), KDD-99 ağ saldırı veri seti üzerinde Hybrid Lion and Exponential PSO (HLEPSOMCA) algoritmasını kullanarak gerçek zamanlı veri akışı kümeleme yönteminde kavram kayması ve kavram evrimi sorunlarını ele almışlardır. Önerilen hibrit yöntem, kümelerin saflığını baz yaklaşımlara kıyasla ortalama  $\sim 13.24$  oranında artırmıştır. Yue vd. (2025), PSO-KM (PSO entegreli K-Means) algoritmasını kullanarak gerçek çok boyutlu verilerden oluşan topluluk yönetim sistemi profilleri veri seti üzerinde yüksek boyutlu karmaşık verilerde kümeleme doğruluğunu ve verimliliğini artırmayı hedeflemişlerdir. PSO'nun küresel arama yeteneğiyle K-Means'i birleştiren yöntem, silüet skoru  $\sim 0.752$  ile geleneksel yöntemleri geride bırakarak GA-K-Means ve DBSCAN'e kıyasla üstün sonuçlar elde etmiştir. Wan vd. (2025), IGWOA-DBSCAN (İyileştirilmiş WOA + DBSCAN) algoritmasını kullanarak Radar sinyal veri akışları (gerçek zamanlı elektromanyetik sinyaller) veri seti ile DBSCAN'in kümeleme parametrelerini (Eps, MinPts) gelişmiş Whale Optimization (WOA) ile otomatik ayarlayarak sinyal kümeleme/doğrulama başarımını artırmayı amaçlamışlardır. Yeni yöntem, klasik DBSCAN'e göre doğruluğu  $\%57.7$  oranında (standart WOA-DBSCAN yaklaşımına göre  $\%37.8$ ) yükseltmiştir.

Bu gelişmeler doğrultusunda geliştirilen MetaCluster platformu, kullanıcıların Python tabanlı bir ortamda farklı meta-sezgisel algoritmaları ve çoklu hedef fonksiyonları ko-

laylıkla bir araya getirmesini sağlayarak sistematik analizler yürütme imkânı tanımaktadır. Bu platform, algoritmaların parametrik karşılaştırmalarına, farklı veri kümeleri üzerindeki tutarlılık analizlerine ve grafiksel sonuç sunumlarına olanak sağlayarak araştırmalarda güçlü bir deneysel altyapı sunmaktadır. Bu çalışma, MetaCluster platformu ile 13 farklı meta-sezgisel algoritma ve üç farklı hedef fonksiyonun karşılaştırmalı analizine yer vererek, literatürdeki önemli bir boşluğu doldurmakta ve ileri düzey karşılaştırmalı kümeleme analizleri için bir referans sunmaktadır.

## 2. Gereç ve Yöntem

Bu çalışmada, doğadan esinlenen 13 farklı meta-sezgisel algoritmanın çok amaçlı optimizasyon perspektifiyle veri kümeleme problemlerine etkisi analiz edilmiştir. Uygulamalar, Python tabanlı ve çoklu hedef fonksiyonları ile analiz desteği sunan MetaCluster platformu aracılığıyla gerçekleştirilmiştir. Kodlar, her kombinasyonun karşılaştırmalı analizine imkân verecek şekilde parametrik ve tekrar edilebilir biçimde yapılandırılmıştır. Çalışmada kullanılan tüm algoritma isimleri ve değerlendirme metriklerine ait tam açıklamalar, Ek 1'de sunulan 'Kısaltmalar Listesi'nde yer almaktadır.

### 2.1. Veri Setleri

Bu çalışmada, farklı geometrik zorluklara sahip üç yapay veri seti kullanılmıştır: circles, moons ve blobs. Circles veri seti, iç içe geçmiş çember yapıları içermektedir ve doğrusal olmayan ayırım gerektirir. Moons veri seti, hilal biçimli iki kümeden oluşur ve karmaşık bir sınırlayıcı fonksiyon gerektirir. Blobs veri seti ise homojen dağılıma sahip, belirgin merkezli kümeler içerir ve referans olarak kullanılır. Her veri seti, Min-Max normalization yöntemiyle 0-1 aralığına ölçeklendirilmiş, böylece algoritmaların giriş verisi üzerindeki duyarlılığı minimize edilmiştir. Veri setlerindeki küme sayıları önceden bilinmekte olup sırasıyla 2, 2 ve 3 küme içermektedir. Kullanılan veri setlerine ait örnek sayısı, özellik sayısı, küme sayısı ve dağılım özellikleri Çizelge 1'de özetlenmiştir.

**Çizelge 1.** Kullanılan veri setlerinin özellikleri.

| Veri Seti      | Örnek Sayısı | Özellik Sayısı | Küme Sayısı | Dağılım Özelliği            |
|----------------|--------------|----------------|-------------|-----------------------------|
| <b>Blobs</b>   | 300          | 2              | 3           | İzotropik                   |
| <b>Circles</b> | 300          | 2              | 2           | Eşmerkezli daire            |
| <b>Moons</b>   | 300          | 2              | 2           | Yarım daire / Hilal biçimli |

### 2.2. MetaCluster Platformu

MetaCluster, Python tabanlı, çok amaçlı optimizasyon destekli bir kümeleme deney platformudur. Kullanıcıların farklı meta-sezgisel algoritmalar, hedef fonksiyonları ve değerlendirme metriklerini bir arada kullanabilmesine olanak sağlar. Platformun önemli özelliklerinden bazıları şunlardır:

- Çoklu optimizasyon algoritmalarını aynı anda çalıştırabilme,
- Kullanıcı tanımlı hedef fonksiyonlarıyla kümeleme başarısını iyileştirme,
- Her çalışmayı otomatik olarak kayıt altına alma (CSV ve görseller),
- Grafiksel karşılaştırmalar.

### 2.3. Metasezgisel Algoritmalar

Bu çalışmada toplam 13 meta-sezgisel algoritma test edilmiştir:

- Sürü zekası tabanlı: Original GWO (Mirjalili vd., 2014), Original SMA (Li vd., 2020), Original WOA (Mirjalili & Lewis, 2016), Original ALO (Mirjalili, 2015)
- Evrimsel temelli: Original BBO (Simon, 2008), Original BMO (Arora & Singh, 2019), Original ICA (Atashpaz-Gargari & Lucas, 2007)
- Fizik/İnsan davranışı temelli: Original TLO (Rao vd., 2012), Original AOA (Abualigah vd., 2021), Original HGSO (Hashim vd., 2019), Original HHO (Heidari vd., 2019), Original GCO (Villaseñor vd., 2018), Original FBIO (Chou & Nguyen, 2020)

Bu çalışmada kullanılan meta-sezgisel algoritmalar, farklı sezgisel kategorileri temsilen seçilmiştir. Bu seçim, literatürde sıkça başvuru yapılan MetaCluster (Van Thieu vd., 2023) kütüphanesinin referans uygulamalarına ve temsil çeşitliliği ilkesine dayanmaktadır.

## 2.4. Hedef Fonksiyonları

Bu çalışmada kullanılan BHI, MIS ve XBI hedef fonksiyonları, MetaCluster platformunun sunduğu yerleşik fonksiyonlardır. Bu fonksiyonlar MetaCluster kütüphanesinin dokümantasyonunda detaylandırılmıştır (Van Thieu vd., 2023; Van Thieu vd., 2025). Bu üç hedef fonksiyonun seçilme nedeni, MetaCluster kütüphanesinde yer alan standart ve yaygın olarak kullanılan çok amaçlı optimizasyon fonksiyonları olmalarıdır.

- BHI, kümeleme sonucundaki kümelerin sıklığını ve ayrılığını ölçen bir kümeleme geçerlilik endeksidir. Kümelerin ne kadar iyi ayrılmış ve sıkı olduğunun nicel bir ölçüsünü sağlar.

$$BHI = \sum \left( \frac{1}{2n_i} \times \frac{\sum d(x, c_i)}{n} \right) \quad (1)$$

Burada toplam veri noktası sayısını,  $n_i$  i. kümedeki örnek sayısını,  $d(x, c_i)$  x veri noktası ile  $i$  kümesinin  $c_i$  ağırlık merkezi arasındaki Öklid uzaklığını göstermektedir. BHI, her veri noktası ile küme merkezi arasındaki ortalama mesafeyi hesaplayarak bunun kümeler genelindeki ortalamasını alır. Değer küçüldükçe kümeler daha kompakt hâle gelir; dolayısıyla düşük BHI, daha iyi tanımlanmış kümeleri ifade eder.

- MIS, küme merkezleri arasındaki minimum uzaklığı maksimize eder; kümeler arası çakışmayı azaltır.

$$MIS = \min_{i \neq j} \|\mu_i - \mu_j\| \quad (2)$$

Burada  $\mu_i$  i. kümenin ortalama vektörünü,  $\|\mu_i - \mu_j\|$  iki küme merkezi arasındaki Öklid uzaklığını temsil eder. MIS değeri büyüdükçe, en yakın iki küme merkezi arasındaki mesafe artar ve kümeler arası çakışma azalır.

- XBI, küme içi sıklığı ve kümeler arası uzaklığı aynı anda dikkate alan çok amaçlı bir denge ölçütüdür.

$$XBI = \frac{\sum_{i=1}^k \sum_{j=1, j \neq i}^k \|\mu_i - \mu_j\|^2}{\sum_{i=1}^k \sum_{x \in C_i} \|x - \mu_i\|^2} \quad (3)$$

Pay, küme merkezleri arasındaki toplam ayrımı, payda ise her kümedeki örneklerin kendi merkezlerine olan uzaklıklarının toplamını temsil etmektedir. Bu çalışmada kullanılan formülasyon altında XBI değeri arttıkça kümeler arası fark büyürken küme içi yoğunluk artmakta, dolayısıyla kümeleme kalitesi yükselmektedir.

## 2.5. Değerlendirme Metrikleri

Kümeleme performansını ölçmek için beş metrik kullanılmıştır. Bu metriklerden BRI, DRI, ve KDI metrikleri MetaCluster platformuna özgü değerlendirme metrikleridir ve platformun yerleşik modülleri aracılığıyla hesaplanmıştır (Van Thieu vd., 2023; Van Thieu vd., 2025).

- BRI, kümelerin varyans yapısını değerlendiren ve küme içi dağılımı ölçen model-tabanlı bir kümeleme geçerlilik endeksidir. Bu indeks, her bir kümenin varyans-kovaryans matrisinin izinin (toplam varyansın) logaritmasını kümedeki örnek sayısı ile ağırlıklandırarak toplamaktadır. BRI, kümelerin ne kadar kompakt olduğunu nicel olarak ifade eder.

$$BRI = \sum_{k=1}^K n_k \log \left( \frac{Tr(WG^{(k)})}{n_k} \right) \quad (4)$$

Burada  $n_k$  k kümedeki örnek sayısını,  $WG^{(k)}$  k. Kümeye ait varyans-kovaryans matrisini,  $Tr(WG^{(k)})$  kümeye ait toplam varyansı temsil eder. BRI değeri azaldıkça, kümeler daha kompakt ve sıkı hâle gelir; dolayısıyla düşük BRI, daha iyi tanımlanmış kümeleri gösterir.

- DBI, kümelerin ayrışma ve sıklık düzeyini eşzamanlı olarak değerlendiren bir geçerlilik ölçütüdür. Bu indeks, her bir kümenin kendisine en çok benzeyen diğer küme ile olan benzerlik oranının ortalamasını hesaplar. Benzerlik, kümelerin iç sıklığının toplamının kümeler arası uzaklığa bölünmesiyle tanımlanır. Dolayısıyla kümelerin daha kompakt ve birbirinden daha iyi ayrılmış olması, DBI değerinin küçülmesine neden olur. Bu yönüyle DBI, çok amaçlı bir denge ölçütü olarak kümeleme kalitesini etkili biçimde yansıtır.

$$DBI = \frac{1}{k} \sum_{i=1}^k \max \left( \frac{\Delta(X_i) + \Delta(X_j)}{\delta(X_i, X_j)} \right) \quad (5)$$

Burada toplam küme sayısını,  $\Delta(X_i)$ ,  $X_i$ , kümesi içindeki örneklerin küme merkezine olan ortalama uzaklığını, yani küme içi sıklığı temsil etmektedir.  $\delta(X_i, X_j)$  ise  $X_i$  ve  $X_j$  ise ve kümeleri arasındaki merkez uzaklığını, yani kümeler arası ayrımı ifade eder. Her bir küme için, bu oran kendisine en çok benzeyen küme ile karşılaştırılarak hesaplanır ve tüm kümeler için bu maksimum oranların ortalaması alınır. DBI değeri küçüldükçe kümeler daha belirgin bir biçimde ayrışmış, daha kompakt ve daha iyi tanımlanmış kabul edilir. Küme şekline ilişkin bir varsayım gerektirmedikinden esnek bir metrik olup, farklı veri yapılarında güvenilir sonuç vermesi nedeniyle sıkça kullanılmaktadır.

- DRI, kümeleme yapısının kalitesini değerlendirmek için kullanılan determinant tabanlı bir geçerlilik ölçütüdür. İndeks, tüm veri kümesinin kovaryans determinantı ile kümelerin bireysel kovaryans determinantları arasındaki oranın temel alır. Amaç, küme içi yayılımın küçük, küme dışı ayrımın ise büyük olmasını sağlamaktır.

$$DRI = \frac{\det(\Sigma)}{\sum_{i=1}^k n_i \det(\Sigma_i)} \quad (6)$$

Burada  $\Sigma$  tüm veri kümesinin kovaryans matrisini,  $n_i$  i. kümenin kovaryans matrisini,  $\Sigma_i$  i. kümede bulunan örnek sayısını temsil eder. Paydaki determinant küresel yayılımı, paydadaki terim ise kümelerin toplam iç yayılımını temsil eder. Pay büyük, payda küçük olduğunda oran arttığı için yüksek DRI, iyi ayrılmış ve kompakt kümeleri gösterir.

- CHI, kümeleme sonuçlarını yalnızca verinin kendi yapısına dayanarak değerlendiren bir iç geçerlilik ölçütüdür. Bu indeks, kümeler arası ayrımın kümeler içi sıklığa oranını ifade eder ve kümelenebilir bir veri setinin ne derece iyi ayrıldığına nicel olarak ölçer.

$$CHI = \frac{BCSS / (k-1)}{WCSS / (n-k)} \quad (7)$$

Burada  $n$  toplam örnek sayısını,  $k$  ise küme sayısını temsil eder. Kümeler arası ayrılma miktarını gösteren BCSS, küme merkezleri ile tüm veri kümesinin global merkezi arasındaki ağırlıklı uzaklıkların toplamıdır. Kümeler içindeki yayılımı gösteren WCSS ise her örneğin kendi küme merkezine olan uzaklığının karesinin toplamıdır. BCSS ve WCSS ifadelerinin sırasıyla  $(k-1)$  ve  $(n-k)$  özgürlük derecelerine bölünmesi, farklı küme sayıları için indeksi karşılaştırılabilir kılar. CH indeksinin yüksek olması, kümelerin arasındaki ayrımın küme içi dağınıklığa göre daha baskın olduğunu gösterir ve bu nedenle daha başarılı bir kümeleme yapısına işaret eder.

- KDI, kümelerin kovaryans yapılarına dayalı olarak küme içi kompaktlığı değerlendiren bir iç geçerlilik ölçütüdür. Bu indeks, her kümenin kovaryans matrisinin determinantını kullanır ve determinant ne kadar küçükse, kümenin o kadar sıkı ve kompakt olduğunu varsayar. Dolayısıyla daha küçük  $Ksq-Detw$  değeri daha iyi bir kümeleme kalitesini temsil eder.

$$KDI = \sum_{k=1}^K n_k \det(\Sigma_k) \quad (8)$$

Burada  $K$  küme sayısını,  $n_k$  k. kümedeki örnek sayısını,  $\Sigma_k$  k. kümenin kovaryans matrisini temsil eder. Determinant, kümenin çok boyutlu yayılım hacmini temsil ettiği için küçük determinantlar kümelerin kompakt ve iyi tanımlanmış olduğunu gösterir. Bu nedenle, KDI değerinin minimizasyonu, hem küme içi sıklığı hem de düşük varyansı teşvik eden uygun bir değerlendirme yaklaşımı sunar.

## 2.6. Deneysel Tasarım ve Parametreler

Tüm algoritmalar aynı parametreler altında test edilmiştir. Çalışmanın tekrarlanabilirliğini sağlamak amacıyla sabit rastgelelik tohumu (seed=42) kullanılmış, deneyler 10 kez tekrarlanarak ortalama ve standart sapma değerleri hesaplanmıştır. Kullanılan parametreler aşağıda özetlenmiştir:

- İterasyon: 50
- Popülasyon boyutu: 50
- Tekrar sayısı (n\_trials): 10
- Rastgelelik tohumu (seed): 42
- Değerlendirme metrikleri: BRI, DBI, DRI, CHI, KDI
- Hedef fonksiyonlar: BHI, MIS, XBI
- Donanım ortamı: macOS 26.0.1, Apple M2 Chip, 16 GB RAM, Python 3.12, MetaCluster 1.3.0

Her algoritma-hedef fonksiyonu kombinasyonu 10 bağımsız çalıştırma ile test edilmiştir. Her kombinasyonun ortalama ve standart sapma değerleri hesaplanarak hem en iyi hem de en kötü durum performansları değerlendirilmiştir.

## 3. Bulgular ve Tartışma

Bu bölümde, 13 farklı meta-sezgisel algoritmanın üç farklı hedef fonksiyonu altında üç farklı yapay veri küme üzerinde elde ettiği kümeleme sonuçları değerlendirilmiştir. Her kombinasyon, aynı parametrelerle çalıştırılmıştır. Elde edilen sonuçlar hem metriksele hem de grafiksel olarak analiz edilmiştir. Elde edilen tüm sayısal metrik değerleri ve süreleri veri seti bazında ayrılarak Blobs veri seti için Çizelge 2’de, Circles veri seti için Çizelge 3’de ve Moons veri seti için Çizelge 4’te gösterilmiştir. Tablolarda görülen  $\pm 0.0000$  standart sapma değerleri, ilgili algoritmanın 10 bağımsız çalıştırmanın tamamında aynı global optimum noktaya ulaştığını ve tam kararlılık sergilediğini göstermektedir.

**Çizelge 2.** Blobs veri seti için metriklerin 10 tekrarlı çalıştırmanın ortalama  $\pm$  standart sapma değerleri.

| Algoritma | Hedef Fonksiyon | BRI ( $\downarrow$ )                  | DBI ( $\downarrow$ )                  | DRI ( $\uparrow$ )                  | CHI ( $\uparrow$ )                    | KDI ( $\downarrow$ ) | Süre (sn) |
|-----------|-----------------|---------------------------------------|---------------------------------------|-------------------------------------|---------------------------------------|----------------------|-----------|
| ALO       | BHI             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,68      |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,787     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 0,815     |
| AOA       | BHI             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,417     |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,478     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 0,522     |
| BBO       | BHI             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,439     |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,543     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 0,519     |
| BMO       | BHI             | -8095.88 $\pm$ 115.06                 | 0.2856 $\pm$ 0.0132                   | 519.97 $\pm$ 96.61                  | 32589.43 $\pm$ 3172.67                | 4.9213 $\pm$ 1.0728  | 0,368     |
|           | MIS             | -8105.07 $\pm$ 103.65                 | 0.2827 $\pm$ 0.0052                   | 532.08 $\pm$ 79.78                  | 32988.23 $\pm$ 2358.69                | 4.8105 $\pm$ 0.9358  | 0,421     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 0,358     |
| FBIO      | BHI             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 1,751     |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 2,144     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 2,195     |
| GCO       | BHI             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,463     |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,548     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 0,568     |
| GWO       | BHI             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,43      |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,518     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 0,539     |
| HGSO      | BHI             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,46      |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,553     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 0,564     |
| HHO       | BHI             | -8142.47 $\pm$ 12.69                  | 0.2807 $\pm$ 0.0009                   | 561.98 $\pm$ 13.63                  | 33843.21 $\pm$ 292.20                 | 4.5023 $\pm$ 0.1572  | 0,71      |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,877     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 0,921     |
| ICA       | BHI             | -7844.50 $\pm$ 598.09                 | 0.3410 $\pm$ 0.1335                   | 436.26 $\pm$ 205.19                 | 28193.11 $\pm$ 9769.51                | 4.1983 $\pm$ 1.1505  | 0,59      |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,706     |
|           | XBI             | -6006.16 $\pm$ 474.81                 | 0.3578 $\pm$ 0.2080                   | 37.43 $\pm$ 8.94                    | 9799.73 $\pm$ 3673.81                 | 0.4372 $\pm$ 0.5500  | 0,724     |
| SMA       | BHI             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,537     |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,6       |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 0,616     |
| TLO       | BHI             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,858     |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 1,036     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 1,068     |
| WOA       | BHI             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,389     |
|           | MIS             | <b>-8146.49 <math>\pm</math> 0.00</b> | 0.2804 $\pm$ 0.0000                   | <b>566.29 <math>\pm</math> 0.00</b> | <b>33935.61 <math>\pm</math> 0.00</b> | 4.4526 $\pm$ 0.0000  | 0,482     |
|           | XBI             | -6150.52 $\pm$ 0.00                   | <b>0.2612 <math>\pm</math> 0.0000</b> | 40.28 $\pm$ 0.00                    | 11470.29 $\pm$ 0.00                   | 0.5313 $\pm$ 0.0000  | 0,513     |

Çizelge 2 Blobs veri setinde 13 farklı metasezgisel algoritmanın ayrı ayrı her bir hedef fonksiyonu için 10'ar kez çalıştırılması sonucu elde edilen ortalama BRI, DBI, CHI,

KDI değerlerini, standart sapmalarını ve ortalama çalışma sürelerini göstermektedir.

Çizelge 3. Circles veri seti için metriklerin 10 tekrarlı çalıştırmanın ortalama  $\pm$  standart sapma değerleri.

| Algoritma | Hedef Fonksiyon | BRI ( $\downarrow$ )                  | DBI ( $\downarrow$ )                  | DRI ( $\uparrow$ )  | CHI ( $\uparrow$ )                  | KDI ( $\downarrow$ )                  | Süre (sn) |
|-----------|-----------------|---------------------------------------|---------------------------------------|---------------------|-------------------------------------|---------------------------------------|-----------|
| ALO       | BHI             | -3724.57 $\pm$ 0.01                   | 1.1814 $\pm$ 0.0000                   | 3.6927 $\pm$ 0.0005 | 869.10 $\pm$ 0.01                   | 0.7928 $\pm$ 0.0074                   | 0,518     |
|           | MIS             | -3425.08 $\pm$ 2.40                   | 1.1682 $\pm$ 0.0109                   | 1.7248 $\pm$ 0.0142 | 396.15 $\pm$ 4.98                   | 2.6202 $\pm$ 0.5395                   | 0,636     |
|           | XBI             | 6.00e+09 $\pm$ 5.16e+09               | 0.8225 $\pm$ 0.2481                   | 1.8098 $\pm$ 1.2989 | 262.34 $\pm$ 418.64                 | 2.9935 $\pm$ 1.5200                   | 0,576     |
| AOA       | BHI             | -3724.56 $\pm$ 0.01                   | 1.1814 $\pm$ 0.0000                   | 3.6930 $\pm$ 0.0007 | 869.09 $\pm$ 0.01                   | <b>0.7881 <math>\pm</math> 0.0113</b> | 0,313     |
|           | MIS             | -3426.10 $\pm$ 2.69                   | 1.1569 $\pm$ 0.0101                   | 1.7157 $\pm$ 0.0153 | 394.51 $\pm$ 5.77                   | 2.8567 $\pm$ 0.5224                   | 0,415     |
|           | XBI             | 7.00e+09 $\pm$ 4.83e+09               | 0.8106 $\pm$ 0.2559                   | 1.8096 $\pm$ 1.2990 | 262.17 $\pm$ 418.74                 | 2.9932 $\pm$ 1.5205                   | 0,382     |
| BBO       | BHI             | -3724.30 $\pm$ 0.51                   | 1.1816 $\pm$ 0.0004                   | 3.6867 $\pm$ 0.0092 | 868.49 $\pm$ 0.83                   | 0.8604 $\pm$ 0.1453                   | 0,334     |
|           | MIS             | -3425.34 $\pm$ 1.82                   | 1.1557 $\pm$ 0.0111                   | 1.7123 $\pm$ 0.0124 | 392.06 $\pm$ 4.23                   | 2.7579 $\pm$ 0.4575                   | 0,433     |
|           | XBI             | 3.00e+09 $\pm$ 4.83e+09               | 1.0197 $\pm$ 0.2602                   | 2.8812 $\pm$ 1.2962 | 608.03 $\pm$ 418.09                 | 1.7272 $\pm$ 1.5266                   | 0,427     |
| BMO       | BHI             | -3722.60 $\pm$ 1.40                   | 1.1824 $\pm$ 0.0015                   | 3.6902 $\pm$ 0.0276 | 865.63 $\pm$ 2.20                   | 1.5957 $\pm$ 0.9328                   | 0,27      |
|           | MIS             | -3427.20 $\pm$ 3.31                   | 1.1442 $\pm$ 0.0098                   | 1.7064 $\pm$ 0.0194 | 390.88 $\pm$ 7.81                   | 2.9107 $\pm$ 0.4743                   | 0,368     |
|           | XBI             | 1.00e+10 $\pm$ 0.00                   | 0.6530 $\pm$ 0.0119                   | 1.0028 $\pm$ 0.0001 | 2.1046 $\pm$ 0.0750                 | 3.9355 $\pm$ 0.0063                   | 0,238     |
| FBIO      | BHI             | <b>-3724.57 <math>\pm</math> 0.00</b> | 1.1814 $\pm$ 0.0000                   | 3.6925 $\pm$ 0.0000 | <b>869.10 <math>\pm</math> 0.00</b> | 0.7952 $\pm$ 0.0000                   | 1,382     |
|           | MIS             | -3424.26 $\pm$ 0.77                   | 1.1686 $\pm$ 0.0047                   | 1.7234 $\pm$ 0.0047 | 394.38 $\pm$ 1.37                   | 2.3714 $\pm$ 0.4432                   | 1,808     |
|           | XBI             | 6.00e+09 $\pm$ 5.16e+09               | 0.6597 $\pm$ 0.0232                   | 1.0041 $\pm$ 0.0015 | 3.0508 $\pm$ 1.1283                 | 3.9418 $\pm$ 0.0031                   | 1,79      |
| GCO       | BHI             | -3724.38 $\pm$ 0.47                   | 1.1815 $\pm$ 0.0004                   | 3.6899 $\pm$ 0.0082 | 868.79 $\pm$ 0.77                   | 0.8188 $\pm$ 0.0992                   | 0,367     |
|           | MIS             | -3423.28 $\pm$ 2.52                   | 1.1575 $\pm$ 0.0094                   | 1.7089 $\pm$ 0.0098 | 389.38 $\pm$ 3.84                   | 2.7008 $\pm$ 0.5134                   | 0,475     |
|           | XBI             | 6.00e+09 $\pm$ 5.16e+09               | 0.6607 $\pm$ 0.0238                   | 1.0043 $\pm$ 0.0020 | 3.2515 $\pm$ 1.5185                 | 3.9419 $\pm$ 0.0054                   | 0,469     |
| GWO       | BHI             | -3724.57 $\pm$ 0.00                   | 1.1814 $\pm$ 0.0000                   | 3.6925 $\pm$ 0.0000 | 869.10 $\pm$ 0.00                   | 0.7953 $\pm$ 0.0005                   | 0,343     |
|           | MIS             | -3425.61 $\pm$ 2.79                   | 1.1640 $\pm$ 0.0088                   | 1.7228 $\pm$ 0.0095 | 395.48 $\pm$ 4.90                   | 2.5862 $\pm$ 0.5432                   | 0,438     |
|           | XBI             | 2.00e+09 $\pm$ 4.22e+09               | 1.0263 $\pm$ 0.2502                   | 2.8856 $\pm$ 1.2986 | 609.15 $\pm$ 418.42                 | 1.7361 $\pm$ 1.5221                   | 0,411     |
| HGSO      | BHI             | -3723.56 $\pm$ 0.49                   | 1.1819 $\pm$ 0.0005                   | 3.6847 $\pm$ 0.0141 | 867.25 $\pm$ 0.80                   | 0.9141 $\pm$ 0.2157                   | 0,352     |
|           | MIS             | -3423.48 $\pm$ 3.02                   | 1.1551 $\pm$ 0.0088                   | 1.7077 $\pm$ 0.0135 | 388.83 $\pm$ 5.56                   | 2.7352 $\pm$ 0.5917                   | 0,475     |
|           | XBI             | 5.00e+09 $\pm$ 5.27e+09               | 0.9232 $\pm$ 0.2725                   | 2.3438 $\pm$ 1.4136 | 434.89 $\pm$ 456.28                 | 2.3626 $\pm$ 1.6618                   | 0,444     |
| HHO       | BHI             | -3724.34 $\pm$ 0.42                   | 1.1815 $\pm$ 0.0003                   | 3.6908 $\pm$ 0.0075 | 868.75 $\pm$ 0.67                   | 0.8358 $\pm$ 0.1468                   | 0,542     |
|           | MIS             | -3428.59 $\pm$ 3.06                   | 1.1608 $\pm$ 0.0119                   | 1.7270 $\pm$ 0.0120 | 399.22 $\pm$ 4.71                   | 3.1183 $\pm$ 0.5246                   | 0,73      |
|           | XBI             | 1.00e+10 $\pm$ 0.00                   | <b>0.6462 <math>\pm</math> 0.0057</b> | 1.0029 $\pm$ 0.0000 | 2.1479 $\pm$ 0.0368                 | 3.9366 $\pm$ 0.0033                   | 0,597     |
| ICA       | BHI             | -3720.47 $\pm$ 3.96                   | 1.1830 $\pm$ 0.0017                   | 3.6140 $\pm$ 0.0877 | 857.65 $\pm$ 12.36                  | 1.0128 $\pm$ 0.4023                   | 0,465     |
|           | MIS             | -3444.99 $\pm$ 51.81                  | 1.1689 $\pm$ 0.0172                   | 1.7887 $\pm$ 0.1818 | 418.70 $\pm$ 63.07                  | 2.6041 $\pm$ 0.5348                   | 0,612     |
|           | XBI             | -3722.00 $\pm$ 2.21                   | 1.1825 $\pm$ 0.0009                   | 3.6488 $\pm$ 0.0403 | 862.77 $\pm$ 5.71                   | 0.8163 $\pm$ 0.0964                   | 0,619     |
| SMA       | BHI             | -3724.57 $\pm$ 0.01                   | 1.1814 $\pm$ 0.0000                   | 3.6927 $\pm$ 0.0005 | 869.10 $\pm$ 0.01                   | 0.7928 $\pm$ 0.0074                   | 0,396     |
|           | MIS             | -3424.78 $\pm$ 3.70                   | 1.1444 $\pm$ 0.0148                   | 1.7025 $\pm$ 0.0182 | 387.88 $\pm$ 6.93                   | 2.6617 $\pm$ 0.4103                   | 0,483     |
|           | XBI             | 1.00e+10 $\pm$ 0.00                   | 0.6552 $\pm$ 0.0093                   | 1.0028 $\pm$ 0.0001 | 2.0898 $\pm$ 0.0600                 | 3.9314 $\pm$ 0.0053                   | 0,417     |

Çizelge 3. devam

| Algoritma | Hedef Fonksiyon | BRI (↓)             | DBI (↓)         | DRI (↑)                | CHI (↑)         | KDI (↓)         | Süre (sn) |
|-----------|-----------------|---------------------|-----------------|------------------------|-----------------|-----------------|-----------|
| TLO       | BHI             | -3724.57 ± 0.00     | 1.1814 ± 0.0000 | 3.6925 ± 0.0000        | 869.10 ± 0.00   | 0.7951 ± 0.0008 | 0,678     |
|           | MIS             | -3424.32 ± 2.27     | 1.1611 ± 0.0056 | 1.7169 ± 0.0099        | 392.30 ± 4.58   | 2.5579 ± 0.5591 | 0,883     |
|           | XBI             | 8.00e+09 ± 4.22e+09 | 0.7518 ± 0.2264 | 1.5407 ± 1.1339        | 175.53 ± 365.50 | 3.3083 ± 1.3268 | 0,874     |
| WOA       | BHI             | -3724.21 ± 0.61     | 1.1814 ± 0.0004 | <b>3.6939 ± 0.0097</b> | 868.50 ± 0.92   | 0.8473 ± 0.1566 | 0,304     |
|           | MIS             | -3426.02 ± 3.73     | 1.1560 ± 0.0113 | 1.7158 ± 0.0164        | 393.79 ± 6.35   | 2.8349 ± 0.4593 | 0,41      |
|           | XBI             | 8.00e+09 ± 4.22e+09 | 0.7552 ± 0.2247 | 1.5407 ± 1.1339        | 175.51 ± 365.51 | 3.3077 ± 1.3265 | 0,346     |

Çizelge 3 Circles veri setinde 13 farklı metasezgisel algoritmanın ayrı ayrı her bir hedef fonksiyonu için 10'ar kez çalıştırılması sonucu elde edilen ortalama BRI, DBI, CHI, KDI değerlerini, standart sapmalarını ve ortalama çalışma sürelerini göstermektedir. Circles veri setinde XBI hedef fonksiyonu altında gözlemlenen yüksek BRI değerleri ( $10^9$ - $10^{10}$  mertebesi), metrikte kullanılan oransal hesaplamaların

çok düşük kümeler arası uzaklık değerlerinde bölme hatasına karşı duyarlılığından kaynaklanmaktadır. Bu durum MetaCluster dokümantasyonunda da olası 'overflow' uyarısı olarak belirtilmiştir. İlgili sonuçlar sayısal anomali olarak değerlendirilmiş, kümelerin yüksek korelasyonlu yapısı nedeniyle BRI'nin bu veri seti için uygun bir gösterge olmaya bileceği not edilmiştir.

Çizelge 4. Moons veri seti için metriklerin 10 tekrarlı çalıştırmanın ortalama ± standart sapma değerleri.

| Algoritma | Hedef Fonksiyon | BRI (↓)                | DBI (↓)         | DRI (↑)         | CHI (↑)               | KDI (↓)         | Süre (sn) |
|-----------|-----------------|------------------------|-----------------|-----------------|-----------------------|-----------------|-----------|
| ALO       | BHI             | <b>-4163.06 ± 0.00</b> | 0.8094 ± 0.0000 | 5.2450 ± 0.0000 | <b>2101.00 ± 0.00</b> | 3.1446 ± 0.0000 | 0,516     |
|           | MIS             | -4129.54 ± 0.00        | 0.8211 ± 0.0000 | 5.0325 ± 0.0000 | 2021.33 ± 0.00        | 2.2920 ± 0.0000 | 0,642     |
|           | XBI             | -4163.00 ± 0.01        | 0.8094 ± 0.0000 | 5.2440 ± 0.0002 | 2100.85 ± 0.03        | 3.1499 ± 0.0057 | 0,621     |
| AOA       | BHI             | -4162.94 ± 0.35        | 0.8095 ± 0.0003 | 5.2427 ± 0.0070 | 2100.72 ± 0.89        | 3.1644 ± 0.0624 | 0,317     |
|           | MIS             | -4130.23 ± 0.76        | 0.8208 ± 0.0003 | 5.0365 ± 0.0051 | 2022.92 ± 1.67        | 2.3014 ± 0.0094 | 0,431     |
|           | XBI             | -4163.01 ± 0.02        | 0.8094 ± 0.0000 | 5.2437 ± 0.0004 | 2100.89 ± 0.04        | 3.1572 ± 0.0096 | 0,421     |
| BBO       | BHI             | -4162.73 ± 0.55        | 0.8094 ± 0.0003 | 5.2434 ± 0.0098 | 2100.15 ± 1.43        | 3.1202 ± 0.1059 | 0,343     |
|           | MIS             | -4127.43 ± 4.79        | 0.8216 ± 0.0015 | 5.0141 ± 0.0378 | 2016.25 ± 11.44       | 2.2877 ± 0.0277 | 0,46      |
|           | XBI             | -4162.57 ± 0.66        | 0.8096 ± 0.0005 | 5.2384 ± 0.0136 | 2099.76 ± 1.70        | 3.1794 ± 0.1328 | 0,443     |
| BMO       | BHI             | -4162.12 ± 0.72        | 0.8100 ± 0.0005 | 5.2287 ± 0.0148 | 2098.48 ± 2.07        | 3.2542 ± 0.1251 | 0,284     |
|           | MIS             | -4096.09 ± 61.70       | 0.8259 ± 0.0098 | 4.6973 ± 0.6089 | 1926.38 ± 173.75      | 2.4650 ± 0.3871 | 0,383     |
|           | XBI             | -4162.02 ± 0.88        | 0.8099 ± 0.0005 | 5.2292 ± 0.0173 | 2098.22 ± 2.38        | 3.2291 ± 0.1491 | 0,283     |
| FBIO      | BHI             | <b>-4163.06 ± 0.00</b> | 0.8094 ± 0.0000 | 5.2450 ± 0.0000 | <b>2101.00 ± 0.00</b> | 3.1446 ± 0.0000 | 1,416     |
|           | MIS             | -4129.54 ± 0.00        | 0.8211 ± 0.0000 | 5.0325 ± 0.0000 | 2021.33 ± 0.00        | 2.2920 ± 0.0000 | 1,903     |
|           | XBI             | -4162.99 ± 0.00        | 0.8094 ± 0.0000 | 5.2441 ± 0.0000 | 2100.85 ± 0.00        | 3.1481 ± 0.0000 | 1,803     |
| GCO       | BHI             | -4163.05 ± 0.01        | 0.8094 ± 0.0000 | 5.2451 ± 0.0014 | 2100.98 ± 0.04        | 3.1415 ± 0.0216 | 0,376     |
|           | MIS             | -4130.54 ± 1.19        | 0.8206 ± 0.0004 | 5.0391 ± 0.0090 | 2023.64 ± 2.85        | 2.3025 ± 0.0105 | 0,495     |
|           | XBI             | -4163.00 ± 0.02        | 0.8094 ± 0.0000 | 5.2438 ± 0.0004 | 2100.88 ± 0.04        | 3.1554 ± 0.0094 | 0,481     |

Çizelge 4. devam

| Algoritma | Hedef Fonksiyon | BRI (↓)                | DBI (↓)                | DRI (↑)                | CHI (↑)               | KDI (↓)                | Süre (sn) |
|-----------|-----------------|------------------------|------------------------|------------------------|-----------------------|------------------------|-----------|
| GWO       | BHI             | <b>-4163.06 ± 0.00</b> | 0.8094 ± 0.0000        | 5.2450 ± 0.0000        | <b>2101.00 ± 0.00</b> | 3.1446 ± 0.0000        | 0,347     |
|           | MIS             | -4129.24 ± 1.35        | 0.8212 ± 0.0005        | 5.0302 ± 0.0102        | 2020.64 ± 3.12        | 2.2904 ± 0.0079        | 0,462     |
|           | XBI             | -4162.99 ± 0.00        | 0.8094 ± 0.0000        | 5.2441 ± 0.0000        | 2100.85 ± 0.00        | 3.1481 ± 0.0000        | 0,455     |
| HGSO      | BHI             | -4162.21 ± 0.62        | 0.8096 ± 0.0004        | 5.2363 ± 0.0132        | 2098.76 ± 1.75        | 3.1432 ± 0.1375        | 0,367     |
|           | MIS             | -4129.53 ± 6.75        | 0.8209 ± 0.0023        | 5.0315 ± 0.0503        | 2021.08 ± 16.40       | 2.2966 ± 0.0518        | 0,493     |
|           | XBI             | -4161.64 ± 1.62        | 0.8098 ± 0.0005        | 5.2313 ± 0.0176        | 2097.36 ± 4.14        | 3.1421 ± 0.1869        | 0,462     |
| HHO       | BHI             | <b>-4163.06 ± 0.00</b> | 0.8094 ± 0.0000        | 5.2450 ± 0.0000        | <b>2101.00 ± 0.00</b> | 3.1446 ± 0.0000        | 0,546     |
|           | MIS             | -4129.59 ± 0.16        | 0.8211 ± 0.0001        | 5.0326 ± 0.0001        | 2021.46 ± 0.42        | 2.2939 ± 0.0062        | 0,756     |
|           | XBI             | -4163.00 ± 0.01        | 0.8094 ± 0.0000        | 5.2439 ± 0.0003        | 2100.86 ± 0.03        | 3.1517 ± 0.0076        | 0,703     |
| ICA       | BHI             | -4153.60 ± 20.60       | 0.8116 ± 0.0041        | 5.1468 ± 0.2129        | 2075.11 ± 57.71       | 3.1417 ± 0.3319        | 0,493     |
|           | MIS             | -4129.54 ± 0.00        | 0.8211 ± 0.0000        | 5.0325 ± 0.0000        | 2021.33 ± 0.00        | 2.2920 ± 0.0000        | 0,646     |
|           | XBI             | -4150.78 ± 24.00       | 0.8136 ± 0.0061        | 5.1174 ± 0.2240        | 2068.08 ± 66.95       | 3.3272 ± 0.4734        | 0,632     |
| SMA       | BHI             | <b>-4163.06 ± 0.00</b> | 0.8094 ± 0.0000        | 5.2450 ± 0.0000        | <b>2101.00 ± 0.00</b> | 3.1446 ± 0.0000        | 0,406     |
|           | MIS             | -4119.73 ± 14.79       | 0.8241 ± 0.0047        | 4.9552 ± 0.1160        | 1996.21 ± 38.15       | <b>2.2332 ± 0.0916</b> | 0,505     |
|           | XBI             | -4162.87 ± 0.44        | 0.8095 ± 0.0003        | 5.2414 ± 0.0079        | 2100.56 ± 1.05        | 3.1751 ± 0.0688        | 0,456     |
| TLO       | BHI             | <b>-4163.06 ± 0.00</b> | 0.8094 ± 0.0000        | 5.2450 ± 0.0000        | <b>2101.00 ± 0.00</b> | 3.1446 ± 0.0000        | 0,684     |
|           | MIS             | -4129.23 ± 0.96        | 0.8212 ± 0.0003        | 5.0302 ± 0.0072        | 2020.60 ± 2.30        | 2.2897 ± 0.0073        | 0,921     |
|           | XBI             | -4162.99 ± 0.00        | 0.8094 ± 0.0000        | 5.2441 ± 0.0000        | 2100.85 ± 0.00        | 3.1481 ± 0.0000        | 0,878     |
| WOA       | BHI             | -4163.06 ± 0.00        | <b>0.8094 ± 0.0000</b> | <b>5.2451 ± 0.0004</b> | 2101.00 ± 0.00        | 3.1427 ± 0.0061        | 0,306     |
|           | MIS             | -4124.12 ± 15.33       | 0.8229 ± 0.0051        | 4.9907 ± 0.1158        | 2007.21 ± 40.28       | 2.2613 ± 0.0974        | 0,424     |
|           | XBI             | -4163.00 ± 0.01        | 0.8094 ± 0.0000        | 5.2440 ± 0.0002        | 2100.85 ± 0.03        | 3.1499 ± 0.0057        | 0,389     |

Çizelge 4 Moons veri setinde 13 farklı metasezgisel algoritmanın ayrı ayrı her bir hedef fonksiyonu için 10'ar kez çalıştırılması sonucu elde edilen ortalama BRI, DBI, CHI, KDI değerlerini, standart sapmalarını ve ortalama çalışma sürelerini göstermektedir.

### 3.1. Metrik Tabanlı Performans Karşılaştırması

Her algoritma ve hedef fonksiyon kombinasyonu için beş farklı metrik hesaplanmıştır: BRI, DBI, DRI, CHI ve KDI. Her veri seti için DBI bakımından en iyi performans gösteren algoritma ve fonksiyon kombinasyonları Çizelge 5'te özetlenmiştir ve bu kombinasyonlar Şekil 1'de grafik olarak sunulmuştur.

Çizelge 5'e göre, her veri kümesi ve hedef fonksiyon kombinasyonu için en düşük ortalama DBI değerini üreten algoritmalar gösterilmektedir. Blobs veri setinde BHI ve MIS altında 12 algoritma, XBI altında ise tüm algoritmalar (ALO, AOA, BBO, BMO, FBIO, GCO, GWO, HGSO,

HHO, ICA, SMA, TLO, WOA) aynı optimum DBI değerlerine çok yakın sonuçlar üretmiş, dolayısıyla tek bir 'en iyi' kombinasyon yerine bir algoritma grubu öne çıkmıştır. Circles veri setinde XBI hedef fonksiyonu altında FBIO en düşük DBI değerini sağlamış, SMA, HHO ve BMO ise onu yakın değerlerle takip etmiştir. Moons veri setinde ise BHI hedef fonksiyonu altında WOA ve GCO aynı en düşük DBI değerini elde etmiş, diğer algoritmalar bu değerlerin hemen çevresinde toplanırken ICA nispeten daha yüksek DBI değerleri ile ayrılmıştır.

### 3.2. Grafikselleştirme Analizler

MetaCluster platformu, deneysel sonuçların görselleştirilmesi için her algoritma-fonksiyon kombinasyonu için kutu grafiği ve yakınsama eğrisi grafiklerini otomatik olarak üretmiştir. Bu grafikler sayesinde algoritmaların kararlılığı ve yakınsama hızları analiz edilmiştir.


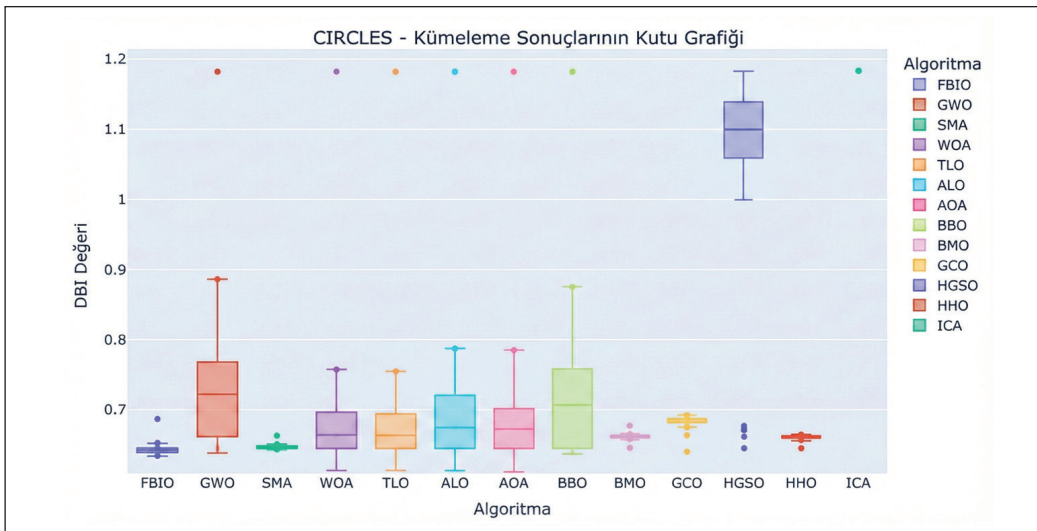
**Çizelge 5.** Veri seti ve hedef fonksiyona göre DBI'ye göre en iyi algoritma(lar).

| Veri Seti | Hedef Fonksiyonu | En İyi Algoritma | Ortalama DBI | Ortalama Süre (sn) |
|-----------|------------------|------------------|--------------|--------------------|
| Blobs     | XBI              | Hepsi            | 0.2612       | 0.69               |
| Blobs     | BHI / MIS        | BMO Hariç Hepsi  | 0.2804       | 0.69 - 0.78        |
| Circles   | XBI              | FBIO             | 0.6444       | 0.55 - 0.65        |
| Moons     | BHI              | WOA, GCO         | 0.8093       | 0.63               |

Şekil 1'e göre Blobs veri setine ait kutu grafiği, tüm algoritmaların DBI değerlerinde son derece düşük varyans gösterdiğini ve neredeyse birbirine eşit sonuçlar ürettiğini ortaya koymaktadır. Kutuların oldukça dar olması ve whisker uzunluklarının minimum düzeyde bulunması, algoritmaların tekrarlar boyunca son derece kararlı bir performans sergilediğini göstermektedir. ICA algoritması dışarıda bırakıldığında, tüm yöntemlerin DBI değerlerinin aynı dar ara-

lıkta toplanmış olması, Blobs veri setinin yapısal olarak kolay ayrışabilen bir kümelene problemine sahip olduğunu desteklemektedir. ICA'nın daha geniş kutusu ve üst uçtaki aykırı değerleri ise bu algoritmanın Blobs veri setinde hem daha değişken hem de daha zayıf bir performans gösterdiğini işaret etmektedir.

Şekil 2'ye göre Circles veri setine ilişkin kutu grafiği, algoritmaların DBI sonuçlarında yüksek değişkenlik bulundu-

**Şekil 1.** Blobs veri setinde meta-sezgisel algoritmaların DBI dağılımları.**Şekil 2.** Circles veri setinde meta-sezgisel algoritmaların DBI dağılımları.

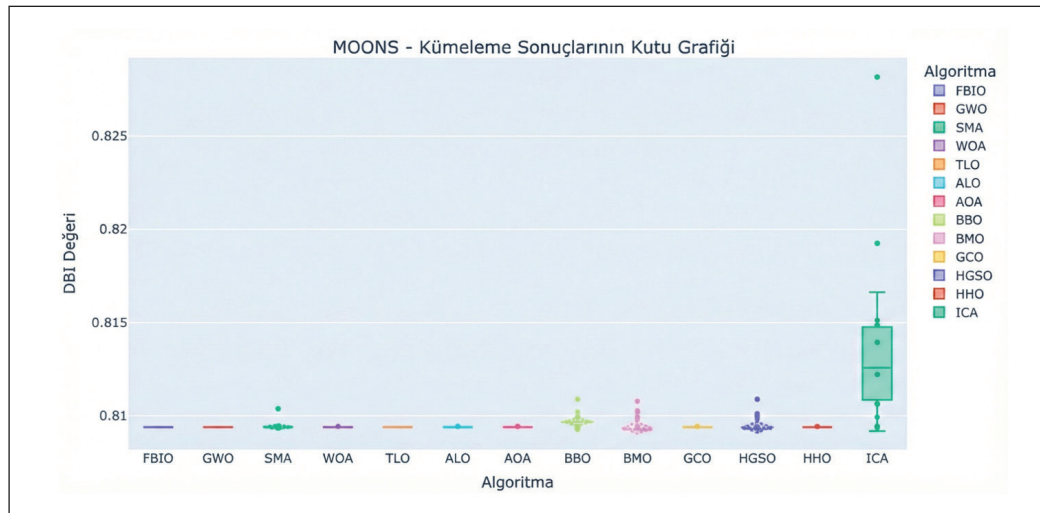
ğunu ve performanslarının istikrarsız olduğunu göstermektedir. Geniş kutular, uzun whisker'lar ve çok sayıda aykırı değer, Circles veri setinin zorlayıcı geometrik yapısı nedeniyle algoritmalar arasında ciddi performans dalgalanmaları oluştuğuna işaret etmektedir. Birçok algortmada kutu genişliklerinin büyük olması, tekrarlar arasında farklı sonuçlar elde edildiğini ve kararlılığın düşük olduğunu ortaya koyar. ICA algoritmasının kutusunun nispeten dar olmakla birlikte yüksek DBI değerlerinde yoğunlaşması ise, algoritmanın tutarlı fakat diğer yöntemlere kıyasla daha kötü performans verdiğini göstermektedir. Bu grafik, Circles veri setinin kümelenme açısından karmaşık yapısını ve çizelgelerdeki yüksek ortalama DBI değerlerini güçlü biçimde desteklemektedir.

Şekil 3'e göre Moons veri setine ait kutu grafiği, algoritmaların DBI değerlerinde oldukça düşük varyans ve yüksek


kararlılık sergilediğini göstermektedir. Kutuların ve whisker'ların son derece dar olması, algoritmaların farklı tekrarlar boyunca neredeyse aynı DBI değerlerini ürettiğini ve Moons veri setinin yapısal olarak istikrarlı bir kümelenme çıktısı sağladığını ortaya koymaktadır. ICA algoritması diğer yöntemlere kıyasla daha geniş bir kutu sergileyerek nispeten daha değişken bir performans göstermiş olsa da genel tablo, tüm algoritmaların Moons veri setinde tutarlı ve benzer DBI değerleri ürettiğini göstermektedir. Bu durum, çizelgelerde sunulan ortalama DBI değerlerinin ( $\approx 0.81$ ) kutu grafiği ile tam uyumlu olduğunu doğrulamaktadır.

Yakınsama eğrileri ise algoritmaların optimizasyon süreci boyunca ne kadar hızlı çözüme ulaştıklarını göstermiştir.

Şekil 4'e göre Blobs veri setine ait yakınsama eğrileri, tüm meta-sezgisel algoritmaların ilk iterasyonlardan itibaren



Şekil 3. Moons veri setinde meta-sezgisel algoritmaların DBI dağılımları.




Şekil 4. Blobs veri seti için XBI hedef fonksiyonuna ait yakınsama eğrileri.

aynı XBI değerine anında ulaştığını ve sonraki tüm iterasyonlarda bu değeri koruduğunu göstermektedir. Eğrilerin tamamen çakışması ve yatay seyretmesi, hem hedef fonksiyonun bu veri kümesi için çok kolay optimize edilebilir olduğunu hem de tüm algoritmaların aynı optimum noktaya deterministik bir şekilde kilitlendiğini ortaya koymaktadır. Bu durum, BLOBs veri setinde daha önce elde edilen kutu grafiği ve tablo sonuçları ile birebir uyumludur; çünkü DBI değerlerinin tüm algoritmalarda aynı çıkması, optimizasyon yolculuğunun da aynı şekilde sonuçlandığını doğrulamaktadır.


Şekil 5'e göre Circles veri setinde yakınsama eğrileri belirgin farklılaşmalar göstermektedir. Bazı algoritmalar (ör. FBIO, BBO, ALO) erken iterasyonlarda hızla yakınsanırken, bazıları (ör. TLO, WOA, GCO) daha geç iterasyonlarda ani düşüşler ile optimuma yaklaşmaktadır. Bazı algoritmaların

(HGSO gibi) başlangıçta yüksek XBI değerleri ile başlaması ve uzun süre plato yapması, bu veri kümesinin gürültü ve dairesel yapı nedeniyle daha zor optimize edildiğini göstermektedir. FBIO'nun en hızlı ve en stabil düşüşü gösterdiği, diğerlerinin ise çeşitli derecelerde dalgalanmalar yaşadığı grafik üzerinde net şekilde görülmektedir. Bu eğriler, kutu grafiklerinde Circles veri setinin yüksek varyanslı ve algoritmalar arasında daha ayırt edici sonuçlara sahip olduğu bulgusunu doğrudan desteklemektedir.

Şekil 6'ya göre Moons veri setinde algoritmaların büyük çoğunluğu ilk birkaç iterasyonda çok hızlı biçimde optimuma yakınsamakta ve XBI değerleri kısa sürede dar bir aralıkta konsolide olmaktadır. Bazı algoritmalarda (ör. HGSO, HHO) yakınsama daha yavaş gerçekleşse de genel olarak tüm eğriler 10. iterasyondan sonra neredeyse birbirine tamamen yaklaşmakta ve aynı değerde sabitlenmektedir. Bu



Şekil 5. Circles veri seti için XBI hedef fonksiyonuna ait yakınsama eğrileri.



Şekil 6. Moons veri seti için XBI hedef fonksiyonuna ait yakınsama eğrileri.

durum Moons veri setinin, tıpkı DBI kutu grafiğinde görüldüğü gibi, algoritmalar için nispeten düşük zorluk derecesine sahip olduğunu ve çözümlerin çok küçük varyansla birbirine yakınladığını göstermektedir. Yakınsama eğrilerinin bu davranışı, tabloda görülen “neredeyse tüm algoritmaların aynı DBI değerini üretmesi” bulgusunu güçlü biçimde doğrulamaktadır

### 3.3. Ortalama Çalışma Süreleri

Yapılan ölçümlerde, her algoritma ve hedef fonksiyonu için çalışma süreleri ayrı ayrı hesaplanmıştır ve sonuçlar Şekil 7’de grafik olarak sunulmuştur. Elde edilen sonuçlara bakıldığında veri setlerine göre ortalama çalışma süreleri 0.33 ile 2.11 saniye arasında değişmektedir. Çalışma süreleri algoritmalar arasında mutlak değer olarak düşük olsa da anlamlı farklılıklar göstermekte; BMO algoritması en kısa sürelerde yakınsama sağlayan yöntem olurken, WOA ve GWO da görece en hızlı çalışan algoritmalar arasında yer almıştır. Buna karşın FBIO algoritması, özellikle tüm hedef fonksiyonlarında daha yüksek süreler üretmiş ve ortalama olarak en uzun çalışma süresine sahip yöntem olmuştur.

### 3.4. İstatistiksel Anlamlılık Analizi

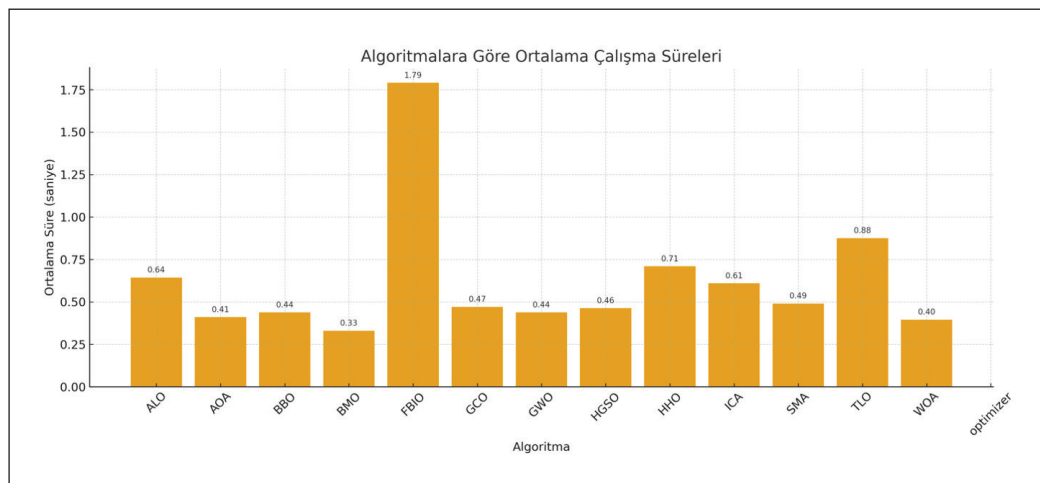
Her algoritma–hedef fonksiyonu kombinasyonu için elde edilen DBI değerleri üzerinde Friedman testi uygulanmıştır. Analiz sonucunda algoritmalar arasında istatistiksel olarak anlamlı bir fark olduğu görülmüştür ( $\chi^2(12) = 62.66$ ,  $p = 0.0071$ ). Bu durum, test edilen kombinasyonlar arasında en az bir tanesinin performansının diğerlerinden ayrıştığını kanıtlamaktadır. Söz konusu farklılığın hangi algoritma çiftlerinden kaynaklandığını belirlemek amacıyla uygulanan Nemenyi post-hoc testi sonuçları ise tüm ikili karşılaştırmalarda  $p > 0.05$  değerini vermiştir.

Bu istatistiksel sonuçlar, Çizelge 2, 3 ve 4’te sunulan sayısal verilerle doğrudan ilişkilidir. Blobs (Çizelge 2) ve Moons (Çizelge 4) veri setlerinde algoritmaların ezici çoğunluğunun  $\pm 0.0000$  standart sapma ile aynı global optimum noktalara (sırasıyla  $\approx 0.2612$  ve  $\approx 0.8094$ ) ulaşmış olması, algoritmaların istatistiksel olarak “aynı başarı grubunda” yer almasına neden olmuştur. Öte yandan, daha karmaşık bir yapıya sahip olan Circles veri setinde (Çizelge 3), FBIO algoritması hem en düşük ortalamayı sağlaması hem de düşük varyansı ile istatistiksel olarak en kararlı performansı sergilemesiyle bu grupta lider konuma yerleşmiştir. Sonuç olarak, hiçbir algoritma çifti arasında  $p < 0.05$  düzeyinde “anlamlı bir fark” bulunamaması, meta-sezgisel algoritmaların bu veri kümelerinde birbirine çok yakın ve yüksek kalitede çözümler ürettiğini ve performans farklarının rastlantısal varyasyon sınırları içinde kaldığını doğrulamaktadır.

## 4. Sonuç ve Öneriler

Bu çalışmada MetaCluster platformu aracılığıyla 13 farklı meta-sezgisel algoritma, üç farklı hedef fonksiyon altında circles, moons ve blobs veri setlerinde karşılaştırılmıştır. Elde edilen sonuçlar literatürde yer alan benzer çalışmalarla kıyaslandığında, bazı ortak eğilimlerin ve farklılıkların ortaya çıktığı görülmektedir.

Öncelikle, XBI hedef fonksiyonunun performansı dikkate değer bulunmuştur. Bu fonksiyon özellikle blobs ve circles veri setlerinde en düşük DBI değerlerini sağlamıştır. Benzer şekilde Yang vd. (2022) çok amaçlı parçacık sürü optimizasyonunu K-means ile birleştirerek Davies–Bouldin ve Silhouette indekslerinde iyileşme elde etmişlerdir. Bu durum, çok amaçlı veya dengeli hedef fonksiyonlarının kümeler arası ayrışma ve küme içi yoğunluğu aynı anda optimize etme noktasında daha başarılı olduğunu göstermektedir.



Şekil 7. Algoritmalarla göre ortalama çalışma süreleri.

Algoritma bazında karşılaştırıldığında, FBIO algoritmasının blobs veri setinde en iyi sonucu vermesi, Chou & Nguyen'nin (Chou & Nguyen, 2020) çalışmasında bildirilen FBIO'nun yüksek uyum performansı ile paralellik göstermekte, ancak diğer algoritmaların da benzer çözüm kalitesine erişebildiğini göstermektedir. HHO algoritmasının circles veri setinde elde ettiği başarı da Heidari vd.'nin (Heidari vd., 2019) literatürde belirttiği güçlü yakınsama kabiliyeti ile örtüşmektedir. Öte yandan moons veri setinde WOA algoritmasının öne çıkması, Mirjalili & Lewis'in (Mirjalili & Lewis, 2016) WOA'nın özellikle karmaşık, doğrusal olmayan veri dağılımlarında etkin olduğuna dair bulgularıyla uyumludur.

Ayrıca, farklı veri seti geometrilerinin algoritma performansları üzerindeki etkisi değerlendirilmiştir. Örneğin, Moons veri setinde karmaşık sınır yapısı nedeniyle özellikle WOA ve GCO gibi sürü zekâsı tabanlı algoritmalar çok hafif bir üstünlük göstermiş, diğer algoritmalar ise benzer DBI değerlerine yakınsamıştır. Blobs veri setinde ise FBIO'nun da içinde bulunduğu geniş bir algoritma grubu, XBI hedef fonksiyonu altında neredeyse aynı ve oldukça düşük DBI değerlerine ulaşarak, algoritmaların bu veri kümesinde benzer düzeyde istikrarlı çözümler ürettiğini ortaya koymaktadır. Ayrıca, bu çalışmada FBIO algoritmasının yüksek doğruluk sağlamasına rağmen çalışma süresinin uzun olması, pratik uygulamalarda hız-başarı dengesinin yeniden değerlendirilmesi gerektiğini göstermektedir.

Genel olarak, bulgular literatürde öne çıkan temel eğilimlerle uyumludur:

- Çok amaçlı optimizasyon yaklaşımları tek amaçlı fonksiyonlara göre daha dengeli sonuçlar sunmaktadır. Bu çalışmada XBI hedef fonksiyonu, özellikle Blobs ve Circles veri kümelerinde en düşük DBI değerlerini üretmiş ve dengeli hedef fonksiyonların tek kriterli yaklaşımlara göre daha başarılı olabildiğini desteklemiştir.
- Algoritmaların başarısı, veri setinin geometrik yapısı ve zorluk seviyesine bağlı olarak değişmektedir. Özellikle Circles veri setinde HGSO ve ICA'nın belirgin şekilde daha yüksek DBI değerleri üretmesi, veri seti geometrisinin (yoğun çember yapısı) algoritma duyarlılığı üzerinde etkili olduğunu göstermektedir; buna karşın Moons ve Blobs veri setlerinde algoritmaların çoğu benzer çözümlere yakınsamıştır.
- Çalışma süreleri algoritmalar arasında belirgin farklılık göstermekte, bu da gerçek zamanlı uygulamalar açısından önemli bir kriter olmaktadır.

Bu çalışmanın özgün katkısı, MetaCluster platformu kullanılarak aynı koşullarda geniş kapsamlı bir karşılaştırma sunmasıdır. Böylece, literatürde tekil algoritmaların öne çıktığı çalışmalardan farklı olarak, sistematik bir değerlendirme yapılmış ve araştırmacılara algoritma-hedef fonksiyon seçiminde kapsamlı bir referans sağlanmıştır.

Gelecek Çalışmalar İçin Öneriler:

- Karmaşık ve problem-özel ağırlıklı yeni hedef fonksiyonlar denenerek kümeleme performansı daha da iyileştirilebilir.
- Gerçek dünya veri setleri (biyomedikal veriler, sosyal ağlar, pazar segmentasyonu gibi) kullanılarak modelin genelleme kapasitesi test edilmelidir.
- Hiperparametre duyarlılığı araştırılarak algoritmalar için otomatik ayarlama yöntemleri (örneğin grid search, Bayesian optimization) geliştirilebilir.
- Platforma derin öğrenme tabanlı kümeleme yaklaşımları entegre edilerek daha güçlü hibrit sistemler oluşturulabilir.
- Bu çalışma üç farklı yapay veri kümesi (circles, moons, blobs) üzerinde yürütülmüştür. Bu veri kümeleri, farklı geometrik zorluk düzeylerini temsil ettiği için algoritmaların davranışlarını anlamada referans niteliğindedir. Ancak gelecekte, gerçek dünya veri setleri (örneğin biyomedikal, finansal veya sosyal ağ verileri) üzerinde testler yapılarak modelin genelleme gücü değerlendirilecektir.

Ayrıca, algoritmaların hiperparametre seçimlerine duyarlılığı gelecekteki çalışmalarda sistematik olarak incelenebilir. Bu kapsamda Grid Search veya Bayesian Optimization gibi otomatik parametre ayarlama stratejilerinin MetaCluster altyapısına entegre edilmesi, algoritmaların farklı veri kümelerindeki performans varyasyonlarını azaltarak genel başarımını artırabilir.

Platformun gelecekteki versiyonlarında derin öğrenme tabanlı kümeleme yöntemlerinin entegrasyonu planlanmaktadır. Bu hibrit yapı sayesinde, meta-sezgisel algoritmaların keşif yetenekleri derin ağların temsil gücüyle birleştirilecek ve özellikle yüksek boyutlu verilerde daha kararlı kümeleme sonuçları elde edilebilecektir.

Sonuç olarak, bu çalışma hem yönetsel derinliği hem de sistematik karşılaştırma yapısı ile çok amaçlı kümeleme alanında literatüre katkı sunmakta; araştırmacılara algoritma seçimi, hedef fonksiyonu değerlendirme ve deneysel analiz açısından yön gösterici olmaktadır.

**Yazar katkısı:** Murat Karakoyun: çalışmayı planlamış ve tasarlamıştır, Münevver Bahar: Çalışma hakkında verileri toplamış ve çalışmanın analizlerini yaparak makaleyi yazmıştır.

**Etik kurul onayı:** Etik kurul izni gerektirmeyen bir çalışma olup, herhangi bir kurumdan etik kurul izni alınmamıştır.

## Kaynaklar

- Abualigah, L., Diabat, A., Mirjalili, S., Abd Elaziz, M., & Gandomi, A.H. (2021).** The Arithmetic Optimization Algorithm. *Computer Methods in Applied Mechanics and Engineering*, 376, 113609. <https://doi.org/10.1016/j.cma.2020.113609>.
- Ananthi, M., Valarmathi, K., Ramathilagam, A., & Praveen, R. (2025).** Hybrid lion and exponential PSO-based metaheuristic clustering approach for efficient dynamic data stream management. *Scientific Reports*, 15(1), 22343. <https://doi.org/10.1038/s41598-025-07404-9>.
- Arora, S. & Singh, S. (2019).** Butterfly optimization algorithm: a novel approach for global optimization. *Soft Computing*, 23(3), 715-734. <https://doi.org/10.1007/s00500-018-3102-4>.
- Atashpaz-Gargari, E. & Lucas, C. (2007).** Imperialist competitive algorithm: An algorithm for optimization inspired by imperialistic competition. 2007 IEEE Congress on Evolutionary Computation, s. 4661-4667. <https://doi.org/10.1109/CEC.2007.4425083>.
- Chou, J.S. & Nguyen, N.-M. (2020).** FBI inspired meta-optimization. *Applied Soft Computing*, 93, 106339. <https://doi.org/10.1016/j.asoc.2020.106339>.
- El Habib Kahla, M., Beggas, M., Laouid, A., & Hammoudeh, M. (2024).** A Nature-Inspired Partial Distance-Based Clustering Algorithm. *Journal of Sensor and Actuator Networks*, 13(4), 36. <https://doi.org/10.3390/jsan13040036>.
- El Haouari, O., Hana, M., Khrissi, L., & El Akkad, N. (2025).** A New and Robust ABC-K-Means Hybrid Approach for Improved Image Clustering.
- Ertöz, L., Steinbach, M., & Kumar, V. (2003).** Finding Clusters of Different Sizes, Shapes, and Densities in Noisy, High Dimensional Data. *Proceedings of the 2003 SIAM International Conference on Data Mining (SDM)*, Society for Industrial and Applied Mathematics, s. 47-58. <https://doi.org/10.1137/1.9781611972733.5>.
- Ester, M., Kriegel, H.-P., & Xu, X. (1996).** A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise.
- Fortunato, S. (2010).** Community detection in graphs. *Physics Reports*, 486(3), 75-174. <https://doi.org/10.1016/j.physrep.2009.11.002>.
- Gang, X., Lefeng, W., & Yuwei, H. (2025).** Quantum walk artificial bee colony algorithm hybrid K-modes for clustering. [https://www.researchgate.net/publication/392616517\\_Quantum\\_walk\\_artificial\\_bee\\_colony\\_algorithm\\_hybrid\\_K-modes\\_for\\_clustering](https://www.researchgate.net/publication/392616517_Quantum_walk_artificial_bee_colony_algorithm_hybrid_K-modes_for_clustering).
- Hart, P.E., Stork, D.G., & Wiley, J. (2000).** *Pattern Classification*.
- Hashim, F.A., Houssein, E.H., Mabrouk, M.S., Al-Atabany, W., & Mirjalili, S. (2019).** Henry gas solubility optimization: A novel physics-based algorithm. *Future Generation Computer Systems*, 101, 646-667. <https://doi.org/10.1016/j.future.2019.07.015>.
- Heidari, A.A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., & Chen, H. (2019).** Harris hawks optimization: Algorithm and applications. *Future Generation Computer Systems*, 97, 849-872. <https://doi.org/10.1016/j.future.2019.02.028>.
- Holland, J.H. (1992).** *Adaptation in Natural and Artificial Systems: An Introductory Analysis with Applications to Biology, Control, and Artificial Intelligence*. MIT Press, 236 s.
- Jain, A.K. (2008).** *Data Clustering: 50 Years Beyond K-means*. W. Daelemans, B. Goethals, & K. Morik (Ed.), *Machine Learning and Knowledge Discovery in Databases*, Springer, Berlin, Heidelberg, s. 3-4. [https://doi.org/10.1007/978-3-540-87479-9\\_3](https://doi.org/10.1007/978-3-540-87479-9_3).
- Karakoyun, M. & Özks, A. (2021).** Transfer Fonksiyonları Kullanarak İkili Güve-Alev Optimizasyonu Algoritmalarının Geliştirilmesi ve Performanslarının Karşılaştırılması. *Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 3(2), 1-10.
- Kennedy, J. & Eberhart, R. (1995).** Particle swarm optimization. *Proceedings of ICNN'95 - International Conference on Neural Networks*, s. 1942-1948 c.4. <https://doi.org/10.1109/ICNN.1995.488968>.
- Li, S., Chen, H., Wang, M., Heidari, A.A., & Mirjalili, S. (2020).** Slime mould algorithm: A new method for stochastic optimization. *Future Generation Computer Systems*, 111, 300-323. <https://doi.org/10.1016/j.future.2020.03.055>.
- Liu, M., Zhu, Q., Yun, H., & Chun, H. (2025).** Enhanced PSO-based clustering algorithm with hybrid approach for population replacement and empty cluster correction. *Egyptian Informatics Journal*, 32, 100814. <https://doi.org/10.1016/j.eij.2025.100814>.
- Mirjalili, S. (2015).** The Ant Lion Optimizer. *Advances in Engineering Software*, 83, 80-98. <https://doi.org/10.1016/j.advengsoft.2015.01.010>.
- Mirjalili, S. & Lewis, A. (2016).** The Whale Optimization Algorithm. *Advances in Engineering Software*, 95, 51-67. <https://doi.org/10.1016/j.advengsoft.2016.01.008>.

- Mirjalili, S., Mirjalili, S.M., & Lewis, A. (2014).** Grey Wolf Optimizer. *Advances in Engineering Software*, 69, 46-61. <https://doi.org/10.1016/j.advengsoft.2013.12.007>.
- Ng, R.T. & Han, J. (2002).** CLARANS: a method for clustering objects for spatial data mining. *IEEE Transactions on Knowledge and Data Engineering*, 14(5), 1003-1016. <https://doi.org/10.1109/TKDE.2002.1033770>.
- Pektaş, A. & İnan, O. (2022).** Ağaç Tohum Algoritmasının Kümeleme Problemlerine Uygulanması. *Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 4(1), 1-10.
- Rao, R.V., Savsani, V.J., & Vakharia, D.P. (2012).** Teaching-Learning-Based Optimization: An optimization method for continuous non-linear large scale problems. *Information Sciences*, 183(1), 1-15. <https://doi.org/10.1016/j.ins.2011.08.006>.
- Sharma, D.K., Varshney, R.P., & Garg, A. (2022).** Hybrid Feature Selection Method with Multi-objective Grey Wolf Optimizer for High Dimension Data. *2022 9th International Conference on Computing for Sustainable Global Development (INDIACom)*, s. 854-859. <https://doi.org/10.23919/INDIACom54597.2022.9763182>.
- Shelokar, P.S., Jayaraman, V.K., & Kulkarni, B.D. (2004).** An ant colony approach for clustering. *Analytica Chimica Acta*, 509(2), 187-195. <https://doi.org/10.1016/j.aca.2003.12.032>.
- Simon, D. (2008).** Biogeography-Based Optimization. *IEEE Transactions on Evolutionary Computation*, 12(6), 702-713. <https://doi.org/10.1109/TEVC.2008.919004>.
- Steinbach, M., Karypis, G., & Kumar, V. (2000).** A Comparison of Document Clustering Techniques.
- Van Thieu, N., Nguyen, N.H., & Heidari, A.A. (2025).** Feature Selection using Metaheuristics Made Easy: Open Source MAFESE Library in Python.
- Van Thieu, N., Oliva, D., & Pérez-Cisneros, M. (2023).** MetaCluster: An open-source Python library for metaheuristic-based clustering problems. *SoftwareX*, 24, 101597. <https://doi.org/10.1016/j.softx.2023.101597>.
- Villaseñor, C., Arana-Daniel, N., Alanis, A.Y., López-Franco, C., & Hernandez-Vargas, E.A. (2018).** Germinal Center Optimization Algorithm. *International Journal of Computational Intelligence Systems*, 12(1), 13-27. <https://doi.org/10.2991/ijcis.2018.25905179>.
- Wan, H., Lu, C., & Cui, Y. (2025).** Improved WOA-DBSCAN Online Clustering Algorithm for Radar Signal Data Streams. *Sensors*, 25(16), 5184. <https://doi.org/10.3390/s25165184>.
- Wedel, M. & Kamakura, W.A. (2000).** Market Segmentation: Conceptual and Methodological Foundations. *Springer Science & Business Media*, 416 s.
- Xu, R. & Wunsch, D. (2005).** Survey of clustering algorithms. *IEEE Transactions on Neural Networks*, 16(3), 645-678. <https://doi.org/10.1109/TNN.2005.845141>.
- Yang, X.-S. (2010).** *Engineering Optimization: An Introduction with Metaheuristic Applications*. John Wiley & Sons, 377 s.
- Yang, Y., Liao, Q., Wang, J., & Wang, Y. (2022).** Application of multi-objective particle swarm optimization based on short-term memory and K-means clustering in multi-modal multi-objective optimization. *Engineering Applications of Artificial Intelligence*, 112, 104866. <https://doi.org/10.1016/j.engappai.2022.104866>.
- Yue, H., Zhang, H., & Dai, Y. (2025).** Application of PSO-integrated K-means algorithm in resident digital portrait classification. *PLOS ONE*, 20(8), e0329123. <https://doi.org/10.1371/journal.pone.0329123>.
- Zhou, X., Zhang, X., Gao, W., Wang, H., & Ma, Y. (2024).** Adaptive multi-population artificial bee colony algorithm based on fitness landscape analysis. *Applied Soft Computing*, 164, 111952. <https://doi.org/10.1016/j.asoc.2024.111952>.
- Zitzler, E., Laumanns, M., & Thiele, L. (2001).** SPEA2: Improving the strength pareto evolutionary algorithm. *ETH Zurich*.

## EK – 1

### Kısaltmalar Listesi

- ALO: Ant Lion Optimizer (Karıncı Aslanı Optimize Edici)
- AOA: Arithmetic Optimization Algorithm (Aritmetik Optimizasyon Algoritması)
- BBO: Biogeography-Based Optimization (Biyocoğrafya Tabanlı Optimizasyon)
- BMO: Barnacles Mating Optimizer (Sülükayak Çiftleşme Optimize Edici)
- FBIO: Forensic-Based Investigation Optimizer (Adli Soruşturma Tabanlı Optimize Edici)
- GCO: Germinal Center Optimization (Germinal Merkez Optimizasyonu)
- GWO: Grey Wolf Optimizer (Gri Kurt Optimize Edici)
- HGSO: Henry Gas Solubility Optimization (Henry Gaz Çözünürlüğü Optimizasyonu)
- HHO: Harris Hawks Optimization (Harris Şahini Optimizasyonu)
- ICA: Imperialist Competitive Algorithm (Emperyalist Rekabetçi Algoritma)
- SMA: Slime Mould Algorithm (Cıvık Mantar Algoritması)
- TLO: Teaching-Learning-Based Optimization (Öğretme-Öğrenme Tabanlı Optimizasyon)
- WOA: Whale Optimization Algorithm (Balina Optimizasyonu Algoritması)
- BHI: Ball-Hall Index
- BRI: Banfeld-Raftery Index
- CHI: Calinski-Harabasz Index
- DBI: Davies-Bouldin Index
- DRI: Det Ratio Index
- KDI: Ksq Detw Index
- MIS: Mutual Information Score
- XBI: Xie-Beni Index