



T.C.
NECMETTİN ERBAKAN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



ÖZELLİK SEÇİM PROBLEMİ İÇİN İKİLİ
ORKA YIRTICI ALGORİTMASININ
GELİŞTİRİLMESİ

Hamide Sena GÜVEN

YÜKSEK LİSANS TEZİ

Mekatronik Mühendisliği Anabilim Dalı

Eylül-2024
KONYA
Her Hakkı Saklıdır

TEZ KABUL VE ONAYI

Hamide Sena GÜVEN tarafından hazırlanan “ÖZELLİK SEÇİM PROBLEMİ İÇİN İKİLİ ORKA YIRTICI ALGORİTMASININ GELİŞTİRİLMESİ” adlı tez çalışması 27/09/2024 tarihinde aşağıdaki jüri tarafından oy birliği ile Necmettin Erbakan Üniversitesi Fen Bilimleri Enstitüsü Mekatronik Mühendisliği Anabilim Dalı’nda YÜKSEK LİSANS olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Başkan

Prof. Dr. Hasan Erdiñ KOÇER

.....

Danışman

Prof. Dr. İlhan İLHAN

.....

Üye

Dr. Öğr. Üyesi Murat KARAKOYUN

.....

Fen Bilimleri Enstitüsü Yönetim Kurulu’nun ... / ... / 20... gün ve sayılı kararıyla onaylanmıştır.

Prof. Dr. Havvanur UÇBEYİAY
FBE Müdürü

TEZ BİLDİRİMİ

Bu tezdeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edildiğini ve tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

DECLARATION PAGE

I hereby declare that all information in this document has been obtained and presented in accordance with academic rules and ethical conduct. I also declare that, as required by these rules and conduct, I have fully cited and referenced all material and results that are not original to this work.

Hamide Sena GÜVEN

27/09/2024

ÖZET

YÜKSEK LİSANS TEZİ

ÖZELLİK SEÇİM PROBLEMİ İÇİN İKİLİ ORKA YIRTICI ALGORİTMASININ GELİŞTİRİLMESİ

Hamide Sena GÜVEN

NECMETTİN ERBAKAN ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
MEKATRONİK MÜHENDİSLİĞİ ANABİLİM DALI

Danışman: Prof. Dr. İlhan İLHAN

2024, 62 Sayfa

Jüri

Prof. Dr. Hasan Erdiç KOÇER

Prof. Dr. İlhan İLHAN

Dr. Öğr. Üyesi Murat KARAKOYUN

Optimizasyon, bir problemin olası çözüm kümesinden en iyi sonucu veren çözümün bulunması sürecidir. Optimizasyon problemlerinin çözümünde klasik ve metasezgisel yöntemler olmak üzere iki temel yaklaşım kullanılmaktadır. Gerçek hayatta karşılaşılan karmaşık, doğrusal olmayan ve geniş çözüm kümesine sahip problemler için klasik yöntemler her zaman yeterli olmayabilir. Bu tür problemler için doğadan ilham alınarak geliştirilen metasezgisel algoritmalar, hızlı ve doğru çözümler sunmaktadır. Bu algoritmalar, canlıların sürü davranışları gibi doğal süreçlerden esinlenerek geliştirilmiştir.

Orka yırtıcı algoritması (Orca Predation Algorithm - OPA), sürekli optimizasyon problemlerini çözmek amacıyla, orka sürüsünün avlanma davranışlarının incelenmesiyle geliştirilmiş yeni ve güncel bir metasezgisel algoritmadır. Bu çalışmada, ikili optimizasyon problemlerini çözmek için OPA'nın ikili versiyonu geliştirilmiş ve ikili orka yırtıcı algoritması (Binary Orca Predation Algorithm - BOPA) olarak adlandırılmıştır. Transfer fonksiyonları kullanılarak geliştirilen algoritma, ikili optimizasyon problemlerinden biri olan özellik seçim (FS) problemine uygulanmıştır. Algoritmanın sınıflandırma doğruluğunu değerlendirmek için birini dışarıda bırak çapraz doğrulama (Leave-One-Out Cross Validation - LOOCV) yöntemi kullanılmıştır. Elde edilen sonuçlar, gri kurt optimizasyonu (Grey Wolf Optimization - GWO), parçacık sürü optimizasyonu (Particle Swarm Optimization - PSO) ve yapay arı kolonisi (Artificial Bee Colony - ABC) algoritmaları gibi popüler metasezgisel algoritmaların ikili versiyonlarıyla karşılaştırılmış ve çeşitli performans metrikleri açısından analiz edilmiştir. Deneysel çalışmalar sonucunda, S-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantlarının, yedi veri setinden beşinde, aynı transfer fonksiyonları kullanılarak geliştirilen diğer algoritmaların varyantlarına eşit veya daha iyi sonuçlar elde ettiği tespit edilmiştir.

Anahtar Kelimeler: Birini Dışarıda Bırak Çapraz Doğrulama, İkili Optimizasyon Problemleri, Özellik Seçimi, Taguchi Metodu, Transfer Fonksiyonu

ABSTRACT

MS THESIS

**DEVELOPMENT OF BINARY ORCA PREDATION ALGORITHM FOR
FEATURE SELECTION PROBLEM**

Hamide Sena GÜVEN

**THE GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCE OF
NECMETTİN ERBAKAN UNIVERSITY
THE DEGREE OF MASTER OF SCIENCE
IN MECHATRONIC ENGINEERING**

Advisor: Prof. Dr. İlhan ILHAN

2024, 62 Pages

Jury

Prof. Dr. Hasan Erdinc KOCER

Prof. Dr. İlhan ILHAN

Asst. Prof. Murat KARAKOYUN

Optimization is the process of finding the best solution from the possible solution set for a given problem. Two basic approaches are used in solving optimization problems: classical and metaheuristic methods. Classical methods may not always be sufficient for solving real-world problems that are complex, nonlinear, and have large solution sets. For such problems, metaheuristic algorithms, inspired by nature, provide fast and accurate solutions. These algorithms were developed by taking inspiration from natural processes such as the herd behavior of living things.

The Orca Predation Algorithm (OPA) is a novel and up-to-date metaheuristic algorithm developed by examining the hunting behavior of orca herds to solve continuous optimization problems. In this study, a binary version of OPA was developed to solve binary optimization problems, referred to as the Binary Orca Predation Algorithm (BOPA). The algorithm, developed using transfer functions, was applied to the feature selection (FS) problem, which is one of the binary optimization problems. The leave-one-out cross validation (LOOCV) method was used to evaluate the classification accuracy of the algorithm. The obtained results were compared with the binary versions of other popular metaheuristic algorithms, such as Grey Wolf Optimization (GWO), Particle Swarm Optimization (PSO) and Artificial Bee Colony (ABC) and analyzed in terms of various performance metrics. As a result of experimental studies, it has been determined that BOPA variants developed using S-shaped transfer functions achieve equal or better results than variants of other algorithms developed using the same transfer functions in five out of seven data sets.

Keywords: Binary Optimization Problems, Feature Selection, Leave-One-Out Cross Validation, Taguchi Method, Transfer Function

ÖNSÖZ

Tezimin hazırlanma sürecinde katkıları büyük olan, bilgi ve deneyimleriyle her zaman yanımda olan sevgili danışmanım, Necmettin Erbakan Üniversitesi öğretim üyelerinden Prof. Dr. İlhan İLHAN'a en içten teşekkürlerimi sunarım. Kendisi hem lisans hem de yüksek lisans süreçlerimde bana rehberlik etmiş ve değerli önerileriyle projelerimi zenginleştirmiştir. Sabrı, özverisi ve sürekli desteği için kendisine minnettarım.

Hayatımın her alanında olduğu gibi bu süreçte de her zaman yanımda olan, başaracağım konusundaki inançlarını hiç yitirmeden beni destekleyen ve güvenen sevgili aileme şükranlarımı sunarım.

Fikirleri, eleştirileri ve teşvikleri ile kişisel ve akademik gelişimime büyük katkı sağlayan sevgili dostlarıma; özellikle, tecrübeleri ve önerileriyle ufkumu açan sevgili Niyazi GÖKDOĞAN'a teşekkürlerimi sunarım.

Son olarak, bu çalışmada kullanılan veri setlerini ve kaynakları sağlayan tüm araştırmacılara, akademik kuruluşlara ve yayıncı kuruluşlara teşekkür ediyorum. Onların katkıları, bu tezin bilimsel değerini artırmış ve literatüre katkı sağlama fırsatını sunmuştur. Bu süreçteki tüm desteklerin, bu çalışmanın başarısında önemli bir rol oynadığını belirtmek isterim.

Hamide Sena GÜVEN
KONYA-2024

İÇİNDEKİLER

ÖZET	iv
ABSTRACT.....	iv
ÖNSÖZ	v
İÇİNDEKİLER	vi
ŞEKİLLER VE ÇİZELGELER DİZİNİ.....	viii
SİMGELER VE KISALTMALAR	ix
1. GİRİŞ.....	1
1.1. Optimizasyon Problemleri	1
1.1.1. Sürekli Optimizasyon Problemleri.....	2
1.1.2. Ayrık Optimizasyon Problemleri.....	3
1.2. İkili Optimizasyon Problemleri	3
1.2.1. 0-1 Sırt Çantası Problemi (KP).....	3
1.2.2. Kapasitesiz Tesis Yerleştirme Problemi (UFLP).....	4
1.2.3. Özellik Seçimi (FS)	4
2. KAYNAK ARAŞTIRMASI	6
3. MATERYAL VE YÖNTEM.....	13
3.1. Orka Yırtıcı Algoritması (OPA)	13
3.1.1. Kovalama Aşaması	14
3.1.1.1. Avın Sürülmesi	14
3.1.1.2. Avın Çevrelenmesi	15
3.1.1.3. Pozisyonların Ayarlanması	16
3.1.2. Saldırı Aşaması	16
3.1.2.1. Pozisyonların Ayarlanması	17
3.2. Önerilen İkili Orka Yırtıcı Algoritması (BOPA).....	18
3.2.1. Transfer Fonksiyonları.....	19
3.3. Özellik Seçimi İçin İkili Orka Yırtıcı Algoritması	20
3.4. Birini Dışarıda Bırak Çapraz Doğrulama (LOOCV).....	21
3.5. Taguchi Metodu	22
3.6. Karşılaştırma İçin Kullanılan Algoritmalar	22
3.6.1. Gri Kurt Optimizasyon (GWO) Algoritması	24
3.6.2. Parçacık Sürü Optimizasyon (PSO) Algoritması.....	26
3.6.3. Yapay Arı Kolonisi (ABC) Algoritması.....	28
4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA.....	31
4.1. Veri Kümeleri	31

4.2. Parametre Ayarı	31
4.3. BOPA İin Deneysel Sonular ve Karşılařtırmalar	34
5. SONULAR VE ÖNERİLER	44
5.1 Sonular	44
5.2 Öneriler	44



ŞEKİLLER VE ÇİZELGELER DİZİNİ

ŞEKİLLER

Şekil 1. 1. Optimizasyon problemlerinin sınıflandırılması.....	2
Şekil 1. 2. Özellik seçim işlemleri için temel adımlar.....	5
Şekil 3. 1. OPA'nın akış diyagramı.....	13
Şekil 3. 2. Orkaların av sürüş modeli.....	14
Şekil 3. 3. Orkaların ava saldırı modeli.....	17
Şekil 3. 4. Orkaların konum güncellemesi için sözde kod.....	18
Şekil 3. 5. S-şekilli ve V-şekilli transfer fonksiyonları.....	19
Şekil 3. 6. Metasezgisel algoritmaların sınıflandırılması.....	23
Şekil 3. 7. Gri kurt hiyerarşisi.....	24
Şekil 3. 8. GWO akış diyagramı.....	26
Şekil 3. 9. PSO akış diyagramı.....	28
Şekil 3. 10. ABC akış diyagramı.....	30
Şekil 4. 1. Parametrelere ait S/N oranları grafiği.....	33

ÇİZELGELER

Çizelge 3. 1. S-şekilli ve V-şekilli transfer fonksiyonları için denklemler.....	19
Çizelge 4. 1. Deneysel kullanımlar için veri kümeleri.....	31
Çizelge 4. 2. L_{16} ortogonal dizisi için elde edilen sonuçlar.....	32
Çizelge 4. 3. Parametrelere ait S/N oranları.....	33
Çizelge 4. 4. BOPA için parametre değerleri.....	35
Çizelge 4. 5. BPSO ve BABC için parametre değerleri.....	35
Çizelge 4. 6. BGWO için uygunluk değerleri.....	36
Çizelge 4. 7. BPSO için uygunluk değerleri.....	37
Çizelge 4. 8. BABC için uygunluk değerleri.....	38
Çizelge 4. 9. BOPA için uygunluk değerleri.....	39
Çizelge 4. 10. Algoritmalara ait ortalama uygunluk değerleri.....	40
Çizelge 4. 11. Algoritmalara ait minimum uygunluk değerleri.....	41
Çizelge 4. 12. Algoritmalara ait ortalama uygunluk değerleri (varyantlar açısından kıyaslama).....	43

SİMGELER VE KISALTMALAR

Kısaltmalar

ABC	: Artificial Bee Colony (Yapay Arı Kolonisi)
AO	: Aquila Optimization (Aquila Optimizasyonu)
ACO	: Ant Colony Optimization (Karıncı Kolonisi Optimizasyonu)
BA	: Bat Algorithm (Yarasa Algoritması)
BALO	: Binary Ant Lion Optimization (İkili Karıncı Aslanı Optimizasyonu)
BBBC	: Bing-Bang Big-Crunch
BBO	: Biogeography-Based Optimizer (Biyocoğrafya Tabanlı Optimizer)
BCO	: Bee Colony Optimization (Arı Kolonisi Optimizasyonu)
BDE	: Binary Differential Evolution (İkili Diferansiyel Evrim)
BOA	: Butterfly Optimization Algorithm (Kelebek Optimizasyon Algoritması)
BOP	: Binary Optimization Problems (İkili Optimizasyon Problemleri)
BOPA	: Binary Orca Predation Algorithm (İkili Orka Yırtıcı Algoritması)
BPSO	: Binary Particle Swarm Optimization (İkili Parçacık Sürü Optimizasyonu)
CAD	: Computer-Aided Diagnosis (Bilgisayar Destekli Tanı)
CBO	: Colliding Bodies Optimization (Çarpışan Gövdeler Optimizasyonu)
CFO	: Central Force Optimization (Merkezi Kuvvet Optimizasyonu)
COA	: Cuckoo Optimization Algorithm (Guguk Kuşu Algoritması)
CSO	: Competitive Swarm Optimization (Rekabetçi Sürü Optimizasyonunu)
DA	: Dragonfly Algorithm (Yusufçuk Algoritması)
DE	: Differential Evolution (Diferansiyel Evrim)
ES	: Evolution Strategy (Evrin Stratejisi)
FA	: Firefly Algorithm (Ateşböceği Algoritması)
FS	: Feature Selection (Özellik Seçimi)
GA	: Genetic Algorithm (Genetik Algoritma)
GbSA	: Galaxy-Based Search Algorithm (Galaksi Tabanlı Arama Algoritması)
GC	: Graph Coloring (Graf Renklendirme)
GP	: Genetic Programming (Genetik Programlama)
GSA	: Gravity Search Algorithm (Yerçekimi Arama Algoritması)
GWO	: Grey Wolf Optimization (Gri Kurt Optimizasyonu)
HPV	: Human Papillomavirus (İnsan Papilloma Virüsü)
HS	: Harmony Search (Uyum Arama)
ICA	: Imperialist Competitive Algorithm (İmperyalist Rekabet Algoritması)
kNN	: k-Nearest Neighbor (k-En Yakın Komşu)
KP	: Knapsack Problem (Sırt Çantası Problemi)
MBTGA	: Modified Binary Tree Growth Algorithm (Değiştirilmiş İkili Ağaç Büyüme Algoritması)
MVO	: Multi-Objective Optimization (Çok Yönlü Optimizasyon)
OPA	: Orca Predation Algorithm (Orka Yırtıcı Algoritması)
OWA	: Whale Optimization Algorithm (Balina Optimizasyon Algoritması)

PBIL	: Probability-Based Incremental Learning (Olasılığa Dayalı Artan Zihinsel Öğrenme)
PSO	: Particle Swarm Optimization (Parçacık Sürü Optimizasyonu)
RST	: Rough Set Theory (Kaba Küme Teorisi)
SA	: Simulated Annealing (Simüle Edilmiş Tavlama)
SBA	: Social-Based Algorithm (Sosyal Tabanlı Algoritma)
SI	: Swarm Intelligence (Sürü Zekası)
SSA	: Salp Swarm Algorithm (Salp Sürü Algoritması)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
TF	: Transfer Function (Transfer Fonksiyonu)
TLBO	: Teaching-Learning-Based Optimization (Öğrenme Tabanlı Optimizasyon Algoritması)
TS	: Tabu Search (Tabu Arama)
TSA	: Tree Seed Algorithm (Ağaç Tohumu Algoritması)
UC	: Unit Loading (Birim Yüklenme)
UFLP	: Uncapacitated Facility Location Problem (Kapasitesiz Tesis Yerleştirme Problemi)
WTP	: Wind Turbine Placement Problem (Rüzgar Türbini Yerleştirme Problemi)

1. GİRİŞ

Optimizasyon, günlük hayatta karşılaşılan birçok karar verme sürecinde önemli yere sahiptir. Kaynakların sınırlı olduğu durumlarda en iyi çözümün bulunmasını sağlayan bu yöntem, özellikle iş dünyası, sağlık, mühendislik ve kamu yönetimi gibi alanlarda verimliliği artırma amacıyla sıkça kullanılmaktadır. Optimizasyon, mevcut alternatifler arasından en uygun olanını seçmeye olanak tanıyarak zaman, maliyet ve kaynak tasarrufu sağlamaktadır. Üretim süreçlerinde malzeme israfını minimize etmek, ulaşım güzergâhlarını en kısa mesafe ile planlamak ya da sağlık sektöründe hasta tedavi süreçlerini hızlandırmak gibi uygulamalar, optimizasyonun sağladığı katkılara örnek gösterilebilir. Dolayısıyla, karmaşık problemlere etkin çözümler sunarak hem bireysel hem de toplumsal düzeyde fayda yaratmaktadır.

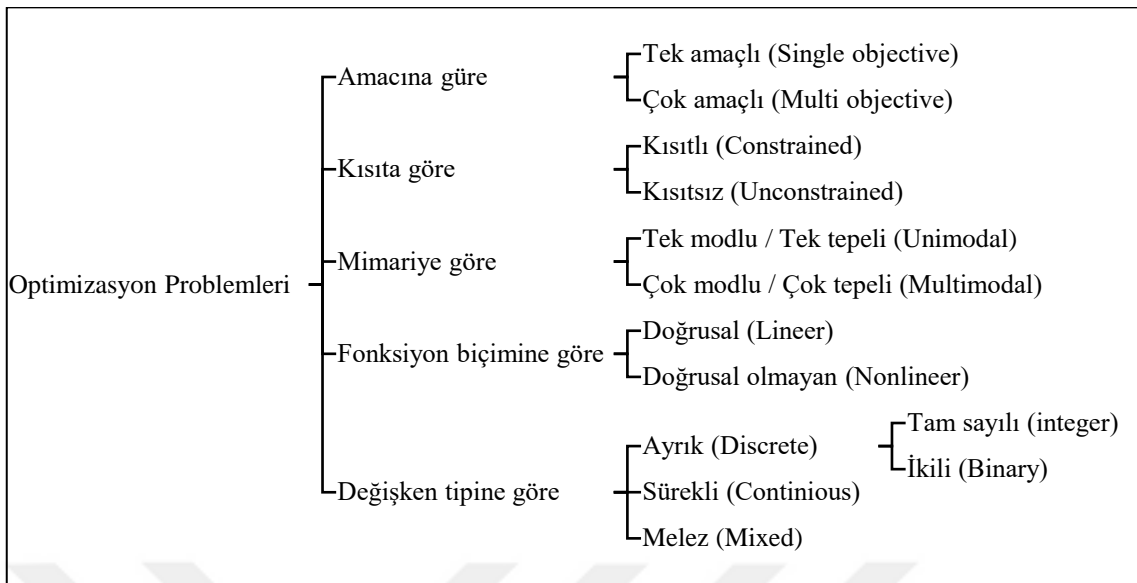
1.1. Optimizasyon Problemleri

Matematikte “en uygun duruma getirme” olarak tanımlanan optimizasyon, bir problemin olası çözümleri arasından en iyi (optimum) çözümü elde etme sürecidir (Korkmaz, 2019). Problemin amacına göre, minimum ya da maksimum değer bulunması işlemi optimizasyon problemi olarak adlandırılır.

Optimizasyon problemlerinde amaç fonksiyonu, karar değişkeni ve kısıtlar olmak üzere üç temel kavram vardır (Yavuz, 2021). Optimizasyon problemlerini ifade eden matematiksel modele amaç fonksiyonu (objective function) denir. Amaç fonksiyonunun çözümü için gerekli giriş değerleri, karar değişkenleri (decision variables) olarak adlandırılır (Aslan, 2020). Kısıtlar, verilen kaynaklar ve performans gerekliliklerini ifade eden fonksiyonlardır. Optimizasyon problemleri, amaç fonksiyonunu minimum ya da maksimum yapacak karar değişkenlerini bulmayı hedefler.

Amaç fonksiyonunu en küçük (global minimum) yapan karar değişkenlerinin arandığı optimizasyon problemlerine minimizasyon problemleri, en büyük (global maksimum) yapan karar değişkenlerinin arandığı optimizasyon problemlerine ise maksimizasyon problemleri denir (Korkmaz, 2019).

Optimizasyon problemleri geleneksel yöntemler ile çözüldüğünde genellikle uzun süreçlere ihtiyaç duyulur. Buna karşılık bu problemler metasezgisel yaklaşımlar ile daha kısa sürelerde ve kabul edilebilir sonuçlar ile çözülebilmektedir. Optimizasyon problemleri Şekil 1.1’de görüldüğü gibi beş ana başlıkta sınıflandırılmaktadır (Korkmaz, 2019; Yang, 2010).



Şekil 1. 1. Optimizasyon problemlerinin sınıflandırılması

Optimizasyon problemleri, karar değişkenlerinin aldıkları değerlere göre üç sınıfa ayrılırlar. Sürekli (continuous) optimizasyon problemlerinde değişkenler reel değerler alırlar. Ayrık optimizasyon problemlerinde ise değişkenler sonlu bir veri kümesi içerisinde değerler alırlar ve problemin amacına bağlı olarak en uygun şekilde gruplandırılır, sıralanır veya seçilirler (Akay, 2009; Ekmekci, 2020). Ayrık problemler de kendi içinde iki grupta incelenirler: Tam sayılı ve ikili optimizasyon problemleri. Karar değişkenleri tam sayı değer alıyorsa optimizasyon problemleri tam sayılı (integer) olarak, sadece 0 (sıfır) ve 1 (bir) değerlerinden birini alabiliyorsa ikili (binary) olarak sınıflandırılırlar. Bunun yanında hem ayrık hem sürekli değerler alabilen problemlere ise melez (mixed) optimizasyon problemleri denilmektedir (Korkmaz, 2019).

1.1.1. Sürekli Optimizasyon Problemleri

Sürekli optimizasyon problemleri, amaç fonksiyonunu en iyi değere ulaştırmayı hedefleyen ve bu süreçte sürekli değerleri kullanan problemlerdir. Literatürde önerilen optimizasyon algoritmalarının çoğu, sürekli problemlerin etkili bir şekilde çözülmesi amacıyla tasarlanmıştır. Dolayısıyla karar değişkenlerinin yapısı reel değer aralığına uygun şekilde belirlenmiştir. Karar değişkenlerinin sürekli değerler alabilmesi, algoritmanın esnekliğini artırmakta ve daha karmaşık problemlerin çözümünde avantaj sağlamaktadır (Berberler, 2009; Korkmaz, 2019; Özkış ve Karakoyun, 2023) .

1.1.2. Ayrık Optimizasyon Problemleri

Ayrık optimizasyon problemlerinde, karar değişkenleri sonlu bir kümenin elemanlarından oluşur (Ekmekci, 2020). Ayrık optimizasyon problemleri, verilerin optimum şekilde seçilmesi, düzenlenmesi, sınıflandırılması ve sıralanması işlemlerini kapsar. Bu tür problemlerde en iyi çözüm, belirli bir sıralama ile elde edildiğinden kombinatoriyal problemler olarak da adlandırılırlar (Doğan, 2019).

Ayrık optimizasyon problemlerini çözmek için kullanılan algoritmaların yapısı da probleme uygun olmalıdır. Literatürde önerilen sürekli optimizasyon yöntemlerinin çoğu belirli modifikasyon işlemleri yardımıyla ayrık problemlerin çözümünde kullanılabilirler (Djelloul ve diğerleri, 2014; Dönmez, 2020) .

1.2. İkili Optimizasyon Problemleri

Ayrık optimizasyon problemlerinin bir alt dalı olan ikili optimizasyon problemlerinde, karar değişkenleri sadece 0 (sıfır) ve 1 (bir) değerlerini alır. Karar değişkeninin 1 değerini alması varlığı, 0 değerini alması yokluğu temsil eder (Özkış ve Karakoyun, 2023). Bu tür problemler evet-hayır, var-yok, seçme-seçmeme gibi net cevaplar verdiği için algoritmalarda kesin sonuçların alınması sağlanmaktadır ve bu özellikleri sayesinde literatürde geniş çalışma alanına sahiptirler (Tanyıldızı ve Çelik, 2020).

İkili optimizasyon problemlerinde, olası çözümler 0 ve 1 değerlerinin kombinasyonlarından oluşur. Yüksek sayıda karar değişkeninin olması, elde edilecek kombinasyonların da artması anlamına gelir. Böylece problem karmaşık hale gelir ve NP-Zor problem sınıfına dahil edilir (Özkış ve Karakoyun, 2023).

0-1 sırt çantası problemi (Knapsack Problems - KP), kapasitesiz tesis yerleştirme (Uncapacitated Facility Location Problem - UFLP), rüzgar türbini yerleştirme (Wind Turbine Placement - WTP), graf renklendirme (Graph Coloring - GC), birim yüklenme (Unit Commitment Problems - UC), özellik seçimi (Feature Selection - FS) gibi problemler ikili optimizasyon problemleri kategorisinde ele alınan problemlerden bazılarıdır (Dönmez, 2020; Korkmaz, 2019).

1.2.1. 0-1 Sırt Çantası Problemi (KP)

Kombinatoriyal optimizasyon problemlerinden biri olan 0-1 sırt çantası problemi, literatürde yaygın uygulama alanına sahip bir problemdir. Kısıtlı bir bütçeyle maksimum

kâr elde etmek, diyetle sınırlı kalori miktarı ile en iyi şekilde doyabilmek, çiftçilikte verimli ve satışı yüksek ürünleri seçip yetiştirmek gibi alanlarda KP uygulanabilir (Azaz, 2016).

Problemde ağırlık ve kar değeri bilinen parçalar, belirli bir kapasiteye sahip sırt çantasına yerleştirilecektir. Her bir parça için iki durum vardır: sırt çantasına konulur (1) ya da dışarıda bırakılır (0). Dolayısıyla bu problemde, karar değişkenleri 0 ve 1 değerlerini alır. Amaç, parçaları en verimli şekilde kullanarak sırt çantasının toplam kar değerini en yüksek seviyede tutmaktır.

1.2.2. Kapasitesiz Tesis Yerleştirme Problemi (UFLP)

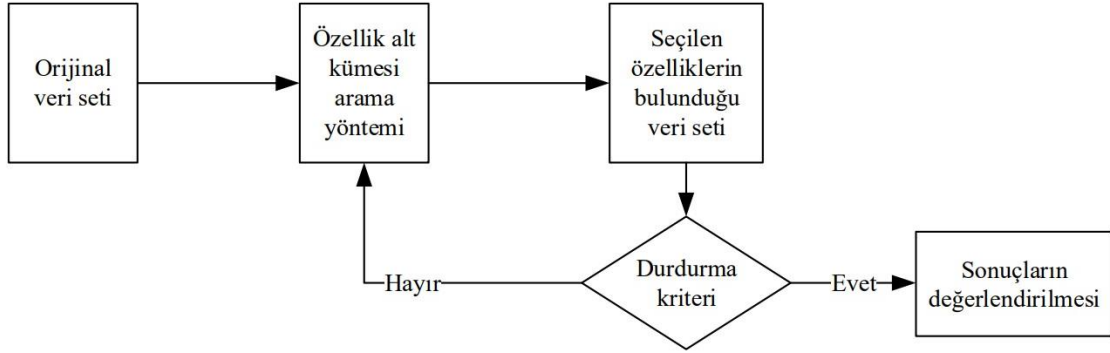
İlk olarak 1965 yılında Balinski tarafından ortaya atılan kapasitesiz tesis yerleştirme problemi, literatürde sıklıkla kullanılan ve çeşitli uygulama alanlarına sahip bir ayrık optimizasyon problemidir. Problemin temelinde, kurulacak tesisler ve tesisler tarafından ihtiyaçları karşılanacak müşteriler bulunmaktadır. Problemin amacı, hangi tesislerin açılacağını belirlemek ve maliyeti minimum seviyede tutmaktır (Korkmaz, 2019).

1.2.3. Özellik Seçimi (FS)

Çok sayıda özellik içeren veri kümelerine sahip sınıflandırma işlemleri yavaş ve yüksek maliyetli olmaktadır. Özellik seçimi, sınıflandırma işlemlerinde performansı iyileştirmek, hızı artırmak ve maliyeti düşürmek amacıyla kullanılan önemli bir ön işlemdir (Sel ve diğerleri, 2019).

Literatürde bazı kaynaklarda öznitelik seçimi olarak da adlandırılan özellik seçimi, örneklem sayısı çok olan veri kümelerinde problemin çözümünde kullanılmayacak, tekrarlanan ve gürültüye sebep olan öznitelikleri eleyerek mevcut özelliklerden bir alt küme oluşturur (Gülgezen, 2009; Özger, 2019). Böylece daha az sayıda özelliği işleme dahil ederek düşük maliyetli, hızlı ve yüksek doğruluğa sahip sonuçlar elde edilir (Çifçi ve diğerleri, 2018).

Özellik seçimi, genel olarak Şekil 1.2'deki adımlardan oluşan bir süreçtir. Orijinal veri setinden oluşturulan alt kümeler, belirli eşitsizlikler kullanılarak değerlendirilir ve böylece ilgili özelliğin seçilip seçilmeyeceğine karar verilir. Seçilen özellik, oluşturulan alt kümeyle dahil edilir ve durdurma kriteri sağlanana kadar işlemler tekrarlanır (Budak, 2018).



Şekil 1. 2. Özellik seçim işlemleri için temel adımlar

Özellik seçim yöntemleri, filtreleme yöntemleri (filter methods) ve sarmalayıcı yöntemler (wrapper methods) olmak üzere iki grupta incelenir. Filtreleme yönteminde, n adet özellik bazı istatistiksel yöntemlere göre sıralanır ve en iyi k adet özellik seçilir. Filtreleme yönteminde özellikler arasındaki ilişkiler göz ardı edilir. Bu nedenle maliyeti düşük olmasına rağmen performansı iyi değildir.

Sarmalayıcı yöntemler, özellikler arasındaki ilişkileri dikkate alarak oluşturdukları özellik alt kümelerini, sınıflandırma algoritmaları ile değerlendirirler. Bu sebeple filtreleme yöntemlerinden daha karmaşık olmasına rağmen daha yüksek performansa sahiptirler (Kohavi ve John, 1997; Özger, 2019).

Tezin geriye kalan bölümleri şu şekilde organize edilmiştir: İkinci bölümde, özellik seçim problemini çözmek için kullanılan algoritmalar ve geliştirilen yeni yöntemlerden bahsedilmiştir. Üçüncü bölümde, OPA'nın temel yapısı ve ilgili kavramlar tanıtılmış, BOPA'yı geliştirmek için kullanılan yöntemler detaylı bir şekilde açıklanmıştır. Ayrıca, sonuçların karşılaştırılması için kullanılan algoritmalar hakkında özet bilgiler sunulmuştur. Dördüncü bölümde, geliştirilen yöntemin performansını değerlendirmek amacıyla kullanılan veri kümeleri tanıtılmış, parametre optimizasyonu anlatılmış ve deneysel sonuçlar paylaşılmıştır. Tez çalışmasına ilişkin genel sonuçlar ve öneriler beşinci bölümde sunulmuştur.

2. KAYNAK ARAŞTIRMASI

İkili optimizasyon problemlerinden biri olan özellik seçimi, veri kümesini en iyi şekilde temsil edecek belirli özelliklerin seçilmesi işlemidir. Daha az veri ile yüksek doğruluk sağlanması ve algoritmanın hızını artırması sebebiyle sınıflandırma problemlerinde sıklıkla tercih edilmektedir (Al-Wajih ve diğerleri, 2021; Erdoğan, 2023).

Özellik seçim problemlerinde, veri setinin büyüklüğü arttıkça problemin karmaşıklığı da artar. Geleneksel yöntemler, karmaşık problemlerin çözümünde yetersiz kalır, bu nedenle sürü tabanlı yöntemler geliştirilmektedir. Önerilen metasezgisel algoritmalar özellik seçim probleminin çözümünde de yaygın olarak kullanılmaktadır.

Parçacık sürü optimizasyonu (Particle Swarm Optimization - PSO) , başarılı sonuçlar veren popüler bir metasezgisel algoritmadır. Literatürde özellik seçim problemlerinin çözümü için PSO'nun kullanıldığı birçok çalışma mevcuttur. Too ve arkadaşları, elektromiyografi (EMG) özellik sayısının artmasıyla, sınıflandırma performansının düştüğünü gözlemlemişler ve bu sorunu çözmek için yeni bir kişisel en iyi (*Pbest*) kılavuzlu ikili parçacık sürüsü optimizasyonu (PBPSO) algoritması önermişlerdir. Özellik seçim problemi üzerine yaptıkları uygulamalarla karmaşıklığı azaltmayı hedeflemişlerdir. Önerilen algoritmanın başarısını değerlendirmek için ikili parçacık sürü optimizasyonu (BPSO), genetik algoritma (GA), değiştirilmiş ikili ağaç büyüme algoritması (MBTGA) ve ikili diferansiyel gelişim (BDE) algoritmalarıyla karşılaştırma yapmışlardır. Sonuçlar, PBPSO'nun diğer tekniklere göre daha az özellikle yeni alt küme oluşturma performansının yüksek olduğunu ve klinik çalışmalar için uygun olduğunu göstermiştir (Too ve diğerleri, 2019).

PSO'da kullanılan geleneksel yöntemlerin çoğu, yüksek boyutlu özellik seçim problemlerinin çözümü için beklenen verimliliği sağlayamamaktadır. Song ve arkadaşları, bu sorunu çözmek amacıyla karşılıklı bilgi (mutual information) ve yalın kemik (bare-bone) tekniklerine dayanan yeni bir ikili özellik seçim algoritması önermişlerdir (Bare-Bones Particle Swarm Optimization - BBPSO). Önerilen algoritma, özellikle sınıflandırma doğruluğunu artırmak için iki yerel arama operatörü (tamamlayıcı ve silme operatörleri) ve adaptif mutasyon mekanizması içerir. Algoritmanın özellikle yüksek boyutlu özellik seçim problemlerinde daha iyi sonuçlar verdiği belirlenmiştir (Song ve diğerleri, 2021).

Yarasa algoritması (Bat Algorithm - BA), yarasaların yankı yoluyla yön bulma davranışından ilham alarak geliştirilen metasezgisel bir optimizasyon algoritmasıdır. Rodrigues ve arkadaşları, BA ve optimum yol ormanı (Optimum-Path Forest - OPF) yöntemlerine dayanan yeni bir sarmalayıcı tabanlı özellik seçimi yaklaşımı önermişlerdir. Bu yaklaşım ile özellik seçiminde verimliliği artırmayı hedeflemişlerdir. Çeşitli veri setleri üzerinde yapılan çalışmalar sonucunda, önerilen yaklaşım ile daha kaliteli özellik alt kümelerinin seçilebileceği ve bazı durumlarda sınıflandırma kalitesinin geliştirilebileceği sonucu elde edilmiştir (Rodrigues ve diğerleri, 2014).

Yang ve arkadaşları, destek vektör makinelerinden (Support Machine Machine - SVM) yararlanarak geliştirdikleri yeni bir BA varyantını (MBAFS) özellik seçme yöntemi olarak sunmuşlardır. Önerilen yöntemde erken yakınsamayı engellemek, bireylerin çeşitliliğini korumak ve problem çözme performansını artırmak için yeni mekanizmalar geliştirilmiştir. MBAFS'nin başarısını değerlendirmek için 12 veri seti kullanılmıştır. Sonuçlar BPSO tabanlı bazı popüler algoritmalarla karşılaştırılmış, MBAFS'nin alternatif yaklaşımlara göre daha iyi performans gösterdiği ve yüksek yakınsama hızına sahip olduğu ortaya konulmuştur (Yang ve diğerleri, 2017).

Yusufçuk algoritması (Dragonfly Algorithm - DA), karmaşık optimizasyon problemlerini çözmek için yusufçukların avlanma ve göç davranışlarının taklit edilmesiyle modellenmiş sürü tabanlı bir optimizasyon algoritmasıdır. Mafarja ve arkadaşları, ikili yusufçuk algoritmasını esas alan sarmalayıcı tabanlı DA geliştirmişlerdir. Önerilen algoritma PSO ve GA ile karşılaştırılmıştır. Yöntemin, sınıflandırma için en kaliteli özellikleri seçebilme başarısı ortaya konulmuştur (Mafarja ve diğerleri, 2017).

Sawhney ve Jain, yeni bir ikili yusufçuk algoritması (Binary Dragonfly Algorithm - BDFA) geliştirmişlerdir. Sınıflandırıcı olarak rastgele orman (Random Forest - RF) kullanılan bu sarmalayıcı yöntem ile son zamanlarda insan papilloma virüsü (Human Papillomavirus - HPV) sebebiyle hızla artan hastalıklar için en uygun tedavi yönteminin seçimini kolaylaştırmayı, dolayısıyla sınıflandırma doğruluğunu artırmayı hedeflemişlerdir. Önerilen yöntem iki farklı tedavi için kullanılmış, elde edilen sonuçlara göre sınıflandırma becerisi ve sınıflandırma kabiliyetinin yüksek olduğu gözlemlenmiştir (Sawhney ve Jain, 2018).

Yüksek boyutlu veri kümesine sahip problemlerin çözümü için bazı araştırmacılar, filtre ve sarmalayıcı tabanlı iki yöntemin de avantajlarından yararlanmayı hedeflemişlerdir. Böylece hibrit yöntemler üzerine çalışmalar ortaya konulmuştur.

Karizaki ve Tavassori, sarmalayıcı olarak yeni bir ikili yusufçuk algoritması (BDA) ve filtreleyici olarak ReliefF algoritması kullanarak iki yöntemin kombinasyonunu içeren yeni bir teknik önermişlerdir. Geliştirilen algoritmayı yüksek boyutlu özellik seçim problemlerinin çözümünde kullanmışlardır. Yapılan deneyler ve karşılaştırmalar sonucunda, yeni yöntemin veri kümesinin boyutunu başarılı şekilde düşürdüğü ve karmaşık yöntemlerle uygulanabilir olduğu gösterilmiştir. Bunun yanında yeni yöntem sayesinde sınıflandırıcının test verileri üzerindeki verimliliği de artırdığı gözlemlenmiştir (Karizaki ve Tavassoldi, 2019).

Cui ve arkadaşları, orijinal veri kümesinden en iyi alt kümeyi oluşturmak ve daha iyi sınıflandırma doğruluğu elde etmek için yeni bir hibrit yusufçuk algoritması (HIDA) geliştirmişlerdir. Önerilen algoritma hem mRMR'nin hem de geliştirilmiş yusufçuk algoritmasının (IDA) avantajlarını içermektedir. HIDA'nın performansı, UCI makine öğrenmesi veri deposundan elde edilen verilerle test edilmiştir. Sonuçlar, önerilen yeni hibrit algoritmanın karşılaştırma yapılan diğer altı yönteme kıyasla daha iyi sonuçlar verdiğini göstermiştir (Cui ve diğerleri, 2020).

Balina optimizasyon algoritması (Whale Optimization Algorithm - WOA), kumbur balinaların avlanma davranışına dayanan sürekli optimizasyon problemlerini çözmek için geliştirilmiş metasezgisel optimizasyon algoritmasıdır. Tawhid ve Ibrahim, özellik seçim problemini çözmek için yeni bir ikili balina optimizasyon algoritması (BWOA) önermişlerdir. Özellik seçimi için etkili bir yöntem olan kaba küme teorisini (RST) ve farklı sınıflandırıcıları kullanmışlardır. BWOA, literatürde yer alan bazı başarılı algoritmalarla karşılaştırılmış, verimliliği hakkında olumlu sonuçlar elde edilmiştir (Tawhid ve Ibrahim, 2020).

Sarmalayıcı özellik seçimi, daha az özellik ile sınıflandırma doğruluğunu artırmayı hedefler. Mafarja ve Mirjalili, balina optimizasyon algoritmasını geliştirerek iki farklı ikili özellik seçim yöntemi üzerine çalışmalar yapmışlardır. Önerilen iki yöntem için de yaygın olarak kullanılan 20 veri seti üzerinde deneyler uygulamışlardır. Veriler PSO, GA, karınca aslanı optimizasyonu (Ant Lion Optimizer - ALO) gibi algoritmalarla kıyaslanmıştır. Sonuç olarak, önerilen yöntemin optimum özelliklerin seçilmesi için yüksek performans sergilediği gözlemlenmiştir (Mafarja ve Mirjalili, 2018).

Salp sürüsü algoritması (Salp Swarm Algorithm - SSA), salp adı verilen deniz canlılarının sürü halindeki davranışlarından esinlenerek ortaya çıkmış sürekli bir optimizasyon algoritmasıdır. İkili problemlere uygulanabilmesi için üzerine çalışmalar yapılmış ve başarılı sonuçlar elde edilmiştir. Mazher ve arkadaşları, özellik seçiminde

kullanılabilecek etkili bir algoritma geliřtirmek amacıyla salp sürüsü algoritmasını (SSA-FS) önermiřlerdir. Doğruluk ve hız alanlarındaki verimliliğini test etmek için parçacık sürüsü optimizasyonu ve diferansiyel gelişim algoritmalarıyla karşılaştırılmış ve oldukça iyi sonuçlar elde edilmiştir (Mazher ve diğeri, 2017).

Hegazy ve arkadaşları, SSA'nın performans, doğruluk ve yakınsama hızı gibi parametreleri iyileřtirmeyi hedefleyerek geliştirilmiş salp sürüsü algoritmasını (ISSA) önermiřlerdir. Bu yeni yöntemi özellik seçim problemine uygulamışlar ve doğruluğunu test etmek için k-en yakın komşu (kNN) sınıflandırıcısını kullanmışlardır. UCI veri havuzundan elde edilen 23 veri seti kullanılarak gerçekleştirilen testlerin sonuçları, temel SSA ve diğeri dört sürü yöntemi ile karşılaştırılmıştır. Deneysel veriler, ISSA'nın diğeri mevcut yöntemlere göre üstün performansa sahip olduğunu göstermiştir (Hegazy ve diğeri, 2020).

Literatürde özellik seçimi için optimum özellik alt kümelerinin bulunması üzerine birçok çalışma yapılmış ve sürü zekası (SI) algoritmalarının üstün performansa sahip olduğu gözlemlenmiştir. Faris ve arkadaşları da en iyi özellik alt kümesini bulabilmek için salp sürüsü algoritmasını (SSA) geliştirerek iki yeni özellik seçim yöntemi önermiřlerdir. İlk yaklaşımda yedi transfer fonksiyonu kullanılarak ikili varyant elde edilmiştir. İkinci yaklaşımda ise algoritmanın keşif davranışını geliřtirmek amacıyla transfer fonksiyonlarına ek olarak çaprazlama operatörü kullanılmıştır. Önerilen iki yaklaşımın sonuçları, popüler ikili algoritmalarla karşılaştırılmıştır. Geliştirilen yöntem veri setlerinin yaklaşık %90'ında başarılı sonuçlar elde etmiştir (Faris ve diğeri, 2018).

Karınca aslanı optimizasyonu (Ant Lion Optimizer - ALO), aslan karıncalarının avlanma davranışlarından ortaya çıkmış, arama yeteneği yüksek, doğadan esinlenmiş bir optimizasyon algoritmasıdır. Zawbaa ve arkadaşları, özellik seçimi için ALO tabanlı bir yöntem geliřtirmiřlerdir. Önerilen yöntem, en çok kullanılan veri setleri üzerinde farklı değerlendirme kriterleri kullanılarak değerlendirilmiştir. İki popüler arama yöntemi olan PSO ve GA ile kıyaslanan yöntem, sınıflandırma performansı ve seçilen özelliklerin kalitesi açısından başarılı sonuçlar üretmiştir (Zawbaa ve diğeri, 2015).

Emary ve arkadaşları, sınıflandırma verimliliğini artırmak için en uygun özellik alt kümesini seçebilmek adına ALO algoritmasının ikili versiyonunu geliřtirmiřlerdir. Önerilen yaklaşım, özellik seçimine uygulanmış ve kullanılacak özelliklerin sayısı en aza indirilirken yüksek sınıflandırma doğruluğu elde edilmiştir. Literatürde yaygın çalışma alanına sahip olan algoritmalarından PSO, GA ve BBA ile yapılan karşılařtırmalar

sonucunda, önerilen yöntemin özellik seçimi için başarısı kanıtlanmıştır (Emary ve diğerleri, 2016).

Mafarja ve arkadaşları çalışmalarında, ALO'yu sarmalayıcı özellik seçim yöntemi olarak kullanmışlardır. Sürekli problemlere uyumlu olan algoritmayı, S-şekilli ve V-şekilli transfer fonksiyonlarını kullanarak ikilileştirmişler ve altı yeni ikili yöntem önermişlerdir. Tüm yaklaşımların performansı, UCI veri setleri ile test edilmiş ve literatürdeki alternatif algoritmalarla karşılaştırılmıştır. Deney sonuçları, önerilen yaklaşımların sınıflandırma doğruluğunu iyileştirdiğini göstermiştir (Mafarja ve diğerleri, 2017).

Emary ve arkadaşları, sınıflandırmada uygun alt kümeleri seçmek için iki farklı yaklaşım kullanarak gri kurt optimizasyonunun yeni bir ikili varyantını geliştirmişlerdir. İlk yöntem, en iyi üç bireyin ikilileştirilmesi üzerinden çaprazlama işlemlerinin gerçekleştirilmesine dayanmaktadır. İkinci yöntem, sigmoid fonksiyonu ile bireylerin konumlarını güncelleyerek ikili değere eşitlemektedir. Önerilen yöntemler PSO ve GA ile karşılaştırılarak belirli performans kriterleri açısından test edilmiştir. Sonuç olarak, her iki versiyonun da en iyi özellik kombinasyonlarını bulma kabiliyeti kanıtlanmıştır (Emary ve diğerleri, 2016).

Li ve arkadaşları, tıbbi veriler arasından optimum alt küme oluşturarak, tıbbi teşhisi kolaylaştırmayı hedeflemişlerdir. Bu kapsamda, geliştirilmiş gri kurt optimizasyonu (IGWO) ve çekirdek aşırı öğrenme makinesi (Kernel Extreme Learning Machine - KELM) kullanarak yeni bir yöntem önermişlerdir (IGWO-KELM). Geliştirilen yöntem, sınıflandırma doğruluğu (classification accuracy), duyarlılık (sensitivity), kesinlik (precision) gibi pek çok kriter kullanılarak karşılaştırılmıştır. Deney sonuçları, IGWO'nun GWO ve GA'ya göre daha üstün olduğunu göstermiştir (Li ve diğerleri, 2017).

Too ve arkadaşları, yeni bir ikili GWO algoritması (CBGWO) önermişler ve bu algoritmayı elektromiyografi sinyalinden elde edilen özellikler arasından ilgisiz olanları elemek için kullanmayı hedeflemişlerdir. Deney sonuçları, CBGWO'nun sınıflandırma performansının yüksek olmasının yanında özellik sayısını düşürme kabiliyetini de ortaya koymaktadır. Algoritmanın gerçek dünya problemlerinde düşük hesaplama maliyetiyle alternatiflerine rakip olacağı da gösterilmiştir (Too ve diğerleri, 2018).

Devanathan ve arkadaşları, nükleolar ve sentromer boyama desenlerini ayırt edebilmek için anahtar nokta özellikleri torbası (Bag-of-Keypoint Features - BoKF) modelini ve ikili GWO algoritması (BGWO) tabanlı özellik seçimini kullanmışlardır.

Seçilen özellikler kNN sınıflandırıcı ile değerlendirilmiştir. Deneyler, BGWO ile belirlenen özelliklerin, nükleolar ve sentromer desenlerini yaklaşık %91,6 oranında doğru sınıflandırabildiğini göstermiştir (Devanathan ve diğerleri, 2019).

Al-Tashi ve arkadaşları, çok amaçlı gri kurt optimizasyon (Multi-objective Grey Wolf Optimization - MOGWO) algoritmasını ayrık ve çok amaçlı problemlerin çözümüne uyarlamak için çalışmalar yapmışlardır. Sigmoid transfer fonksiyonlarını kullanarak ikili varyantı önerilen algoritma BMOGW-S olarak adlandırılmıştır. Algoritma özellik seçim problemlerine uygulanmış ve özelliklerin sınıflandırılma verimliliğini değerlendirmek için yapay sinir ağları (Artificial Neural Network - ANN) kullanılmıştır. Önerilen yöntem 15 veri seti ile test edilmiş ve bazı algoritmalarla karşılaştırılmıştır. Sonuçlar, yeni ikili varyantın özellik alt küme sayısını ve maliyeti düşürürken sınıflandırma kalitesini artırdığını ortaya koymuştur (Al-Tashi ve diğerleri, 2020).

Hu ve arkadaşları, sürekli optimizasyon problemleri için önerilen GWO algoritmasını ikili problemlere uygulayabilmek için ikili varyantını geliştirmişlerdir (BGWO). GWO'daki sürekli değerleri ikiliye dönüştürmek için beş transfer fonksiyonu kullanmışlardır. BGWO, özellik seçimine uygulanmış ve sınıflandırma hatalarını düşürdüğü gözlemlenmiştir. Yapılan deneyler, önerilen ikili varyantın daha hızlı ve sürekli GWO'ya göre daha yüksek performansa sahip olduğunu göstermiştir (Hu ve diğerleri, 2020).

Meme kanserinin tanımlanmasında bilgisayar destekli tanı (CAD) sistemi önemli bir yere sahiptir. Sathiyabhama ve arkadaşları, GWO ve Rough-Set yöntemlerini kullanarak hibrit bir çalışma yürütmüşler ve yeni bir CAD sistemi önermişlerdir (GWORS). Bu sayede mamogram görüntülerinden gereksiz özellikleri eleyerek daha etkili sonuçlar elde etmeyi amaçlamışlardır. Önerilen GWORS'un performansını ölçmek için, literatürdeki bazı popüler algoritmalar kullanılmıştır. Sonuçlar, önerilen yöntemin diğer yöntemlere göre daha yüksek doğruluk sağladığını göstermiştir (Sathiyabhama ve diğerleri, 2021).

Gerçek hayatta kronik hastalıkların erken teşhisi oldukça önemlidir ve literatürde de bu konu hakkında çalışmalara yer verilmiştir. Deep, kronik hastalık verilerine özellik seçimini uyguladığı çalışmalarda GWO algoritmasının yeni bir versiyonunu geliştirmiştir ve rastgele yürüyen gri kurt optimizasyon (Random Walk Grey Wolf Optimization - RWGWO) algoritması olarak adlandırmıştır. Önerilen yöntem, kronik hastalıklar üzerine

18 veri seti ile test edilmiştir. Birkaç yeni yöntemle karşılaştırıldığında en iyi sonuçları verdiği gözlemlenmiştir (Deep, 2022).

Wang ve arkadaşları, karmaşık sınıflandırma problemlerinin çözümünde en iyi özelliklerin seçilmesini sağlamak amacıyla uyarlanabilir dengeli gri kurt optimizasyonu (Adaptively Balanced Grey Wolf Optimization - ABGWO) algoritmasını sunmuşlardır. ABGWO'nun verimliliğini artırmak üzerine yapılan çalışmada yedi farklı özellik seçim yöntemiyle karşılaştırma uygulanmıştır. Önerilen algoritma çalışma süresi, sınıflandırma doğruluğu ve özellik alt kümelerinin boyutu gibi kriterlerde daha etkin sonuçlar üretmiştir (Wang ve diğerleri, 2022).

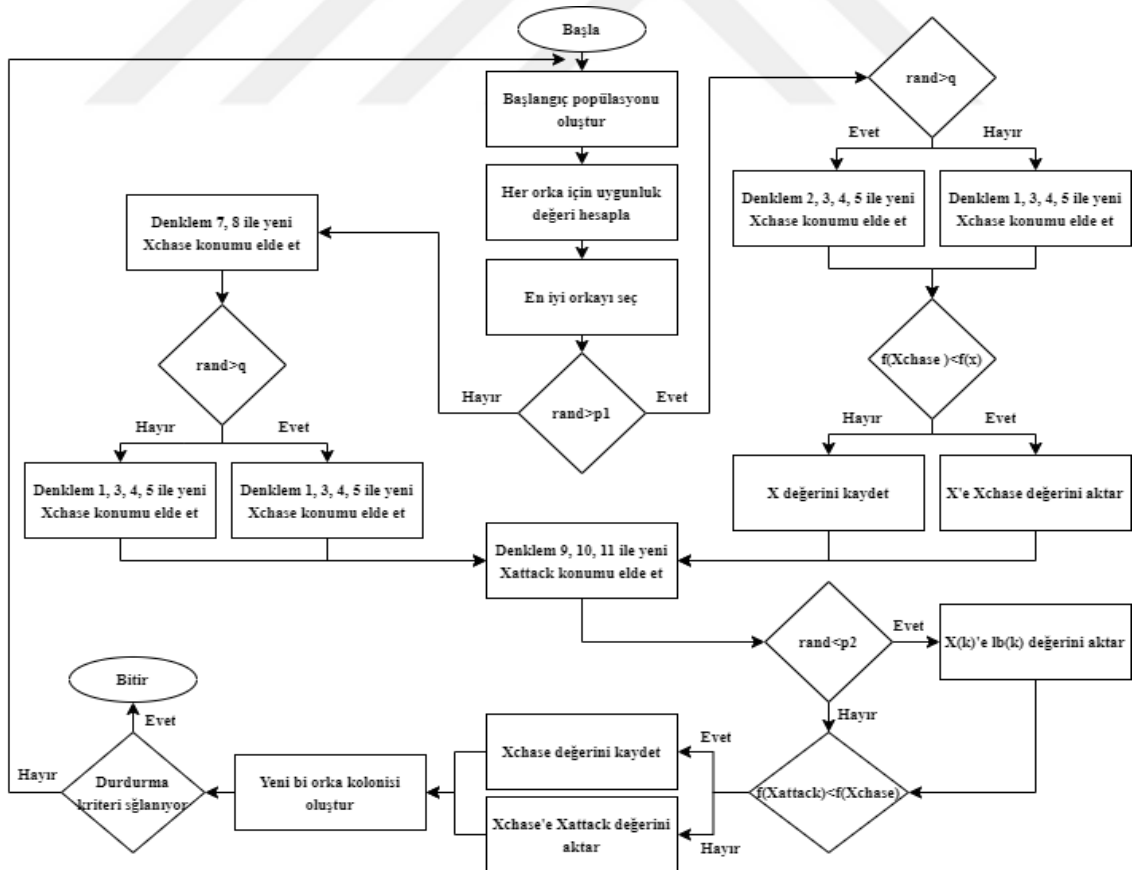


3. MATERYAL VE YÖNTEM

3.1. Orka Yırtıcı Algoritması (OPA)

Orkalar, son derece zeki, yırtıcı ve etçil memelilerdir. Katil balina olarak da bilinen sosyal etkileşimi yüksek olan bu canlılar, ortalama 18 bireyden oluşan aile grupları halinde yaşarlar. Grubun üyeleri genellikle birbirlerinden 100 metre uzaklıkta yüzerler ve nadiren yiyecek bulmak için gruptan ayrılan bireyler birkaç saat içerisinde dönerler (Jiang ve diğerleri, 2022; Kılınç ve İlhan, 2024).

Orkalar ortamı algılamak ve aralarında haberleşmek için sonarlarını kullanırlar. Balık sürüsü fark ettiklerinde direkt avlanmak yerine birbirleriyle etkileşime girerek stratejik şekilde ilerlerler. Orkaların bu avlanma davranışından esinlenerek Jiang ve arkadaşları (2022) tarafından Orka Yırtıcı Algoritması önerilmiştir. OPA, orkaların avlanma davranışını çeşitli matematiksel modellerle ifade eden metasezgisel bir optimizasyon yöntemidir. Orkaların avlanma süreci avı kovalama ve ava saldırma olmak üzere iki adıma indirgenebilir. OPA'ya ait akış şeması Şekil 3.1'de verilmiştir.



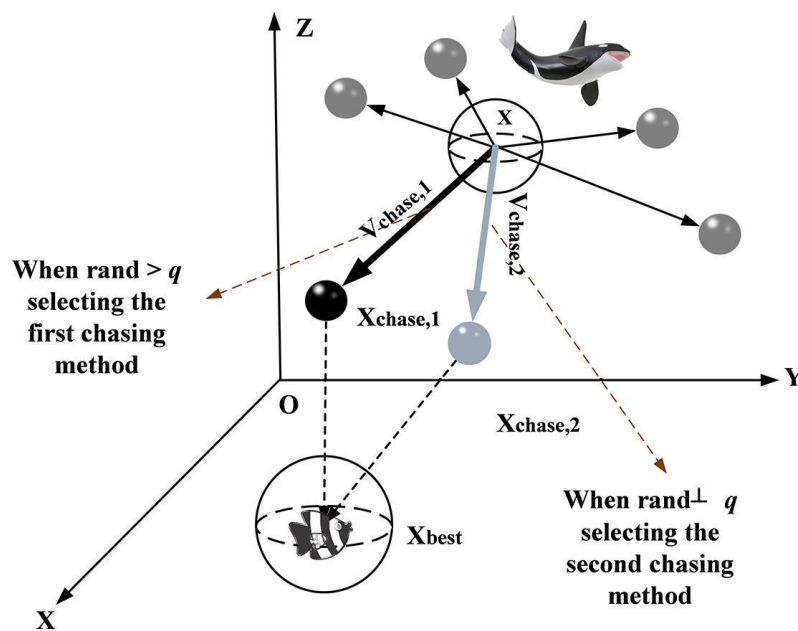
Şekil 3. 1. OPA'nın akış diyagramı

3.1.1. Kovalama Aşaması

Orkalar, bir grup balıkla karşılaştıklarında sonarları aracılığıyla haberleşerek koordine olurlar ve iş birliği içinde hareket ederler. Balık sürüsü, orka grubu tarafından yüzeye çıkmaya zorlanır ve kontrol altına alınır. Orkaların bu stratejisinden yola çıkarak kovalama aşaması iki davranışta incelenir: avın sürülmesi ve çevrenmesi. Orkaların bu iki davranışı birbirinden bağımsız şekilde gerçekleştirme olasılığı için $p1$ parametresi kullanılır. $[0,1]$ aralığında rastgele üretilen bir sayının $p1$ 'den büyük olması avın sürülmesi, küçük olması avın çevrenmesi anlamına gelir (Houssein ve diğerleri, 2023; Jiang ve diğerleri, 2022).

3.1.1.1. Avın Sürülmesi

Orkalar, gördükleri balık sürüsünü yüzeye kadar kovalarlar. Bu süreçte orka grubunun büyüklüğüne bağlı iki yöntem mevcuttur. Orka grubunun büyük, avlanma alanının geniş ve karmaşık olması sebebiyle, orkaların dağılarak hedeften sapma ihtimali artar. Bu durumda ($\text{rand} > q$) birinci yöntem uygulanır. Orka grubunun küçük ve avlanma ortamının basit olması halinde, avın konumu daha hızlı ve kolay tespit edilir. Bu şartlarda ise ($\text{rand} \leq q$) ikinci yöntem kullanılır. Orkanın av sürüş modeli Şekil 3.2'de, hız ve konum formülasyonu Denklem 1-5'te verilmiştir (Houssein ve diğerleri, 2023; Jiang ve diğerleri, 2022).



Şekil 3. 2. Orkaların av sürüş modeli

$$v_{chase,1,i}^t = a \times (d \times x_{best}^t - F \times (b \times M^t + c \times x_i^t)) \quad (1)$$

$$v_{chase,2,i}^t = e \times x_{best}^t - x_i^t \quad (2)$$

$$M = \frac{\sum_{i=1}^N x_i^t}{N} \quad (3)$$

$$c = 1 - b \quad (4)$$

$$\begin{cases} x_{chase,1,i}^t = x_i^t + v_{chase,1,i}^t, & \text{Eğer } rand > q \\ x_{chase,2,i}^t = x_i^t + v_{chase,2,i}^t, & \text{Eğer } rand \leq q \end{cases} \quad (5)$$

Burada birinci ve ikinci takip yöntemleri için, i 'inci orkanın t 'inci iterasyondaki kovalama hızlarını sırasıyla $v_{chase,1,i}^t$ ve $v_{chase,2,i}^t$, orkaların hareket ettikten sonraki konumlarını sırasıyla $x_{chase,1,i}^t$ ve $x_{chase,2,i}^t$ ifade eder. a , b , d sayıları $[0, 1]$ arasında ve e sayısı $[0, 2]$ arasında rasgele üretilen değerlerdir. F değeri 2 olarak belirlenmiştir. $[0, 1]$ arasında sabit bir sayı olan q avın sürülme yöntemini belirleyen bir parametredir. M , orka grubundaki bireylerin ortalama konumunu temsil eder (Jiang ve diğerleri, 2022).

3.1.1.2. Avın Çevrenmesi

Avın çevrenmesi, yüzeye çıkarılan balık sürüsünün stratejik bir şekilde yakalanması için orkalar tarafından çevrenerek kontrol altına alınması sürecidir. Bu aşamada, orkalar bir sonraki konumlarını belirleyebilmek için çevresindeki orkalarla etkileşime girerler. Orkaların hareket yönünü belirlerken rastgele seçilen üç orkanın konumlarından faydalandığı varsayılır. Karar verme mekanizmasının bir parçası olan bu konumlar, bazı matematiksel ifadelerle güncellenir. Güncel konumların hesaplanmasında kullanılan formülasyonlar Denklem 6 ve 7'de tanımlanmıştır (Kılınç ve İlhan, 2024).

$$x_{chase,3,i,k}^t = x_{j1,k}^t + u * (x_{j2,k}^t - x_{j3,k}^t) \quad (6)$$

$$u = 2 \times (rand - 1 / 2) \times \frac{Max_iter - t}{Max_iter} \quad (7)$$

Burada $x_{chase,3,i,k}^t$, avın çevrenmesi sırasında i 'inci orkanın güncel pozisyonunu, $j1$, $j2$ ve $j3$ ise rastgele seçilen üç orkayı ifade eder ($j1 \neq j2 \neq j3$). Max_iter , maksimum yinelenme sayısıdır.

3.1.1.3. Pozisyonların Ayarlanması

Orkalar, gelişmiş sonar sistemleri sayesinde su altında bulunan balık sürülerinin davranışlarını izleyebilir ve avın konumunu kesin bir şekilde tespit edebilirler. Bunun yanında kendi hareketlerini etkili şekilde yönlendirmek için yine sonarlarından faydalanırlar. Avın sürülmesi sırasında balıkların orka grubuna yaklaştığı algılanırsa, orkalar konumlarını güncelleyerek kovalama işlemine devam ederler, aksi takdirde eski konumunda kalırlar. Balıkların hareketleri, orkaların stratejik karar verme mekanizmalarını doğrudan etkilediğinden bu süreç, avın yakalanması için kritik öneme sahiptir. Orkaların konum güncelleme stratejisini açıklamak için geliştirilmiş matematiksel ifade Denklem 8’de verilmiştir.

$$x_i^t = \begin{cases} x_{chase,i}^t, & \text{Eğer } f(x_{chase,i}^t) < f(x_i^t) \\ x_i^t, & \text{Aksi durumda} \end{cases} \quad (8)$$

Burada $f(x_{chase,i}^t)$ ve $f(x_i^t)$ sırasıyla $x_{chase,i}^t$ ve x_i^t ‘ye karşılık gelen uygunluk fonksiyonu değerlerini ifade eder. Uygunluk değerinin minimum olması, ilgili konumun iyi olduğu anlamına gelmektedir (Jiang ve diğerleri, 2022).

3.1.2. Saldırı Aşaması

Orkalar, avın etrafını sardıktan sonra sırayla çembere girerek, balıkları yönlendirmek ya da sersemletmek amacıyla kuyruklarını ava doğru savururlar ve beslenme faaliyetini gerçekleştirirler. Avlanma işlemi tamamlayan orka geri döner ve bir başka orka ile yer değiştirir.

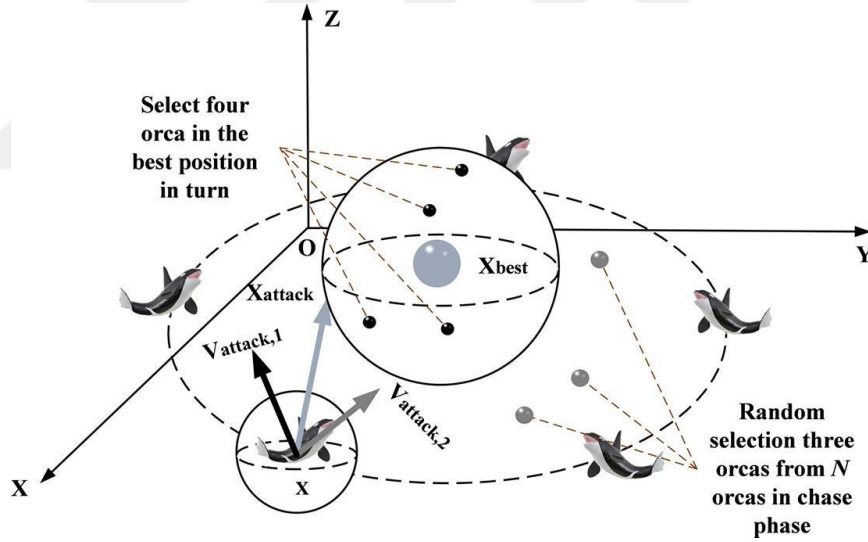
Çemberdeki en iyi dört saldırı pozisyonunu temsil eden dört orka olduğu varsayılır. Daha az sayıda orka, parçacıkların tek bir yönde hareket etmesine, fazla sayıda orka ise yakınsama hızının ve avlanma performansının düşmesine neden olabilir. Bu nedenle, dört orka ideal kabul edilir. Diğer orkalar, kafese girmek ve beslenmek için bu dört orkanın pozisyonlarını kullanırlar. Beslendikten sonra geri dönmek için ise rastgele seçtikleri orkaların konumlarını dikkate alarak hareket yönlerini belirleyebilirler. Orkaların saldırı modeli Şekil 3.3’te, saldırı aşamasında orkaların ilerleme hızı ve konularıyla ilgili matematiksel ifadeler Denklem 9-11’de verilmiştir. Bu denklemler, orkaların hareket stratejilerini ve avlanma taktiklerini açıklamaktadır (Jiang ve diğerleri, 2022) .

$$v_{attack,1,i}^t = (x_{first}^t + x_{second}^t + x_{third}^t + x_{four}^t) / 4 - x_{chase,i}^t \quad (9)$$

$$v_{attack,2,i}^t = (x_{chase,j1}^t + x_{chase,j2}^t + x_{chase,j3}^t) / 3 - x_i^t \quad (10)$$

$$x_{attack,i}^t = x_{chase,i}^t + g1 \times v_{attack,1,i}^t + g2 \times v_{attack,2,i}^t \quad (11)$$

Burada i 'inci orkanın avlanmaya giderken sahip olduğu hız $v_{attack,1,i}^t$, muhafazaya geri dönerken sahip olduğu hız ise $v_{attack,2,i}^t$ ile ifade edilir. Seçilen optimum dört orkanın konumları sırasıyla $x_{first}^t, x_{second}^t, x_{third}^t, x_{four}^t$ 'dir. $j1, j2$ ve $j3$ kovalama aşamasında rastgele seçilen üç orkadır ($j1 \neq j2 \neq j3$). Muhafazaya geri dönecek olan orka, bu üç orkanın konumunu kullanır ve bu sırasıyla $x_{chase,j1}^t, x_{chase,j2}^t, x_{chase,j3}^t$ şeklinde ifade edilir. $x_{attack,i}^t$, saldırı aşamasından sonra i 'inci orkanın konumudur. $g1$ $[0,2]$ arasında ve $g2$ $[-2.5, 2.5]$ arasında rastgele sayılardır (Jiang ve diğerleri, 2022; Olivares ve diğerleri, 2024).



Şekil 3. 3. Orkaların ava saldırı modeli

3.1.2.1. Pozisyonların Ayarlanması

Orkalar, gelişmiş sonar sistemleri aracılığıyla su altındaki hareketleri algılayarak, çevresel koşulları ve avın davranışlarını sürekli olarak izlemekte, bu sayede pozisyonlarını dinamik bir şekilde ayarlayabilmektedirler. Bu yetenek, orkaların avlarını daha etkili bir şekilde yönlendirmelerine ve yakalama stratejileri geliştirmelerine olanak tanır.

Pozisyon güncellemesi, orkaların çevresel koşullara ve avın davranışlarına anında tepki vermelerini sağlayarak avlanma başarısını artıracığından kritik öneme sahiptir. Orkaların konum değişikliği işlemi Şekil 3.4'deki sözde kod ile ifade edilebilir.

```

1:  if  $f(x_{attack,i}^t) < f(x_{chase,i}^t)$ 
2:       $x_i^{t+1} = x_{attack,i}^t$ 
3:  else
4:       $q = rand$ ;
5:      for  $k = 1$  to  $d$ 
6:          if  $q < p2$ 
7:               $x_{j,k}^{t+1} = lb(k)$ 
8:          else
9:               $x_{j,k}^{t+1} = x_{chase,i,k}^t$ 
10:         end if
11:      end for
12: end if

```

Şekil 3. 4. Orkaların konum güncellemesi için sözde kod

Burada lb problemin uygulanabilir aralıkta kalmasını sağlayan minimum sınır değerini ifade eder. $p2$ probleme göre farklılık gösterebilen $[0,2]$ aralığında bir sabittir, u ise $[0,1]$ aralığında rastgele bir sayıdır (Jiang ve diğerleri, 2022; Kılınç ve İlhan, 2024) .

3.2. Önerilen İkili Orka Yırtıcı Algoritması (BOPA)

Metasezgisel algoritmaların çoğu, sürekli optimizasyon problemlerini çözmek amacıyla tasarlanmıştır. Bu tür algoritmaları ikili optimizasyon problemlerinin çözümünde kullanabilmek için, sürekli değerlere sahip arama uzayını ikili değerlere (0 ve 1) dönüştürmek gerekir (Karakoyun ve Özkış, 2021). Literatürde bu amaca yönelik iki yöntem vardır. İlk yöntemde konum vektörleri, ikili vektörler olarak modellenir. Güncel konumu ifade eden orijinal denklem, ikili vektörler ve bu vektörler arasında uygulanan operatörler kullanılarak yeniden ifade edilir. Dolayısıyla sürekli algoritmanın yapısı değişir.

İkinci yöntemde algoritmanın yapısı değiştirilmeden, konum vektörleri sürekli uzayda olduğu gibi kullanılır. Değiştirilmiş konum denklemi, büyük değer önceliği, açılı modülasyonu ve transfer fonksiyonları gibi ikilileştirme yöntemleri kullanılarak çözüm vektörleri her iterasyonda gerçek değerlerden ikili değerlere dönüştürülür. Transfer

fonksiyonları, basit ve hızlı olması sebebiyle yaygın olarak kullanılmaktadır (Pan ve diğerleri, 2023; Thom de Souza ve diğerleri, 2020) .

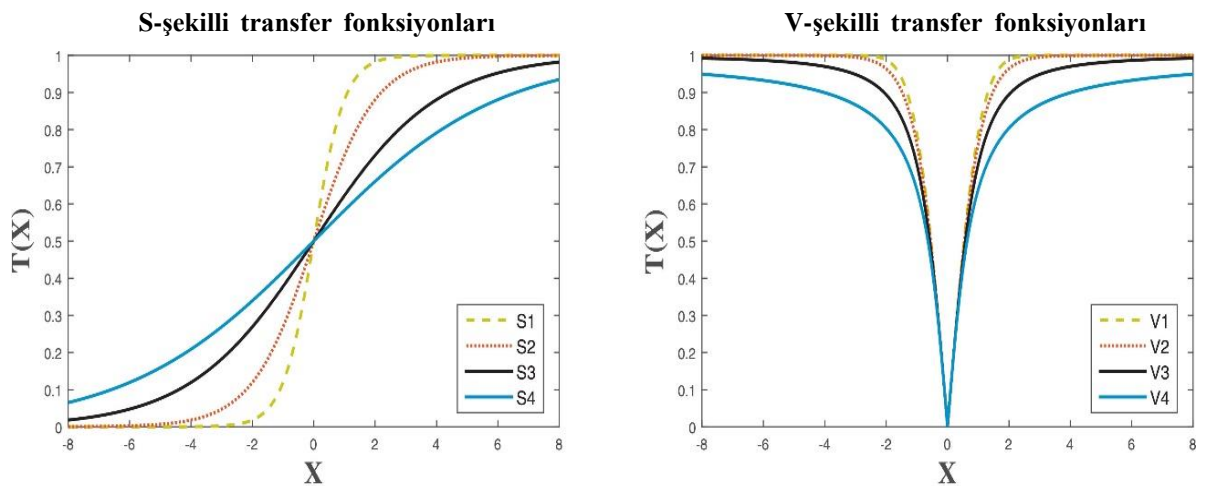
3.2.1. Transfer Fonksiyonları

Transfer fonksiyonları, sürekli değerlere sahip arama uzayını ikili değerlerle ifade edebilmek için kullanılan bir fonksiyonlardır. Bu fonksiyonlar, konum vektöründeki elemanların 0'dan 1'e veya tersi yönde değişme olasılığını ifade ederler.

Literatürde, ikili dönüşüm işlemlerinde en sık kullanılan transfer fonksiyonları arasında S-şekilli ve V-şekilli transfer fonksiyonları öne çıkmaktadır. Transfer fonksiyonları, her bir elemanı olasılığa dayanan yöntemlerle 0 ve 1 değerlerine dönüştürür. Bu fonksiyonların matematiksel ifadeleri Çizelge 3.1'de, genel formları Şekil 3.5'te verilmiştir.

S-şekilli transfer fonksiyonları		V-şekilli transfer fonksiyonları	
S1:	$f(x) = \frac{1}{1 + e^{-2x}}$	V1:	$f(x) = \left \operatorname{erf} \left(\frac{\sqrt{\pi}}{2} x \right) \right $
S2:	$f(x) = \frac{1}{1 + e^{-x}}$	V2:	$f(x) = \tanh(x) $
S3:	$f(x) = \frac{1}{1 + e^{-x/2}}$	V3:	$f(x) = \left \frac{x}{\sqrt{1 + x^2}} \right $
S4:	$f(x) = \frac{1}{1 + e^{-x/3}}$	V4:	$f(x) = \left \frac{2}{\pi} \arctan \left(\frac{\pi}{2} x \right) \right $

Çizelge 3. 1. S-şekilli ve V-şekilli transfer fonksiyonları için denklemler



Şekil 3. 5. S-şekilli ve V-şekilli transfer fonksiyonları

Transfer fonksiyonları bir sayı dizisine uygulandığında, sonuçlar $[0,1]$ aralığında gerçel sayılardan oluşur. Bu değerleri 0 ve 1 olarak ifade edebilmek için belirli kurallar vardır. S-şekilli transfer fonksiyonları için Denklem 12, V-şekilli transfer fonksiyonları için Denklem 13 kullanılarak ikili değerler elde edilir (Arora ve Anand, 2019; Karakoyun ve Özkış, 2021).

$$x_i^t(t+1) = \begin{cases} 1 & \text{if } rand < f(x_i^t) \\ 0 & \text{if } rand \geq f(x_i^t) \end{cases} \quad (12)$$

$$\text{if } rand < T(x_i^t) \quad x_i^t(t+1) = \begin{cases} 0 & \text{if } mod(x_i^t, 1) > 0.5 \\ 1 & \text{if } mod(x_i^t, 1) \leq 0.5 \end{cases} \quad (13)$$

$$\text{if } rand > T(x_i^t) \quad x_i^t(t+1) = \begin{cases} 1 & \text{if } mod(x_i^t, 1) > 0.5 \\ 0 & \text{if } mod(x_i^t, 1) \leq 0.5 \end{cases}$$

Burada $f(x_i^t)$, transfer fonksiyonunun uygulanmasıyla elde edilen gerçel değerlerdir. $x_i^t(t+1)$, ilgili kısıtların uygulanması sonucunda elde edilen ikili değerler vektörünü ifade eder. $rand$, $[0,1]$ arasında rastgele üretilen bir sayıdır.

Bir transfer fonksiyonu her problem için en iyi çözümü vermeyebilir. Bu nedenle uygun transfer fonksiyonun seçilmesi kritik öneme sahiptir (Karakoyun ve Özkış, 2021). OPA'nın ikili forma dönüştürülmesi için farklı transfer fonksiyonları kullanılmış ve Bölüm 4'te ilgili kıyaslamalara yer verilmiştir.

3.3. Özellik Seçimi İçin İkili Orka Yırtıcı Algoritması

Özellik seçimi, mevcut özellikler arasından minimum sayıda özelliği seçerek verimliliği artırmayı hedefler. Seçilen özellik alt kümelerinin değerlendirilmesi için literatürde iki yöntem mevcuttur: Sarmalayıcı tabanlı yöntemler ve filtre tabanlı yöntemler.

Filtre tabanlı yöntemler, seçilen özellikleri bir öğrenme algoritmasından bağımsız değerlendirirken sarmalayıcı yöntemlerde özellik alt kümelerini analiz etmek için bir öğrenme algoritmasına (sınıflandırıcı) ihtiyaç vardır. Sarmalayıcı yöntemlerde, optimizasyonun her aşamasında seçilen özellikler öğrenme algoritması tarafından değerlendirilmelidir. Dolayısıyla özellik alt kümelerinin bulunması, filtre tabanlı yöntemlere göre daha maliyetli ve zordur (Mafarja ve diğerleri, 2019).

Özellik seçimi için çözümün kalitesi, seçilen özellik sayısının minimum olmasına ve aynı zamanda özellik alt kümesinin yüksek sınıflandırma doğruluğuna sahip olmasına bağlıdır. Bu çalışmada, literatürde sıklıkla kullanılan kNN sınıflandırıcısı kullanılır ve elde edilen sınıflandırma doğruluğu uygunluk fonksiyonuna dahil edilir (Arora ve Anand, 2019; Mafarja ve diğerleri, 2019) .

En az özellik sayısı ve en yüksek sınıflandırma doğruluğu olmak üzere iki amacı dikkate alan uygunluk fonksiyonu Denklem 14’te verilmiştir.

$$fitness = \alpha \gamma_R(D) + \beta \frac{|R|}{|N|} \quad (14)$$

$$\gamma_R(D) = \frac{\text{Yanlış tahminlerin sayısı}}{\text{Toplam örnek sayısı}} \quad (15)$$

Burada $\gamma_R(D)$ sınıflandırıcıya ait hata oranıdır. $|R|$ seçilen özelliklerin sayısı ve $|N|$ toplam özellik sayısıdır. α ve β sınıflandırma kalitesini ve alt küme uzunluğunu belirten sabit iki parametredir: $\alpha \in [0,1]$ ve $\beta = (1 - \alpha)$ (Arora ve Anand, 2019; Mafarja ve diğerleri, 2019) .

3.4. Birini Dışarıda Bırak Çapraz Doğrulama (LOOCV)

Birini dışarıda bırak çapraz doğrulama (LOOCV), algoritmaların sınıflandırma yeteneğini değerlendirmek için yaygın olarak kullanılan bir yöntemdir. Bu yaklaşımda, bir veri setindeki her bir örnek, sırasıyla test seti olarak belirlenir ve geriye kalan tüm gözlemler eğitim seti olarak kullanılır. Test verisi, eğitim verileri üzerinden analiz edilir ve performans ölçütüne (doğruluk, hata oranı gibi) göre değerlendirilir. Bu süreç, veri setindeki her bir gözlem için tekrarlanır (Wong ve Yeh, 2020).

LOOCV yönteminin en büyük avantajı, her bir gözlem için modelin performansını değerlendirme imkânı tanıyarak daha tutarlı ve güvenilir sonuçların elde edilmesini sağlamasıdır. Ancak, yüksek hesaplama maliyeti nedeniyle büyük veri setlerinde uygulanabilirliği sınırlıdır. Her bir gözlem için ayrı bir model eğitmek, zaman ve kaynak açısından önemli bir yük oluşturur.

Bu çalışmada, LOOCV ile kNN birbirine entegre olarak kullanılmıştır. Veri setindeki her bir örneğin diğer örneklerle arasındaki Öklid mesafesi hesaplanmıştır. En yakın 5 komşunun değerleri kullanılarak, sınıflandırıcıya ait hata oranı bulunmuştur. Hata oranı kullanılarak ilgili bireyin uygunluk değeri hesaplanmıştır.

3.5. Taguchi Metodu

Parametre optimizasyonu, optimizasyon sürecinin hızlı, verimli ve düşük maliyetli olması için önemli bir araçtır. En uygun parametre değerlerinin belirlenmesinde farklı yöntemler kullanılmaktadır. Taguchi metodu bunlardan biridir.

Taguchi metodu, 1950’li yıllarda Genichi Taguchi tarafından geliştirilmiştir (Chen ve diğerleri, 2022). Parametrelerin en iyi kombinasyonunu bularak, az sayıda deney ile çok sayıda değişkeni incelemeyi hedefleyen, deney tasarımına dayalı istatistiksel bir optimizasyon yöntemidir (Li ve diğerleri, 2019; Mohamad ve diğerleri, 2021). Taguchi metodu, sistemin performansını değerlendirmek için sinyal-gürültü (S/N) oranını ve parametrelerin algoritma üzerindeki etkilerini inceler (Ansari ve diğerleri, 2023; Ghosh ve diğerleri, 2017; İlhan, 2021).

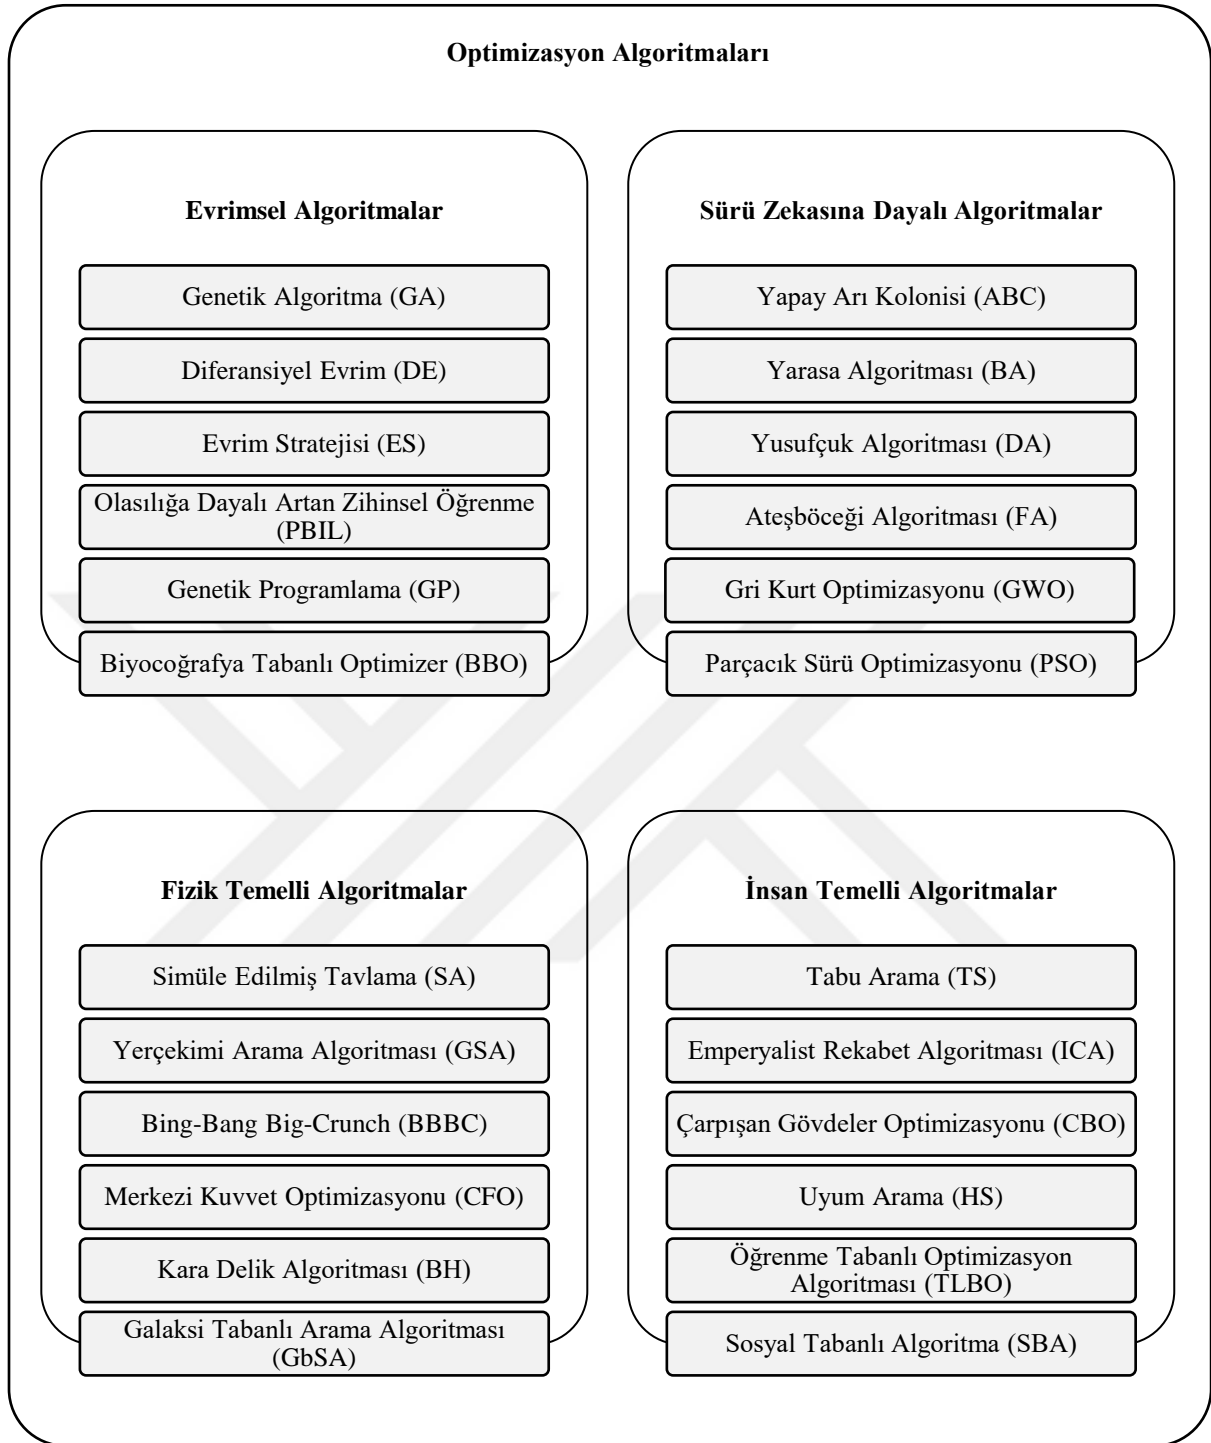
Taguchi metodu ile yapılan parametre optimizasyonuna ait sonuçlar Bölüm 4’te verilmiştir.

3.6. Karşılaştırma İçin Kullanılan Algoritmalar

Optimizasyon problemleri karmaşık yapıları, geniş arama alanları, doğrusal olmayan kısıtlar gibi bazı temel sebeplerden dolayı genellikle uzun hesaplama süresi gerektiren zor problemlerdir. Bu problemleri daha hızlı, doğru ve etkili çözebilmek için birçok geleneksel ve metasezgisel yöntem geliştirilmiş ve uygulanmıştır (Abualigah ve diğerleri, 2021; Mirjalili ve Lewis, 2016).

Metasezgisel yöntemler, basit bir yapıya sahiptir ve problemlere kolaylıkla uygulanabilir. Bu algoritmaların arama stratejisi keşif ve sömürüye dayanır. Keşfetme yetenekleri sayesinde yerel optimumdan kaçınırlar. Sömürü yetenekleri ise çözüm kalitesini iyileştirir. Sağladığı birçok avantaj sebebiyle, karmaşık problemlerin çözümünde sıklıkla tercih edilen başarılı yöntemlerdir (Erdoğan, 2023; Mirjalili ve Lewis, 2016).

Metasezgisel algoritmalar; evrimsel algoritmalar, sürü zekasına dayanan algoritmalar, fizik temelli algoritmalar ve insan temelli algoritmalar olmak üzere ilham aldığı prensipler doğrultusunda sınıflandırılırlar. Şekil 3.6’te ilgili gruplandırmaya ait şema verilmiştir.



Şekil 3. 6. Metasezgisel algoritmaların sınıflandırılması

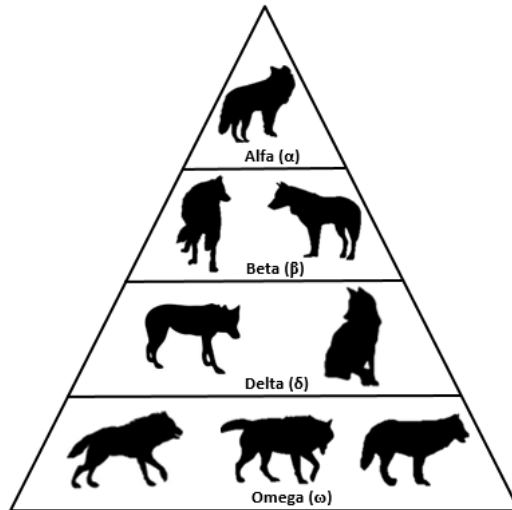
Evrimsel algoritmalar, evrim yasalarından esinlenirler ve en iyi bireylerden yeni nesiller oluşturulması prensibine dayanırlar. Fizik temelli algoritmalar, fizik yasa ve kurallarını temel alan yöntemlerdir. İnsan temelli algoritmalar, insanların toplum içindeki davranışlarından ilham alarak tasarlanmışlardır. Sürü zekasına dayalı algoritmalar ise, topluluk halinde yaşayan hayvanların sosyal ve avlanma davranışlarından esinlenerek ortaya çıkmışlardır (Erdoğan, 2023).

Bu çalışmada, BOPA'nın performansını değerlendirmek için sürü zekasına dayalı algoritmalarından üç tanesi kullanılmış, bu algoritmalarla ilgili detaylı bilgiler aşağıdaki bölümlerde verilmiştir.

3.6.1. Gri Kurt Optimizasyon (GWO) Algoritması

GWO algoritması 2014 yılında Mirjalili ve arkadaşları tarafından önerilen metasezgisel bir optimizasyon yöntemidir. Algoritma, problemlerin çözümünde gri kurtların sosyal hiyerarşisini ve avlanma davranışlarını taklit eder.

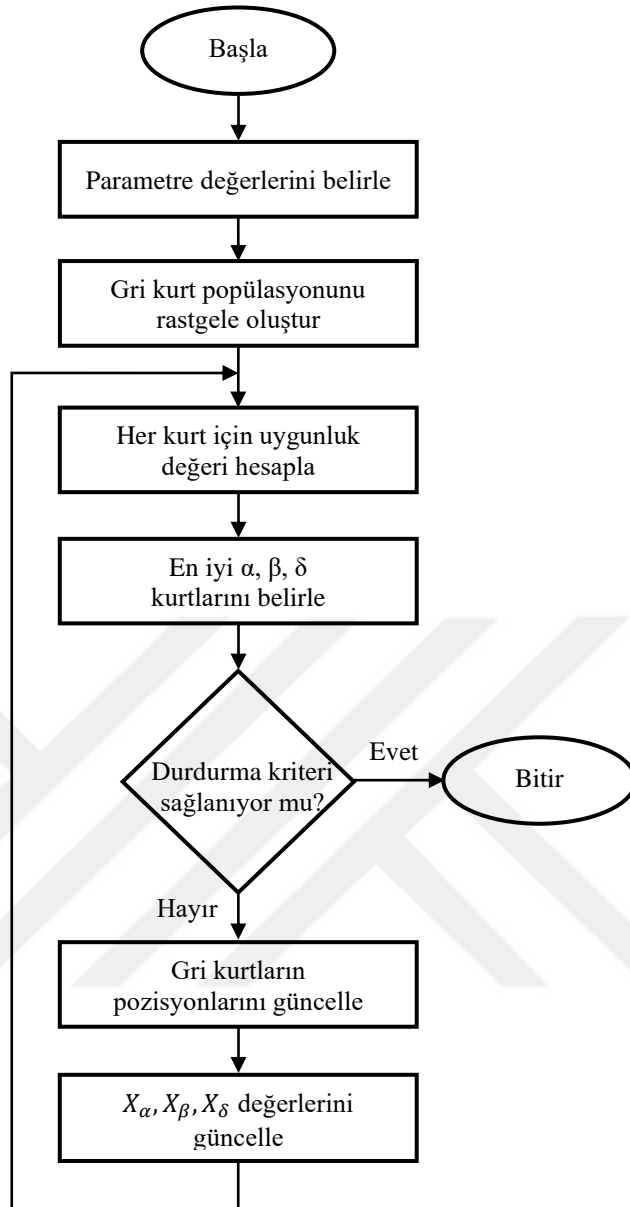
Gri kurtlar besin zincirinde en üst düzey avcılar olarak bilinir. 5-12 bireyden oluşan gruplar halinde yaşarlar. Sürü içerisinde hiyerarşik bir düzen hakimdir ve buna göre kurtlar dört sınıfa ayrılır: alfa (α), beta (β), delta (δ) ve omega (ω). Alfalar, sürünün lideridir ve avlanma, uyuma gibi davranışlara karar vererek sürüyü yönetir. Betalar, tüm faaliyetlerde alfaya yardımcı olan bir alt sınıftır. Alfanın kararları doğrultusunda sürüyü disipline eder. Delta kurtlar, betaya boyun eğmek zorundadır, ancak omegaya hükmederler. Bölge sınırlarını izlemek, sürü güvenliğini sağlamak, tehlike durumunda sürüyü uyarmak, avlanma sürecinde alfa ve betalara yardım etmek gibi görevleri vardır. Sürünün en düşük rütbeli gri kurtları omegalardır. Sürü içinde önemi olmayan kurtları kapsar ve bu kurtlar sürüdeki tüm kurtlara boyun eğmek zorundadır. Gri kurtların çok katlı sosyal hiyerarşik sistemi Şekil 3.7'de verilmiştir (Dada ve diğerleri, 2022; Yu ve Hu, 2024).



Şekil 3. 7. Gri kurt hiyerarşisi

GWO, kurtların avı kuşatma, takip etme ve saldırma gibi davranışlarını matematiksel olarak modeller. Bu yöntem, özellikle karmaşık ve çok boyutlu optimizasyon problemlerinin çözümünde yüksek performans sağlar. Fiziksel teoremler gerektirmediğinden yapısı oldukça basittir ve az sayıda parametre içerir, dolayısıyla uygulaması kolaydır (Yu ve Hu, 2024). GWO'ya ait akış diyagramı Şekil 3.8'de verilmiştir. Şekilden de görülebildiği gibi öncelikle, algoritmanın çalışabilmesi için gerekli parametre değerleri belirlenir ve gri kurt popülasyonu rastgele oluşturulur. Her bir kurt için amaç fonksiyona göre uygunluk değerleri hesaplanır ve en iyi uygunluk değerine sahip ilk üç lider kurt alfa, beta ve delta olarak belirlenir. Diğer kurtlar, liderlerin pozisyonlarına göre kendi pozisyonlarını günceller. Bu süreç, durdurma kriteri sağlanana kadar tekrarlanır.





Şekil 3. 8. GWO akış diyagramı

3.6.2. Parçacık Sürü Optimizasyon (PSO) Algoritması

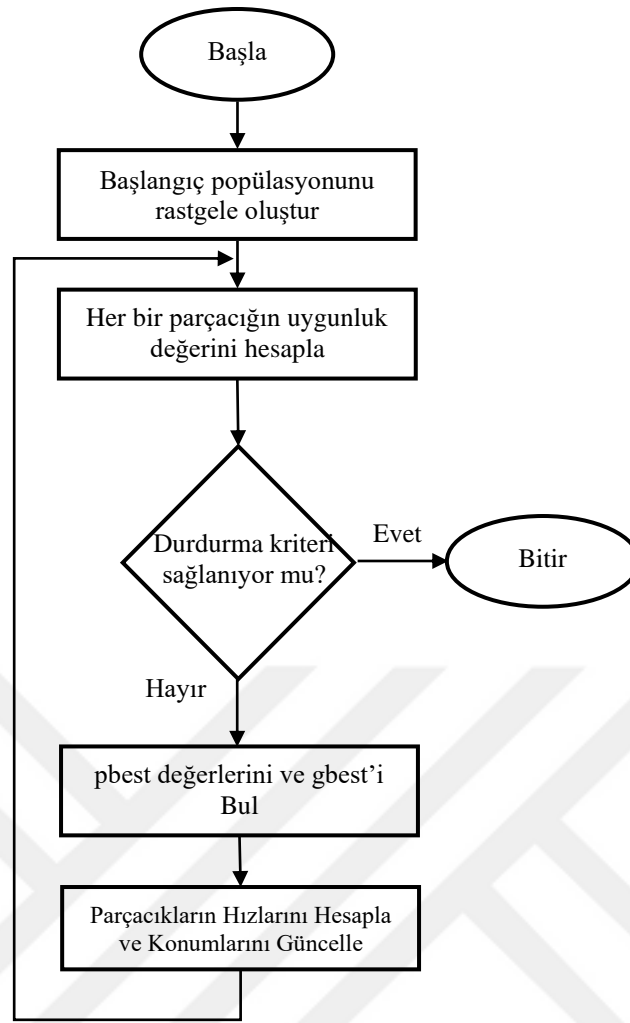
PSO algoritması, kuşlar veya balıklar gibi biyolojik canlıların sürü halindeki sosyal davranışlarına dayanan popülasyon temelli bir optimizasyon tekniğidir. İlk olarak 1995 yılında Kennedy ve Eberhart tarafından literatüre kazandırılmıştır (Chuanjun ve diğerleri, 2023).

PSO, n boyutlu bir uzayda rastgele yerleştirilmiş, ağırlığı olmayan parçacıklar olduğunu kabul eder. Her parçacık sürüdeki bir bireyi temsil eder. Bireylerin kendilerine ait mevcut konumu ve ilerleme hızı vardır. Algoritmanın optimizasyon sürecinde, her parçacık sürüdeki davranışları taklit ederek kendi konumunu ve ilerleme hızını sürekli

olarak ayarlar. Dolayısıyla popülasyonun optimum çözümü de sürekli olarak güncellenir (Cai ve diğerleri, 2020).

PSO'nun temel hedefi, bireylerin konumlarını sürüdeki en iyi bireyin konumuna yaklaştırmaktır. Bu yaklaşma süreci, rastgele bir gelişim gösterir ve bireyler eski konumlarına göre daha iyi bir konuma gelmeyi amaçlar. Her iterasyonda, parçacıkların pozisyonları güncellenerek, optimum çözüme ulaşmak için belirli bir strateji izlenir. PSO algoritmasının bu dinamik yapısı, bireylerin sürekli olarak kendilerini geliştirmelerine ve sürü içinde daha etkili bir şekilde hareket etmelerine olanak tanır.

Farklı uygulama alanlarında sağladığı başarılar ve çok sayıda parametre ile çalışabilme yeteneği, PSO algoritmasının optimizasyon problemlerinin çözümünde ne kadar etkili bir yöntem olduğunu göstermektedir. PSO algoritması için genel akış diyagramı Şekil 3.9'de verilmiştir. Şekilden de görülebildiği gibi algoritmanın başlangıcında parçacıklar rastgele pozisyon ve hızlarla başlatılırlar. Her bir parçacığın uygunluk değeri hesaplanır. Kişisel (pbest) en iyi pozisyonlar ile küresel (gbest) en iyi pozisyon belirlenir. Parçacıkların kendi en iyi pozisyonları ve sürünün en iyi pozisyonu dikkate alınarak hızları ve konumları güncellenir. Bu süreç, durdurma kriteri sağlanıncaya kadar tekrarlanır.



Şekil 3. 9. PSO akış diyagramı

3.6.3. Yapay Arı Kolonisi (ABC) Algoritması

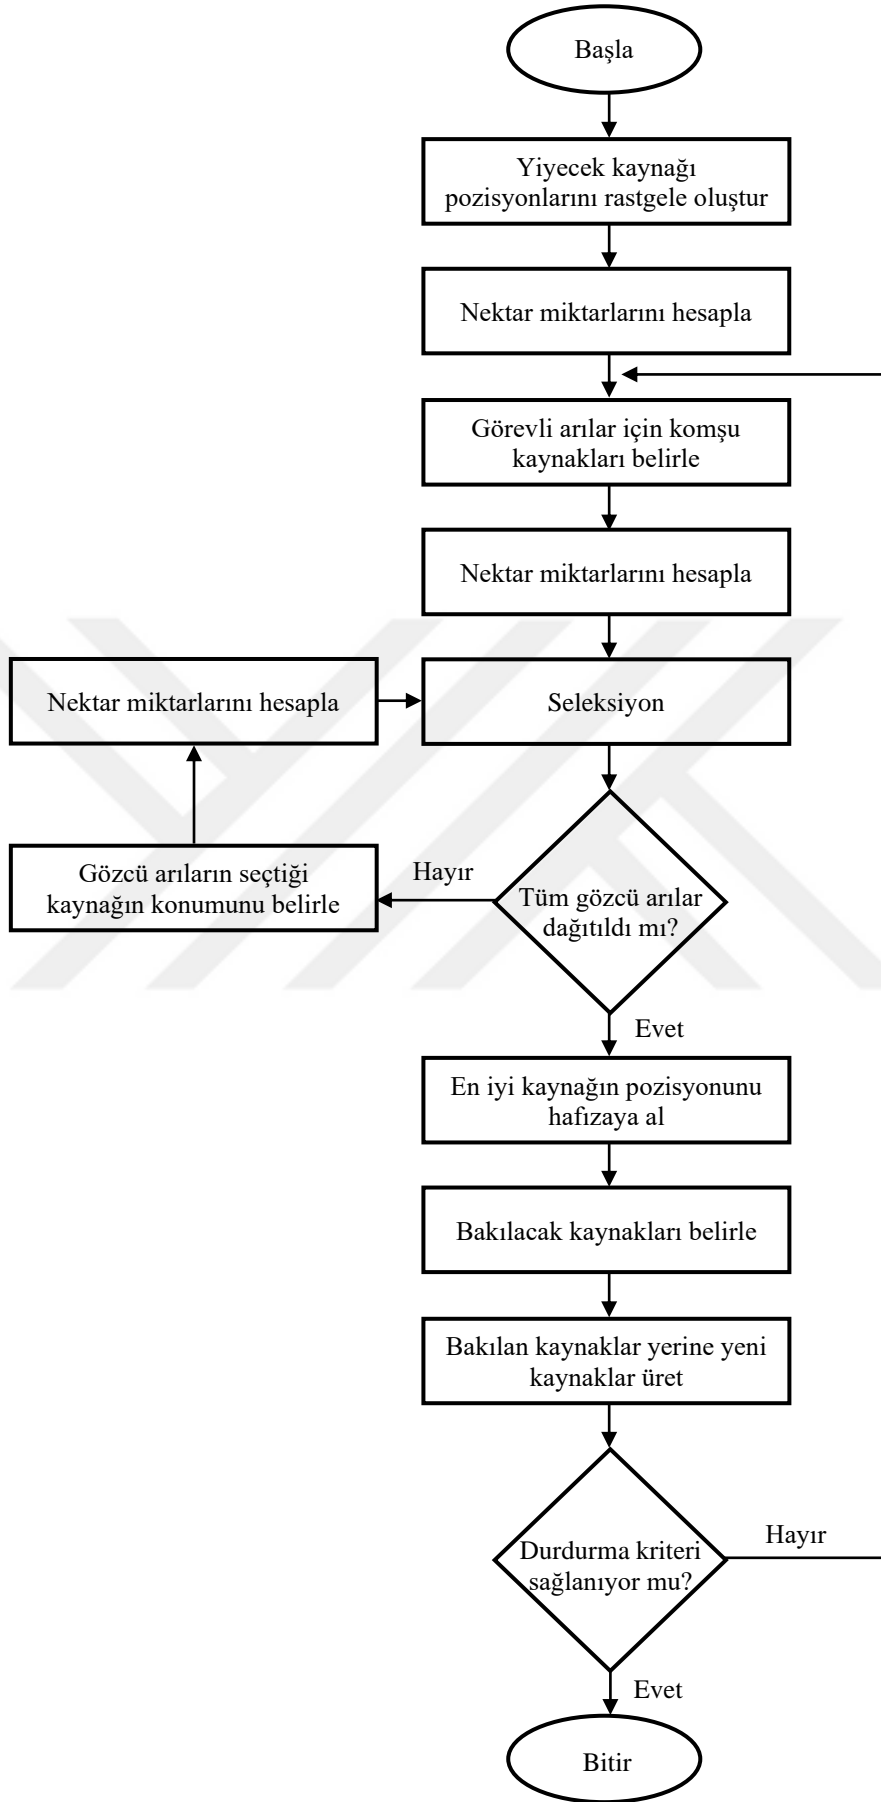
Yapay arı kolonisi algoritması, arıların yiyecek arama davranışlarından esinlenerek geliştirilmiş, sayısal optimizasyon problemlerini çözmeye yönelik bir metasezgisel yaklaşımdır. Sürü zekası ilkelerine dayanan bu algoritma, doğal sistemlerin kendini organize edebilme yeteneklerinden faydalanarak, karmaşık problemlerin çözümü için etkin bir yöntem sunar. 2005 yılında önerilen algoritma, en iyi yiyecek kaynağını bulmayı hedefler (Karaboga, 2005; Karaboga ve Ozturk, 2011).

Bir arı kolonisi içerisinde, arıların farklı görevler üstlenerek koloni faaliyetlerine katkı sağladıkları bir iş bölümü sistemi mevcuttur. Bu iş bölümü, arıların doğal organizasyon becerileri doğrultusunda, koloninin ihtiyaçlarını karşılayacak şekilde dinamik olarak yürütülür. Görevlerine göre arılar üç gruba ayrılır: işçi arılar, gözcü arılar ve keşif arılar. İş paylaşımı arıların kendisi tarafından yapılır ve bu yetenek sürü zekası tabanlı algoritmaların önemli bir özelliğidir.

Arılar polen bulmak için yiyecek kaynaklarına giderler. Yiyecek kaynağının kalitesi, yuvaya yakınlığı, çeşidi, nektar yoğunluğu gibi birçok kritere göre belirlenir. Besin kaynaklarından polen getirmek işçi arıların görevidir. Kaşif arılar, yeni ve alternatif besin kaynaklarını ararlar. Gözcü arılar ise, kovanda bekleyerek diğer arılar tarafından paylaşılan bilgiler doğrultusunda yeni kaynaklara yönelirler (Aslan ve diğerleri, 2018; Li, 2023).

ABC algoritmasında, arılar arasında bilgi alışverişi dans yoluyla gerçekleşir. Yiyecek kaynağını bulan arılar, kovana döndüklerinde dans ederek diğer arılara kaynağın yeri ve kalitesi hakkında bilgi verirler. Dans esnasında diğer arılar antenleriyle bu arılara dokunarak, kaynağın yerini ve uygunluk derecesini öğrenirler. Bu süreç, algoritmanın optimizasyon mekanizmasının temelini oluşturur. Yiyecek kaynağının kalitesi, nektar yoğunluğu ile ölçülür ve bu değer uygunluk fonksiyonunu ifade eder. ABC algoritmasının amacı, en yüksek nektar miktarına sahip yiyecek kaynağını bulmaktır.

ABC algoritmasının akış diyagramı, Şekil 3.10'da sunulmuştur. Şekilden de görülebildiği gibi algoritmanın başlangıcında yiyecek kaynakları rastgele oluşturulur ve bu kaynaklara ait nektar miktarları hesaplanır. Daha sonra görevli arılar için komşu kaynaklar belirlenir. Belirlenen kaynakların nektar miktarlarına göre bir seleksiyon süreci iletilir. Bu süreç tüm gözcü arılar kaynaklara dağıtılıncaya kadar devam eder. Nektar miktarı azalan kaynaklar belirlenir ve yerlerine yeni kaynaklar üretilir. Bu adımlar, durdurma kriteri sağlanana kadar tekrarlanır.



Şekil 3. 10. ABC akış diyagramı

4. ARAŞTIRMA SONUÇLARI VE TARTIŞMA

4.1. Veri Kümeleri

Veri kümelerinin üzerinde çalışılan problemle doğrudan ilgili ve uyumlu olması, algoritma performansının doğru bir şekilde değerlendirilmesi açısından büyük önem taşımaktadır. Bu çalışmada, önerilen BOPA algoritmasının performansını değerlendirebilmek amacıyla, literatürde yaygın olarak kullanılan çeşitli veri setleri incelenmiştir. Sınıflandırma problemlerinde sıklıkla tercih edilen ve farklı zorluk düzeylerine sahip veri setleri arasından yedi tanesi seçilmiştir. Bu veri setleri, UCI (University of California, Irvine) makine öğrenimi veri deposundan temin edilmiş, her bir veri setine ait temel nitelikler, yani özellik (değişken) sayısı, örnek sayısı ve sınıf sayısı bilgileri Çizelge 4.1'de detaylı olarak listelenmiştir.

No	Veri seti	Özellik sayısı	Örnek sayısı	Sınıf sayısı
1	BreastEW	30	569	2
2	HeartEW	13	270	2
3	IonosphereEW	34	351	2
4	Lymphography	18	148	4
5	Tic-Tac-Toe	9	958	2
6	Wine	13	178	3
7	Zoo	16	101	7

Çizelge 4. 1. Deneylerde kullanılan veri kümeleri

4.2. Parametre Ayarı

BOPA, üç parametreye sahiptir: $p1$, q ve $p2$. Tüm alternatif durumları içeren deney tasarımı için $4^3 = 64$ deney yapılması gerekirken Taguchi metodu, 16 parametre kombinasyonu üretmiştir. Üç veri seti için yapılan 16 deney, güvenilirliği artırmak amacıyla 5 kez tekrarlanmış ve elde edilen uygunluk değerlerinin ortalaması alınmıştır. İlgili veriler Çizelge 4.2'de verilmektedir.

Parametreler			Ortalama uygunluk değerleri		
<i>p1</i>	<i>q</i>	<i>p2</i>	Wine	Zoo	Lymphography
0.1	0.1	0.1	0,0746	0,0744	0,1656
0.1	0.3	0.3	0,0751	0,0864	0,1601
0.1	0.7	0.7	0,0766	0,0973	0,1760
0.1	0.9	0.9	0,0863	0,1430	0,2032
0.3	0.1	0.3	0,0762	0,0800	0,1692
0.3	0.3	0.1	0,0756	0,0813	0,1635
0.3	0.7	0.9	0,0792	0,0889	0,1748
0.3	0.9	0.7	0,0776	0,0838	0,1747
0.7	0.1	0.7	0,0757	0,0881	0,1682
0.7	0.3	0.9	0,0798	0,1039	0,1715
0.7	0.7	0.1	0,0752	0,0713	0,1670
0.7	0.9	0.3	0,0741	0,0729	0,1652
0.9	0.1	0.9	0,0777	0,0949	0,1699
0.9	0.3	0.7	0,0757	0,0924	0,1686
0.9	0.7	0.3	0,0736	0,0800	0,1602
0.9	0.9	0.1	0,0742	0,0726	0,1600

Çizelge 4. 2. L₁₆ ortogonal dizisi için elde edilen sonuçlar

Taguchi yönteminde, hedeflenen performans kriterlerine ulaşabilmek için faktörlerin hangi seviyelerinin daha çok katkı sağladığını analiz etmek gerekir. Bu değerlendirme için S/N oranı önemli bir göstergedir. S/N oranı, istenen çıktının (sinyal), istenmeyen durumlara (gürültü) oranını ifade eder ve hangi faktör seviyelerinin yüksek performans sergilediğini belirlemede önemli bir rol oynar. S/N oranını hesaplamak için "Daha Büyük, Daha İyi" prensibine dayanan en yüksek değer formülü kullanılmıştır ve ilgili matematiksel ifade Denklem 16'da sunulmuştur. Denklem, ilgili deneylerin sonuçlarını değerlendirmek amacıyla logaritmik bir ölçüm sağlamakta ve sistemin performansını optimize etmeye yardımcı olmaktadır.


$$\frac{S}{N} = -10 \log \left(\frac{1}{n} \sum_{i:1}^n \frac{1}{y_i^2} \right) \quad (16)$$

Formül, sinyalin (S) gücünü artırırken, gürültünün (N) etkisini minimize etmeyi hedefler. Denklemde yer alan n , yapılan deneylerin toplam sayısını belirtir ve güvenilir sonuçların elde edilmesi için önemlidir. y_i , karakteristik değer olarak adlandırılır ve belirli bir deneyde elde edilen bireysel ölçüm değerini ifade eder.

Yüksek S/N değeri, ilgili parametre seviyelerinin kalite üzerinde olumlu bir etkiye sahip olduğunu ve sistemin istenen performansa daha yakın sonuçlar ürettiğini

göstermektedir. Bu durum, sistemdeki gürültünün (varyasyon veya sapma) etkisinin minimize edildiğini ve istenen sinyalin (performans) baskın hale geldiğini işaret eder. Ayrıca, yüksek S/N oranı, sürecin kararlılığını artırarak dış etkenlerden daha az etkilendiğini ve belirlenen hedeflere sürdürülebilir bir şekilde ulaşılabileceğini gösterir. Bu bağlamda, yüksek S/N değeri, kalite kontrol ve optimizasyon süreçlerinde başarı kriteri olarak önemli bir rol oynamaktadır. Öte yandan, S/N oranının düşük olması, ilgili parametre seviyelerinin kalite üzerinde olumsuz etkiler yarattığını ortaya koymaktadır. Dolayısıyla, Taguchi yönteminde S/N oranının analizi, kalite iyileştirme süreçlerinin etkinliği açısından kritik bir öneme sahiptir.

Çizelge 4.2'deki sonuçları sinyal-gürültü oranına dönüştürmek için Minitab istatistik yazılımı kullanılmıştır. Parametrelerin S/N oranları, Şekil 4.1'de görsel olarak sunulmuş ve ilgili değerler Çizelge 4.3'te detaylı bir şekilde listelenmiştir.



Şekil 4. 1. Parametrelere ait S/N oranları grafiği

Seviye	A (p1)	B (q)	C (p2)
1	18,07	18,62	18,96
2	18,54	18,58	18,89
3	18,63	18,58	18,38
4	18,75	18,22	17,77
Delta	0,68	0,40	1,19
Rank	2	3	1

Çizelge 4. 3. Parametrelere ait S/N oranları

Çizelge 4.3'te yer alan 'delta' ve 'rank' ifadeleri, parametrelerin sistem kalitesi üzerindeki etkilerini gösteren değerlerdir. Delta, her faktör için seviyeler arasındaki maksimum farkı verir. Yüksek delta değeri, ilgili faktörün yanıt üzerindeki etkisinin büyük olduğu anlamına gelir. Rank ise faktörleri delta değerlerine göre sıralar ve en etkili faktörü ortaya koyar. Tablodaki delta ve rank değerleri incelendiğinde, sistem kalitesine en çok etki eden faktörün C yani $p2$ parametresi olduğu görülmektedir.

Her faktöre ait en yüksek S/N oranı, o faktörün belirli bir deney tasarımı için sağladığı en iyi performans seviyesini temsil eder. Sonuçlara göre, A faktörü için en başarılı seviye 4, B faktörü için seviye 1 ve C faktörü için seviye 1 olarak belirlenmiştir. Buradan yola çıkarak deneylerde kullanılacak optimum parametre değerleri $p1=0,9$, $q=0,1$ ve $p2=0,1$ olarak belirlenmiştir.

4.3. BOPA İçin Deneysel Sonuçlar ve Karşılaştırmalar

Bu çalışmada, OPA'nın ikili problemlere uygulanabilmesi amacıyla sekiz farklı transfer fonksiyonu kullanılarak ikili değerlere sahip BOPA varyantları geliştirilmiştir. Bu varyantlar, literatürde sıkça kullanılan ve çeşitli zorluk düzeylerine sahip yedi farklı veri seti üzerinde test edilmiştir. Algoritmanın performansını objektif bir şekilde değerlendirmek ve sonuçların güvenilirliğini artırmak amacıyla, her bir veri seti üzerinde deneyler 10 kez tekrarlanmıştır. Tekrarlı çalıştırmalar, daha tutarlı ve daha güvenilir bir karşılaştırma ortamı sağlamıştır. Deneyler, Intel Core i5-13500H işlemci, 4.7 GHz işlemci hızı, 16 GB RAM ve Microsoft Windows 11 işletim sistemine sahip bir bilgisayarda gerçekleştirilmiştir.

Yapılan tüm deneylerde, popülasyon büyüklüğü 50 ve iterasyon sayısı 100 olarak belirlenmiştir. $p1$, $p2$ ve q parametreleri, Taguchi metodu ile yapılan istatistiksel deneylerden elde edilen değerlere ayarlanmıştır. Diğer parametreler için literatürdeki çalışmalarda yaygın olarak kabul gören değerler tercih edilmiştir. k parametresi, kNN sınıflandırıcısı için komşu sayısını temsil eder. α ve β parametreleri, kullanılan uygunluk fonksiyonuna ait $[0,1]$ aralığında sabit değerlerdir ve çalışmalarda genellikle $\alpha=0,9$ olarak seçilmektedir ($\beta=1-\alpha$). İlgili parametre değerleri Çizelge 4.4'te verilmiştir.

Parametre	Değer
$p1$	0,9
q	0,1
$p2$	0,1
k	5
α	0,9
β	0,1
Sınırlar [lb, ub]	[-10,10]

Çizelge 4. 4. BOPA için parametre değerleri

Önerilen BOPA'nın performansını değerlendirmek için yaygın olarak kullanılan üç farklı optimizasyon algoritması ile karşılaştırmalar yapılmıştır. Bu algoritmalar GWO PSO ve ABC algoritmalarıdır. Sonuçların objektif olması amacıyla, bu sürekli optimizasyon algoritmaları OPA'nın ikili hale getirilmesinde kullanılan aynı yöntemler uygulanarak BGWO, BPSO ve BABC ikili algoritmalarına dönüştürülmüştür. Bu algoritmalar için deneyler, BOPA ile aynı şartlarda gerçekleştirilmiştir.

BPSO'da kullanılan $c1$ ve $c2$ parametreleri hız katsayılarıdır. Parçacıkların $pbest$ ve $gbest$ 'e ne kadar yaklaştığını kontrol etmek için kullanılırlar. İki değer de genellikle [1, 2] aralığında seçilir. w , atalet katsayısıdır ve BPSO'da parçacıkların hızını kontrol eden parametredir. Bu değer büyük olması parçacıkların daha geniş bir alanda hareket etmesini sağlamaktadır. $Limit$ parametresi ise BABC algoritmasında kullanılır. Keşif sürecinde arıların belirli bir çözüm üzerine ne kadar araştırma yapacaklarını sınırlayan bir ifadedir. Bu dört parametre için kullanılan değerler Çizelge 4.5'te verilmiştir.

Parametre	Değer
$c1$	2
$c2$	2
w	0,3
$Limit$	10

Çizelge 4. 5. BPSO ve BABC için parametre değerleri

Önerilen yöntemi karşılaştırmak için kullanılan BGWO, BPSO ve BABC algoritmalarından elde edilen uygunluk değerleri Çizelge 4.6 - 4.8'de verilmiştir. BOPA'nın her tekrarda elde edilen uygunluk değerleri ise Çizelge 4.9'da listelenmiştir. Bu çizelgelerde TF sütunu transfer fonksiyonlarını ifade etmektedir.

Veri Seti	TF	Tekrar										
		1	2	3	4	5	6	7	8	9	10	
BreastEW	S1	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353
	S2	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353
	S3	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353
	S4	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353
	V1	0,3420	0,3387	0,3353	0,3420	0,3387	0,3453	0,3353	0,3487	0,3353	0,3453	0,3453
	V2	0,3353	0,3353	0,3387	0,3353	0,3420	0,3420	0,3420	0,3420	0,3420	0,3420	0,3387
	V3	0,3420	0,3420	0,3420	0,3353	0,3453	0,3487	0,3487	0,3487	0,3387	0,3420	0,3453
	V4	0,3487	0,3420	0,3387	0,3387	0,3387	0,3387	0,3453	0,3387	0,3387	0,3353	0,3387
HeartEW	S1	0,1697	0,1697	0,1697	0,1718	0,1874	0,1774	0,1941	0,1718	0,1718	0,1774	0,1774
	S2	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	S3	0,1697	0,1697	0,1697	0,1697	0,1731	0,1731	0,1774	0,1718	0,1697	0,1774	0,1774
	S4	0,1718	0,1874	0,1731	0,1718	0,1731	0,1697	0,1718	0,1697	0,1731	0,1718	0,1718
	V1	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1718	0,1697	0,1697	0,1697	0,1697
	V2	0,1718	0,1697	0,1718	0,1697	0,1697	0,1718	0,1718	0,1718	0,1718	0,1697	0,1697
	V3	0,1697	0,1718	0,1697	0,1731	0,1774	0,1718	0,1697	0,1718	0,1718	0,1718	0,1774
	V4	0,1697	0,1718	0,1718	0,1718	0,1697	0,1828	0,1718	0,1731	0,1718	0,1697	0,1697
IonosphereEW	S1	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	S2	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	S3	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	S4	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	V1	0,3260	0,3260	0,3290	0,3319	0,3290	0,3319	0,3260	0,3319	0,3231	0,3260	0,3260
	V2	0,3260	0,3290	0,3319	0,3290	0,3260	0,3231	0,3290	0,3290	0,3319	0,3260	0,3260
	V3	0,3260	0,3290	0,3290	0,3290	0,3260	0,3290	0,3348	0,3260	0,3290	0,3348	0,3348
	V4	0,3319	0,3290	0,3290	0,3378	0,3319	0,3407	0,3319	0,3260	0,3290	0,3231	0,3231
Lymphography	S1	0,1721	0,1605	0,1550	0,1550	0,1843	0,1605	0,1682	0,1550	0,1550	0,1732	0,1732
	S2	0,1782	0,1550	0,1550	0,1550	0,1777	0,1550	0,1616	0,1732	0,1550	0,1550	0,1616
	S3	0,1732	0,1550	0,1550	0,1621	0,1550	0,1682	0,1550	0,1605	0,1610	0,1737	0,1737
	S4	0,1732	0,1803	0,1550	0,1616	0,1737	0,1687	0,1687	0,1616	0,1550	0,1550	0,1550
	V1	0,1605	0,1727	0,1605	0,1721	0,1737	0,1732	0,1661	0,1661	0,1600	0,1610	0,1610
	V2	0,1616	0,1655	0,1666	0,1711	0,1666	0,1793	0,1550	0,1550	0,1616	0,1788	0,1788
	V3	0,1605	0,1661	0,1605	0,1621	0,1600	0,1737	0,1721	0,1600	0,1671	0,1605	0,1605
	V4	0,1721	0,1610	0,1661	0,1676	0,1727	0,1661	0,1600	0,1655	0,1605	0,1600	0,1600
Tic-Tac-Toe	S1	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	S2	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	S3	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	S4	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V1	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V2	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V3	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V4	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
Wine	S1	0,0763	0,0736	0,0763	0,0763	0,0714	0,0739	0,0763	0,0763	0,0763	0,0763	0,0736
	S2	0,0736	0,0736	0,0763	0,0763	0,0736	0,0736	0,0763	0,0736	0,0763	0,0763	0,0763
	S3	0,0714	0,0763	0,0736	0,0739	0,0763	0,0763	0,0736	0,0739	0,0763	0,0763	0,0736
	S4	0,0763	0,0763	0,0763	0,0736	0,0739	0,0763	0,0736	0,0787	0,0763	0,0763	0,0763
	V1	0,0714	0,0714	0,0739	0,0739	0,0739	0,0763	0,0714	0,0763	0,0714	0,0763	0,0763
	V2	0,0714	0,0714	0,0714	0,0739	0,0714	0,0714	0,0736	0,0736	0,0736	0,0736	0,0714
	V3	0,0739	0,0714	0,0736	0,0739	0,0736	0,0787	0,0714	0,0736	0,0714	0,0714	0,0714
	V4	0,0736	0,0739	0,0739	0,0714	0,0714	0,0714	0,0739	0,0714	0,0739	0,0714	0,0714
Zoo	S1	0,0758	0,0847	0,0847	0,0758	0,0642	0,0847	0,0705	0,0847	0,0794	0,0883	0,0883
	S2	0,0642	0,0883	0,0705	0,0758	0,0642	0,0883	0,0821	0,0794	0,0794	0,0847	0,0847
	S3	0,0883	0,0946	0,0794	0,0883	0,0794	0,0642	0,0642	0,0910	0,0794	0,0847	0,0847
	S4	0,0642	0,0642	0,0642	0,0883	0,0847	0,0883	0,0936	0,0883	0,0767	0,0910	0,0910
	V1	0,0794	0,0767	0,0767	0,0642	0,0642	0,0794	0,0642	0,0767	0,0847	0,0758	0,0758
	V2	0,0705	0,0767	0,0767	0,0705	0,0642	0,0794	0,0705	0,0821	0,0767	0,0821	0,0821
	V3	0,0794	0,0830	0,0642	0,0794	0,0794	0,0794	0,0794	0,0767	0,0767	0,0767	0,0767
	V4	0,0705	0,0767	0,0936	0,0642	0,0767	0,0705	0,0767	0,0705	0,0758	0,0758	0,0767

Çizelge 4. 6. BGWO için uygunluk değerleri

Veri Seti	TF	Tekrar									
		1	2	3	4	5	6	7	8	9	10
BreastEW	S1	0,3353	0,3353	0,3353	0,3587	0,3353	0,3653	0,3620	0,3620	0,3353	0,3353
	S2	0,3453	0,3353	0,3353	0,3353	0,3553	0,3353	0,3353	0,3353	0,3353	0,3487
	S3	0,3353	0,3420	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3387
	S4	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3453
	V1	0,3587	0,3620	0,3720	0,3587	0,3553	0,3553	0,3587	0,3687	0,3353	0,3687
	V2	0,3353	0,3753	0,3620	0,3587	0,3353	0,3687	0,3620	0,3687	0,3553	0,3687
	V3	0,3720	0,3653	0,3553	0,3520	0,3353	0,3687	0,3553	0,3620	0,3553	0,3687
	V4	0,3620	0,3353	0,3687	0,3520	0,3620	0,3653	0,3553	0,3387	0,3587	0,3687
HeartEW	S1	0,2341	0,2485	0,2131	0,2051	0,2374	0,1697	0,2328	0,2008	0,2162	0,2441
	S2	0,2295	0,2487	0,2341	0,2141	0,1828	0,1941	0,1731	0,2185	0,2041	0,1774
	S3	0,1697	0,2141	0,2305	0,1774	0,2085	0,1872	0,1941	0,2308	0,2185	0,1895
	S4	0,2318	0,2008	0,1697	0,1908	0,1774	0,2208	0,2310	0,2051	0,2415	0,2141
	V1	0,2462	0,2128	0,1995	0,2151	0,2285	0,1951	0,2205	0,2308	0,2172	0,1941
	V2	0,1808	0,2318	0,2051	0,2331	0,2310	0,2208	0,1985	0,1774	0,2285	0,2095
	V3	0,1972	0,2385	0,2285	0,2241	0,2138	0,2549	0,2172	0,2285	0,2341	0,2331
	V4	0,1918	0,2318	0,1985	0,2085	0,2218	0,2418	0,1951	0,2308	0,1964	0,1972
IonosphereEW	S1	0,3466	0,3290	0,3554	0,3437	0,3378	0,3378	0,3231	0,3231	0,3231	0,3407
	S2	0,3407	0,3584	0,3554	0,3231	0,3437	0,3407	0,3495	0,3231	0,3437	0,3231
	S3	0,3348	0,3231	0,3231	0,3231	0,3231	0,3260	0,3437	0,3231	0,3466	0,3231
	S4	0,3319	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	V1	0,3495	0,3554	0,3319	0,3525	0,3495	0,3525	0,3348	0,3613	0,3584	0,3525
	V2	0,3495	0,3231	0,3290	0,3554	0,3437	0,3525	0,3437	0,3437	0,3554	0,3495
	V3	0,3231	0,3437	0,3584	0,3466	0,3584	0,3231	0,3495	0,3466	0,3231	0,3525
	V4	0,3231	0,3495	0,3525	0,3525	0,3378	0,3495	0,3231	0,3231	0,3319	0,3319
Lymphography	S1	0,1920	0,2142	0,1854	0,2031	0,2020	0,2203	0,1965	0,1904	0,2036	0,1859
	S2	0,2081	0,1909	0,1854	0,1777	0,2092	0,1782	0,1854	0,2097	0,2010	0,1954
	S3	0,2086	0,1742	0,1661	0,1732	0,2092	0,2041	0,1742	0,2290	0,2092	0,2041
	S4	0,1854	0,1909	0,1925	0,1864	0,2335	0,2031	0,1814	0,1920	0,2411	0,1986
	V1	0,1954	0,1909	0,2086	0,1788	0,1904	0,2142	0,2015	0,2086	0,1965	0,2187
	V2	0,2041	0,1869	0,1920	0,1909	0,2208	0,2065	0,2279	0,1803	0,2015	0,1605
	V3	0,1772	0,1965	0,1914	0,2047	0,2203	0,2137	0,2213	0,2031	0,2015	0,1833
	V4	0,2208	0,1970	0,1788	0,1925	0,2015	0,1959	0,2076	0,2020	0,1899	0,2285
Tic-Tac-Toe	S1	0,3119	0,3230	0,3119	0,3230	0,3341	0,3230	0,3230	0,3230	0,3341	0,3230
	S2	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3230	0,3230
	S3	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3230	0,3230
	S4	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V1	0,3230	0,3119	0,3230	0,3119	0,3119	0,3230	0,3230	0,3341	0,3119	0,3341
	V2	0,3341	0,3230	0,3230	0,3230	0,3452	0,3230	0,3230	0,3230	0,3119	0,3341
	V3	0,3119	0,3230	0,3119	0,3230	0,3119	0,3230	0,3119	0,3119	0,3230	0,3119
	V4	0,3119	0,3119	0,3230	0,3341	0,3230	0,3119	0,3230	0,3230	0,3230	0,3230
Wine	S1	0,0914	0,0787	0,0864	0,1070	0,1095	0,0739	0,0989	0,0965	0,0840	0,0840
	S2	0,0864	0,0943	0,0888	0,1018	0,0969	0,0763	0,0963	0,0763	0,0864	0,0739
	S3	0,0736	0,1143	0,0991	0,0787	0,0967	0,0787	0,0864	0,0965	0,0941	0,0864
	S4	0,0787	0,1198	0,0994	0,1242	0,0813	0,1090	0,0963	0,1070	0,0736	0,0840
	V1	0,0991	0,0890	0,0763	0,0917	0,0787	0,0864	0,0787	0,0914	0,0866	0,0917
	V2	0,0813	0,0840	0,0815	0,0866	0,0840	0,1066	0,0941	0,0965	0,0787	0,0991
	V3	0,0991	0,0864	0,0763	0,0840	0,0813	0,0917	0,0787	0,0914	0,0787	0,1044
	V4	0,0991	0,0941	0,0989	0,0866	0,0917	0,0813	0,0917	0,0864	0,0864	0,0842
Zoo	S1	0,1186	0,0946	0,0999	0,0972	0,1329	0,1124	0,1124	0,1186	0,1097	0,0767
	S2	0,1177	0,1124	0,0847	0,1035	0,1150	0,1150	0,1035	0,1266	0,1150	0,0999
	S3	0,1114	0,0936	0,0758	0,1088	0,0999	0,1239	0,1052	0,0856	0,1025	0,1061
	S4	0,0847	0,1177	0,0847	0,1071	0,1285	0,1025	0,1124	0,1177	0,1088	0,1275
	V1	0,0972	0,1061	0,1150	0,1025	0,0999	0,1088	0,0946	0,1035	0,1035	0,1150
	V2	0,1213	0,0856	0,1213	0,1150	0,1186	0,1088	0,1071	0,1124	0,1061	0,0972
	V3	0,0999	0,1266	0,1239	0,0794	0,1035	0,0946	0,0936	0,0946	0,1035	0,1150
	V4	0,1061	0,1088	0,0883	0,1124	0,1239	0,1097	0,0856	0,1035	0,1186	0,0767

Çizelge 4. 7. BPSO için uygunluk değerleri

Veri Seti	TF	Tekrar									
		1	2	3	4	5	6	7	8	9	10
BreastEW	S1	0,3487	0,3553	0,3453	0,3520	0,3520	0,3453	0,3453	0,3487	0,3487	0,3453
	S2	0,3420	0,3420	0,3353	0,3420	0,3353	0,3353	0,3353	0,3353	0,3387	0,3387
	S3	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353
	S4	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353
	V1	0,3487	0,3520	0,3520	0,3520	0,3520	0,3553	0,3453	0,3520	0,3453	0,3420
	V2	0,3487	0,3520	0,3520	0,3553	0,3520	0,3453	0,3453	0,3520	0,3487	0,3520
	V3	0,3520	0,3487	0,3487	0,3520	0,3487	0,3420	0,3520	0,3553	0,3487	0,3553
	V4	0,3487	0,3553	0,3520	0,3520	0,3520	0,3520	0,3553	0,3520	0,3520	0,3453
HeartEW	S1	0,1874	0,1862	0,1874	0,1718	0,1731	0,1697	0,1862	0,1718	0,1718	0,1731
	S2	0,1697	0,1697	0,1872	0,1718	0,1895	0,1774	0,1697	0,1731	0,1774	0,1774
	S3	0,1874	0,1918	0,1731	0,1697	0,1862	0,1697	0,1718	0,1697	0,1974	0,1697
	S4	0,1774	0,1828	0,1731	0,1697	0,1697	0,1828	0,1731	0,1697	0,1718	0,1731
	V1	0,1697	0,1697	0,1697	0,1697	0,1718	0,1697	0,1718	0,1731	0,1718	0,1718
	V2	0,1718	0,1697	0,1731	0,1718	0,1697	0,1697	0,1731	0,1697	0,1697	0,1718
	V3	0,1697	0,1697	0,1731	0,1697	0,1697	0,1718	0,1697	0,1697	0,1718	0,1718
	V4	0,1697	0,1718	0,1697	0,1697	0,1697	0,1731	0,1718	0,1718	0,1774	0,1697
IonosphereEW	S1	0,3437	0,3407	0,3407	0,3319	0,3437	0,3378	0,3348	0,3407	0,3437	0,3378
	S2	0,3290	0,3260	0,3260	0,3231	0,3231	0,3290	0,3231	0,3290	0,3260	0,3231
	S3	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	S4	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	V1	0,3437	0,3437	0,3407	0,3466	0,3378	0,3407	0,3437	0,3378	0,3407	0,3437
	V2	0,3407	0,3348	0,3407	0,3407	0,3348	0,3437	0,3407	0,3348	0,3466	0,3466
	V3	0,3378	0,3378	0,3378	0,3407	0,3407	0,3407	0,3437	0,3466	0,3378	0,3466
	V4	0,3378	0,3319	0,3437	0,3407	0,3378	0,3319	0,3407	0,3466	0,3407	0,3378
Lymphography	S1	0,1711	0,1711	0,1655	0,1671	0,1727	0,1727	0,1914	0,2031	0,1793	0,1742
	S2	0,1742	0,1621	0,1616	0,1716	0,1809	0,1732	0,1848	0,1803	0,1899	0,1732
	S3	0,1737	0,1737	0,1621	0,1621	0,1782	0,1803	0,1727	0,1742	0,1793	0,1864
	S4	0,1854	0,1788	0,1848	0,1798	0,1682	0,1600	0,1687	0,1727	0,1737	0,1737
	V1	0,1655	0,1721	0,1727	0,1742	0,1550	0,1655	0,1793	0,1550	0,1600	0,1666
	V2	0,1727	0,1655	0,1550	0,1550	0,1782	0,1661	0,1788	0,1600	0,1655	0,1616
	V3	0,1666	0,1782	0,1732	0,1550	0,1727	0,1655	0,1610	0,1727	0,1772	0,1600
	V4	0,1600	0,1671	0,1687	0,1838	0,1788	0,1655	0,1737	0,1798	0,1716	0,1716
Tic-Tac-Toe	S1	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	S2	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	S3	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	S4	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V1	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V2	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V3	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V4	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
Wine	S1	0,0736	0,0736	0,0763	0,0739	0,0763	0,0736	0,0736	0,0763	0,0787	0,0714
	S2	0,0736	0,0815	0,0787	0,0714	0,0714	0,0763	0,0739	0,0739	0,0763	0,0736
	S3	0,0787	0,0736	0,0763	0,0714	0,0763	0,0787	0,0739	0,0787	0,0787	0,0736
	S4	0,0787	0,0714	0,0736	0,0736	0,0787	0,0787	0,0763	0,0714	0,0736	0,0763
	V1	0,0714	0,0739	0,0736	0,0763	0,0736	0,0739	0,0714	0,0787	0,0714	0,0714
	V2	0,0714	0,0714	0,0736	0,0714	0,0714	0,0739	0,0736	0,0714	0,0739	0,0736
	V3	0,0763	0,0763	0,0714	0,0714	0,0714	0,0739	0,0736	0,0739	0,0736	0,0739
	V4	0,0714	0,0714	0,0736	0,0714	0,0714	0,0736	0,0714	0,0739	0,0714	0,0736
Zoo	S1	0,0794	0,0794	0,0794	0,0856	0,0830	0,0892	0,0883	0,0767	0,0767	0,0758
	S2	0,0767	0,0794	0,0705	0,0794	0,0830	0,0794	0,0767	0,0705	0,0767	0,0946
	S3	0,0642	0,0847	0,0856	0,0919	0,0830	0,0892	0,0919	0,0856	0,0767	0,0910
	S4	0,0767	0,1061	0,0758	0,0794	0,0847	0,0910	0,0963	0,0847	0,0830	0,0642
	V1	0,0705	0,0767	0,0767	0,0705	0,0758	0,0767	0,0642	0,0767	0,0856	0,0794
	V2	0,0642	0,0794	0,0883	0,0642	0,0705	0,0767	0,0847	0,0767	0,0642	0,0821
	V3	0,0642	0,0642	0,0794	0,0830	0,0794	0,0705	0,0794	0,0642	0,0642	0,0794
	V4	0,0705	0,0767	0,0767	0,0705	0,0642	0,0830	0,0705	0,0705	0,0705	0,0705

Çizelge 4. 8. BABC için uygunluk değerleri

Veri Seti	TF	Tekrar									
		1	2	3	4	5	6	7	8	9	10
BreastEW	S1	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3387	0,3353
	S2	0,3353	0,3353	0,3353	0,3342	0,3353	0,3353	0,3412	0,3353	0,3353	0,3353
	S3	0,3353	0,3353	0,3353	0,3353	0,3486	0,3353	0,3353	0,3353	0,3353	0,3353
	S4	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353
	V1	0,3687	0,3653	0,3787	0,3787	0,3653	0,3687	0,3687	0,3653	0,3687	0,3653
	V2	0,3353	0,3753	0,3353	0,3353	0,3353	0,3687	0,3353	0,3353	0,3553	0,3353
	V3	0,3420	0,3353	0,3353	0,3353	0,3453	0,3487	0,3353	0,3387	0,3420	0,3353
	V4	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353
HeartEW	S1	0,1697	0,1718	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697
	S2	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1718	0,1697
	S3	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697
	S4	0,1697	0,1731	0,1731	0,1697	0,1731	0,1718	0,1718	0,1731	0,1697	0,1697
	V1	0,2572	0,2459	0,2259	0,2051	0,2459	0,2295	0,1941	0,2592	0,2162	0,2164
	V2	0,2472	0,1774	0,2215	0,2285	0,1718	0,2095	0,2251	0,2449	0,2262	0,2095
	V3	0,1985	0,2205	0,2459	0,2503	0,2395	0,2218	0,2387	0,1918	0,1718	0,1985
	V4	0,2505	0,2449	0,1972	0,1872	0,2372	0,2451	0,2095	0,1905	0,2405	0,2428
IonosphereEW	S1	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	S2	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	S3	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	S4	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231
	V1	0,3584	0,3554	0,3613	0,3613	0,3613	0,3613	0,3584	0,3613	0,3584	0,3643
	V2	0,3613	0,3701	0,3554	0,3672	0,3643	0,3613	0,3554	0,3613	0,3584	0,3613
	V3	0,3554	0,3554	0,3613	0,3584	0,3554	0,3584	0,3613	0,3584	0,3643	0,3613
	V4	0,3643	0,3495	0,3613	0,3466	0,3554	0,3437	0,3525	0,3584	0,3672	0,3701
Lymphography	S1	0,1621	0,1550	0,1616	0,1550	0,1616	0,1687	0,1550	0,1550	0,1550	0,1550
	S2	0,1550	0,1616	0,1687	0,1687	0,1687	0,1550	0,1687	0,1550	0,1550	0,1550
	S3	0,1687	0,1616	0,1687	0,1732	0,1550	0,1550	0,1550	0,1610	0,1550	0,1550
	S4	0,1550	0,1616	0,1550	0,1550	0,1610	0,1550	0,1616	0,1550	0,1550	0,1621
	V1	0,2324	0,2131	0,2269	0,2197	0,1944	0,2303	0,2203	0,2147	0,1767	0,2258
	V2	0,1888	0,2147	0,2142	0,2152	0,2086	0,2147	0,2298	0,2314	0,2192	0,2126
	V3	0,2102	0,1814	0,2197	0,2158	0,2020	0,2152	0,2253	0,2324	0,2086	0,2076
	V4	0,2020	0,2065	0,2187	0,2142	0,2359	0,2102	0,2197	0,2269	0,2158	0,2137
Tic-Tac-Toe	S1	0,3119	0,3119	0,3119	0,3230	0,3119	0,3119	0,3230	0,3119	0,3119	0,3119
	S2	0,3119	0,3119	0,3230	0,3119	0,3119	0,3119	0,3119	0,3119	0,3230	0,3119
	S3	0,3119	0,3119	0,3119	0,3119	0,3119	0,3230	0,3119	0,3119	0,3230	0,3119
	S4	0,3230	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V1	0,3230	0,3341	0,3230	0,3230	0,3341	0,3230	0,3230	0,3341	0,3230	0,3230
	V2	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V3	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	V4	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
Wine	S1	0,0763	0,0736	0,0736	0,0739	0,0736	0,0736	0,0787	0,0736	0,0739	0,0736
	S2	0,0736	0,0763	0,0763	0,0714	0,0736	0,0736	0,0736	0,0736	0,0763	0,0736
	S3	0,0739	0,0763	0,0736	0,0736	0,0787	0,0736	0,0763	0,0739	0,0739	0,0736
	S4	0,0763	0,0736	0,0736	0,0763	0,0736	0,0736	0,0736	0,0763	0,0736	0,0736
	V1	0,0941	0,0994	0,1044	0,0965	0,0991	0,1095	0,1018	0,1095	0,1046	0,1044
	V2	0,0763	0,0994	0,0739	0,1070	0,0941	0,0890	0,1018	0,0941	0,0890	0,0917
	V3	0,1123	0,1018	0,1018	0,1068	0,0941	0,1046	0,1123	0,1070	0,1016	0,1070
	V4	0,0991	0,0941	0,1018	0,1143	0,0943	0,1068	0,0917	0,1018	0,0967	0,1248
Zoo	S1	0,0642	0,0642	0,0847	0,0642	0,0847	0,0847	0,0642	0,0642	0,0642	0,0642
	S2	0,0642	0,0847	0,0642	0,0642	0,0642	0,0642	0,0642	0,0642	0,0642	0,0642
	S3	0,0883	0,0642	0,0642	0,0794	0,0847	0,0642	0,0642	0,0642	0,0847	0,0910
	S4	0,0847	0,0883	0,0642	0,0642	0,0642	0,0642	0,0847	0,0910	0,0642	0,0794
	V1	0,1097	0,1061	0,0919	0,1160	0,1008	0,1150	0,0972	0,1160	0,1133	0,1249
	V2	0,1025	0,1186	0,1196	0,1311	0,1061	0,1239	0,1008	0,1160	0,1249	0,0972
	V3	0,1222	0,1186	0,1097	0,1150	0,1204	0,0972	0,1302	0,0972	0,0946	0,1222
	V4	0,1177	0,1150	0,0910	0,1035	0,1025	0,1177	0,1186	0,1239	0,1311	0,1186

Çizelge 4. 9. BOPA için uygunluk değerleri

Uygunluk değeri, çözümün ne kadar iyi olduğunu gösteren bir ölçüdür. Bu çalışmada ele alınan problem bir minimizasyon problemi olduğundan, en küçük uygunluk değeri optimum çözüm olarak kabul edilmektedir. Geliştirilen BOPA varyantlarının performansını diğer algoritmalarla karşılaştırmak amacıyla, her bir veri setine ait ortalama ve minimum sonuçlar gruplandırılarak Çizelge 4.10 ve 4.11'de sunulmuştur. Çizelgelerde her bir transfer fonksiyonu için algoritmalarından elde edilen en iyi çözümler koyu renkle vurgulanmıştır. Çözümler sütun bazında incelendiğinde, dört algoritma arasından en iyi çözümü hangi algoritmanın elde ettiği net bir şekilde gözlemlenebilmektedir.

Veri Seti	Algoritma	S1	S2	S3	S4	V1	V2	V3	V4
BreastEW	BGWO	0,3353	0,3353	0,3353	0,3353	0,3407	0,3393	0,3430	0,3403
	BPSO	0,3460	0,3397	0,3363	0,3363	0,3593	0,3590	0,3590	0,3567
	BABC	0,3487	0,3380	0,3353	0,3353	0,3497	0,3503	0,3503	0,3817
	BOPA	0,3357	0,3358	0,3367	0,3353	0,3693	0,3447	0,3393	0,3353
HeartEW	BGWO	0,1761	0,1705	0,1722	0,1733	0,1699	0,1708	0,1724	0,1724
	BPSO	0,2202	0,2076	0,2020	0,2083	0,2160	0,2116	0,2270	0,2114
	BABC	0,1778	0,1763	0,1787	0,1743	0,1709	0,1710	0,1707	0,1715
	BOPA	0,1699	0,1699	0,1697	0,1715	0,2295	0,2162	0,2177	0,2245
IonosphereEW	BGWO	0,3231	0,3231	0,3231	0,3231	0,3281	0,3281	0,3293	0,3310
	BPSO	0,3360	0,3401	0,3290	0,3240	0,3498	0,3445	0,3425	0,3375
	BABC	0,3395	0,3257	0,3231	0,3231	0,3419	0,3404	0,3410	0,3390
	BOPA	0,3231	0,3231	0,3231	0,3231	0,3601	0,3616	0,3590	0,3569
Lymphography	BGWO	0,1639	0,1627	0,1619	0,1653	0,1666	0,1661	0,1643	0,1652
	BPSO	0,1993	0,1941	0,1952	0,2005	0,2004	0,1972	0,2013	0,2014
	BABC	0,1768	0,1752	0,1743	0,1746	0,1666	0,1658	0,1682	0,1721
	BOPA	0,1584	0,1611	0,1608	0,1576	0,2154	0,2149	0,2118	0,2164
Tic-Tac-Toe	BGWO	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	BPSO	0,3230	0,3141	0,3141	0,3119	0,3208	0,3263	0,3163	0,3208
	BABC	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	BOPA	0,3141	0,3141	0,3141	0,3130	0,3263	0,3119	0,3119	0,3119
Wine	BGWO	0,0750	0,0750	0,0745	0,0757	0,0736	0,0723	0,0733	0,0726
	BPSO	0,0910	0,0877	0,0905	0,0973	0,0870	0,0892	0,0872	0,0987
	BABC	0,0747	0,0751	0,0760	0,0752	0,0736	0,0726	0,0736	0,0723
	BOPA	0,0745	0,0742	0,0747	0,0744	0,1023	0,0916	0,1049	0,1025
Zoo	BGWO	0,0793	0,0777	0,0813	0,0804	0,0742	0,0749	0,0774	0,0752
	BPSO	0,1073	0,1093	0,1013	0,1092	0,1046	0,1093	0,1035	0,1034
	BABC	0,0814	0,0787	0,0844	0,0842	0,0753	0,0751	0,0728	0,0724
	BOPA	0,0704	0,0663	0,0749	0,0749	0,1091	0,1141	0,1127	0,1140

Çizelge 4. 10. Algoritmalarla ait ortalama uygunluk değerleri

Veri Seti	Algoritma	S1	S2	S3	S4	V1	V2	V3	V4
BreastEW	BGWO	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353
	BPSO	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353	0,3353
	BABC	0,3453	0,3353	0,3353	0,3353	0,3420	0,3453	0,3420	0,3453
	BOPA	0,3353	0,3342	0,3353	0,3353	0,3653	0,3353	0,3353	0,3353
HeartEW	BGWO	0,1697	0,1705	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697
	BPSO	0,1697	0,1731	0,1697	0,1697	0,1941	0,1774	0,1972	0,1918
	BABC	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697	0,1697
	BOPA	0,1697	0,1697	0,1697	0,1697	0,1941	0,1718	0,1718	0,1872
IonosphereEW	BGWO	0,3231	0,3231	0,3231	0,3231	0,3231	0,3231	0,3260	0,3231
	BPSO	0,3231	0,3231	0,3231	0,3231	0,3319	0,3231	0,3231	0,3231
	BABC	0,3319	0,3231	0,3231	0,3231	0,3378	0,3348	0,3378	0,3319
	BOPA	0,3231	0,3231	0,3231	0,3231	0,3554	0,3554	0,3554	0,3437
Lymphography	BGWO	0,1550	0,1550	0,1550	0,1550	0,1600	0,1550	0,1600	0,1600
	BPSO	0,1854	0,1777	0,1661	0,1814	0,1788	0,1605	0,1772	0,1788
	BABC	0,1655	0,1616	0,1621	0,1600	0,1550	0,1550	0,1550	0,1600
	BOPA	0,1550	0,1550	0,1550	0,1550	0,1767	0,1888	0,1814	0,2020
Tic-Tac-Toe	BGWO	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	BPSO	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	BABC	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	BOPA	0,3119	0,3119	0,3119	0,3119	0,3230	0,3119	0,3119	0,3119
Wine	BGWO	0,0714	0,0736	0,0714	0,0736	0,0714	0,0714	0,0714	0,0714
	BPSO	0,0739	0,0739	0,0736	0,0736	0,0763	0,0787	0,0763	0,0813
	BABC	0,0714	0,0714	0,0714	0,0714	0,0714	0,0714	0,0714	0,0714
	BOPA	0,0736	0,0714	0,0736	0,0736	0,0941	0,0739	0,0941	0,0917
Zoo	BGWO	0,0642	0,0642	0,0642	0,0642	0,0642	0,0642	0,0642	0,0642
	BPSO	0,0767	0,0847	0,0758	0,0847	0,0946	0,0856	0,0794	0,0767
	BABC	0,0758	0,0705	0,0642	0,0642	0,0642	0,0642	0,0642	0,0642
	BOPA	0,0642	0,0642	0,0642	0,0642	0,0919	0,0972	0,0946	0,0910

Çizelge 4. 11. Algoritmalara ait minimum uygunluk değerleri

Çizelge 4.10'daki ortalama uygunluk değerleri açısından bakıldığında S-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantlarının diğer algoritmaların aynı transfer fonksiyonları kullanılarak geliştirilen varyantlarına kıyasla daha iyi bir performans sergilediği görülmektedir. Örneğin BOPA'nın S1 transfer fonksiyonu kullanılarak geliştirilen varyantı yedi veri kümesinin dördünde diğer algoritmaların aynı transfer fonksiyonu kullanılarak geliştirilen varyantlarından daha iyi bir sonuç elde etmiştir. Benzer bir durum BOPA'nın S2, S3 ve S4 transfer fonksiyonları kullanılarak geliştirilen varyantlarında da söz konusudur. V-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantlarının BPSO'nun aynı transfer fonksiyonları kullanılarak geliştirilen varyantlarına kıyasla daha iyi bir performans sergilediği yine aynı çizelgeden görülebilmektedir.

Çizelge 4.11'deki minimum uygunluk değerleri açısından bakıldığında S-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantlarının diğer algoritmaların aynı transfer fonksiyonları kullanılarak geliştirilen varyantlarına kıyasla eşit veya daha iyi bir performans sergilediği görülmektedir. Örneğin BOPA'nın S1 transfer fonksiyonu kullanılarak geliştirilen varyantı yedi veri kümesinin altısında diğer algoritmaların aynı transfer fonksiyonu kullanılarak geliştirilen varyantlarına eşit veya daha iyi bir sonuç elde etmiştir. Benzer bir durum BOPA'nın S2, S3 ve S4 transfer fonksiyonları kullanılarak geliştirilen varyantlarında da söz konusudur. V-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantlarının diğer algoritmaların aynı transfer fonksiyonları kullanılarak geliştirilen varyantlarına kıyasla daha kötü bir performans sergilediği de yine aynı çizelgeden görülebilmektedir.

Çizelge 4.10 ve 4.11 genel olarak incelendiğinde, S-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantlarının V-şekilli transfer fonksiyonları kullanılarak geliştirilen varyantlarına kıyasla daha başarılı sonuçlar ürettiği görülmektedir. BPSO'nun varyantları için de benzer bir durum söz konusu iken BGWO ve BABC'nin varyantlarında ise tam tersi bir durum söz konusudur.

Algoritmalara ait varyantlar her bir veri kümesi üzerinde 10'ar kez çalıştırılmış, elde edilen uygunluk değerlerinin ortalaması hesaplanarak sonuçlar Çizelge 4.10'da paylaşılmıştır. Bu çizelgedeki sonuçlar Çizelge 4.12'de farklı bir açıdan listelenmiştir. Algoritmaların farklı transfer fonksiyonları kullanılarak elde edilen varyantları arasında performans karşılaştırması yapabilmek amacıyla, bu çizelgenin her satırındaki optimum değerler koyu renkle işaretlenmiştir. Çizelgeden de görülebildiği gibi BOPA'nın varyantları arasında en iyi sonuçları S2 ve S4 transfer fonksiyonları kullanılarak geliştirilen varyantlar elde etmiştir. BGWO'nun varyantları arasında en iyi sonuçları S3 transfer fonksiyonu kullanılarak geliştirilen varyant elde etmiştir. BPSO'nun varyantları arasında en iyi sonuçları iki varyant (S3 ve S4), BABC'nin varyantları arasında ise üç varyant (S3, S4 ve V4) vermiştir. Bir transfer fonksiyonu belirli bir algoritma için en iyi sonuçları üretirken, diğer algoritmalar için yeterince iyi sonuçlar üretmemiştir. Bu durum transfer fonksiyonlarının algoritmaların performansı üzerindeki etkilerini göstermiştir.

Algoritma	Veri Seti	S1	S2	S3	S4	V1	V2	V3	V4
BGWO	BreastEW	0,3353	0,3353	0,3353	0,3353	0,3407	0,3393	0,3430	0,3403
	HeartEW	0,1761	0,1705	0,1722	0,1733	0,1699	0,1708	0,1724	0,1724
	IonosphereEW	0,3231	0,3231	0,3231	0,3231	0,3281	0,3281	0,3293	0,3310
	Lymphography	0,1639	0,1627	0,1619	0,1653	0,1666	0,1661	0,1643	0,1652
	Tic-Tac-Toe	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	Wine	0,0750	0,0750	0,0745	0,0757	0,0736	0,0723	0,0733	0,0726
	Zoo	0,0793	0,0777	0,0813	0,0804	0,0742	0,0749	0,0774	0,0752
BPSO	BreastEW	0,3460	0,3397	0,3363	0,3363	0,3593	0,3590	0,3590	0,3567
	HeartEW	0,2202	0,2076	0,2020	0,2083	0,2160	0,2116	0,2270	0,2114
	IonosphereEW	0,3360	0,3401	0,3290	0,3240	0,3498	0,3445	0,3425	0,3375
	Lymphography	0,1993	0,1941	0,1952	0,2005	0,2004	0,1972	0,2013	0,2014
	Tic-Tac-Toe	0,3230	0,3141	0,3141	0,3119	0,3208	0,3263	0,3163	0,3208
	Wine	0,0910	0,0877	0,0905	0,0973	0,0870	0,0892	0,0872	0,0987
	Zoo	0,1073	0,1093	0,1013	0,1092	0,1046	0,1093	0,1035	0,1034
BABC	BreastEW	0,3487	0,3380	0,3353	0,3353	0,3497	0,3503	0,3503	0,3817
	HeartEW	0,1778	0,1763	0,1787	0,1743	0,1709	0,1710	0,1707	0,1715
	IonosphereEW	0,3395	0,3257	0,3231	0,3231	0,3419	0,3404	0,3410	0,3390
	Lymphography	0,1768	0,1752	0,1743	0,1746	0,1666	0,1658	0,1682	0,1721
	Tic-Tac-Toe	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119	0,3119
	Wine	0,0747	0,0751	0,0760	0,0752	0,0736	0,0726	0,0736	0,0723
	Zoo	0,0814	0,0787	0,0844	0,0842	0,0753	0,0751	0,0728	0,0724
BOPA	BreastEW	0,3357	0,3358	0,3367	0,3353	0,3693	0,3447	0,3393	0,3353
	HeartEW	0,1699	0,1699	0,1697	0,1715	0,2295	0,2162	0,2177	0,2245
	IonosphereEW	0,3231	0,3231	0,3231	0,3231	0,3601	0,3616	0,3590	0,3569
	Lymphography	0,1584	0,1611	0,1608	0,1576	0,2154	0,2149	0,2118	0,2164
	Tic-Tac-Toe	0,3141	0,3141	0,3141	0,3130	0,3263	0,3119	0,3119	0,3119
	Wine	0,0745	0,0742	0,0747	0,0744	0,1023	0,0916	0,1049	0,1025
	Zoo	0,0704	0,0663	0,0749	0,0749	0,1091	0,1141	0,1127	0,1140

Çizelge 4. 12. Algoritmalarla ait ortalama uygunluk değerleri (varyantlar açısından kıyaslama)

S-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantları, yedi veri setinden beşinde, aynı transfer fonksiyonları kullanılarak geliştirilen diğer algoritmaların varyantlarına eşit veya daha iyi sonuçlar elde etmiştir. Bu veri setleri HeartEW, IonosphereEW, Lymphography, Wine ve Zoo'dur. Bu veri setleri, BreastEW ve Tic-Tac-Toe veri setlerine göre daha az ve birbirlerine yakın örnek sayılarına sahiptir.

5. SONUÇLAR VE ÖNERİLER

5.1 Sonuçlar

Bu çalışmada, sürekli optimizasyon algoritması olan OPA'nın ikili versiyonu geliştirilmiş ve BOPA olarak adlandırılmıştır. BOPA'nın geliştirilmesinde dört tanesi S-şekilli, dört tanesi de V-şekilli olmak üzere toplam sekiz transfer fonksiyonu kullanılmıştır. Önerilen algoritmanın performansını değerlendirmek için literatürde yaygın olarak kullanılan UCI makine öğrenimi veri deposundan yedi veri kümesi seçilmiştir. BOPA'nın sınıflandırma doğruluğu LOOCV yöntemi kullanılarak değerlendirilmiştir. Elde edilen sonuçlar, BGWO, BPSO ve BABC algoritmalarından elde edilen sonuçlarla karşılaştırılmış ve çeşitli performans metrikleri açısından analiz edilmiştir.

S-şekilli ve V-şekilli transfer fonksiyonları açısından bir değerlendirme yapıldığında, S-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantlarının V-şekilli transfer fonksiyonları kullanılarak geliştirilen varyantlarına kıyasla daha başarılı sonuçlar ürettiği görülmüştür. BPSO'nun varyantları için de benzer bir durum söz konusu iken BGWO ve BABC'nin varyantlarında ise tam tersi bir durum söz konusudur.

S-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantları, yedi veri setinden beşinde, aynı transfer fonksiyonları kullanılarak geliştirilen diğer algoritmaların varyantlarına eşit veya daha iyi sonuçlar elde etmiştir. V-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantları ise, aynı transfer fonksiyonları kullanılarak geliştirilen BPSO'nun varyantlarına eşit veya daha iyi sonuçlar elde ederken diğer iki algoritmanın varyantlarından daha kötü sonuçlar elde etmiştir.

5.2 Öneriler

Gelecek çalışmalarda, literatürde bulunan farklı transfer fonksiyonları kullanılarak BOPA'nın daha farklı varyantları geliştirilebilir. BOPA üzerinde birtakım yapısal değişiklikler yapılarak algoritmanın performansı artırılabilir. V-şekilli transfer fonksiyonları kullanılarak geliştirilen BOPA varyantlarının performanslarının artırılması adına bu tür transfer fonksiyonlarında iyi sonuç üreten BGWO ve BABC algoritmaları ile hibritleme çalışmaları yapılabilir.

BOPA, kapasitesiz tesis yerleştirme, 0-1 sırt çantası problemi gibi yaygın olarak karşılaşılan ikili optimizasyon problemlerinin çözümünde kullanılabilir. BOPA'da

kullanılan kNN sınıflandırıcısının yerine yapay sinir ağı, destek vektör makineleri gibi alternatif sınıflandırıcılar kullanılabilir.



6. KAYNAKLAR

- Abualigah, L., Diabat, A., Mirjalili, S., Abd Elaziz, M. ve Gandomi, A. H. (2021). The Arithmetic Optimization Algorithm. *Computer Methods in Applied Mechanics and Engineering*, 376.
- Akay, B. (2009). Nümerik optimizasyon problemlerinde Yapay Arı Kolonisi (Artificial Bee Colony) algoritmasının performans analizi.
- Al-Tashi, Q., Abdulkadir, S. J., Rais, H. M., Mirjalili, S., Alhussian, H., Ragab, M. G. ve Alqushaibi, A. (2020). Binary Multi-Objective Grey Wolf Optimizer for Feature Selection in Classification. *IEEE Access*, 8, 106247-106263.
- Al-Wajih, R., Abdulkadir, S. J., Aziz, N., Al-Tashi, Q. ve Talpur, N. (2021). Hybrid binary grey Wolf with Harris hawks optimizer for feature selection. *IEEE Access*, 9, 31662-31677.
- Ansari, M. A., Shariq, M. ve Mahdi, F. (2023). Geopolymer concrete for clean and sustainable construction – A state-of-the-art review on the mix design approaches. *Structures*.
- Arora, S. ve Anand, P. (2019). Binary butterfly optimization approaches for feature selection. *Expert Systems with Applications*, 116, 147-160.
- Aslan, M. (2020). Ayırık optimizasyon problemlerinin çözümü için jaya algoritması tabanlı yeni yaklaşımlar.
- Aslan, S., Aksoy, A. ve Gunay, M. (2018). Performance of Parallel Artificial Bee Colony Algorithm on Solving Probabilistic Sensor Deployment Problem. *2018 International Conference on Artificial Intelligence and Data Processing (IDAP)* içinde .
- Azaz, D. (2016). Fuzzy knapsack problem for operating room scheduling.
- Berberler, M. E. (2009). Sırt çantası problem türleri ve uygulamaları.
- Budak, H. (2018). Özellik seçim yöntemleri ve yeni bir yaklaşım. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 22, 21.
- Cai, L., Hou, Y., Zhao, Y. ve Wang, J. (2020). Application Research And Improvement Of Particle Swarm Optimization Algorithm. *2020 IEEE International Conference on Power, Intelligent Computing and Systems (ICPICS)* içinde (ss. 238-241).
- Chen, W. H., Carrera Uribe, M., Kwon, E. E., Lin, K. Y. A., Park, Y. K., Ding, L. ve Saw, L. H. (2022). A comprehensive review of thermoelectric generation optimization by statistical approach: Taguchi method, analysis of variance (ANOVA), and response surface methodology (RSM). *Renewable and Sustainable Energy Reviews*.

- Chuanjun, W., Ling, W. ve Xuejing, R. (2023). General particle swarm optimization algorithm. *2023 IEEE 2nd International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA)* içinde (ss. 1204-1208).
- Cui, X., Li, Y., Fan, J., Wang, T. ve Zheng, Y. (2020). A Hybrid Improved Dragonfly Algorithm for Feature Selection. *IEEE Access*, 8, 155619-155629.
- Çifçi, F., Kaleli, C. ve Günal, S. (2018). Öznitelik seçme ve makine öğrenmesi yöntemleriyle eğitim performansının tahmin edilmesi. *Anadolu Journal Of Educational Sciences International*, 419-440.
- Dada, E. G., Joseph, S. B., Oyewola, D. O., Fadele, A. A., Chiroma, H. ve Abdulhamid, S. M. (2022). Application of Grey Wolf Optimization Algorithm: Recent Trends, Issues, and Possible Horizons. *Gazi University Journal of Science*, 35(2), 485-504.
- Deep, K. (2022). A random walk Grey wolf optimizer based on dispersion factor for feature selection on chronic disease prediction. *Expert Systems with Applications*, 206.
- Devanathan, K., Ganapathy, N. ve Swaminathan, R. (2019). Binary Grey Wolf Optimizer based Feature Selection for Nucleolar and Centromere Staining Pattern Classification in Indirect Immunofluorescence Images. *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*.
- Djelloul, H., Sabba, S. ve Chikhi, S. (2014). Binary bat algorithm for graph coloring problem. *2014 Second World Conference on Complex Systems (WCCS)*.
- Doğan, C. (2019). Balina optimizasyon algoritması ve gri kurt optimizasyonu algoritmaları kullanılarak yeni hibrit optimizasyon algoritmalarının geliştirilmesi.
- Dönmez, H. (2020). Düello optimizasyon algoritmasının ikili optimizasyon problemlerine uygulaması.
- Ekmekci, D. (2020). 0-1 çok boyutlu sırt çantası probleminin fermonal Yapay Arı koloni (fYAK) algoritması ile çözümü. *Academic Platform Journal of Engineering and Science*, 355-364.
- Emary, E., Zawbaa, H. M. ve Hassanien, A. E. (2016a). Binary ant lion approaches for feature selection. *Neurocomputing*, 213, 54-65.
- Emary, E., Zawbaa, H. M. ve Hassanien, A. E. (2016b). Binary grey wolf optimization approaches for feature selection. *Neurocomputing*, 172, 371-381.
- Erdoğan, F. (2023). İkili Gri Kurt Optimizasyon Algoritmasının İkili Optimizasyon Problemlerine Uygulanması.

- Faris, H., Mafarja, M. M., Heidari, A. A., Aljarah, I., Al-Zoubi, A. M., Mirjalili, S. ve Fujita, H. (2018). An efficient binary Salp Swarm Algorithm with crossover scheme for feature selection problems. *Knowledge-Based Systems*, 154, 43-67.
- Ghosh, D. (2003). Neighborhood search heuristics for the uncapacitated facility location problem. *European Journal of Operational Research*, 150(1), 150-162.
- Ghosh, N., Pal, P. K. ve Nandi, G. (2017, 1 Ağustos). GMAW dissimilar welding of AISI 409 ferritic stainless steel to AISI 316L austenitic stainless steel by using AISI 308 filler wire. *Engineering Science and Technology, an International Journal*. Elsevier B.V.
- Gülgezen, G. (2009). Kararlı ve başarıımı yüksek öznelik seçimi.
- Hegazy, A. E., Makhlouf, M. A. ve El-Tawel, G. S. (2020). Improved salp swarm algorithm for feature selection. *Journal of King Saud University - Computer and Information Sciences*, 32(3), 335-344.
- Houssein, E. H., Saad, M. R., Ali, A. A. ve Shaban, H. (2023). Multiple Strategies Boosted Orca Predation Algorithm for Engineering Optimization Problems. *International Journal of Computational Intelligence Systems*, 16(1).
- Hu, P., Pan, J.-S. ve Chu, S.-C. (2020). Improved Binary Grey Wolf Optimizer and Its application for feature selection, 195, 105746.
- İlhan, İ. (2021). An improved simulated annealing algorithm with crossover operator for capacitated vehicle routing problem. *Swarm and Evolutionary Computation*, 64.
- Jiang, Y., Wu, Q., Zhu, S. ve Zhang, L. (2022). Orca predation algorithm: A novel bio-inspired algorithm for global optimization problems. *Expert Systems with Applications*, 188.
- Karaboga, D. (2005). An Idea Based On Honey Bee Swarm For Numerical Optimization.
- Karaboga, D. ve Ozturk, C. (2011). A novel clustering approach: Artificial Bee Colony (ABC) algorithm. *Applied Soft Computing Journal*, 11(1), 652-657.
- Karakoyun, M. ve Özkış, A. (2021). Transfer Fonksiyonları Kullanarak İkili Güve-Alev Optimizasyonu Algoritmalarının Geliştirilmesi ve Performanslarının Karşılaştırılması. *Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, 3(2).
- Karizaki, A. A. ve Tavassoldi, M. (2019). A novel hybrid feature selection based on ReliefF and binary dragonfly for high dimensional datasets. *9th International Conference on Computer and Knowledge Engineering (ICCCKE2019)*.

- Kılınç, H., İlhan, İ. (2024). Discrete orca predation algorithm for the traveling salesman problem. *Neural Computing & Applications* <https://doi.org/10.1007/s00521-024-10475-w>
- Kohavi, R. ve John, G. H. (1997). Wrappers for feature subset selection.
- Korkmaz, S. (2019). İkili Optimizasyon Problemlerinin Çözümü İçin Yapay Alg Algoritması Tabanlı Yeni Yaklaşımlar.
- Li, N., Shi, C., Zhang, Z., Wang, H. ve Liu, Y. (2019). A review on mixture design methods for geopolymer concrete. *Composites Part B: Engineering*.
- Li, Q., Chen, H., Huang, H., Zhao, X., Cai, Z. N., Tong, C., ... Tian, X. (2017). An Enhanced Grey Wolf Optimization Based Feature Selection Wrapped Kernel Extreme Learning Machine for Medical Diagnosis. *Computational and Mathematical Methods in Medicine, 2017*.
- Li, W. (2023). Application of Artificial Bee Colony Algorithm in Intelligent Price Supervision System of Digital Economy. *2023 2nd International Conference on Data Analytics, Computing and Artificial Intelligence (ICDAI)* içinde (ss. 435-441).
- Mafarja, M., Aljarah, I., Faris, H., Hammouri, A. I., Al-Zoubi, A. M. ve Mirjalili, S. (2019). Binary grasshopper optimisation algorithm approaches for feature selection problems. *Expert Systems with Applications, 117*, 267-286.
- Mafarja, M., Eleyan, D., Abdullah, S. ve Mirjalili, S. (2017). S-shaped vs. V-shaped transfer functions for ant lion optimization algorithm in feature selection problem. *ACM International Conference Proceeding Series* içinde (C. Part F130522).
- Mafarja, M. M., Eleyan, D., Jaber, I., Hammouri, A. ve Mirjalili, S. (2017). Binary Dragonfly Algorithm for Feature Selection. *Proceedings - 2017 International Conference on New Trends in Computing Sciences, ICTCS 2017* içinde (C. 2018-January, ss. 12-17).
- Mafarja, M. ve Mirjalili, S. (2018). Whale optimization approaches for wrapper feature selection. *Applied Soft Computing, 62*, 441-453.
- Mazher, W., Tariq Al-Rayes, H., Ucan, O. N., Tariq Ibrahim, H., Jalil Mazher, W. ve Bayat, O. (2017). Feature Selection using Salp Swarm Algorithm for Real Biomedical Datasets. *IJCSNS International Journal of Computer Science and Network Security* (C. 17).
- Mirjalili, S. ve Lewis, A. (2016). The Whale Optimization Algorithm. *Advances in Engineering Software, 95*, 51-67.
- Mohamad, Z., Fardoun, F. ve Meftah, F. (2021). A review on energy piles design, evaluation, and optimization. *Journal of Cleaner Production*.

- Olivares, R., Ravelo, C., Soto, R. ve Crawford, B. (2024). Escaping Stagnation through Improved Orca Predator Algorithm with Deep Reinforcement Learning for Feature Selection. *Mathematics*, 12(8).
- Özger, Z. B. (2019). Büyük boyutlu verilerde öznelik seçimi için ikili yapay arı kolonisi yaklaşımı.
- Özkış, A. ve Karakoyun, M. (2023). A binary jaya algorithm with selection-based local search mechanism for large-scale optimization problems. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 38(4), 2435-2449.
- Pan, J. S., Hu, P., Snášel, V. ve Chu, S. C. (2023). A survey on binary metaheuristic algorithms and their engineering applications. *Artificial Intelligence Review*, 56(7), 6101-6167.
- Rodrigues, D., Pereira, L. A. M., Nakamura, R. Y. M., Costa, K. A. P., Yang, X. S., Souza, A. N. ve Papa, J. P. (2014). A wrapper approach for feature selection based on Bat Algorithm and Optimum-Path Forest. *Expert Systems with Applications*, 41(5), 2250-2258.
- Sathiyabhama, B., Kumar, S. U., Jayanthi, J., Sathiya, T., Ilavarasi, A. K., Yuvarajan, V. ve Gopikrishna, K. (2021). A novel feature selection framework based on grey wolf optimizer for mammogram image analysis. *Neural Computing and Applications*, 33(21), 14583-14602.
- Sawhney, R. ve Jain, R. (2018). Modified Binary Dragonfly Algorithm for Feature Selection in Human Papillomavirus-Mediated Disease Treatment. *International Conference on Communication, Computing and Internet of Things (IC3IoT)*.
- Sel, I., Karcı, A. ve Hanbay, D. (2019). Feature selection for text classification using mutual information. *2019 International Conference on Artificial Intelligence and Data Processing Symposium, IDAP 2019*.
- Song, X. fang, Zhang, Y., Gong, D. wei ve Sun, X. yan. (2021). Feature selection using bare-bones particle swarm optimization with mutual information. *Pattern Recognition*, 112.
- Tanyıldızı, E. ve Çelik, A. (2020). Güncel ikili optimizasyon algoritmalarının kısıtsız kıyaslama fonksiyonlarındaki performans karşılaştırmaları. *Fırat Üniversitesi Müh. Bil. Dergisi*, 32(2), 369-380.
- Tawhid, M. A. ve Ibrahim, A. M. (2020). Feature selection based on rough set approach, wrapper approach, and binary whale optimization algorithm. *International Journal of Machine Learning and Cybernetics*, 11(3), 573-602.
- Thom de Souza, R. C., de Macedo, C. A., dos Santos Coelho, L., Pierezan, J. ve Mariani, V. C. (2020). Binary coyote optimization algorithm for feature selection. *Pattern Recognition*, 107.

- Too, J., Abdullah, A. R., Saad, N. M., Ali, N. M. ve Tee, W. (2018). A new competitive binary grey wolf optimizer to solve the feature selection problem in EMG signals classification. *Computers*, 7(4).
- Too, J., Abdullah, A. R., Saad, N. M. ve Tee, W. (2019). EMG feature selection and classification using a Pbest-guide binary particle swarm optimization. *Computation*, 7(1).
- Wang, J., Lin, D., Zhang, Y. ve Huang, S. (2022). An adaptively balanced grey wolf optimization algorithm for feature selection on high-dimensional classification. *Engineering Applications of Artificial Intelligence*, 114.
- Wong, T. T. ve Yeh, P. Y. (2020). Reliable Accuracy Estimates from k-Fold Cross Validation. *IEEE Transactions on Knowledge and Data Engineering*, 32(8), 1586-1594.
- Yang, B., Lu, Y., Zhu, K., Yang, G., Liu, J. ve Yin, H. (2017). Feature selection based on modified bat algorithm. *IEICE Transactions on Information and Systems* içinde (C. E100D, ss. 1860-1869).
- Yang, X.-S. (2010). Engineering optimization: An introduction with metaheuristic applications.
- Yavuz, İ. B. (2021). Küme birleşimli sırt çantası probleminin adaptif yapay arı kolonisi yöntemi ile çözümü.
- Yu, X. ve Hu, Z. (2024). A multi-strategy driven reinforced hierarchical operator in the grey wolf optimizer for feature selection. *Information Sciences*, 677.
- Zawbaa, H. M., Emary, E. ve Parv, B. (2015). Feature Selection Based on Antlion Optimization Algorithm. *2015 Third World Conference on Complex Systems (WCCS)*.