



**T. C.
SİVAS CUMHURİYET ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**GÜNCEL METASEZGİSEL ALGORİTMALARIN
PERFORMANS ANALİZİ**

YÜKSEK LİSANS TEZİ

**Metin KALYON
(20219257012)**

**Bilgisayar Mühendisliği Ana Bilim Dalı
Tez Danışmanı: Doç. Dr. Sibel ARSLAN**

**SİVAS
AĞUSTOS 2024**

Metin KALYON 'un hazırladığı ve “**GÜNCEL METASEZGİSEL ALGORİTMALARIN PERFORMANS ANALİZİ**” adlı bu çalışma aşağıdaki jüri tarafından **BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**’nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Tez Danışmanı	Doç. Dr. Sibel ARSLAN Sivas Cumhuriyet Üniversitesi	
Jüri Üyesi	Doç. Dr. Hidayet TAKÇI Sivas Cumhuriyet Üniversitesi	
Jüri Üyesi	Doç. Dr. Turgut ÖZSEVEN Tokat Gaziosmanpaşa Üniversitesi	

Bu tez, Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü tarafından **YÜKSEK LİSANS TEZİ** olarak onaylanmıştır.

Prof. Dr. Nevcihan GÜRSOY
FEN BİLİMLERİ ENSTİTÜSÜ MÜDÜRÜ

Bu tez, Sivas Cumhuriyet Üniversitesi Senatosu'nun 20.08.2014 tarihli ve 7 sayılı kararı ile kabul edilen Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kılavuzu (Yönerge)' nda belirtilen kurallara uygun olarak hazırlanmıştır.





Bütün hakları saklıdır.

Kaynak göstermek koşuluyla alıntı ve gönderme yapılabilir.

© Metin KALYON, 2024

ETİK

Sivas Cumhuriyet Üniversitesi Fen Bilimleri Enstitüsü, Tez Yazım Kılavuzu (Yönerge)' nda belirtilen kurallara uygun olarak hazırladığım bu tez çalışmasında;

- ✓ Bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- ✓ Görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- ✓ Başkalarının eserlerinden yararlanılması durumunda ilgili eserlere, bilimsel normlara uygun olarak atıfta bulunduğumu ve atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- ✓ Bütün bilgilerin doğru ve tam olduğunu, kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ✓ Tezin herhangi bir bölümünü, Sivas Cumhuriyet Üniversitesi veya bir başka üniversitede, bir başka tez çalışması olarak sunmadığımı; beyan ederim.

12.08.2024

Metin KALYON

KATKI BELİRTME VE TEŞEKKÜR

Çalışmalarım boyunca beni yönlendiren, hiçbir konuda yardımlarını esirgemeyen, bilgi ve deneyimlerinden sürekli yararlandığım kıymetli danışman hocam Doç. Dr. Sibel ARSLAN' a saygılarımı sunar, teşekkürü bir borç bilirim.

Çalışmalarımda hiç tereddüt etmeden her türlü desteği sağlayan sevgili eşim Ümmühan BULUT KALYON' a çok teşekkür ederim.

Son olarak hayatım boyunca her zaman yanımda olan, bugünlere gelmemi sağlayan babam Halil KALYON başta olmak üzere tüm aileme en içten şükranlarımı sunarım.

ÖZET

GÜNCEL METASEZGİSEL ALGORİTMALARIN PERFORMANS ANALİZİ

Metin KALYON

Yüksek Lisans Tezi

Bilgisayar Mühendisliği Ana Bilim Dalı

Danışman: Doç. Dr. Sibel ARSLAN

2024, 113+xvi sayfa

Günümüzde, metasezgiseller optimizasyon problemlerinin çözümünde çok önemli bir rol oynamaktadır. Bu tez çalışmasında, son 5 yılda önerilen popülasyon tabanlı 10 metasezgisel (Harris Şahinleri Optimizasyonu-HHO, İslî Sumru Optimizasyon Algoritması-STOA, Karadul Optimizasyonu-BWO, Aritmetik Optimizasyon Algoritması-AOA, Afrika Akbabaları Optimizasyon Algoritması-AVOA, Kaya Kartalı Optimizasyon Algoritması-AO, Yapay Tavşan Optimizasyonu-ARO, Dağ Ceylanı Optimizasyonu-MGO, Çayır Köpeği Optimizasyonu-PDO, Kerevit Optimizasyon Algoritması-COA) kıyaslanmıştır. Algoritmalar ile kalite test fonksiyonları ve mühendislik tasarım problemleri çözülmüştür. Bildiğimiz kadarıyla, bu algoritmaların performansları ilk kez karşılaştırılmıştır. Simülasyon sonuçları, yakınsama grafikleri ve istatistiksel test sonuçlarına göre en yüksek başarıya sahip üç algoritma sırasıyla AVOA, MGO ve AO' dur. Gelecekteki çalışmalarda çeşitli metasezgisellerden yararlanılarak bu üç algoritmanın daha sağlam versiyonları ile farklı mühendislik problemlerinin çözülmesi hedeflenmektedir.

Anahtar kelimeler: Metasezgiseller, Afrika Akbabaları Optimizasyon Algoritması, Dağ Ceylanı Optimizasyonu, Kaya Kartalı Optimizasyonu, Kalite Test Fonksiyonları, Mühendislik Tasarım Problemleri

ABSTRACT

PERFORMANCE ANALYSIS OF CURRENT METAHEURISTIC ALGORITHMS

Metin KALYON

Master of Science Thesis

Department of Computer Engineering

Supervisor: Asst. Prof. Sibel ARSLAN

2024, 113+ xvi pages

Nowadays, metaheuristics play a very important role in solving optimization problems. In this thesis study, 10 population-based metaheuristics proposed in the last 5 years (Harris Hawks Optimization-HHO, Sooty Tern Optimization Algorithm-STOA, Black Widow Optimization -BWO, Arithmetic Optimization Algorithm-AOA, African Vultures Optimization Algorithm-AVOA, Aquila Optimization Algorithm) - AO, Artificial Rabbit Optimization-ARO, Mountain Gazelle Optimization-MGO, Prairie Dog Optimization-PDO, Crayfish Optimization Algorithm-COA) were compared. Quality test functions and engineering design problems are solved with algorithms. To our knowledge, this is the first time the performances of these algorithms have been compared. According to simulation results, convergence graphs and statistical test results, the three most successful algorithms are AVOA, MGO and AO, respectively. In future studies, it is aimed to solve different engineering problems with more robust versions of these three algorithms by utilizing various metaheuristics.

Keywords: Metaheuristics, African Vultures Optimization Algorithm, Mountain Gazelle Optimization, Aquilla Optimization, Quality Test Functions, Engineering Design Problems

İÇİNDEKİLER

	<u>Sayfa</u>
ETİK.....	v
KATKI BELİRTME VE TEŞEKKÜR.....	vi
ÖZET.....	vii
ABSTRACT.....	viii
İÇİNDEKİLER	ix
ŞEKİLLER DİZİNİ	xi
ÇİZELGELER DİZİNİ	xii
KISALTMALAR DİZİNİ	xvi
1. GİRİŞ	1
1.1 Tezin Amacı, Kapsamı ve Katkıları	1
1.2 Tezin Bölümleri.....	4
2. METASEZGİSELLER	6
2.1 Harris Şahinleri Optimizasyonu (HHO).....	6
2.1.1 Keşif Aşaması.....	6
2.1.2 Sömürü Aşaması.....	7
2.2 İslı Sumru Optimizasyon Algoritması (STOA).....	10
2.2.1 Keşif Aşaması.....	10
2.2.2 Sömürü Aşaması.....	11
2.3 Karadul Optimizasyonu (BWO).....	12
2.3.1 Popülasyonun başlatılması	13
2.3.2 Üreme	13
2.3.3 Yamyamlık	13
2.3.4 Mutasyon	14
2.4 Aritmetik Optimizasyon Algoritması (AOA).....	14
2.4.1 Başlatma Aşaması	15
2.4.2 Keşif Aşaması.....	15
2.4.3 Sömürü (Kullanım) Aşaması.....	16
2.5 Afrika Akbabaları Optimizasyon Algoritması (AVOA).....	17
2.5.1 En İyi Akbaba Seçimi.....	18
2.5.2 Akbabaların Açlık Oranı	18
2.5.3 Keşif Aşaması.....	19
2.5.4 Sömürü Aşaması.....	20
2.6 Kaya Kartalı Optimizasyon Algoritması (AO)	24
2.6.1 Başlatma	24
2.6.2 Genişletilmiş keşif.....	25
2.6.3 Daraltılmış keşif	25
2.6.4 Genişletilmiş sömürü	26
2.6.5 Daraltılmış sömürü.....	26
2.7 Yapay Tavşan Optimizasyon Algoritması (ARO)	28
2.7.1 Başlatma Aşaması	29
2.7.2 Dolambaçlı yiyecek arama	29
2.7.3 Rastgele saklanma	30
2.7.4 Enerji küçültme.....	31
2.8 Dağ Ceylanı Optimizasyonu (MGO)	32
2.8.1 Bölgesel Bekar Erkekler.....	32
2.8.2 Doğum Sürüleri	34

2.8.3	Bekar Erkek Sürüleri.....	34
2.8.4	Yiyecek Aramaya Geçiş	34
2.9	Çayır Köpeği Optimizasyon Algoritması (PDO)	36
2.9.1	Başlatma Aşaması	36
2.9.2	Keşif Aşaması	38
2.9.3	Sömürü Aşaması.....	39
2.10	Kerevit Optimizasyon Algoritması (COA).....	41
2.10.1	Yazlık Tatil Yeri Aşaması (Keşif)	42
2.10.2	Rekabetçi Davranış Aşaması (Sömürü).....	42
2.10.3	Yiyecek Toplama Aşaması (Sömürü).....	43
3.	TEST PROBLEMLERİNİN ÇÖZÜMÜNDE METASEZGİSELLERİN	
	UYGULANMASI	45
3.1	Giriş	45
3.2	Deneysel Tasarım	45
3.2.1	Fonksiyonlar.....	45
3.2.2	Parametreler	52
3.3	Sonuçlar.....	53
3.3.1	Simülasyon Sonuçları	53
3.3.2	Yakınsama Grafikleri Analizi	61
3.4	İstatistiksel Test Sonuçları.....	69
4.	MÜHENDİSLİK PROBLEMLERİNİN METASEZGİSELLER İLE	
	ÇÖZÜMÜ	71
4.1	Giriş	71
4.2	Mühendislik Problemleri	71
4.2.1	Germe/Sıkıştırma Yay Tasarımı.....	71
4.2.2	Basıncılı Kap Tasarımı	72
4.2.3	Kaynaklı Kiriş Tasarım Problemi	74
4.2.4	Hız Düşürücü Tasarımı	76
4.2.5	Dişli Takımı Tasarım Problemi	77
4.2.6	Üç Çubuklu Kafes Tasarım Problemi.....	78
4.3	Sonuçlar.....	79
4.3.1	Simülasyon sonuçları	80
4.3.2	Yakınsama Grafikleri Analizi	80
4.3.3	En İyi Modellerin Analizi	84
4.4	T-Test Sonuçları	89
5.	TARTIŞMA, SONUÇ VE ÖNERİLER.....	106
5.1	Tartışma ve Sonuç	106
	KAYNAKLAR	108

ŞEKİLLER DİZİNİ

Sayfa

Şekil 1.1.1 Metasezgisel optimizasyon algoritmalarının sınıflandırılması.....	3
Şekil 2.6.1 AO akış şeması	28
Şekil 2.9.1 PDO' nun keşif ve sömürü aşama modelleri	39
Şekil 3.2.1 Tek modlu test fonksiyon grafikleri ($F1, F2, F4, F7$).....	49
Şekil 3.2.2 Çok modlu test fonksiyon grafikleri ($F8, F9, F10, F12$).....	50
Şekil 3.2.3 Farklı boyutlu çok modlu fonksiyon grafikleri ($F13, F14, F18, F23$)....	51
Şekil 3.3.1 Fonksiyonların yakınsama grafikleri ($F1 - F4$)	62
Şekil 3.3.2 Fonksiyonların yakınsama grafikleri ($F5 - F8$)	63
Şekil 3.3.3 Fonksiyonların yakınsama grafikleri ($F9 - F12$)	64
Şekil 3.3.4 Fonksiyonların yakınsama grafikleri ($F13 - F16$).....	65
Şekil 3.3.5 Fonksiyonların yakınsama grafikleri ($F17 - F20$).....	66
Şekil 3.3.6 Fonksiyonların yakınsama grafikleri ($F21 - F23$).....	67
Şekil 4.2.1 Germe/Sıkıştırma Yayı Tasarımı	71
Şekil 4.2.2 Basınçlı Kap Tasarımı	73
Şekil 4.2.3 Dişli Takımı Tasarımı.....	78
Şekil 4.2.4 Üç Çubuklu Kafes Tasarımı	79
Şekil 4.3.1 Germe Sıkıştırma yayı tasarımı yakınsama grafiği	80
Şekil 4.3.2 Basınçlı kap tasarımı yakınsama grafiği.....	81
Şekil 4.3.3 Kaynaklı giriş tasarımı yakınsama grafiği.....	81
Şekil 4.3.4 Hız düşürücü tasarım problemi yakınsama grafiği.....	82
Şekil 4.3.5 Dişli takımı tasarımı problemi yakınsama grafiği	82
Şekil 4.3.6 Üç çubuklu kafes tasarım problemi yakınsama grafiği	83

ÇİZELGELER DİZİNİ

Sayfa

Çizelge 1.1.1 Metasezgisel optimizasyon algoritmaları	4
Çizelge 2.1.1 Harris Şahinleri Optimizasyonu Adımları	9
Çizelge 2.2.1 İslî Sumru Optimizasyon Algoritması Adımları.....	12
Çizelge 2.3.1 Karadul Optimizasyonu Adımları.....	14
Çizelge 2.4.1 Aritmetik Optimizasyon Algoritması Sözde Kodu.....	17
Çizelge 2.5.1 Afrika Akbabaları Optimizasyon Algoritması Sözde Kodu.....	23
Çizelge 2.7.1 Yapay Tavşan Algoritması Adımları	32
Çizelge 2.8.1 Dağ Ceylanı Optimizasyonu Sözde Kodu	35
Çizelge 2.9.1 Çayır Köpeği Optimizasyonu Sözde Kodu.....	40
Çizelge 2.10.1 Kerevit Optimizasyon Algoritması Sözde Kodu	44
Çizelge 3.2.1 Tek modlu test fonksiyonları	46
Çizelge 3.2.2 Çok modlu test fonksiyonları.....	47
Çizelge 3.2.3 Farklı boyutlu çok modlu test fonksiyonları.....	48
Çizelge 3.2.4 Algoritma parametreleri ve değerleri.....	52
Çizelge 3.3.1 Tek modlu test fonksiyonları ($F1-F4$).....	54
Çizelge 3.3.2 Tek modlu test fonksiyonları ($F5-F7$).....	55
Çizelge 3.3.3 Çok modlu test fonksiyonları ($F8-F13$).....	56
Çizelge 3.3.4 Farklı boyutlu çok modlu test fonksiyonları ($F14-F18$).....	57
Çizelge 3.3.5 Farklı boyutlu çok modlu test fonksiyonları ($F19-F23$).....	58
Çizelge 3.3.6 Test fonksiyonları karşılaştırması.....	59
Çizelge 3.4.1 Fonksiyon t test sonuçları	70
Çizelge 4.3.1 Germe sıkıştırma yayı tasarım problemi sonuçları.....	85
Çizelge 4.3.2 Basınçlı kap tasarımı problemi sonuçları	85
Çizelge 4.3.3 Kaynaklı giriş tasarımı problemi sonuçları	86
Çizelge 4.3.4 Hız düşürücü tasarımı problemi sonuçları.....	86
Çizelge 4.3.5 Dişli takımı tasarımı problemi sonuçları	87
Çizelge 4.3.6 Üç çubuklu tasarım problemi sonuçları.....	87
Çizelge 4.3.7 Mühendislik tasarım problemleri başarı sıralamaları	88
Çizelge 4.4.1 t testi sonuçları.....	90

SİMGELER DİZİNİ

$X_{\text{tavşan}}$	Tavşanın anlık konumu
X_{rand}	Tavşanın rastgele konumu
X_m	Şahinlerin ortalama konumu
$X(t)$	Şahinlerin anlık konumu
r	Bir avın başarılı şekilde kaçma olasılığı değeri
$r_1, r_2, r_3, r_4,$	Şahin konumunu belirleyen 0 – 1 arasındaki rastgele sayılardır
t	Problem çözümünde uygulanan adımlardan her biri
LB	Problem alt sınırı
UB	Problem üst sınırı
T	Problem çözümünde uygulanan toplam adım sayısı
N	Toplam şahin sayısı
$\Delta X(t)$	Tavşanın t 'inci iterasyondaki pozisyon vektörü
J	Tavşan konumu belirleyen bir parametre
r_5	Tavşan konumu belirleyen 0 – 1 aralığındaki rastgele bir sayı
$X_i(t)$	t . iterasyondaki şahin konumu
E	Avın kaybolan enerjisi
E_0	Avın ilk enerjisi
D	Problem boyutu
s	Rastgele bir vektör
Z	Harris şahinin hesaplanan ani dalış değeri
Y	Harris şahinin hesaplanan yumuşak kuşatma değeri
LF	Levy uçuşu fonksiyonu
$\vec{C}_{st}$	İsli Sumrular ile çarpışmayan kuşun konumunu
$\vec{P}_{st}(z)$	İsli Sumru'nun geçerli konumu
$\vec{P}_{bst}(z)$	İsli Sumru'nun en iyi konumu
$\vec{D}_{st}$	İsli Sumru'nun en iyi konumu ile geçerli konumu arasındaki fark
S_A	Geçerli yineleme
$\vec{C}_f$	Geçerli yinelemeyi ayarlayan kontrol değişkeni
$\vec{M}_{st}$	İsli Sumru'nun ulaştığı farkı konum
R_{adius}	İsli Sumru'nun spiral dönüş yarıçapı
u	İsli Sumru'nun yaptığı spiral hareketin sabiti
v	İsli Sumru'nun yaptığı spiral hareketin sabiti
C_B	Keşiften sorumlu değişken
y_1, y_2	Genç örümcekler
x_1, x_2	Ebeveyn örümcekler
X	Çözüm dizisi
$C_{\text{iterasyon}}$	Geçerli iterasyon adımı
$M_{\text{iterasyon}}$	Maksimum iterasyon adımı
ϵ	Adım boyu katsayısı
α	Adım doğruluk katsayısı
$x_{i,j}(C_{\text{iterasyon}})$	Geçerli iterasyondaki i 'nci çözümün j 'nci konumunu verir.
$R(i)$	Akbaba uygunluk değeri
L_1, L_2	Akbaba uygunluk değer parametreleri
p_i	Akbaba grupları için en iyi çözüm seçilme parametresi

F_i	i . akbabanın uygunluk değeri
n	Toplam akbaba sayısı
t_c	Değerlendirme sayısı
F	Akbaba doygunluğunu gösteren parametre
w	Keşif ve operasyon bilgisi veren parametre
P	Akbaba konum vektörü
$R(i)$	Seçilen en iyi akbaba
$D(i)$	En iyi akbaba ile mevcut akbaba arasındaki konum
$d(t)$	Akbabanın gruptaki en iyi akbabaya olan mesafesi
S_1	1. en iyi akbaba dönme hareket değeri
S_2	2. en iyi akbaba dönme hareket değeri
LB_j	Problem alt sınırı
UB_j	Problem üst sınırı
QF	Keşif yöntemlerini dengeleyen kalite fonksiyonu
$\vec{x}_{i,d}$	i . tavşanın konum vektörü
f	Uygunluk değeri
$\vec{v}_i(t + 1)$	$t + 1$. anındaki i . tavşan konumu
L	Hareket hızını temsil eden koşu uzunluğu
H	Gizlenme parametresi
$\vec{b}_{i,j}$	i . tavşanın j . yuva konumu
$\vec{b}_{i,r}$	i . tavşan tarafında rastgele seçilen yuva konumu
$A(t)$	Tavşanın enerji seviyesi
BH	Ceylan genç erkek sürüsü etki faktör katsayısı
Cof_r	Arama yeteneğini artırmak için kullanılan bir katsayı vektörü
n_1	Standart dağılım sayısı
$CT_{i,j}$	Kolonideki i . zümrenin j . boyutunun konumu
$PD_{i,j}$	i . çayır köpeğinin j . boyutunun konumu
$GBest_{i,j}$	Global en iyi çözüm
$eCBest_{i,j}$	Mevcut en iyi çözümün etkisi
Δ	Çayır köpekleri arasındaki tam sayı farkı
PD_ϵ	Çayır köpekleri besin kaynağının kalitesini gösteren parametre
$CPD_{i,j}$	Kolonideki tüm çayır köpeklerinin toplam etkisi
PE	Avcı etkisi
μ	Kerevitler için en uygun sıcaklık değeri
X_G	Kerevitler için en uygun konum
X_L	Anlık kerevit konumu
Q	Kerevit yiyecek boyutu
C_3	En büyük kerevit yiyecek faktörü
$d x_1$	Tel çapı
$D x_2$	Ortalama bobin çapı
$N x_3$	Aktif bobin sayısı
g_1	Minimum sapma
g_2	Kayma gerilimi
g_3	Darbe frekansı
g_4	Dış çap sınırı
$T_s(X_1)$	Kabuğun kalınlığı
$T_h(X_2)$	Kafa kalınlığı
$R(X_3)$	İç yarıçap

L (X₄)	Kafa göz alınmadan silindirik bölümün uzunluğu
h (x₁)	Kabuğun kalınlığı
l (x₂)	Kaynak bağlantı uzunluğu
t (x₃)	Kirişin genişliği
b (x₄)	Kiriş kalınlığı
b x₁	Yüz genişliği
m x₂	Diş modülü
z x₃	Pinyondaki diş sayısı
l₁ x₄	Yataklar arasındaki ilk milin uzunluğu
l₂ x₅	Yataklar arasındaki ikinci milin uzunluğu
d₁ x₆	Birinci milin çapı
d₂ x₇	İkinci milin çapı
T_a	1.çarkın diş sayısı
T_b	2.çarkın diş sayısı
T_c	3.çarkın diş sayısı
T_d	4.çarkın diş sayısı
A₁	Kafes çapraz kesit alanı
A₂	Kafes dikey kesit alanı

KISALTMALAR DİZİNİ

ABC	Yapay Arı Koloni (Artificial Bee Colony)
AO	Kaya Kartalı Optimizasyon Algoritması (Aquila Optimizer)
AOA	Aritmetik Optimizasyon Algoritması (Aritmetich Optimization Algorithm)
ARO	Yapay Tavşan Optimizasyonu (Artificial Rabbits Optimization)
AVOA	Afrika Akbabaları Optimizasyon Algoritması (African Vulture Optimization Algorithm)
BWO	Karadul Optimizasyonu (Black Widow Optimization)
COA	Kerevit Optimizasyon Algoritması (Crayfish Optimization Algorithm)
GA	Genetik Algoritma (Genetic Algorithm)
HHO	Harris Hawks Optimizasyonu (Harris Hawks Optimization)
MGO	Dağ Ceylanı Optimizasyonu (Mountain Gazelle Optimizer)
PDO	Çayır Köpeği Optimizasyonu (Prairie Dog Optimization)
STOA	İsli Sumru Optimizasyon Algoritması (Sooty Tern Optimization Algorithm)

1. GİRİŞ

1.1 Tezin Amacı, Kapsamı ve Katkıları

Optimizasyon, bir problemin belirli koşullar altında var olan çözümlerinden en iyisini seçme işlemidir [1]. Optimizasyon problemlerinde genellikle matematiksel ve klasik sezgisel yöntemler kullanılmaktadır. Karmaşık sistemler için matematiksel modelin kurulması zorluğunun yanında, çözüm uzayının geniş olduğu problemlerde matematiksel yöntemler maliyet açısından dezavantajlı oldukları için tercih edilmezler. Klasik optimizasyon yöntemleri ise sürekli ve türevlenebilir amaç fonksiyonlarının optimum çözümünü bulmakta kullanışlıdır. Değişken sayısı arttıkça problemlerin klasik optimizasyon yöntemleri ile çözümü zorlaşmakta veya çok uzun süre almaktadır [2]. Optimizasyon problemlerinin çözümünde kullanılan matematiksel ve klasik sezgisel yöntemlerin yerine çok daha başarılı sonuçlar veren metasezgisel optimizasyon algoritmaları geliştirilmiştir.

Metasezgisel optimizasyon algoritmaları, bir optimizasyon problemindeki matematiksel modelin oluşturulmasının zor olduğu durumlarda veya büyük ölçekli, çok değişkenli optimizasyon problemlerine ait kabul edilebilir çözümler üreten bir optimizasyon yaklaşımıdır. Metasezgisel optimizasyon algoritmaların temelinde doğa olayları, canlı türlerinin sosyal davranışları ve evrimsel kavramlar yer almaktadır [3]. Bu algoritmalar çözüme ulaşmak için iki temel yapı kullanır. Bunlar: Keşif (exploration) ve sömürü (exploitation) mekanizmalarıdır. Keşif aşaması çözüme dair arama uzayını, arama sürecini ifade ederken; sömürü aşaması ise keşif ile elde edilen alanda daha doğru bir arama sürecini ifade eder. Metasezgisel bir optimizasyon algoritmasında keşif aşamasının yeteneği yerel optimumdan kurtulmasını ve farklı çözümler bulmasını sağlarken; sömürü aşamasının yeteneği ise çözümlerin optimuma yakınlığını sağlamaktadır. Bu nedenle metasezgisel optimizasyon algoritmalarında iki aşamanın dengeli olması gerekmektedir [4]. Bu algoritmalar; ekonomi, ticaret, finans, enerji, çizelgeleme, görüntü işleme, optimal kontrol ve mühendislik tasarım uygulamalarında çeşitli alanlarda kullanılmaktadır [5].

En temelde metasezgisel optimizasyon algoritmaları 4 kategoride ele alınır: Evrimsel optimizasyon algoritmaları, sürü zekasına dayalı optimizasyon algoritmaları, fizik

tabanlı optimizasyon algoritmaları ve insan tabanlı optimizasyon algoritmalarıdır [6]. Şekil 1.1.1' de gösterilmiştir [7].

Bu tez çalışmasında son zamanlarda ortaya çıkmış 10 farklı metasezgisel optimizasyon algoritması ayrıntılı olarak ele alınmış ve çalışma prensipleri hakkında bilgi verilmiştir. Daha sonra ise bu algoritmalar 23 klasik kalite testi fonksiyonları ile karşılaştırılmıştır. Bu metasezgisellerin seçilen gerçek dünya problemleri karşısındaki performansları da bu çalışma ile ortaya çıkarılmıştır. Çalışmanın temel katkıları aşağıda sıralanmıştır:

- Literatür taramasına göre bu çalışmada kullanılan algoritmalar ilk kez kıyaslanmıştır.
- Algoritmaların performansı çeşitli işlevler üzerinde test edilmiştir.
- Deneysel çalışmalara göre en iyi performans gösteren metasezgiseller değerlendirilmiştir.



Şekil 1.1.1 Metasezgisel optimizasyon algoritmalarının sınıflandırılması

Çalışmada yer alan metasezgisel optimizasyon algoritmaları Çizelge 1.1.1’ de yer verilmiştir.

Çizelge 1.1.1 Metasezgisel optimizasyon algoritmaları

Algoritma Adı	Yıl	Sınıflandırma	Önerildiği Yayın
Harris Şahinleri Optimizasyon Algoritması	2019	Popülasyon tabanlı	[8]
İsli Sumru Optimizasyon Algoritması	2019	Popülasyon tabanlı	[9]
Karadul Optimizasyon Algoritması	2020	Popülasyon tabanlı	[10]
Aritmetik Optimizasyon Algoritması	2020	Popülasyon tabanlı	[11]
Afrika Akbabaları Optimizasyon Algoritması	2021	Popülasyon tabanlı	[12]
Kaya Kartalı Optimizasyon Algoritması	2022	Popülasyon tabanlı	[13]
Yapay Tavşan Optimizasyon Algoritması	2022	Popülasyon tabanlı	[14]
Dağ Ceylanı Optimizasyonu	2022	Popülasyon tabanlı	[15]
Çayır Köpeği Optimizasyon Algoritması	2022	Popülasyon tabanlı	[16]
Kerevit Optimizasyon Algoritması	2023	Popülasyon tabanlı	[17]

1.2 Tezin Bölümleri

İlk bölümde; tezin amaç, kapsam ve katkıları açıklanmıştır. Tez çalışmasında kullanılan yöntemlerden kısa bir şekilde bahsedilmiştir.

Tezin ikinci bölümünde, karşılaştırılan güncel 10 metasezgisel optimizasyon algoritması hakkında detaylı bir literatür çalışması yapılmış, algoritmaların çalışma prensipleri ve sözde kodları ayrıntılı şekilde açıklanmıştır.

Üçüncü bölümde, öncelikle kıyaslama için kullanılacak standart test fonksiyonları açıklanmış, bu çalışmada kullanılan metasezgisellilerin seçilen standart test fonksiyonları ile karşılaştırma sonuçlarını ortaya koyan deneysel çalışmalar ve sonuçları, algoritmalarda yer alan parametrelere dair ayrıntılı bilgiler sunulmuştur. Ayrıca bu bölümde standart test fonksiyonları sonucu ortaya çıkan sonuçların belirgin olup olmadığı ortaya koyabilmek için t test yapılmış ve sonuçları yer almaktadır.

Dördüncü bölümde, seçilen algoritmaların gerçek dünya problemleri üzerindeki başarısını ortaya koyabilmek için seçilen problemlere yer verilmiş, bu algoritmaların seçilen problemler üzerindeki performans sonuçları sunulmuştur. Üçüncü bölümde ifade edildiği gibi algoritmaların gerçek dünya problemleri karşısındaki başarı oranları arasındaki farkın belirgin olup olmadığını daha net ortaya koyabilmek için yine t test tekniği uygulanmış ve sonuçları bu bölümde aktarılmıştır.

Beşinci bölümde, tez çalışmasında elde edilen tüm sonuçlar değerlendirilmiştir. Bununla birlikte ilerideki çalışmalarda yapılabilecekler tartışılmıştır.



2. METASEZGİSELLER

Bu bölümde, karşılaştırma yapılacak metasezgisel optimizasyon algoritmalarına ait literatür çalışması yapılarak algoritmalar hakkında detaylı bilgiye yer verilmiştir

2.1 Harris Şahinleri Optimizasyonu (HHO)

HHO, Harris şahinlerinin davranışlarından ve avlanma metotlarından esinlenerek oluşturulmuş sürü tabanlı bir optimizasyon algoritmasıdır [8]. Harris şahinlerinin avı keşfetme, ava sürpriz saldırı ve enerji durumuna göre çeşitli saldırı stratejileri bu algoritmanın keşif ve sömürü aşamalarını kapsamaktadır. Algoritmanın aşamaları aşağıdaki gibidir.

2.1.1 Keşif Aşaması

Harris şahinlerinin en büyük fiziksel özelliklerinden birisi, avlarını kısa sürede fark edebilmesini sağlayan görme yetenekleridir. Bu durum her zaman geçerli olmayabilir, Harris şahinleri bu gibi durumlarda av bölgelerinde bekleyip gözlem yapmak zorunda kalırlar. HHO’ da keşif aşaması, Harris şahinlerinin avlarını keşfetmek adına gözlem yapma sürecini anlatır. Harris şahinleri rastgele av bölgesine yerleşirler ve avlarını tespit edebilmek için 2 farklı strateji ile beklemeye geçerler. Bu stratejiler Denklem 2.1’ de yer alan q değerine göre belirlenir. Harris şahinlerinin her birisi aday çözümü oluştururken, avın konumu ise amaçlanan aday çözümlerin en iyisidir. Keşif aşaması Denklem 2.1’ de gösterilmiştir.

$$X(t+1) = \begin{cases} X_{\text{rand}}(t) - r_1 |X_{\text{rand}}(t) - 2r_2 X(t)| & q \geq 0.5 \\ (X_{\text{tavşan}}(t) - X_m(t)) - r_3(LB + r_4(UB - LB)) & q < 0.5 \end{cases} \quad [2.1]$$

Burada eşit olasılıkla q değerine göre stratejiler belirlenir. Denklem 2.1’ de, $X(t+1)$ t ’inci iterasyonundaki şahinin konum vektörü, $X_{\text{tavşan}}(t)$ tavşanın anlık konumu, $X(t)$ şahinlerin anlık pozisyonları, r_1, r_2, r_3, r_4 ve $q, 0 - 1$ arasında belirlenen rastgele sayılardır ve her iterasyonda değişmektedirler. Denklem 2.1’ de, LB (lower bound, alt sınır) ve UB (upper bound, üst sınır) ise problemin alt sınır ve üst sınır değerleri, X_m ise o anki konumlanan şahinlerin ortalama değeri olmaktadır ve Denklem 2.2’ de gösterildiği gibi hesaplanmaktadır.

$$X_m(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \quad [2.2]$$

Burada $X_i(t)$ t 'inci iterasyondaki şahinin konumunu, N toplam şahin sayısını ifade eder [11].

HHO algoritması, keşiften sömürüye geçiş yapar ve avın kaçma esnasında azalan enerjisine bağlı olarak farklı saldırı davranışları gösterir. Avın kaçışı sırasında önemli ölçüde enerjisi azalır. Azalan avın enerjisi Denklem 2.3'te hesaplanmıştır.

$$E = 2E_0 \left(1 - \frac{t}{T}\right) \quad [2.3]$$

Denklem 2.3' de, E avın kaybolan enerjisini, T toplam iterasyon sayısını ve E_0 avın başlangıç enerjisini ifade eder. E_0 rastgele olarak $(-1,1)$ aralığında her iterasyonda değişmektedir. E_0 'ın değeri 0 dan -1 ' e düştüğünde av fiziksel olarak zayıf düşerken, E_0 'ın değeri 0 ' dan 1 ' e çıktığında, tavşan güçlenmektedir. Avlar, her zaman tehdit edici durumlardan kaçmaya çalışmaktadırlar. Dinamik kaçış enerjisi E iterasyonlar sırasında azalan bir eğilime sahiptir.

$|E| \geq 1$ olduğunda şahinler bir tavşanın yerini keşfetmek için farklı bölgeleri aramaktadır. Dolayısıyla HHO, keşif aşamasını gerçekleştirmektedir ve $|E| < 1$ olduğu zaman, algoritma sömürü aşaması boyunca çözümlerin komşuluğundan yararlanmaya çalışmaktadır [18].

r bir avın başarılı bir şekilde kaçma olasılığı olarak varsayılırsa, sürpriz saldırıdan önce $r < 0.5$ durumunda av başarılı bir şekilde kaçarken; $r \geq 0.5$ durumunda ise, av başarılı bir şekilde kaçamamaktadır. Avın davranışına göre şahinler, avı yakalamak için sert veya yumuşak kuşatma yapacaklardır [8].

2.1.2 Sömürü Aşaması

Bir önceki aşamada tespit edilen ava, Harris şahinleri sürpriz saldırı gerçekleştirir. Avın kaçma davranışlarına ve Harris şahinlerinin kovalama stratejilerine göre 4 farklı saldırı türü gerçekleştirilir [19]:

▪ Yumuşak Kuşatma

$r \geq 0.5$ ve $|E| \geq 0.5$ durumunda, tavşanın yeterli enerjisi olduğundan kaçma davranışları göstermekte; fakat bunu başaramamaktadır. Harris şahinleri ise buna

karşın avın etrafını sarar ve avı yorarak sürpriz saldırı davranışlarında bulunurlar. Denklem 2.4' te bu davranış gösterilmiştir.

$$\begin{aligned} X(t+1) &= \Delta X(t) - E|JX_{\text{tavşan}}(t) - X(t)| \\ \Delta X(t) &= X_{\text{tavşan}}(t) - X(t) \end{aligned} \quad [2.4]$$

$\Delta X(t)$ tavşanın t ' inci iterasyondaki pozisyon vektörüdür ve o anki pozisyonun farkını ifade etmektedir, r_5 , $0 - 1$ arasında bir rastgele bir sayıdır ve $J = 2(1 - r_5)$ olarak ifade edilmektedir. J değeri, her iterasyonda rastgele olarak değişmektedir.

▪ Sert Kuşatma

$r \geq 0.5$ ve $|E| < 0.5$ durumunda, av yorulmuştur ve kaçış enerjisi çok düşüktür. Harris şahinleri, sürpriz saldırıyı gerçekleştirmek için avı kuşatmaktadırlar. Bu durum Denklem 2.5' teki gibidir.

$$X(t+1) = X_{\text{tavşan}}(t) - E|\Delta X(t)| \quad [2.5]$$

▪ Aşamalı Hızlı Dalışlarla Yumuşak Kuşatma

$|E| \geq 0.5$ ve $r < 0.5$ durumunda, av kaçmak için için yeterli enerjiye sahiptir. Bu nedenle sürpriz saldırıdan önce, yumuşak bir kuşatma inşa edilmelidir. Yumuşak bir kuşatma gerçekleştirmek için, şahinlerin bir sonraki hamleleri Denklem 2.6'da gösterilmiştir.

$$Y = X_{\text{tavşan}}(t) - E|JX_{\text{tavşan}}(t) - X(t)| \quad [2.6]$$

Avın kaçış hareketlerine karşın iyi bir dalış olup olmayacağını tespit etmek için böyle bir hareketin olası sonucu önceki dalışla karşılaştırılmaktadır. Bu karşılaştırma sonucu Denklem 2.6' da hesaplanan Y başarılı olmaz ise ani bir dalış gerçekleştirirler. Bu ani dalış olan Lévy uçuşu tabanlı dalış, Denklem 2.7'de modellenmiştir.

$$Z = Y + S \times LF(D) \quad [2.7]$$

Denklem 2.7'de, D problemin boyutu, s bir rastsal vektör ve LF , Lévy uçuşu fonksiyonudur. Yumuşak kuşatma aşamasında şahinlerin konumlarını güncellemek için Denklem 2.8 kullanılmaktadır.

$$X(t + 1) = \begin{cases} Y & \text{eğer } F(Y) < F(X(t)) \\ Z & \text{eğer } F(Z) < F(X(t)) \end{cases} \quad [2.8]$$

Her adımda, sadece daha iyi konum Y veya Z bir sonraki konum olarak seçilmektedir.

▪ **Aşamalı Hızlı Dahışlarla Sert Kuşatma**

Bu adımda, $|E| < 0,5$ ve $r < 0,5$ olduğunda tavşanın kaçmak için yeterli enerjisi yoktur ve sürpriz saldırıdan önce avını yakalamak ve öldürmek için sert bir kuşatma inşa edilmektedir. Şahinler, kaçan av ile ortalama konumlarının mesafesini azaltmaya çalışmaktadırlar. Bu durum Denklem 2.9’ da modellenmektedir.

$$X(t + 1) = \begin{cases} Y & \text{eğer } F(Y) < F(X(t)) \\ Z & \text{eğer } F(Z) < F(X(t)) \end{cases} \quad [2.9]$$

- Bu adımda Y ve Z aşağıdaki yeni kurallara dayanarak elde edilmektedir.

$$Y = X_{\text{tavşan}}(t) - E|X_{\text{tavşan}}(t) - X_m(t)| \quad [2.10]$$

$$Z = Y + S \times LF(D) \quad [2.11]$$

HHO algoritması adımları aşağıda Çizelge 2.1.1’ de gösterilmiştir [20].

Çizelge 2.1.1 Harris Şahinleri Optimizasyonu Adımları

Harris Şahinleri Optimizasyonu
Adım 1. Başlangıç parametrelerini tanımla
Adım 2. Başlangıç şahinlerini üret.
Adım 3. Şahinlerin uygunluk değerini hesapla.
Adım 4. Algoritma parametrelerini ve şahinlerin konumlarını güncelle.
Adım 6. Güncel uygunluk değerini hesapla.
Adım 7. Durdurma kriteri sağlanıyor mu?
a. Sağlanıyor:
- En iyi şahini çözüm olarak seç.
b. Sağlanmıyor:
- 4. Adıma geç

2.2 İsli Sumru Optimizasyon Algoritması (STOA)

STOA, isli sumruların göç ve saldırı davranışlarını simüle eder [9]. Bu algoritmanın ana ilham kaynağı deniz kuşlarından biri olan isli sumruların göç ve saldırı davranışlarıdır. Bu algorithmada göç davranışı keşif aşamasını; saldırı davranışı ise sömürü (kullanım) aşamasını ifade eder.

2.2.1 Keşif Aşaması

Göç sırasında isli sumruların gösterdiği davranışlar algorithmada aşağıdaki gibi modellenmiştir:

- Çarpışmadan kaçınma: Göç sırasında isli sumrular arasındaki çarpışmayı önlemek için yeni isli sumrunun konumu Denklem 2.12. ile hesaplanır.

$$\vec{C}_{st} = S_A \times \vec{P}_{st}(z) \quad [2.12]$$

$\vec{C}_{st}$ Diğer isli sumrular ile çarpışmayan kuşun konumunu, $\vec{P}_{st}(z)$ isli sumrunun geçerli konumunu ve S_A mevcut yinelemeyi gösterir ve Denklem 2.13 ile aşağıdaki gibi hesaplanır.

$$S_A = C_f - \left(z \times (C_f / \text{Maksimum iterasyon}) \right) \quad [2.13]$$

Burada z değeri Denklem 2.14 ile aşağıdaki gibi hesaplanır.

$$z = 0, 1, 2, \dots, \text{Maksimum iterasyon} \quad [2.14]$$

C_f , S_A 'yı ayarlamak için kontrol değişkenidir.

- En iyi komşu yönüne yaklaşma: Çarpışmadan kaçındıktan sonra isli sumrular, en iyi komşunun yönüne doğru hareket ederler. Hareket, Denklem 2.15 ile hesaplanmaktadır.

$$\vec{M}_{st} = C_B \cdot \vec{P}_{st}(z) \left(\vec{P}_{bst}(z) - \vec{P}_{st}(z) \right) \quad [2.15]$$

Burada $\vec{M}_{st}$ İsli sumrunun ulaştığı farklı konumlarını ifade eder. $\vec{P}_{bst}(z)$ İsli sumrunun en iyi konumunu verir. $\vec{P}_{st}(z)$ İsli sumrunun geçerli konumudur. C_B daha iyi bir keşiften sorumlu bir değişkeni ifade eder ve aşağıdaki şekilde hesaplanır.

$$C_B = 0.5 \times R_{\text{and}} \quad [2.16]$$

Burada R_{and} $[0, 1]$ aralığında yer alan rastgele bir sayıdır.

- En iyi isli sumru konumuna göre güncelleme: En sonunda arama temsilcisi veya isli sumru, en iyi konuma sahip isli sumruya göre konumunu güncelleyebilir. Denklem 2.17' de bu güncelleme hesaplanmıştır.

$$\vec{D}_{st} = \vec{C}_{st} + \vec{M}_{st} \quad [2.17]$$

$\vec{D}_{st}$ En iyi konuma sahip isli sumru ile isli sumrunun o anki konumu arasındaki farkı ifade eder.

2.2.2 Sömürü Aşaması

Sömürü aşaması, isli sumruların göç sırasındaki hız ve saldırı açılarını değiştirebilme davranışlarını kapsamaktadır. İsli sumrular bu değişikliği kanatlarını hareket ettirerek irtifa kazanırlar. Avlarına saldırırken havada aşağıda spiral davranışlar sergilerler [21]. Bu süreç aşağıdaki denklemler ile gösterilmiştir.

$$x' = R_{\text{adius}} \times \sin(i) \quad [2.18]$$

$$y' = R_{\text{adius}} \times \cos(i) \quad [2.19]$$

$$z' = R_{\text{adius}} \times i \quad [2.20]$$

$$R_{\text{adius}} = u \times e^{kv} \quad [2.21]$$

R_{adius} spiralin her dönüşünün yarıçapını, i , $[0 \leq k \leq 2\pi]$ aralığı arasında yer alan değişkeni, u ve v spiral şeklini tanımlayan sabitleri, e doğal logaritmanın tabanıdır. Denklem 2.21'deki u ve v sabitlerinin değeri 1 olarak alınmıştır [21]. İsli sumrunun konum güncellemesi Denklem 2.22 ile hesaplanmaktadır.

$$\vec{P}_{st}(Z) = \left(\vec{D}_{st} \times (x' + y' + z') \right) \times \vec{P}_{bst}(Z) \quad [2.22]$$

Burada $\vec{P}_{bst}(z)$ İsli sumrunun en iyi konumunu, $\vec{P}_{st}(z)$ İsli sumrunun geçerli konumu iken $\vec{D}_{st}$ ise en iyi konuma sahip isli sumru ile isli sumrunun o anki konumu arasındaki farktır. x' , y' ve z' , göç sırasındaki isli sumruların değişen açılarıdır. STOA algoritması adımları aşağıda Çizelge 2.2.1 'de gösterilmiştir [9].

Çizelge 2.2.1 İslı Sumru Optimizasyon Algoritması Adımları

İslı Sumru Optimizasyon Algoritması	
Girdi:	İslı Sumru nüfusu
Çıktı:	En iyi isli sumru konumu
Adım 1.	STOA prosedürünü başlat
Adım 2.	S_A ve C_B parametrelerini başlat
Adım 3.	Her bir isli sumrunun konumunu hesapla
Adım 4.	En iyi isli sumru konumu
Adım 5.	while ($z < \text{Max iterations}$) do
Adım 6.	for her bir isli sumru için do
Adım 7.	İslı Sumruların konumunu güncelle
Adım 8.	end for
Adım 9.	S_A ve C_B parametrelerini güncelleyin
Adım 10.	Her bir isli sumrunun uygunluk değerini güncelleyin
Adım 11.	En iyi isli sumru konumundan daha iyi bir konuma sahip isli sumru varsa konum güncellemesi yapın
Adım 12.	$z = z + 1$
Adım 13.	end while
Adım 14.	En iyi isli konumunu al
Adım 15.	Prosedürü bitir.

2.3 Karadul Optimizasyonu (BWO)

BWO, Karadul örümceklerinin çiftleşme davranışlarından ilham alınarak geliştirilmiş popülasyon tabanlı bir algoritmadır [10].

Algoritma, genel anlamda karadul örümceklerine ait olan üreme ve sonrasındaki yamyamlık davranışı olan Darwin' in evrim teorisinin yani en uygun olanın hayatta kalması ve en güçlü olanın üstünlüğü düşüncelerini yansıtır. Özel anlamda ise örümcek popülasyonundaki mutasyonu; ayrıntı boyutunda ise genetik değişiklikleri ifade eder [22]. BWO; popülasyon başlatma, üreme, yamyamlık ve mutasyon olmak üzere dört aşamadan meydana gelmektedir.

2.3.1 Popölasyonun başlatılması

Karadul optimizasyon algoritmasında karadul örümceklerinin her birisi çözüme dair potansiyel bir çözümü ifade eder. D boyutlu bir problemde karadullar Denklem 2.23' te gösterilmiştir.

$$\text{Örümcek} = [x_1, x_2, \dots, x_{N_{\text{var}}}] \quad [2.23]$$

Burada x_1 problemdeki her bir karadulu ifade ederken, $x_{N_{\text{var}}}$ problem boyudur. Dizi şeklinde gösterilen her bir karadulun uygunluk değeri Denklem 2.24 ile hesaplanmaktadır.

$$\text{Fitness} = f(\text{örümcek}) = f(x_1, x_2, \dots, x_{N_{\text{var}}}) \quad [2.24]$$

Popölasyonu başlatmak için $N_{\text{pop}} \times N_{\text{var}}$ boyutlarında bir matris oluşturulur. Daha sonra üreme aşaması için çiftler rastgele seçilerek bir sonraki aşamaya geçilir.

2.3.2 Üreme

Yeni oluşturulan nesil, karadulların kendilerine özgü olan çiftleşme yöntemi ile oluşturulmaktadır. Algoritmada, yeni nesil oluşturmak için 0 – 1 arasında rastgele değerler alabilen α adında D boyutlu bir dizi oluşturulur. Bu dizideki değerler karadullara karşılık gelmektedir. Yeni nesil örümcekler aşağıdaki Denklem 2.25 ile oluşturulmaktadır.

$$\begin{aligned} y_1 &= \alpha \times x_1 + (1 - \alpha) \times x_2 \\ y_2 &= \alpha \times x_2 + (1 - \alpha) \times x_1 \end{aligned} \quad [2.25]$$

Denklem 2.25' te yer alan Y_1 ve Y_2 üreme sonucu gelen genç örümcekleri, x_1 ve x_2 ise anne ve baba örümcekleri temsil eder. Yukarıdaki işlem $D/2$ kez tekrar eder ve α dizisi elemanlarından her adımda farklı seçim yapılarak hesaplama yapılır.

2.3.3 Yamyamlık

3 çeşit yamyamlık türü vardır [10]. Bunlar:

- **Cinsel yamyamlık:** Dişi karadulun çiftleşme sırasında veya sonrasında erkek örümceği yemesi. Bu yamyamlık dişi ve erkek karadulun uygunluk değerine göre uygulanır.

- **Kardeş yamyamlık:** Güçlü örümcek yavrularının zayıf kardeşlerini yediği yamyamlık türüdür. Uygunluk değeri yüksek genç örümcekler popülasyonda kalır ve diğerleri popülasyondan atılır.
- **Yavru ve anne arasındaki yamyamlık:** Bazı güçlü yavru örümcekler annelerini yerler ve yeni nesle geçerler.

Bütün bu süreçte, güçlü veya zayıf örümcekleri belirlemek için uygunluk değerlerinden yararlanılmaktadır.

2.3.4 Mutasyon

Algoritmada mutasyon, belirlenen sayıda genç örümceğin rastgele olarak popülasyondan seçilmesiyle başlar. Her bir seçilen örümceğin iki elementi rastgele olarak yer değiştirmektedir. BWO algoritması adımları aşağıda çizelgede gösterilmiştir [20].

Çizelge 2.3.1 Karadul Optimizasyonu Adımları

Karadul Optimizasyonu
Adım 1. Başlangıç parametrelerini tanımla
Adım 2. Başlangıç örümcek popülasyonunu üret.
Adım 3. Popülasyonun uygunluk değerini hesapla.
Adım 4. Durdurma kriteri sağlanıyor mu?
a. Sağlanıyor:
- En iyi örümceği çözüm olarak seç.
b. Sağlanmıyor:
- Popülasyonu güncelle.
- 2. Adıma geç

2.4 Aritmetik Optimizasyon Algoritması (AOA)

AOA, matematiksel işlemlerden dört işlem olarak adlandırılan çarpma, bölme, çıkarma ve toplama işlemlerinin kullanım durumlarını modelleyen popülasyon tabanlı bir optimizasyon algoritmasıdır [11]. Ayrıca, optimizasyon problemlerini türev hesabı yapmadan çözer [23]. AOA iki temel bölümden meydana gelir. Bunlar keşif ve sömürü

(kullanım) aşamalarıdır. Keşif aşamasında, aday çözümlerin konumları çarpma ve bölme işlemlerinde kullanılırken, sömürü aşamasında toplama ve çıkarma işlemleri yapılır. AOA' nın matematiksel modeli şu şekildedir:

2.4.1 Başlatma Aşaması

AOA' da optimizasyon süreci, rastgele oluşturulmuş bir dizi aday çözüm ile başlar ve her yinelemede en iyi aday çözüm, şimdiye kadar elde edilen en iyi çözüm kabul edilir. Denklem 2.47 ile aday çözüm dizisi (X) gösterilir.

$$X = \begin{bmatrix} x_{1,1} & \cdots & \cdots & x_{1,j} & x_{1,n-1} & x_{1,n} \\ x_{2,1} & \cdots & \cdots & x_{2,j} & \cdots & x_{2,n} \\ \cdots & \cdots & \cdots & \cdots & \cdots & \cdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{N-1,1} & \cdots & \cdots & x_{N-1,j} & \cdots & x_{N-1,n} \\ x_{N,1} & \cdots & \cdots & x_{N,j} & x_{N,n-1} & x_{N,n} \end{bmatrix} \quad [2.47]$$

AOA' da arama sürecinden önce hangi aşamada çalışacağı belirlenmelidir. Bu belirleme Denklem 2.48 ile hesaplanmaktadır.

$$MOA(C_{iterasyon}) = Min + C_{iterasyon} \times \left(\frac{maks - min}{M_{iterasyon}} \right) \quad [2.48]$$

MOA (**Hızlandırılmış Matematik Optime Edici**) çalışılacak aşamayı gösteren denklemdir. $MOA(C_{iterasyon})$ $C_{iterasyon}$ deki hesaplanan fonksiyon değeridir. $C_{iterasyon}$ geçerli yinelemeyi, $M_{iterasyon}$ ise maks yinelemeyi ifade eder. Min ve Maks fonksiyonun alabileceği en küçük ve en büyük değerleri tanımlar.

2.4.2 Keşif Aşaması

Keşif aşamasında, aritmetik operatörlerden bölme (D) ve çarpma (M) operatörü, keşif aşamasını yüksek dağılımlarından dolayı kullanılır [11]. AOA' da arama alanı birkaç bölgede rastgele keşfedilir ve Denklem 2.49' da modellenen iki ana arama stratejisine bağlı olarak daha iyi bir çözüm bulmaya çalışır.

$$x_{i,j}(C_{iterasyon} + 1) = \begin{cases} \text{en iyi } (x_j) \times MOP \times ((UB_j - LB_j) \times \mu + LB_j), & \text{için } r_2 > 0.5, \\ \text{en iyi } (x_j) \div (MOP + \varepsilon) \times ((UB_j - LB_j) \times \mu + LB_j), & \text{için } r_2 < 0.5, \end{cases} \quad [2.49]$$

$x_i(C_{\text{iterasyon}} + 1)$ sonraki yinelemedeki çözümü gösterir. $x_{i,j}(C_{\text{iterasyon}})$ geçerli yinelemedeki i 'nci çözümün j 'nci konumunu verir. ε pozitif bir tam sayı olup adım boyunu ifade eder. UB_j ve LB_j j 'nci pozisyonun alt ve üst sınırlarıdır.

$$MOP(C_{\text{iterasyon}}) = 1 - \left(\frac{C_{\text{iterasyon}}}{M_{\text{iterasyon}}} \right)^{1/\alpha} \quad [2.50]$$

$MOP(C_{\text{iterasyon}})$ mevcut iterasyondaki işlev değerini, α iterasyondaki doğruluğu ifade eder 5 olarak kabul edilmiştir [24].

2.4.3 Sömürü (Kullanım) Aşaması

Aritmetik operatörlerden toplama (A) ve çıkarma (S) düşük dağılımlı olduklarından dolayı (A) veya (S) hedefe daha kolay yaklaşırlar. Bundan dolayı hedefe kolay yaklaştıkları için sömürü aşamasında kullanılırlar. (A) ve (S) arama alanını birkaç yoğun bölgede Denklem 2.51' deki gibi derinlemesine araştırır.

$$x_{i,j}(C_{\text{Iter}} + 1) = \begin{cases} \text{best}(x_j) - (MOP) \times ((UB_j - LB_j) \times \mu + LB_j), r3 < 0.5 \\ \text{best}(x_j) + MOP \times ((UB_j - LB_j) \times \mu + LB_j), \text{diğer} \end{cases} \quad [2.51]$$

AOA algoritmasının sözde kodu Çizelge 2.4.1 'de verilmiştir [11].

Çizelge 2.4.1 Aritmetik Optimizasyon Algoritması Sözde Kodu

Aritmetik Optimizasyon Algoritması	
Adım 1.	Giriş: α, μ ve M_{Iter}
Adım 2.	Başlangıç değeri için ($X_i, i = 1, 2, \dots, N$)
Adım 3.	While ($C_{Iter} < M_{Iter}$) do
Adım 4.	Her bir temsilci için uygunluk değeri hesaplayın
Adım 5.	En iyi temsilciyi best (x) olarak belirleyin
Adım 6.	MOA ve MOP denklemlerini sırasıyla güncelleyin
Adım 7.	for $i = 1$ to N do
Adım 8.	for $j = 1$ to Dim do
Adım 9.	r_1, r_2 ve r_3 değerlerini güncelleyin
Adım 10.	if ($r_1 > MOA$) then
Adım 11.	Keşif Aşaması
Adım 12.	X_i 'yi güncellemek için Denklem 2.51'i kullanın
Adım 13.	else
Adım 14.	Sömürü Aşaması
Adım 15.	X_i 'yi güncellemek için Denklem 2.49'u kullanın
Adım 20.	end if
Adım 21.	end for
Adım 22.	end for
Adım 23.	$C_{Iter} = C_{Iter} + 1$
Adım 24.	end while
Adım 25.	X_{best} alın

2.5 Afrika Akbabaları Optimizasyon Algoritması (AVOA)

AVOA, Afrika akbabalarının yiyecek arama davranışları ve sosyal davranışlarından ilham alan doğa tabanlı bir metasezgiseldir [12]. Afrika akbabalarının bu davranışları matematiksel olarak modellenirken aşağıdaki temel noktalara göre şekillenmiştir [25].

- Probleme bağlı olarak belirlenecek olan ortamdaki akbaba sayısı (N), popülasyon büyüklüğü ile eşittir [25].
- Akbabalar fiziksel olarak iki kategoriye ayrılır. Akbabalar kategorilere ayrılmadan önce her birinin uygunluk değeri hesaplanır. Uygunluk değeri en

yüksek olan en uygun tepkiyi temsil için; ikinci en yüksek uygunluk değerine sahip olan ise ikinci en iyi akbabayı temsil ediyor. Her adımda en üstteki iki akbabadan biri başka akbaba popülasyonu ile değiştirilir veya değiştirilir [26].

- Akbabalarda yiyecek arama davranışı popülasyonun ortak hareketi sonucu gerçekleşir. Bunun nedeni, bir popülasyondaki her bir akbabanın yiyecek avlama ve yakalama becerilerinin farklı olmasıdır.[25]
- AVOA’ da uygunluk değerlerine göre grup üyeleri uygunluk değeri en yüksek akbabaya yaklaşırlar; uygunluk değeri en düşük olan akbabadan ise uzaklaşırlar. [25]

AVOA’ nın matematiksel modeli aşağıdaki adımlar ile gösterilmiştir.

2.5.1 En İyi Akbaba Seçimi

Başlangıç popülasyonu oluşturulduktan sonra akbabaların uygunluk değeri hesaplanır. En yüksek uygunluk değerine sahip akbaba, birinci grubun en iyi akbabası; ikinci en yüksek uygunluk değerine sahip akbaba ise, ikinci grubun en iyi akbabası olarak belirlenir. Her bir adımda bu seçim tekrarlanır. Bu durum Denklem 2.52 ile aşağıdaki gibi gösterilmiştir [12].

$$R(i) = \begin{cases} \text{En iyi akbaba}_1 & \text{eğer } p_i = L_1 \\ \text{En iyi akbaba}_2 & \text{eğer } p_i = L_2 \end{cases} \quad [2.52]$$

L_1 ve L_2 , 0-1 arasındaki parametrelerdir ve $L_1 + L_2 = 1$ dir. Denklem 2.53 kullanılarak her grup için en iyi çözümlerin, p_i seçme olasılığı her birinin seçilmesi amacıyla rulet çarkı kullanılarak elde edilir.

$$p_i = \frac{F_i}{\sum_{i=1}^n F_i} \quad [2.53]$$

F_i , i . akbabanın uygunluk değerini, n ise toplam akbaba sayısını ifade eder.

2.5.2 Akbabaların Açlık Oranı

Akbabalar yüksek enerjiye sahip olduklarında genellikle yiyecek arama davranışı gösterirler. Bu durum onların yiyecek aramak için daha uzun mesafeler gidebilmelerini sağlar; fakat enerjileri olmadığında uzun mesafelere gidemezler. Akbabaların yeterli enerjiye sahip olmadığında kendilerinden güçlü olan akbabaları takip ettikleri durumu, Denklem 2.54 ile aşağıdaki gibi gösterilmiştir.[12]

$$F = (2 \times \text{rand}_1 + 1) \times z \times \left(1 - \frac{\text{iterasyon}_i}{\text{maksimum}_{\text{iterasyon}}}\right) + t \quad [2.54]$$

F akbabaların doyduğunu, iteration i , geçerli yinelemeyi, $\text{max}_{\text{iterasyon}}$ ve z yinelemeyi değiştiren -1 ile +1 arasındaki rastgele bir değerdir. Rand ise 0 ile 1 arasındaki rastgele bir sayıdır. Denklem 2.54' te yer alan t aşağıda yer alan Denklem 2.55 ile hesaplanmaktadır.

$$t = h \times \left(\sin^w \left(\frac{\pi}{2} \times \frac{\text{iterasyon}_i}{\text{maksimum}_{\text{iterasyon}}} \right) + \cos \left(\frac{\pi}{2} \times \frac{\text{iterasyon}_i}{\text{maksimum}_{\text{iterasyon}}} \right) - 1 \right) \quad [2.55]$$

h , -2 ile +2 arasındaki rastgele bir sayıdır. w , sabit bir sayı olup keşif ve operasyon aşamaları hakkında bilgi veren bir parametredir. w değeri arttıkça keşif aşamasına girme olasılığı artarken; azalması durumunda ise arama aşamasına girme olasılığı azalır [12].

2.5.3 Keşif Aşaması

Denklem 2.54' te hesaplanan F değerinin 1' den büyük olduğu durumda akbabalar keşif aşamasındadırlar. Bu aşamadaki akbabaların görme yetenekleri, yiyecek tespit edebilme ve ölmekte olan hayvanları fark edebilme yetenekleri oldukça başarılıdır. Akbabalar uzun süre yiyecek bulamadıklarında uzun mesafeler alabilirler. Algoritma başlatıldıktan sonra keşif aşamasında, alan taraması yapmak için öncelikle 0 ve 1 arasında değer alan p_1 parametresini göre belirlerler. Daha sonra kullanacakları iki farklı keşif yöntemini seçebilmek için $[0,1]$ aralığında değer alan rand_{p_1} değeri seçilir [27]. Kullanılacak keşif yöntemini belirleme denklemleri aşağıdaki gibidir [12].

$$P(i+1) = \begin{cases} \text{Denklem(2.57) eğer } P_1 \geq \text{rand}_{p_1} \\ \text{Denklem(2.59) eğer } P_1 < \text{rand}_{p_1} \end{cases} \quad [2.56]$$

$$P(i+1) = R(i) - D(i) \times F \quad [2.57]$$

$$D(i) = |X \times R(i) - P(i)| \quad [2.58]$$

$$P(i+1) = R(i) - F + \text{rand}_2 \times ((ub - lb) \times \text{rand}_3 + lb) \quad [2.59]$$

Burada $P(i + 1)$, bir sonraki yinelemede konum vektörüdür. F , akbaba doyurulma oranını, $R(i)$ seçilen en iyi akbabalardan birisini, X ise akbabaların yiyeceklerini diğer akbabalardan korumak için hareket ettikleri konumu ifade eder. $ub - lb$, üst sınır ve alt sınırları tanımlar. $D(i)$ ise en iyi akbaba ile mevcut akbaba arasındaki konumu ifade eder. $rand_1$, $rand_2$ ve $rand_3$ rastgele sayılardır

2.5.4 Sömürü Aşaması

Denklem 2.54' te hesaplanan F değerinin 1' den küçük olduğu durumda akbabalar sömürü aşamasındadırlar. AVOA' da sömürü aşaması iki aşamadan oluşur ve her bir aşama için iki farklı strateji kullanılır [26]. Sömürü aşamasında yer alan iki aşamada kullanılan stratejiler için p_2 ve p_3 parametreleri kullanılır. p_2 , birinci aşamadaki strateji seçimi için, p_3 ise ikinci aşamadaki strateji seçimi için kullanılır [12]. F değeri 1 ile 0,5 arasında olduğunda sömürde ilk aşama gerçekleşir. Sömürünün ilk aşamasında akbabalar dönüşümlü uçuş ve kuşatma savaşı stratejilerini uygularlar. p_2 parametresinin değeri bu aşama öncesinde tanımlı hale gelir, daha sonra $rand_2$ üretilir. Denklem 2.60 ile dönel uçuş ya da kuşatma stratejileri belirlenir.

$$P(i + 1) = \begin{cases} \text{Denklem (2.61) eğer } P_2 \geq rand_{p_2} \\ \text{Denklem (2.65) eğer } P_2 < rand_{p_2} \end{cases} \quad [2.60]$$

F , değerinin 1 – 0,5 arasında olduğu durumda akbaba tok ve yeterli enerjiye sahiptir. Akbabaların bu şekilde bir besin kaynağına yönelmeleri kendi aralarında çatışmalara neden olur. Bu davranış matematiksel olarak Denklem 2.61 ile gösterilmiştir.

$$P(i + 1) = D(i) \times (F + rand_4) - d(t) \quad [2.61]$$

$$d(t) = R(i) - P(i) \quad [2.62]$$

$rand_4$, 0 ve 1 arasındaki rastgele bir sayıdır ve rastgele katsayısını artırmak için kullanılır.

Akbabalar dönel uçuş stratejileri ile dönme hareketi yaparlar. Bu hareket spiral model ile gösterilmiştir. Bu yöntemde tüm akbabalar ile en iyi iki akbabadan biri arasında sarmal bir denklem yaratılır. Bu denklemler Denklem 2.63, Denklem 2.64 ve Denklem 2.65 ile aşağıdaki gibi gösterilmiştir.

$$S_1 = R(i) \times \left(\frac{rand_5 \times P(i)}{2\pi} \right) \times \cos(P(i)) \quad [2.63]$$

$$S_2 = R(i) \times \left(\frac{\text{rand}_6 \times P(i)}{2\pi} \right) \times \sin(P(i)) \quad [2.64]$$

$$P(i + 1) = R(i) - (S_1 - S_2) \quad [2.65]$$

Sin ve *cos* parametreleri sinüs ve kosinüs fonksiyonlarına ait temsilleridir. rand_5 ve rand_6 0 ve 1 arasında rastgele değerler alan parametrelerdir. Akbabaların konumu denklem 2.65 ile güncellenir.

F değerinin 0,5' ten daha küçük olduğu durumda sömürünün ikinci aşaması gerçekleştirilir. Bu aşamada, iki akbabanın hareketleri diğer akbabaların yiyecek kaynağı üzerinde birikmelerine sebep olur ve bu durum rekabetin yanında çatışmalara yol açar. Aşama öncesinde rand_{p_3} olarak tanımlanan 0 ve 1 arasında değer alan parameter üretilir. Eğer rand_{p_3} , p_3 değerinden büyük veya ona eşitse besin kaynağı etrafında akbabaların toplanması, eğer üretilen değer p_3 parametresinden küçükse agresif kuşatma savaşı uygulaması yapılır [12]. Denklem 2.66 ile gösterilmiştir.

$$P(i + 1) = \begin{cases} \text{Denklem 2.68} & \text{eğer } P_3 \geq \text{rand}_{p_3} \\ \text{Denklem 2.69} & \text{eğer } P_3 < \text{rand}_{p_3} \end{cases} \quad [2.65]$$

Akbabaların beslenme kaynağına doğru tüm hareketleri gözlemlenir. Akbabaların yiyecek bulmada zorluk çektiği dönemlerde, akbabalar besin kaynağı için yoğun bir rekabete yol açar ve bu durum farklı ağababa türlerinin aynı besin kaynağında toplanması ile sonuçlanır. Bu durum Denklem 2.66, Denklem 2.67 ve 2.68 ile aşağıdaki gibi gösterilmiştir.

$$A_1 = \text{En iyi akbaba}_1(i) - \frac{\text{En iyi akbaba}_1(i) \times P(i)}{\text{En iyi akbaba}_1(i) - P(i)^2} \times F \quad [2.66]$$

$$A_2 = \text{En iyi akbaba}_2(i) - \frac{\text{En iyi akbaba}_2(i) \times P(i)}{\text{En iyi akbaba}_2(i) - P(i)^2} \times F \quad [2.67]$$

$\text{En iyi akbaba}_1(i)$, mevcut yinelemede birinci gruptaki en uygun 1. akbabayı, $\text{En iyi akbaba}_2(i)$ ise ikinci gruptaki en uygun 1. Akbabayı temsil eder. $P(i)$ akbabanın mevcut pozisyonunu tanımlar. Tüm akbabaları birleştirme işlem Denklem 2.68 ile aşağıdaki gibidir.

$$P(i + 1) = \frac{A_1 + A_2}{2} \quad [2.68]$$

Gruplardaki baş akbabaların yeterli beslenmeleri sonucunda zayıf düşerler ve diğer akbabalarla mücadele için yeterince enerjiye sahip olamazlar. Diğer akbabalar da beslenemediklerinden saldırganlaşırlar. Bu durum Denklem 2.69 ile tanımlanmıştır.

$$P(i + 1) = R(i) - |d(t)| \times F \times \text{Levy}(d) \quad [2.69]$$

$d(t)$, akbabanın gruplardaki en iyi akbabaya olan mesafeyi tanımlar. Levy ise Denklem 2.70 ile aşağıdaki gibi hesaplanmaktadır.

$$LF(x) = 0.01 \times \frac{u \times \sigma}{|v|^{\frac{1}{\beta}}}, \sigma = \left(\frac{\Gamma(1 + \beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma(1 + \beta/2) \times \beta \times 2^{\left(\frac{\beta-1}{2}\right)}} \right)^{\frac{1}{\beta}} \quad [2.70]$$

d problem boyutunu, u ve v 0 ve 1 arasında değer alabilen rastgele değişkenlerdir. β ise değeri 1,5 olan bir sabittir [12]. AVOA algoritmasının sözde kodu Çizelge 2.5.1’de verilmiştir [26].

Çizelge 2.5.1 Afrika Akbabaları Optimizasyon Algoritması Sözde Kodu

Afrika Akbabaları Optimizasyon Algoritması	
Adım 1.	Giriş: Popülasyon büyüklüğü N ve maksimum yineleme sayısı T
Adım 2.	Akbabaların konumu ve uygunluk değeri
Adım 3.	$(P_i i = 1, 2, \dots, N)$ popülasyonu rastgele başlatın
Adım 4.	While (durma koşulu tamamlanmıyor) do
Adım 5.	Akbabanın uygunluk değerini hesaplayın
Adım 6.	Konum ayarla Akbaba $_1$ (1. gruptaki en iyi akbabanın)
Adım 7.	Konum ayarla Akbaba $_2$ (2. gruptaki en iyi akbabanın)
Adım 8.	for (Her akbaba için $P(i)$ yi hesapla) do
Adım 9.	Denklem 2.52' yi kullanarak $R(i)$ ' yi seçin
Adım 10.	Denklem 2.54' ü kullanarak F' yi güncelleyin
Adım 11.	if ($ F \geq 1$) then
Adım 12.	if ($p_1 \geq rand_{p1}$) then
Adım 13.	Denklem 2.57 ile akbabanın konumunu güncelle
Adım 14.	else
Adım 15.	Denklem 2.59 ile akbabanın konumunu güncelle
Adım 20.	if ($ F < 1$) then
Adım 21.	if ($ F \geq 0.5$) then
Adım 22.	if ($p_2 \geq rand_{p2}$) then
Adım 23.	Denklem 2.61 ile akbabanın konumunu güncelle
Adım 24.	else
Adım 25.	Denklem 2.65 ile akbabanın konumunu güncelle
Adım 26.	else
Adım 27.	if ($p_3 \geq rand_{p3}$) then
Adım 28.	Denklem 2.68 ile akbabanın konumunu güncelle
Adım 29.	else
Adım 30.	Denklem 2.69 ile akbabanın konumunu güncelle
Adım 31.	P Akbaba $_1$ 'i getir

2.6 Kaya Kartalı Optimizasyon Algoritması (AO)

AO, kaya kartallarının avlanma ve avlarını yakalama becerilerinden ilham alan popülasyon tabanlı bir optimizasyon algoritmasıdır [13]. Kaya kartalları tarafından kullanılan avlanma ve av yakalama yöntemleri şu şekildedir:

- Birinci yöntem, dikey eğimli yüksek uçuş, kaya kartallarının yükseklerde uçuş esnasındaki avlanma yöntemidir. Kaya kartalı, av bulduklarında, ava doğru dikey bir dalış gerçekleştirir [28].
- İkinci yöntem, kısa süzülme saldırısıyla kontur uçuşu, kaya kartallarının yerden düşük bir seviyedeki uçuşu esnasındaki avlanma yöntemidir. En sık olarak tercih edilen avlanma yöntemidir. Orman tavuğu, yer sincapları ve deniz kuşları avı için bu yöntem özellikle tercih edilmektedir [29].
- Üçüncü yöntem, yavaş alçalma saldırısı ile alçak uçuş, kaya kartallarının yere inerek ve sonrasında avına saldırarak avlanmasıdır. Kaya kartalları bu yöntem ile avını boynundan ve sırtından yakalayarak avlar. Daha çok yavaş hareket eden avlar için kullanılan bir yöntemdir [30].
- Dördüncü yöntem, Kaya kartalının yürüyerek avını yakalaması, Kaya kartalları av için yere inerek avı yakalar. Bu yöntem daha çok büyük avların yavrularını avlamak için tercih edilir [13].

Kaya kartalı optimizasyonunda keşif ve sömürü aşaması aşağıda yer alan Denklem 2.62' deki şarta bağlı olarak seçilir [13].

$$t \leq \left(\frac{2}{3}\right) * T \quad [2.62]$$

t anlık iterasyonu, T ise maksimum iterasyon sayısını tanımlar. $t \leq \left(\frac{2}{3}\right) * T$ koşulu sağlandığı durumda keşif aşaması, sağlanmadığı durumda ise algoritması sömürü aşamasındadır.

2.6.1 Başlatma

AOA, Denklem 2.63' te gösterildiği gibi rastgele oluşturulan bir aday çözüm havuzu ile başlatılır [28].

$$X = \begin{bmatrix} x_{1,1} & x_{1,2} & \cdots & x_{1,D-1} & x_{1,D} \\ x_{2,1} & \ddots & \cdots & \ddots & x_{2,D} \\ \vdots & \cdots & \ddots & \cdots & \vdots \\ x_{N-1,1} & \ddots & \cdots & \ddots & x_{N-1,D} \\ x_{N,1} & x_{N,2} & \cdots & x_{N,D-1} & x_{N,D} \end{bmatrix}_{N \times D} \quad [2.63]$$

X her bir bireyi, N aday çözüm sayısını, D ise problem boyutunu ifade etmektedir. Denklem 2.63' te yer alan her bir aday çözüm aşağıda yer alan Denklem 2.64 ile ortaya çıkarılmaktadır.

$$X_{ij} = \text{rand} * (UB_j - LB_j) + LB_j, i = 1, 2, \dots, N, j = 1, 2, \dots, D \quad [2.64]$$

X_i i . çözümün değerini, LB_j j . alt sınırı, UB_j j . üst sınırı ve rand ise rastgele bir sayıyı tanımlar.

2.6.2 Genişletilmiş keşif

Kaya kartalları, av için bölgesini yüksekte uçarak tanır ve en iyi avlanma alanını seçer. Burada geniş çapta keşifler yapılır. Av bulunduğu zaman dikey bir dalış gerçekleştirir. Bu hareket Denklem 2.65 ile gösterilmiştir [30].

$$X_1(t+1) = X_{\text{en iyi}}(t) \times \left(\frac{1-t}{T}\right) + (X_M(t) - X_{\text{en iyi}}(t) \times \text{rand}) \quad [2.65]$$

$X_1(t+1)$ t 'den bir sonraki adım çözümünü, X_1 ilk aday çözümü, $X_{\text{en iyi}}(t)$ t . adımdaki en iyi aday çözümü, $\left(\frac{1-t}{T}\right)$ ise keşif kontrolü tanımlar. $X_M(t)$ t . adımdaki çözümlerin ortalamasıdır. Rand 0 ile 1 arasındaki rastgele bir sayıdır.

2.6.3 Daraltılmış keşif

Kaya kartalları yüksek uçuş ile av bölgesini belirlediklerinde, kaya kartalı, hedefin üzerinde daireler çizerek inmeye hazırlanır ve ardından avına saldırır. Bu kaya kartallarının 2.avlanma yöntemi olan kısa süzülme saldırısıyla kontur uçuşudur [30]. Bu davranış Denklem 2.66 ile gösterilmiştir

$$X_2(t+1) = X_{\text{en iyi}}(t) * \text{Levy}(D) + X_R(t) + (y - x) * \text{rand} \quad [2.66]$$

$X_2(t+1)$, $t+1$.adımındaki çözümdür. $X_R(t)$, t . iterasyonundaki $[1 \ N]$ aralığındaki rastgele bir çözümdür. Levy (D) levy flight dağılım fonksiyonudur ve Denklem 2.67 ile hesaplanmaktadır.

$$\text{Levy}(D) = s \times \frac{u \times \sigma}{|v|^{\frac{1}{\beta}}} \quad [2.67]$$

s değeri 0,01 olarak kabul edilir . u ve v , 0 ve 1 arasındaki rastgele değerlerdir. σ parametresi ise Denklem 2.68 ile aşağıdaki gibi hesaplanmaktadır.

$$\left(\frac{\Gamma(1 + \beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1 + \beta}{2}\right) \times \beta \times 2^{\frac{\beta-1}{2}}} \right) \quad [2.68]$$

β değeri 1,5 olan bir sabittir. Denklem 2.66’ daki x ve y aramadaki spiral şekli ifade ederler. x ve y Denklem 2.69 ile aşağıdaki şekilde hesaplanır.

$$\begin{aligned} y &= r \times \cos(\theta) \text{ ve } x = r \times \sin(\theta), \\ r &= r_1 + U \times D_1 \text{ ve } \theta = -\omega \times D_1 + \theta_1, \theta_1 = \frac{3\pi}{2} \end{aligned} \quad [2.69]$$

r_1 , 1 ile 20 arasındaki arama döngü sayısı olup sabit bir sayıdır. U , 0,00565 değerine eşittir [29]. D_1 , 1 ile arama uzayının boyutu (D) arasındaki bir tam sayıdır ve ω sayısı 0,005’ e eşittir [30].

2.6.4 Genişletilmiş sömürü

Kaya kartalları, av alanını belirledikten sonra saldırı için hazır hale gelirler. Bu bir ön saldırıdır ve bu saldırı ile avın tepkisi ölçülür. Kaya kartalları burada, yavaş alçalma saldırısı ile alçak uçuş yöntemini kullanarak ava daha fazla yaklaşmış olurlar. Kaya kartallarının bu davranışı Denklem 2.70 ile gösterildiği gibidir [31].

$$X_3(t + 1) = (X_{\text{en iyi}}(t) - X_M(t)) \times \alpha - r_4 + ((UB - LB) \times r_5 + LB) \times \delta \quad [2.70]$$

$X_3(t + 1)$, $t + 1$. iterasyondaki çözümü, α ve δ 0,1 değerlerine sahip parametrelerdir.

2.6.5 Daraltılmış sömürü

Kaya kartallarının, avın konumuna en yakın olduğu anda gerçekleştirmiş olduğu saldırı türüdür. Bu saldırı karada gerçekleşir ve yürüyerek avın yakalanması yöntemi uygulanır. Bu davranış Denklem 2.71 ile aşağıdaki gibi gösterilmiştir [31].

$$\begin{aligned} X_4(t + 1) &= QF \times X_{\text{en iyi}}(t) - (G_1 \times X(t) \times \text{rand}) - G_2 \times \text{Levy}(D) \\ &+ \text{rand} \times G_1 \end{aligned} \quad [2.71]$$


$$QF(t) = t^{\frac{2 \times \text{rand}() - 1}{(1-T)^2}} \quad [2.72]$$

$$G_1 = 2 \times \text{rand} - 1 \quad [2.73]$$

$$G_2 = 2 \times \left(1 - \frac{t}{T}\right) \quad [2.74]$$

$X_4(t + 1)$, $t + 1$. iterasyondaki çözümü, QF keşif yöntemlerini dengeleyen kalite fonksiyonunu temsil eder. G_1 , $[-1, +1]$ aralığındaki kaçma sırasında avı takip için, G_2 2’den 0’ doğru azalan, kaçma sırasında avı takip için kullanılan eğim parametreleridir. $X(t)$, t .adımdaki çözümdür. r_6, r_7 ve r_8 0 ve 1 arasında rastgele bir değer alan parametrelerdir. AOA’ nın akış şeması Şekil 2.6.1 ile aşağıdaki gibi gösterilmiştir [32].





Şekil 2.6.1 AO akış şeması

2.7 Yapay Tavşan Optimizasyon Algoritması (ARO)

2022 yılında önerilen ARO; tavşanların yiyecek arama, rastgele saklanma ve enerji küçültme stratejilerini taklit eden bir optimizasyon algoritmasıdır [14]. Optimizasyon algoritmalarının temeli olan keşif aşaması ARO ‘da yiyecek arama davranışını, sömürü aşaması ise rastgele saklanma aşamasına karşılık gelir. ARO’ da keşif

aşamasından sömürü aşamasına geçiş, enerji küçültme stratejisi ile gerçekleştirilmektedir [33]. ARO' nun matematiksel modeli şu şekildedir:

2.7.1 Başlatma Aşaması

AROA' da ilk adım, aday çözümlerin(tavşan) rastgele olarak konumlandırılıp bunların uygunluk değerlerinin hesaplanmasıdır. Aşağıda Denklem 2.73 ile aday çözümlerin rastgele konumlandırılması, Denklem 2.74 ile ise aday çözümlerin uygunluk değeri hesaplanması yer almaktadır.

$$\vec{x}_{i,d} = lb_d + \text{rand} \times (ub_d - lb_d) \quad i = (1, 2, \dots, N) \text{ ve } d = (1, 2, \dots, D) \quad [2.75]$$

$\vec{x}_{i,d}$ i . tavşanın konum vektörü, N ve D sırasıyla tavşan sayısı problem boyutu, tasarım parametreleri ve ub_d ve lb_d d . boyutun alt ve üst sınırlarıdır.

$$P \equiv \begin{bmatrix} x_{1,1} & \dots & x_{1,D} \\ \vdots & \ddots & \vdots \\ x_{N,1} & \dots & x_{N,D} \end{bmatrix}_{N \times D} \quad f = \begin{bmatrix} f_1 \\ \vdots \\ f_N \end{bmatrix}_{N \times 1} \quad [2.76]$$

P tavşan popülasyonunu, f uygunluk değerini ifade eder.

2.7.2 Dolambaçlı yiyecek arama

AROA' da popülasyondaki her bir tavşan başlatma aşaması ile rastgele olarak konumlandırılmıştır. Her bir konumdaki tavşanın yiyecek ve saklanma için bir yuvaya sahip olduğu varsayılmaktadır. Tavşanlar yiyecek arama işlemlerini kendi bulundukları konumda değil de komşu tavşanların konumlarında yaparlar. Tavşanların bu hareketine dolambaçlı yiyecek arama (keşif) denir [14]. Bu davranış modeli aşağıdaki gibi hesaplanmaktadır.

$$\vec{v}_i(t+1) = \vec{x}_j(t) + R \cdot (\vec{x}_i(t) - \vec{x}_j(t)) + \text{round}(0.5 \cdot (0.05 + r_1)) \cdot n_1 \quad [2.77]$$

$$i, j = 1, \dots, n \text{ ve } j \neq i$$

$$R = L \cdot c \quad [2.78]$$

$$L = \left(e - e^{\left(\frac{t-1}{T}\right)^2} \right) \cdot \sin(2\pi r_2) \quad [2.79]$$

$$c(k) = \begin{cases} 1 & \text{if } k == g(l) \\ 0 & \text{else} \end{cases} \quad k = 1, \dots, d \text{ and } l = 1, \dots, [r_3 \cdot d] \quad [2.80]$$

$$g = rand_{perm}(d) \quad [2.81]$$

$$n_1 \sim N(0,1) \quad [2.82]$$

$\vec{v}_i(t+1)$, $t+1$. anındaki i . tavşan konumunu, $\vec{x}_i(t)$, t anındaki tavşan konumunu, N popülasyon büyüklüğünü, t o anki iterasyonu, T max iterasyon sayısını ifade eder. $rand_{perm}$ 1' den d ' ye kadarki tam sayıların geriye döndürüldüğü bir permütasyon değeridir. r_1, r_2 ve r_3 0 ile 1 arasındaki rastgele bir sayıdır. L modeldeki hareket hızını temsil eden koşu uzunluğudur. n_1 ise standart normal bir dağılımdır [34].

2.7.3 Rastgele saklanma

ARO' da her bir yineleme boyunca her bir tavşan kendi çevresinde rastgele yuva oluştururlar. Tehditlere karşı tavşanlar saklanmak amacıyla kendi yuvaları yerine komşu tavşanların oluşturmuş olduğu yuvalardan birini rastgele seçerler [36]. Denklem 2.83 ile bir tavşanın çevresinde oluşturmuş olduğu yuvalar gösterilmiştir [32]. Diğer denklemler (2.84-2.86) bu denklemin hesaplanması için kullanılmaktadır.

$$\vec{b}_{i,j}(t) = \vec{x}_i(t) + H \cdot g \cdot \vec{x}_i(t), i = 1, \dots, n \text{ and } j = 1, \dots, d \quad [2.83]$$

$$H = \frac{T - t + 1}{T} \cdot r_4 \quad [2.84]$$

$$n_2 \sim N(0,1) \quad [2.85]$$

$$g(k) = \begin{cases} 1 & \text{if } k == j \\ 0 & \text{else} \end{cases} k = 1, \dots, d \quad [2.86]$$

H , gizleme parametresidir ve doğrusal olarak yinelemeler boyunca 1' den $1/T$ 'ye düşer. $\vec{b}_{i,j}$, i . tavşanın j . yuvasıdır. n_2 ise standart normal bir dağılımdır.

Tehditlere karşı tavşanlar rastgele olarak komşu tavşanların yapmış oldukları yuvalardan birini rastgele seçerler [35]. Bu seçme işlemi Denklem 2.87, Denklem 2.88 ve Denklem 2.59 ile gösterilmiştir [14].

$$\vec{v}_i(t+1) = \vec{x}_i(t) + R \cdot (r_4 \cdot \vec{b}_{i,r}(t) - \vec{x}_i(t)), i = 1, \dots, n \quad [2.87]$$

$$g_r(k) = \begin{cases} 1 & \text{if } k == \lceil r_5 \cdot d \rceil \\ 0 & \text{else} \end{cases} k = 1, \dots, d \quad [2.88]$$

$$\vec{b}_{i,r}(t) = \vec{x}_i(t) + H \cdot g_r \cdot \vec{x}_i(t) \quad [2.89]$$

$\vec{b}_{i,r}$, i . tavşan tarafında rastgele seçilmiş yuvayı, r_4 ve r_5 0 ile 1 arasındaki rastgele bir sayıdır.

ARO' da dolambaçlı yiyecek arama ve rastgele saklanma gerçekleştikten sonra konum güncellemesi yapılır. Konum güncelleme denklemi Denklem 2.90 ile ortaya çıkarılmaktadır [14].

$$\vec{x}_i(t+1) = \begin{cases} \vec{x}_i(t) & f(\vec{x}_i(t)) \leq f(\vec{v}_i(t+1)) \\ \vec{v}_i(t+1) & f(\vec{x}_i(t)) > f(\vec{v}_i(t+1)) \end{cases} \quad [2.90]$$

Denklem 2.90 ile mevcut konum uygunluk değeri aday çözüme ait uygunluk değerinden daha iyiye yer değiştirme yapılmaz, iyi değilse yer değiştirme yapılır.

2.7.4 Enerji küçültme

ARO' da tavşanlar enerji seviyesine göre ilerlemeler arttıkça keşif aşamasından sömürü aşamasına geçerler [36]. Denklem 2.91 geçişi temsil edilmektedir [14].

$$A(t) = 4 \left(1 - \frac{t}{T} \right) \ln \frac{1}{r} \quad [2.91]$$

r değeri 0 ile 1 arasında rastgele bir değerdir. Tavşanlar $A(t) > 1$ ise, yiyecek arama yani keşif aşaması; $A(t) < 1$ olduğunda ise rastgele saklanma yani sömürü aşamasındadırlar. ARO algoritmasının temel adımları Çizelge 2.7.1 ile aşağıdaki gibi gösterilmiştir [14].

Çizelge 2.7.1 Yapay Tavşan Algoritması Adımları

Yapay Tavşan Algoritması	
Adım 1.	Başlatma
Adım 2.	P , rastgele bir tavşan popülasyonu oluşturun
Adım 3.	for $i = 1: N$ (tavşan sayısı) do
Adım 4.	f_i : Her bir tavşanın uygunluk değerini hesaplayın
Adım 5.	end
Adım 6.	repeat
Adım 7.	Adım 1: Seçim aşaması
Adım 8.	P başlangıç tavşanlarını seçin
Adım 9.	Adım 2: Arama aşaması
Adım 10.	Dolambaçlı yiyecek arama (Keşif)
Adım 11.	Rastgele saklanma (Sömürü)
Adım 12.	Adım 3: Güncelleme aşaması
Adım 13.	Tavşanların uygunluk değerlerine göre P popülasyonu güncelle
Adım 14.	until
Adım 15.	end

2.8 Dağ Ceylanı Optimizasyonu (MGO)

MGO, yabani dağ ceylanlarının sosyal yaşamlarını ve kendi aralarındaki hiyerarşilerini ilham alan metasezgisel bir algoritmadır [15]. Bu algoritma dağ ceylanlarının yaşamlarındaki dört temel noktayı ele alır. Bunlar: Bekar erkek sürüleri, doğum sürüleri, bölgesel bekar erkekler ve yiyecek bulmak için gerçekleştirilen göç davranışı [37]. MGO’ da her bir ceylan X_i , bekar erkek sürüsü, doğum sürüsü ya da bölgesel erkek sürüsü üyelerinden birisi olabilir [38]. MGO algoritmasının matematiksel modeli aşağıdaki gibi sunulmuştur.

2.8.1 Bölgesel Bekar Erkekler

Erkek dağ ceylanları yetişkin olup güçlendiklerinde kendilerine bir bölge oluştururlar. Bu bölgeler birbirlerinden oldukça mesafelidir ve bu şekilde dağ ceylanları bölgesel olarak yaşarlar. Erkek dağ ceylanları, dişi ceylanlar üzerinde hakimiyet ve bölge kontrolü mücadelesi verirler. Burada genç erkek ceylanlar ise bölge işgali ve dişi

hakimiyeti kurmak istediklerinde dağ ceylanlarının koruma davranışı ile karşılaşılır [39]. Yetişkin dağ ceylanını bölge modellemesi Denklem 2.92 ile aşağıdaki gibidir [15].

$$TSM = \text{erkek}_{\text{ceylan}} - |(ri_1 \times BH - ri_2 \times X(t)) \times F| \times \text{Cof}_r \quad [2.92]$$

Burada $\text{erkek}_{\text{ceylan}}$, en iyi küresel çözümün konum vektörü; ri_1, ri_2 parametreleri 1 veya 2 rastgele tamsayılarıdır. BH genç erkek sürü katsayısı, Cof_r her yinelemede güncellenen, arama yeteneğini artırmak için kullanılan rastgele bir katsayı vektörüdür. BH Denklem 2.93 ile aşağıdaki gibi hesaplanır [15].

$$BH = X_{ra} \times [r_1] + M_{pr} \times [r_2], ra = \left\{ \left\lfloor \frac{N}{3} \right\rfloor \dots N \right\} \quad [2.93]$$

X_{ra} , Genç bir ceylanın ra aralığındaki rastgele bir çözümdür. r_1 ve r_2 0 ve 1 arasındaki rastgele sayılardır. Rastgele seçilmiş çözüm adaylarının ortalama değeridir. N ise toplam dağ ceylanı sayısıdır. F değeri Denklem 2.94 ile aşağıdaki gibi hesaplanmaktadır [15].

$$F = N_1(D) \times \exp \left(2 - \text{iterasyon} \times \left(\frac{2}{\text{Maksimum}_{\text{iterasyon}}} \right) \right) \quad [2.94]$$

N_1 , standart dağılımdan rastgele bir sayıdır. $\exp$ üstel fonksiyon, $\text{Maksimum}_{\text{iterasyon}}$, maksimum adım sayısıdır. Cof_r , Denklem 2.95 ile aşağıdaki gibi hesaplanmaktadır [15].

$$\text{Cof}_i = \begin{cases} (a + 1) + r_3, \\ a \times N_2(D), \\ r_4(D), \\ N_3(D) \times N_4(D)^2 \times \cos((r_4 \times 2) \times N_3(D)) \end{cases} \quad [2.95]$$

r_3, r_4 ve $rand$ 0 ve 1 arasındaki rastgele sayılardır. N_2, N_3 ve N_4 normal aralığa ve problem boyutlarına göre rastgele sayılardır. a parametresi ise Denklem 2.96 ile ifade edilir [15].

$$a = -1 + \text{iterasyon} \times \left(\frac{-1}{\text{Maksimum}_{\text{iterasyon}}} \right) \quad [2.96]$$

2.8.2 Doğum Sürüleri

Dağ ceylanları, erkek yavrular üretmek için doğum sürülerine bağımlı olan bir türdür. Erkek ceylanlar, dişi elde etmeye çalışan genç erkeklerle yardımlarının yanında dişi ceylanların doğumuna da yardımcı olabilirler [40]. Bu davranışları Denklem 2.97 ile tanımlanır [15].

$$MH = (BH + \text{Cof}_{1,r}) + r_{i_3} \times \text{erkek}_G - r_{i_4} \times X_{\text{rand}}) \times \text{Cof}_{2,r} \quad [2.97]$$

BH , genç erkeklerin etki faktörü, $\text{Cof}_{1,r}$ ve $\text{Cof}_{2,r}$ bağımsız olarak hesaplanan rastgele seçilmiş katsayı vektörleridir. r_{i_3} ve r_{i_4} 1 ya da 2 değerini alan rastgele tamsayılardır. X_{rand} , tüm popülasyondan seçilen rastgele bir ceylanın konum vektörüdür.

2.8.3 Bekar Erkek Sürüleri

Erkek ceylanlar olgunlaştıkça bölge üretme ve dişi ceylanlar üzerinde kontrolü ele geçirme eğilimindedir. Bu noktada genç erkek ceylanlar dişiler üzerinde hâkimiyet kurmak için yetişkin erkeklerle mücadele etmeye başlar ve şiddet ortaya çıkabilir [41]. Bu davranış matematiksel olarak Denklem 2.98 ile aşağıdaki şekilde ifade edilir [15].

$$BMH = (X(t) - D) + (r_{i_5} \times \text{erkek}_{\text{ceylan}} - r_{i_6} \times BH) \times \text{Cof}_r \quad [2.98]$$

$X(t)$, anlık ceylan vektörel konumu, r_{i_5} ve r_{i_6} 1 ya da 2 tamsayılarını alan rastgele sayılardır. $\text{erkek}_{\text{ceylan}}$, erkek ceylanın vektörel konumudur. BH ise genç erkek sürüsünün etki faktörü, Cof_r rastgele seçilmiş katsayı vektörüdür. D Denklem 2.99 ile aşağıdaki gibi tanımlanır.

$$D = (|X(t)| + |\text{erkek}_{\text{gazelle}}|) \times (2 \times r_6 - 1) \quad [2.99]$$

r_6 0 ve 1 arasındaki rastgele bir sayıdır.

2.8.4 Yiyecek Aramaya Geçiş

Dağ ceylanları, otlamak ve yiyecek kaynağı bulabilmek için devamlı uzun yolculuklar yaparlar. Bu yolculukları, yüksek hızlı koşma ve atlama becerileri yardımıyla gerçekleştirirler [41]. Dağ ceylanlarının bu davranışı Denklem 2.100 ile aşağıdaki gibi gösterilir [15].

$$MSF = (ub - lb) \times r_7 + lb \quad [2.100]$$

ub ve lb sırasıyla problemin üst ve alt sınırlarıdır. r_7 0 ve 1 arasındaki rastgele bir sayıdır.

Yeni nesil ceylanlar üretmek için yukarıdaki dört mekanizma tüm ceylanlara uygulanır. Popülasyona yeni bir nesil eklenir ve her nesil bir kopyaya eşittir. Her bir nesilde ceylanlar çözüm kalitelerine göre sıralanmaktadır. Kaliteli ve gelecek vaat eden çözümlere sahip, maliyeti daha düşük olan en iyi ceylanlar toplam popülasyonda korunmaktadır. Yaşlı veya zayıf olduğu düşünülen diğer ceylanlar ise tüm popülasyondan uzaklaştırılır. En iyi ceylan aynı zamanda bölgenin sahibi olan yetişkin erkek ceylan olarak da kabul edilir [15]. MGO' nun sözde kodu Çizelge 2.8.1 ile aşağıdaki gibi gösterilmiştir [37].

Çizelge 2.8.1 Dağ Ceylanı Optimizasyonu Sözde Kodu

Dağ Ceylanı Optimizasyonu	
Adım 1.	Girdi: Popülasyon büyüklüğü N ve maksimum yineleme sayısı T
Adım 2.	Çıktı: Ceylanın konumu ve uygunluk potansiyeli
Adım 3.	$X_i (i = 1, 1, \dots, N)$ ' yi kullanarak rastgele bir popülasyon oluşturun
Adım 4.	Ceylanların uygunluk değerlerini hesaplayın
Adım 5.	While durma koşulu sağlanmadığı sürece
Adım 6.	for (her bir ceylan için X_i hesapla)
Adım 7.	Bölgesel bekar erkekler hesapla
Adım 8.	Doğum sürüleri hesapla
Adım 9.	Bekar erkek sürüleri hesapla
Adım 10.	Yiyecek aramaya geçiş hesapla
Adım 11.	Bölgesel bekar erkekler, Doğum sürüleri, Bekar erkek sürüleri ve Yiyecek aramaya geçiş aşamalarının uygunluk değerlerini hesaplayın ve bunları alana ekleyin
Adım 12.	end for
Adım 13.	Popülasyonu artan sırada sıralayın
Adım 14.	$en\ iyi_{ceylan}$ güncelle
Adım 15.	Maksimum popülasyon da $en\ iyi_{ceylan}$ ' ı kaydedin
Adım 16.	end while
Adım 17.	Return $en\ iyi_{ceylan}$

2.9 Çayır Köpeği Optimizasyon Algoritması (PDO)

PDO, çayır köpeklerinin yiyecek arama ve yuva yapma davranışlarından ilham alarak geliştirilmiş bir optimizasyon algoritmasıdır [16]. PDO’ da çayır köpeklerinin yiyecek arama ve yuva inşa etme faaliyetleri, optimizasyon için keşif aşamasıdır. Çayır köpeklerinin en önemli özelliklerinden biri de iletişim becerileridir. Bu iletişim becerileri ile avcı tehditleri, yiyecek ile ilgili çeşitli bilgiler gibi seslere sahiptirler. PDO’ da sömürü aşaması ise çayır köpeklerinin iletişim ve avcılara karşı mücadelelerini kapsamaktadır [42]. PDO’ da keşif ve sömürü aşamaları $maks_{iterasyon}$ sayısına bağlı olarak uygulanır. İlk iki bölüm, keşif aşamasını; son iki bölüm ise sömürü aşamasını tanımlar [16]. Algoritmanın keşif ve sömürü aşamaları sırasıyla Denklem 2.103 ve Denklem 2.104 olarak aşağıda gösterilmiştir [42].

$$\text{iterasyon} < \frac{Maksimum_{iterasyon}}{4} \text{ ve } \frac{Maksimum_{iterasyon}}{4} \leq \text{iterasyon} \quad [2.103]$$

$$< \frac{Maksimum_{iterasyon}}{2}$$

$$\frac{Maksimum_{iterasyon}}{2} \leq \text{iterasyon} \quad [2.104]$$

$$\leq 3 \frac{Maksimum_{iterasyon}}{4} \text{ ve } 3 \frac{Maksimum_{iterasyon}}{4}$$

$$\leq \text{iterasyon} \leq Maksimum_{iterasyon}$$

PDO’ nın matematiksel modeli aşağıdaki alt bölümlerde tanımlanmıştır.

2.9.1 Başlatma Aşaması

PDO’ da çayır köpekleri (PD) rastgele olarak konumlandırılarak başlangıç popülasyonu oluşturulur. Çayır köpeği popülasyonları, arama araçlarıdır ve her bir çayır köpeğini temsil etmek için d-boyutlu uzayda vektör kullanılır [16]. Bir PDO kolonisi, m adet zümre ve bu m adet zümrede, n adet çayır köpeğinin yer almasıyla oluşur. Zümredeki her bir çayır köpeğinin (PD) konumu vektör ile gösterilir. Denklem 2.105 ile bir kolonideki zümrelerin konumları gösterilir.

$$CT = \begin{bmatrix} CT_{1,1} & CT_{1,2} & \cdots & CT_{1,d} & CT_{1,d} \\ CT_{2,1} & CT_{2,2} & \cdots & CT_{2,d-1} & CT_{2,d} \\ \vdots & \vdots & CT_{i,j} & \vdots & \vdots \\ CT_{m,1} & CT_{m,2} & \cdots & CT_{m,d-1} & CT_{m,d} \end{bmatrix} \quad [2.105]$$

$CT_{i,j}$ kolonideki i . zümrenin j . boyutunu ifade eder. Bir zümredeki çayır köpeklerinin konumu ise Denklem 2.106 ile aşağıdaki gibidir.

$$PD = \begin{bmatrix} PD_{1,1} & PD_{1,2} & \cdots & PD_{1,d-1} & PD_{1,d} \\ PD_{2,1} & PD_{2,2} & \cdots & PD_{2,d-1} & PD_{2,d} \\ \vdots & \vdots & PD_{i,j} & \vdots & \vdots \\ PD_{n,1} & PD_{n,2} & \cdots & PD_{n,d-1} & PD_{n,d} \end{bmatrix} \quad [2.106]$$

$PD_{i,j}$ i . çayır köpeğinin j . boyutunu verir. $n \leq m$ koşulu sağlanmalıdır. Her bir çayır köpeği ve zümrenin konumu sırasıyla Denklem 2.107 ve Denklem 2.108 ile aşağıdaki gibi gösterilir.

$$CT_{i,j} = U(0,1) * (UB_j - LB_j) + LB_j \quad [2.107]$$

$$PD_{i,j} = U(0,1) * (ub_j - lb_j) + lb_j \quad [2.108]$$

UB_j ve LB_j , optimizasyon problemine dair j . boyutun üst ve alt sınırlarıdır. $ub_j = UB_j/m$, $lb_j = LB_j/m$ ve U , 0 ile 1 arasındaki rastgele bir sayıdır. Her bir çayır köpeğinin konumuna ait uygunluk değeri yiyeceğin kalitesini, yuva kurma potansiyelini ve avcılardan korunma derecesini gösterir. Uygunluk değeri hesabı her bir çayır köpeği için yapıldıktan sonra bir dizi şeklinde sıralama yapılır ve optimizasyon problemine göre minimum 4 ya da maksimum 4 değer alınır. Minimizasyon problemleri için alınan 4 değerden minimum olanı en iyi çözüm kabul edilir. Maksimizasyon problemi için ise 4 değerden maksimum olanı alınarak en iyi kabul edilir. Geriye kalan 3 değer çayır köpeklerinin yuva inşa etme davranışı için dikkate alınır [16]. PDO' da her bir çayır köpeğinin uygunluk değeri Denklem 2.209' de olduğu gibi hesaplanmaktadır [42].

$$f(PD) = \begin{bmatrix} f_1([PD_{1,1} & PD_{1,2} & \cdots & PD_{1,d-1} & PD_{1,d}]) \\ f_2([PD_{2,1} & PD_{2,2} & \cdots & PD_{2,d-1} & PD_{2,d}]) \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ f_n([PD_{n,1} & PD_{n,2} & \cdots & PD_{n,d-1} & PD_{n,d}]) \end{bmatrix} \quad [2.109]$$

Burada $f(PD_{n,d})$ n . çayır köpeğinin d . boyutundaki uygunluk değerini verir.

2.9.2 Keşif Aşaması

Çayır köpeklerinin yiyecek arama ve yuva inşa etme faaliyetleri bu aşamada gerçekleştirilir. Çayır köpekleri yuvalarını besin kaynağının bol olduğu alanlara inşa ederler. Besin kaynakları tükendiği anda yeni besin kaynağı keşfederek, besin kaynağı çevresine yeni yuvalarını inşa ederler. Denklem 2.101 ile algoritmanın keşif aşaması tanımlanmıştır. Çayır köpeklerinin yiyecek arama davranışı Levy uçuş hareketi ile gösterilir. Bu hareket ile çayır köpekleri geniş bir alanda besin kaynakları için keşif yaparlar. Yiyecek kaynakları keşfedildiğinde, çayır köpekleri kullandıkları sesler ile sürünün diğerlerine bilgi verilir. Besin kaynağının miktarı ve kalitesine göre yeni yuva inşa edilir. Denklem 2.108 ile yiyecek arama için konum güncellemesi aşağıdaki gibi hesaplanmıştır [16].

$$PD_{i+1,j+1} = GEn\ iyi_{i,j} - eCEn\ iyi_{i,j} \times \rho - CPD_{i,j} \times Levy(n) \forall \text{ iterasyon} < \frac{\text{Maksimum iterasyon}}{4} \quad [2.108]$$

Denklem 2.109 ile yeni yuva inşa konum güncellemesi aşağıdaki gibi gösterilmiştir.

$$PD_{i+1,j+1} = GBest_{i,j} \times rPD \times DS \times Levy(n) \forall \frac{\text{Maksimum iterasyon}}{4} \leq \text{iterasyon} < \frac{\text{Maksimum iterasyon}}{2} \quad [2.109]$$

$GBest_{i,j}$, global anlamdaki en iyi çözüm olduğu durumda $eCBest_{i,j}$ mevcut en iyi çözümün etkinini tanımlar ve Denklem 2.110 ile aşağıdaki hesaplanır.

$$eCEn\ iyi_{i,j} = GEn\ iyi_{i,j} \times \Delta + \frac{PD_{i,j} \times mean(PD_{n,m})}{GEn\ iyi_{i,j} \times (UB_j - LB_j) + \Delta} \quad [2.110]$$

$$CPD_{i,j} = \frac{GEn\ iyi_{i,j} - rPD_{i,j}}{GEn\ iyi_{i,j} + \Delta} \quad [2.111]$$

$$DS = 1.5 \times r \times \left(1 - \frac{\text{iterasyon}}{\text{Maksimum iterasyon}} \right)^{\left(2 \frac{\text{iterasyon}}{\text{Maksimum iterasyon}} \right)} \quad [2.112]$$

r , keşif için kullanılan -1 veya $+1$ değerlerini alan bir parametredir. Δ ise çayır köpekleri arasındaki farkı ifade eden bir tam sayıdır.

2.9.3 Sömürü Aşaması

Çayır köpeklerinin iletişim ve avcılara karşı mücadeleleri bu aşamada gerçekleştirilir. PDO’ da kullanılan sömürü mekanizmalarının amacı, keşif aşamasında keşfedilen bölgelerin yoğun bir şekilde araştırmaktır. Bu aşama Denklem 2.102 ile tanımlanmıştır. Çayır köpeklerinin iki özel çağrısı bulunmaktadır. Bunlar bir yırtıcı hayvan önleme ve yeni besin kaynağı (yeni yuva inşa etme) çağrısıdır. Sömürü aşamasında kullanılan stratejiler Denklem 2.113 ve Denklem 2.114 ile aşağıdaki gibi gösterilmiştir [43].


$$PD_{i+1,j+1} = GEN\ iyi_{i,j} - eCEn\ iyi_{i,j} \times \varepsilon - CPD_{i,j} \times rand \forall \frac{Maks_{iterasyon}}{2} \leq iterasyon < 3 \frac{Maks_{iterasyon}}{4} \quad [2.113]$$

$$PD_{i+1,j+1} = GEN\ iyi_{i,j} \times PE \times rand \forall 3 \frac{Maks_{iterasyon}}{4} \leq iterasyon < Maks_{iterasyon} \quad [2.114]$$

ε , besin kaynağının kalitesini gösteren parametre, rand ise 0 ve 1 arasındaki rastgele bir sayıyı, $CPD_{i,j}$ kolonideki tüm çayır köpeklerinin toplam etkisini tanımlar. PE avcı etkisi olup Denklem 2.115 ile aşağıdaki gibi hesaplanır.

$$PE = 1.5 \times \left(1 - \frac{iterasyon}{Maksimum_{iterasyon}} \right)^{\left(2 \frac{iterasyon}{Maksimum_{iterasyon}} \right)} \quad [2.115]$$

PDO’ nun keşif ve sömürü aşamaları Şekil 2.5 ile aşağıdaki gibi gösterilmiştir [44].



Şekil 2.9.1 PDO’ nun keşif ve sömürü aşama modelleri

PDO' nın sözde kodu Çizelge 2.9.1 ile aşağıdaki gibi gösterilmiştir [16].

Çizelge 2.9.1 Çayır Köpeği Optimizasyonu Sözde Kodu

Çayır Köpeği Optimizasyonu	
Adım 1.	Başlatma
Adım 2.	n, m, ρ, ε parametrelerini ayarla
Adım 3.	$GBest$ ve $CBest$ $\emptyset$ olarak ayarla
Adım 4.	CT ve PD aday çözümleri başlat
Adım 5.	While (iterasyon < $Maks_{iterasyon}$) do
Adım 6.	for ($i = 1$ to m) do
Adım 7.	for ($j = 1$ to n) do
Adım 8.	PD 'nin uygunluk değerini hesapla
Adım 9.	Şu ana kadar ki en iyi çözümü bul ($CBest$)
Adım 10.	$GBest$ ' i güncelle
Adım 11.	DS ve PE ' yi güncelle
Adım 12.	$CPD_{i,j}$ ' yi güncelle
Adım 13.	if (iterasyon < $\frac{Maks_{iterasyon}}{4}$) then {yiyecek arama}
Adım 14.	Denklemler [2.108]'ı çalıştır
Adım 15.	else if ($\frac{Maks_{iterasyon}}{4} \leq \text{iterasyon} < \frac{Maks_{iterasyon}}{2}$) then {yeni yuva oluşturma aktivitesi}
Adım 16.	Denklemler [2.109]' ı çalıştır.
Adım 17.	else if ($\frac{Maks_{iterasyon}}{2} \leq \text{iterasyon} \leq 3 \frac{Maks_{iterasyon}}{4}$) then {yiyecek alarmı}
Adım 18.	Denklemler [2.113]' ü çalıştır.
Adım 19.	else {avcı alarmı}
Adım 20.	Denklemler [2.114]' ü çalıştır.
Adım 21.	end if
Adım 22.	end for
Adım 23.	end for
Adım 24.	iterasyon = iterasyon + 1
Adım 25.	end while
Adım 26.	Return en iyi çözüm ($GBest$)
Adım 27.	end

2.10 Kerevit Optimizasyon Algoritması (COA)

COA, kerevitlerin yiyecek arama, yaz tatili ve rekabetçi davranışlarından ilham alan bir metasezgiseldir. Yiyecek arama aşaması ve rekabetçi davranış aşaması COA' nın kullanım aşamasına, yazlık tatil yeri aşaması COA' nın keşif aşamasına karşılık gelir [17]. COA algoritması popülasyon tabanlı bir algoritmadır, bu nedenle öncelikle bir dizi aday çözüm oluşturulur [45]. COA' daki aday çözüm Denklem 2.116 'da aşağıdaki gibidir [17].

$$X = [X_1, X_2, \dots, X_N] = \begin{bmatrix} X_{1,1} & \dots & X_{1,j} & \dots & X_{1,dim} \\ \vdots & \dots & \vdots & \dots & \vdots \\ X_{i,1} & \dots & X_{i,j} & \dots & X_{i,dim} \\ \vdots & \dots & \vdots & \dots & \vdots \\ X_{N,1} & \dots & X_{N,j} & \dots & X_{N,dim} \end{bmatrix} \quad [2.115]$$

X , başlangıç popülasyon konumu, N popülasyon sayısı, dim ise popülasyon boyutudur. $X_{i,j}$, i 'nin j boyutundaki konumudur ve Denklem 2.116 ile hesaplanmaktadır [17].

$$X_{i,j} = lb_j + (ub_j - lb_j) \times rand \quad [2.116]$$

lb_j, ub_j sırasıyla j . boyutun alt ve üst sınırlarıdır. Rand rastgele bir tamsayıdır.

COA' da keşif ve kullanım aşamaları sıcaklığa göre düzenlenir. Sıcaklığın değişmesi kerevitlerin davranışlarını etkileyerek farklı aşamalara geçmelerini sağlamaktadır. $sıcaklık \geq 30^\circ\text{C}$ olduğunda kerevitler yazlık tatil yeri aşamasına geçerler. Kerevitler $sıcaklık < 30^\circ\text{C}$ ve $sıcaklık > 20^\circ\text{C}$ aralığında ideal yiyecek arama davranışı gösterirler. Kerevitlerin beslenme miktarında sıcaklık ile bağlantılıdır. İdeal sıcaklık aralığında beslenme miktarları artar [45]. Sıcaklık Denklem 2.117 ile, kerevit alımı Denklem 2.118 ile aşağıdaki gibi hesaplanmaktadır [17].

$$sıcaklık = rand \times 15 + 20 \quad [2.117]$$

$sıcaklık$, kerevitin bulunduğu ortam sıcaklığı, $rand$, rastgele bir tamsayıyı ifade eder.

$$p = C_1 \times \left(\frac{1}{\sqrt{2 \times \pi} \times \sigma} \times \exp \left(-\frac{(sıcaklık - \mu)^2}{2\sigma^2} \right) \right) \quad [2.118]$$

μ , kerevitler için en uygun sıcaklığı, σ ve C_1 farklı sıcaklıklarda kerevit alımını kontrol etmek için kullanılan parametreleri tanımlar.

2.10.1 Yazlık Tatil Yeri Aşaması (Keşif)

$sıcaklık \geq 30^\circ\text{C}$ olduğunda, bu sıcaklık değeri kerevitler için çok yüksektir. Bu durumda kerevitler genellikle gölgeli ve serin mağaralara sığınır ve yazlık tatil yeri sağlanmış olur [46]. Denklem 2.119 ile bu durum tanımlanmıştır [17].

$$X_{\text{shade}} = (X_G + X_L)/2 \quad [2.119]$$

X_G en uygun konumu, X_L anlık konumu ifade eder.

Kerevitlerin serin mağaralar için savaşıması rastgele bir olaydır. Bu rastgeleliği tanımlayan $rand < 0,5$ ise mağara için rekabetin olmadığı, kerevitin mağaraya doğrudan girebileceğini tanımlar [45]. Bu durum Denklem 2.220 ile aşağıdaki gibi gösterilir [17].

$$X_{i,j}^{t+1} = X_{i,j}^t + C_2 \times rand \times (X_{\text{shade}} - X_{i,j}^t) \quad [2.220]$$

t mevcut yineleme sayısını, $t + 1$ bir sonraki yinelemeyi, C_2 ise azalan bir eğridir ve Denklem 2.221 ile aşağıdaki gibi tanımlanır.

$$C_2 = 2 - (t/T) \quad [2.221]$$

T maksimum iterasyon sayısıdır. Yazlık tatil yeri aşamasında kerevitler çözüme en uygun mağaraya yaklaşmayı hedeflerler. Bu bireyleri etkili bir şekilde en iyi çözüme yaklaştırır. Bu COA' nın kullanım yeteneğini daha da artırarak algoritma yakınsamasını hızlandırır [45].

2.10.2 Rekabetçi Davranış Aşaması (Sömürü)

$sıcaklık \geq 30^\circ\text{C}$ ve $rand \geq 0,5$ olduğunda kerevitler mağara seçimi için mücadele içerisine gireceklerdir[17]. Kerevitlerin mağara için mücadeleleri Denklem 2.222 ile aşağıdaki gibidir [17].

$$X_{i,j}^{t+1} = X_{i,j}^t - X_{z,j}^t + X_{\text{shade}} \quad [2.222]$$

z rastgele kereviti ifade eder ve Denklem 2.223 ile hesaplanır.

$$z = \text{round} (rand \times (N - 1)) + 1 \quad [2.223]$$

N popülasyon sayısıdır.

2.10.3 Yiyecek Toplama Aşaması (Sömürü)

$sıcaklık \leq 30$, kerevitlerin beslenmeleri için ideal bir sıcaklıktır. Bu sıcaklıkta kerevitler yiyeceğe doğru hareket ederler ve yiyecek bulunduktan sonra, yiyeceğin büyüklüğüne karar verirler. Yiyeceğin çok büyük olması durumunda kerevit, yiyeceği parçalar ve yer [47]. Yiyeceğin konumu Denklem 2.224 ile aşağıdaki gibi gösterilmiştir [17].

$$X_{yiyecek} = X_G \quad [2.224]$$

Yiyeceğin boyutu Q ile gösterilir ve Denklem 2.225 ile aşağıdaki gibi hesaplanır [12].

$$Q = C_3 \times \text{rand} \times (\text{en iyi}_i / \text{en iyi}_{yiyecek}) \quad [2.225]$$

C_3 en büyük temsil eden yiyecek faktörüdür ve sabit değerli olup değeri 3 tür. en iyi_i , $\text{en iyi}_{yiyecek}$, sırasıyla i . kerevitin ve yiyeceğin uygunluk değerleridir. Eğer $Q > (C_3 + 1)/2$ ise yiyecek boyutu çok büyüktür ve ayağıyla kerevit yiyeceği parçalar. Bu işlem Denklem 2.226 ile aşağıdaki gibi gösterilmiştir [17].

$$X_{yiyecek} = \exp\left(-\frac{1}{Q}\right) \times X_{yiyecek} \quad [2.226]$$

Yiyecek parçalanıp küçüldüğünde, ikinci ve üçüncü ayaklar sırasıyla parçayı tüketirler [47]. Yiyecek arama denklemi aşağıdaki Denklem 2.227 ile gösterilmiştir [17].

$$X_{i,j}^{t+1} = X_{i,j}^t + X_{\text{food}} \times p \times (\cos(2 \times \pi \times \text{rand}) - \sin(2 \times \pi \times \text{rand})) \quad [2.227]$$

Eğer $Q \leq (C_3 + 1)/2$ ise kerevit doğrudan yiyeceğe yönelir yiyeceği tüketir. Bu Denklem 2.228 ile gösterilmiştir [17].

$$X_{i,j}^{t+1} = (X_{i,j}^t - X_{yiyecek}) \times p + p \times \text{rand} \times X_{i,j}^t \quad [2.228]$$

COA' nın sözde kodu Çizelge 2.10.1 ile aşağıdaki gibi gösterilmiştir [17].

Çizelge 2.10.1 Kerevit Optimizasyon Algoritması Sözde Kodu

Kerevit Optimizasyon Algoritması	
Adım 1.	Başlatma, T toplam adım sayısı, N popülasyon sayısı, dim problem boyutu
Adım 2.	Rastgele bir başlangıç popülasyonu oluşturun
Adım 3.	X_G, X_L uygunluk değerlerini hesaplayın
Adım 4.	While ($t < T$)
Adım 6.	Denklem 2.117' yi kullanarak sıcaklığı hesaplayın
Adım 7.	if sıcaklık > 30 ise
Adım 8.	Denklem 2.119' u kullanarak x_{shade} 'i hesaplayın
Adım 9.	if rand $< 0,5$ ise
Adım 10.	Yazlık Tatil Yeri Aşaması
Adım 11.	else
Adım 12.	Rekabetçi Davranış Aşaması
Adım 13.	end
Adım 14.	else
Adım 15.	p, Q değerlerini hesaplayın
Adım 16.	if $Q > 2$ ise
Adım 17.	Denklem 2.226 ile yiyeceği parçala
Adım 18.	Denklem 2.227 ile yiyeceği tüket
Adım 19.	else
Adım 20.	Denklem 2.228 ile yiyeceğe yönel
Adım 21.	end
Adım 22.	end
Adım 23.	X_G, X_L uygunluk değerlerini güncelleyin
Adım 24.	$t = t + 1$
Adım 25.	End

3. TEST PROBLEMLERİNİN ÇÖZÜMÜNDE METASEZGİSELLERİN UYGULANMASI

3.1 Giriş

Bu bölüm, 2. bölümde önerilen güncel metasezgisel algoritmaların 23 farklı test fonksiyonları üzerindeki karşılaştırmalarını içermektedir. Bölümün temel katkıları aşağıda sıralanmıştır:

- Literatür taramasına göre bu metasezgisellerin simülasyon sonuçları, yakınsama hızları gibi farklı değerlendirme kriterleri ilk kez karşılaştırılmıştır.
- Algoritmaların simülasyon sonuçlarına göre en başarılı düşünülen beş metasezgiselin diğerleriyle başarısının kıyaslanması için tek kuyruk t-testi yapılmıştır.
- Deneysel çalışmalara göre AVOA ve MGO' nun diğer metasezgisellere üstünlük sağladığı değerlendirilmiştir.

Bölümün geri kalanında kıyaslama yapılan test fonksiyonları, parametreler, simülasyon sonuçları ve istatistiksel test sonuçlarının verildiği deneysel çalışmalar sunulmuştur.

3.2 Deneysel Tasarım

Bu bölümde test fonksiyonlarına ve karşılaştırmada kullanılan algoritmaların kendilerine ait parametrelerine yer verilmiştir.

3.2.1 Fonksiyonlar

Bu bölümde, algoritmalar birçok çalışmada kullanılan 23 farklı test fonksiyonu ile kıyaslanmıştır [14]. Fonksiyonlar üç temel gruba ayrılmaktadır: Tek modlu, çok modlu ve farklı boyutlu çok modlu. Her bir grup sırasıyla Çizelge 3.2.1, Çizelge 3.2.2 ve Çizelge 3.2.3' te sunulmuştur. Tablolarda verilen aralık fonksiyonların arama uzayının sınırlarını f_{min} optimum değerini temsil etmektedir.

Çizelge 3.2.1 Tek modlu test fonksiyonları





Fonksiyon	Boyut	Aralık	f_{min}
$f_1(x) = \sum_{i=1}^n x_i^2$	30	[-100,100]	0
$f_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	[-10,10]	0
$f_3(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2$	30	[-100,100]	0
$f_4(x) = \max_i \{ x_i , 1 \leq i \leq n\}$	30	[-100,100]	0
$f_5(x) = \sum_{i=1}^{n-1} \left[100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2 \right]$	30	[-30,30]	0
$F_6(x) = \sum_{i=1}^n (x_i + 0.5)^2$	30	[-100,100]	0
$F_7(x) = \sum_{i=1}^n ix_i^4 + \text{random} [0, 1)$	30	[-1,28, +1,28]	0

Çizelge 3.2.2 Çok modlu test fonksiyonları





Fonksiyon	Boyut	Aralık	f_{min}
$F_8(x) = -\sum_{i=1}^n \left(x_i \sin \left(\sqrt{ x_i } \right) \right)$	30	$[-500,500]$	-12569,5
$F_9(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	$[-5.12,5.12]$	0
$F_{10}(x) = -20 \exp \left(-0.2 \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \right) - \exp \left(\frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i) \right) + 20 + e$	30	$[-32,32]$	0
$F_{11}(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos \left(\frac{x_i}{\sqrt{i}} \right) + 1$	30	$[-600,600]$	0
$F_{12}(x) = \frac{\pi}{n} \left\{ 10 \sin(\pi y_1) + \sum_{i=1}^{n-1} (y_i - 1)^2 [1 + 10 \sin^2(\pi y_{i+1})] + (y_n - 1)^2 \right\}$ $+ \sum_{i=1}^n u(x_i, 10, 100, 4) y_i = 1 + \frac{x_i + 1}{4}$	30	$[-50,50]$	0
$u(x_i, a, k, m) = \begin{cases} k(x_i - a)^m & x_i > a \\ 0 & -a < x_i < a \\ k(-x_i - a)^m & x_i < -a \end{cases}$			
$F_{13}(x) = 0.1 \left\{ \sin^2(3\pi x_1) + \sum_{i=1}^n (x_i - 1)^2 [1 + \sin^2(3\pi x_i + 1)] \right.$ $\left. + (x_n - 1)^2 [1 + \sin^2(2\pi x_n)] \right\} + \sum_{i=1}^n u(x_i, 5, 100, 4)$	30	$[-50,50]$	0

Çizelge 3.2.3 Farklı boyutlu çok modlu test fonksiyonları





Fonksiyon	Boyut	Aralık	f_{min}
$F_{14}(x) = \left[\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{j=1}^2 (x_i - a_{ij})^6} \right]^{-1}$	2	$[-65,536, 65,536]$	0,998
$F_{15}(x) = \sum_{i=1}^{11} \left a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4} \right ^2$	4	$[-5, 5]$	$3,075 \times 10^{-4}$
$F_{16}(x) = 4x_1^2 - 2.1x_1^4 + \frac{1}{3}x_1^6 + x_1x_2 - 4x_2^2 + 4x_2^4$	2	$[-5, 5]$	-1.0316
$F_{17}(x) = \left(x_2 - \frac{5.1}{4\pi^2} x_1^2 + \frac{5}{\pi} x_1 - 6 \right)^2 + 10 \left(1 - \frac{1}{8\pi} \right) \cos x_1 + 10$	2	$[-5, 5] \times [0, 15]$	0,398
$F_{18}(x) = [1 + (x_1 + x_2 + 1)^2(19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)] \times [30 + (2x_1 + 1 - 3x_2)^2(18 - 32x_1 + 12x_1^2 + 48x_2 - 36x_1x_2 + 27x_2^2)]$	2	$[-2, 2]$	3
$F_{19}(x) = - \sum_{i=1}^4 \exp \left[- \sum_{j=1}^3 a_{ij}(x_j - p_{ij})^2 \right]$	3	$[0, 1]$	-3,86
$F_{20}(x) = - \sum_{i=1}^4 \exp \left[- \sum_{j=1}^6 a_{ij}(x_j - p_{ij})^2 \right]$	6	$[0, 1]$	-3,322
$F_{21}(x) = - \sum_{i=1}^5 (x_i - a_i)(x_i - a_i)^T + c_i ^{-1}$	4	$[0, 10]$	-10,1532
$F_{22}(x) = - \sum_{i=1}^7 (x_i - a_i)(x_i - a_i)^T + c_i ^{-1}$	4	$[0, 10]$	-10,4028
$F_{23}(x) = - \sum_{i=1}^{10} (x_i - a_i)(x_i - a_i)^T + c_i ^{-1}$	4	$[0, 10]$	-10,5363



Şekil 3.2.1 Tek modlu test fonksiyon grafikleri (F_1, F_2, F_4, F_7)



Şekil 3.2.2 Çok modlu test fonksiyon grafikleri (F_8, F_9, F_{10}, F_{12})



Şekil 3.2.3 Farklı boyutlu çok modlu test fonksiyon grafikleri ($F_{13}, F_{14}, F_{18}, F_{23}$)

3.2.2 Parametreler

Çizelge 3.2.4 'teki parametre değerleri, kullanıldığı algoritmanın önerildiği makalelere ait kalite test fonksiyonları için tavsiye edilen değerlerdir. Bu çalışmada da aynı test fonksiyonları kullanıldığından aynı değerler tercih edilmiştir. Adil bir karşılaştırma olması için tüm algoritmalarda popülasyon büyüklüğü 50, maksimum iterasyon sayısı 1000 olarak belirlenmiştir.

Çizelge 3.2.4 Algoritma parametreleri ve değerleri

Algoritma	Simge	Anlam	Değer
AO	α	Keşif parametresi	0,1
	δ	Sömürü parametresi	0,1
AOA	α	İterasyon doğruluğu	5
	μ	Arama doğruluğu düzenleyicisi	0,5
BWO	P_p	Üreme hızı	0,6
	C_R	Yamyamlık oranı	0,44
	P_M	Mutasyon oranı	0,4
STOA	C_f	Çarpışma kontrolü	2
	C_B	Keşif parametresi	[0 – 0,5]
	u	Spiral davranış parametresi	1
	v	Spiral davranış parametresi	1
AVOA	L_1	Arama öncesi parametre	0,8
	L_2	Arama öncesi parametre	0,2
	w	Operasyon aşama bilgisi	2,5
	p_1	Keşif yöntemi belirleme parametresi	0,6
	p_2	Birinci aşama seçimi	0,4
	p_3	İkinci aşama seçimi	0,6
PDO	ρ	Yiyecek kaynağı alarmı	0,1
	ε	Besin kaynağı kalite göstergesi	$2,22E - 12$
	Δ	Çayır köpekleri konum farkı	0,005
COA	C_1	Kerevit alım kontrolü	0,2
	C_3	En büyük yiyecek	3
	μ	Uygun sıcaklık değeri	25
	σ	Kerevit alım kontrolü	3

3.3 Sonular

3.3.1 Simlasyon Sonuları

alıřmada tm algoritmalar 100 kez bağımsız kořturulmuřtur. Algoritmalar MATLAB 2022b platformu kullanılarak yazılmıřtır. Kullanılan bilgisayar, Ryzen 9 3950X, 3.5 GHz hıza ve 64 GB RAM' e sahiptir. Simlasyon sonuları sırasıyla tek modlu fonksiyonlar iin izelge 3.3.1 ve izelge 3.3.2' da ok modlu fonksiyonlar iin izelge 3.3.3 ve farklı boyutlu ok modlu fonksiyonlar iin izelge 3.3.4 ve izelge 3.3.5' da paylařılmıřtır. Her fonksiyon iin kořmaların ortalama, standart sapma, en iyi ve en kt sonuları bu izelgelerde verilmiřtir. Ayrıca algoritmaların test fonksiyonlarında gstermiř olduėu performans sıralamaları ve genel toplamaları izelge 3.3.6' da yer almaktadır.

Çizelge 3.3.1 Tek modlu test fonksiyonları (F_1 - F_4)

		AO	AOA	ARO	AVOA	BWO	COA	HHO	MGO	PDO	STOA
F_1	ORTALAMA	6,34E-208	0,00E+00	3,23E-124	0,00E+00	0,00E+00	0,00E+00	5,82E-192	4,48E-167	0,00E+00	8,13E-19
	STD SAPMA	0,00E+00	0,00E+00	3,20E-123	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	2,30E-18
	MİNİMUM	0,00E+00	0,00E+00	4,33E-144	0,00E+00	0,00E+00	0,00E+00	6,82E-219	1,68E-183	0,00E+00	1,40E-22
	MAKSİMUM	6,34E-206	0,00E+00	3,20E-122	0,00E+00	0,00E+00	0,00E+00	4,45E-190	4,16E-165	0,00E+00	1,68E-17
	SIRALAMA	2	1	5	1	1	1	3	4	1	6
F_2	ORTALAMA	1,28E-121	0,00E+00	2,07E-68	0,00E+00	0,00E+00	0,00E+00	9,29E-100	3,72E-96	0,00E+00	8,69E-13
	STD SAPMA	1,28E-120	0,00E+00	1,39E-67	0,00E+00	0,00E+00	0,00E+00	9,27E-99	1,74E-95	0,00E+00	1,23E-12
	MİNİMUM	7,38E-158	0,00E+00	4,79E-77	0,00E+00	0,00E+00	0,00E+00	8,51E-120	1,12E-102	0,00E+00	9,90E-15
	MAKSİMUM	1,28E-119	0,00E+00	1,13E-66	0,00E+00	0,00E+00	0,00E+00	9,27E-98	1,41E-94	0,00E+00	7,55E-12
	SIRALAMA	2	1	5	1	1	1	3	4	1	6
F_3	ORTALAMA	2,86E-196	0,00E+00	1,63E-94	0,00E+00	0,00E+00	0,00E+00	8,86E-153	2,01E-21	0,00E+00	1,35E-09
	STD SAPMA	0,00E+00	0,00E+00	1,63E-93	0,00E+00	0,00E+00	0,00E+00	8,86E-152	1,70E-20	0,00E+00	2,71E-09
	MİNİMUM	0,00E+00	0,00E+00	8,78E-117	0,00E+00	0,00E+00	0,00E+00	1,52E-198	3,64E-33	0,00E+00	3,65E-12
	MAKSİMUM	2,86E-194	0,00E+00	1,63E-92	0,00E+00	0,00E+00	0,00E+00	8,86E-151	1,69E-19	0,00E+00	2,15E-08
	SIRALAMA	2	1	4	1	1	1	3	5	1	6
F_4	ORTALAMA	7,91E-145	0,00E+00	1,60E-52	0,00E+00	0,00E+00	0,00E+00	8,95E-96	6,38E-55	0,00E+00	4,86E-06
	STD SAPMA	7,89E-144	0,00E+00	7,09E-52	0,00E+00	0,00E+00	0,00E+00	7,26E-95	4,82E-54	0,00E+00	8,43E-06
	MİNİMUM	2,41E-158	0,00E+00	4,14E-62	0,00E+00	0,00E+00	0,00E+00	8,88E-111	5,51E-65	0,00E+00	2,51E-07
	MAKSİMUM	7,89E-143	0,00E+00	4,54E-51	0,00E+00	0,00E+00	0,00E+00	7,21E-94	4,74E-53	0,00E+00	7,19E-05
	SIRALAMA	2	1	5	1	1	1	3	4	1	6

Çizelge 3.3.2 Tek modlu test fonksiyonları (F_5 - F_7)

		AO	AOA	ARO	AVOA	BWO	COA	HHO	MGO	PDO	STOA
F_5	ORTALAMA	5,35E-04	5,20E+00	4,60E-03	1,71E-06	2,89E+01	2,44E+01	1,44E-03	8,76E-31	7,87E+00	2,77E+01
	STD SAPMA	9,16E-04	2,77E-01	8,56E-03	1,70E-06	3,50E-02	4,84E-01	2,30E-03	3,08E-30	1,06E+01	6,37E-01
	MİNİMUM	6,11E-07	4,53E+00	7,78E-05	4,22E-08	2,88E+01	2,34E+01	4,50E-07	0,00E+00	2,90E-01	2,61E+01
	MAKSİMUM	6,19E-03	5,92E+00	6,39E-02	9,54E-06	2,90E+01	2,63E+01	1,35E-02	2,50E-29	2,90E+01	2,88E+01
	SIRALAMA	3	6	5	2	10	8	4	1	7	9
F_6	ORTALAMA	0,00E+00	1,41E-02	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	2,16E+00
	STD SAPMA	0,00E+00	4,80E-03	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	5,04E-01
	MİNİMUM	0,00E+00	3,83E-03	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	7,52E-01
	MAKSİMUM	0,00E+00	2,65E-02	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	3,27E+00
	SIRALAMA	1	2	1	1	1	1	1	1	1	3
F_7	ORTALAMA	3,39E-05	1,98E-05	2,62E-04	4,86E-05	4,45E-05	2,14E-05	4,94E-05	1,45E-04	2,92E-05	1,55E-03
	STD SAPMA	3,11E-05	1,88E-05	1,97E-04	4,91E-05	3,70E-05	2,23E-05	4,94E-05	1,07E-04	2,64E-05	1,22E-03
	MİNİMUM	1,91E-07	1,81E-07	8,32E-06	5,53E-07	1,45E-06	1,61E-07	7,97E-08	6,40E-06	4,17E-09	1,73E-04
	MAKSİMUM	1,43E-04	1,01E-04	1,07E-03	2,42E-04	1,68E-04	1,11E-04	3,34E-04	5,68E-04	1,32E-04	6,01E-03
	SIRALAMA	4	1	9	6	5	2	7	8	3	10

Çizelge 3.3.3 Çok modlu test fonksiyonları (F_8 - F_{13})

		AO	AOA	ARO	AVOA	BWO	COA	HHO	MGO	PDO	STOA
F_8	ORTALAMA	-9,85E+03	-3,44E+03	-1,11E+04	-1,25E+04	-4,94E+03	-9,36E+03	-1,26E+04	-1,26E+04	-4,07E+03	-5,67E+03
	STD SAPMA	3,31E+03	2,53E+02	4,29E+02	2,00E+02	6,24E+02	5,74E+02	4,76E+01	1,04E-09	2,98E+02	6,18E+02
	MİNİMUM	-1,26E+04	-3,95E+03	-1,21E+04	-1,26E+04	-6,46E+03	-1,09E+04	-1,26E+04	-1,26E+04	-4,92E+03	-7,98E+03
	MAKSİMUM	-4,58E+03	-2,86E+03	-1,02E+04	-1,09E+04	-3,54E+03	-8,25E+03	-1,21E+04	-1,26E+04	-3,41E+03	-4,63E+03
	SIRALAMA	5	10	4	3	8	6	2	1	9	7
F_9	ORTALAMA	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	7,29E-01
	STD SAPMA	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	2,16E+00
	MİNİMUM	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
	MAKSİMUM	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	1,39E+01
	SIRALAMA	1	1	1	1	1	1	1	1	1	2
F_{10}	ORTALAMA	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	5,15E-16	4,44E-16	2,00E+01
	STD SAPMA	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	5,00E-16	0,00E+00	1,83E-03
	MİNİMUM	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	2,00E+01
	MAKSİMUM	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,44E-16	4,00E-15	4,44E-16	2,00E+01
	SIRALAMA	1	1	1	1	1	1	1	2	1	3
F_{11}	ORTALAMA	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	7,03E-03
	STD SAPMA	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	1,32E-02
	MİNİMUM	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00
	MAKSİMUM	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	0,00E+00	8,35E-02
	SIRALAMA	1	1	1	1	1	1	1	1	1	2
F_{12}	ORTALAMA	1,95E-07	5,94E-01	7,58E-08	1,06E-11	6,74E-01	2,56E-04	8,41E-07	1,57E-32	5,89E-01	1,61E-01
	STD SAPMA	3,60E-07	3,48E-02	6,51E-08	7,66E-12	2,29E-01	1,24E-03	1,50E-06	5,50E-48	5,35E-01	8,58E-02
	MİNİMUM	7,94E-12	4,78E-01	7,82E-09	1,70E-12	2,40E-01	6,71E-08	1,99E-11	1,57E-32	1,04E-02	5,67E-02
	MAKSİMUM	1,95E-06	7,11E-01	3,76E-07	4,64E-11	1,34E+00	6,50E-03	1,13E-05	1,57E-32	1,60E+00	6,17E-01
	SIRALAMA	4	9	3	2	10	6	5	1	8	7
F_{13}	ORTALAMA	2,45E-06	8,22E-01	9,25E-04	5,22E-10	2,94E+00	1,49E+00	8,52E-06	1,35E-32	2,93E+00	1,56E+00
	STD SAPMA	3,67E-06	1,46E-01	4,87E-03	3,88E-10	1,83E-01	3,29E-01	1,27E-05	5,50E-48	2,33E-01	2,26E-01
	MİNİMUM	2,17E-09	4,56E-01	3,44E-08	3,59E-11	1,94E+00	5,47E-01	2,16E-09	1,35E-32	1,61E+00	9,08E-01
	MAKSİMUM	2,77E-05	9,95E-01	4,39E-02	1,82E-09	3,00E+00	2,67E+00	8,63E-05	1,35E-32	3,00E+00	2,09E+00
	SIRALAMA	3	6	5	2	10	7	4	1	9	8

Çizelge 3.3.4 Farklı boyutlu çok modlu test fonksiyonları (F_{14} - F_{18})

		AO	AOA	ARO	AVOA	BWO	COA	HHO	MGO	PDO	STOA
F_{14}	ORTALAMA	1,68E+00	9,08E+00	9,98E-01	1,04E+00	1,97E+00	2,64E+00	1,05E+00	9,98E-01	3,55E+00	1,33E+00
	STD SAPMA	2,17E+00	3,94E+00	0,00E+00	2,79E-01	2,18E+00	3,30E+00	2,18E-01	1,48E-16	3,58E+00	1,15E+00
	MİNİMUM	9,98E-01	9,98E-01	9,98E-01	9,98E-01	9,98E-01	9,98E-01	9,98E-01	9,98E-01	9,98E-01	9,98E-01
	MAKSİMUM	1,27E+01	1,27E+01	9,98E-01	2,98E+00	1,27E+01	1,27E+01	1,99E+00	9,98E-01	1,27E+01	1,08E+01
	SIRALAMA	5	9	1	2	6	7	3	1	8	4
F_{15}	ORTALAMA	4,17E-04	1,26E-02	3,07E-04	3,26E-04	5,38E-03	2,07E-03	3,20E-04	3,35E-04	9,68E-04	1,18E-03
	STD SAPMA	1,07E-04	2,43E-02	1,77E-16	1,29E-04	1,25E-02	5,43E-03	1,24E-05	1,57E-04	4,53E-04	2,01E-04
	MİNİMUM	3,19E-04	3,20E-04	3,07E-04	3,07E-04	3,07E-04	3,07E-04	3,08E-04	3,07E-04	3,08E-04	3,08E-04
	MAKSİMUM	1,24E-03	1,30E-01	3,07E-04	1,22E-03	6,33E-02	2,04E-02	3,60E-04	1,22E-03	2,26E-03	1,31E-03
	SIRALAMA	5	10	1	3	7	8	4	2	6	9
F_{16}	ORTALAMA	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00
	STD SAPMA	1,25E-04	4,90E-08	6,53E-16	4,99E-16	4,99E-16	4,76E-16	1,36E-12	6,41E-16	4,33E-04	3,45E-07
	MİNİMUM	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00
	MAKSİMUM	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00	-1,03E+00
	SIRALAMA	2	1	1	1	1	1	1	1	1	1
F_{17}	ORTALAMA	3,98E-01	4,03E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	4,02E-01	3,98E-01
	STD SAPMA	1,46E-04	4,13E-03	0,00E+00	0,00E+00	0,00E+00	3,57E-10	1,29E-07	0,00E+00	1,92E-02	4,94E-05
	MİNİMUM	3,98E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01
	MAKSİMUM	3,99E-01	4,20E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	3,98E-01	5,80E-01	3,98E-01
	SIRALAMA	1	3	1	1	1	1	1	1	2	1
F_{18}	ORTALAMA	3,01E+00	7,23E+00	3,00E+00	3,00E+00	3,81E+00	3,00E+00	3,00E+00	3,00E+00	3,00E+00	3,00E+00
	STD SAPMA	9,11E-03	9,75E+00	9,30E-16	1,33E-07	4,63E+00	3,76E-14	1,70E-09	1,21E-15	1,16E-13	1,13E-05
	MİNİMUM	3,00E+00	3,00E+00	3,00E+00	3,00E+00	3,00E+00	3,00E+00	3,00E+00	3,00E+00	3,00E+00	3,00E+00
	MAKSİMUM	3,04E+00	3,00E+01	3,00E+00	3,00E+00	3,00E+01	3,00E+00	3,00E+00	3,00E+00	3,00E+00	3,00E+00
	SIRALAMA	2	4	1	1	3	1	1	1	1	1

Çizelge 3.3.5 Farklı boyutlu çok modlu test fonksiyonları (F_{19} - F_{23})

		AO	AOA	ARO	AVOA	BWO	COA	HHO	MGO	PDO	STOA
F_{19}	ORTALAMA	-3,86E+00	-3,85E+00	-3,86E+00	-3,86E+00	-3,85E+00	-3,86E+00	-3,86E+00	-3,86E+00	-3,86E+00	-3,86E+00
	STD SAPMA	2,39E-03	2,86E-03	2,23E-15	1,73E-15	1,09E-01	3,52E-15	8,52E-04	2,17E-15	3,71E-03	9,35E-04
	MİNİMUM	-3,86E+00	-3,86E+00	-3,86E+00	-3,86E+00	-3,86E+00	-3,86E+00	-3,86E+00	-3,86E+00	-3,86E+00	-3,86E+00
	MAKSİMUM	-3,85E+00	-3,84E+00	-3,86E+00	-3,86E+00	-3,09E+00	-3,86E+00	-3,86E+00	-3,86E+00	-3,85E+00	-3,85E+00
	SIRALAMA	3	6	1	1	7	1	2	1	4	5
F_{20}	ORTALAMA	-3,20E+00	-3,12E+00	-3,31E+00	-3,27E+00	-3,18E+00	-3,28E+00	-3,18E+00	-3,26E+00	-3,05E+00	-2,98E+00
	STD SAPMA	7,34E-02	6,72E-02	3,74E-02	5,94E-02	1,28E-01	5,84E-02	8,37E-02	5,93E-02	2,62E-01	2,96E-01
	MİNİMUM	-3,31E+00	-3,28E+00	-3,32E+00	-3,32E+00	-3,32E+00	-3,32E+00	-3,32E+00	-3,32E+00	-3,32E+00	-3,32E+00
	MAKSİMUM	-2,98E+00	-2,87E+00	-3,20E+00	-3,20E+00	-2,75E+00	-3,20E+00	-2,89E+00	-3,20E+00	-1,58E+00	-1,16E+00
	SIRALAMA	5	8	1	3	7	2	6	4	9	10
F_{21}	ORTALAMA	-1,02E+01	-4,02E+00	-1,02E+01	-1,02E+01	-8,01E+00	-7,71E+00	-5,26E+00	-1,02E+01	-5,59E+00	-5,17E+00
	STD SAPMA	2,00E-03	1,18E+00	1,06E-05	2,94E-15	2,58E+00	2,56E+00	9,94E-01	4,46E-15	2,29E+00	4,29E+00
	MİNİMUM	-1,02E+01	-8,04E+00	-1,02E+01	-1,02E+01	-1,02E+01	-1,02E+01	-1,01E+01	-1,02E+01	-1,02E+01	-1,02E+01
	MAKSİMUM	-1,01E+01	-1,58E+00	-1,02E+01	-1,02E+01	-2,63E+00	-5,06E+00	-5,05E+00	-1,02E+01	-2,73E+00	-3,51E-01
	SIRALAMA	2	8	1	1	3	4	6	1	5	7
F_{22}	ORTALAMA	-1,04E+01	-4,57E+00	-1,03E+01	-1,04E+01	-7,76E+00	-8,00E+00	-5,62E+00	-1,04E+01	-6,06E+00	-7,14E+00
	STD SAPMA	4,64E-03	1,52E+00	7,48E-01	3,70E-15	2,87E+00	2,75E+00	1,59E+00	3,23E-15	2,91E+00	4,13E+00
	MİNİMUM	-1,04E+01	-9,11E+00	-1,04E+01	-1,04E+01	-1,04E+01	-1,04E+01	-1,04E+01	-1,04E+01	-1,04E+01	-1,04E+01
	MAKSİMUM	-1,04E+01	-1,47E+00	-5,09E+00	-1,04E+01	-9,10E-01	-2,77E+00	-5,09E+00	-1,04E+01	-2,18E+00	-5,21E-01
	SIRALAMA	3	9	2	1	5	4	8	1	7	6
F_{23}	ORTALAMA	-1,05E+01	-4,41E+00	-1,05E+01	-1,05E+01	-8,24E+00	-8,35E+00	-5,34E+00	-1,05E+01	-5,94E+00	-7,96E+00
	STD SAPMA	2,10E-03	1,57E+00	6,70E-01	1,73E-15	2,87E+00	2,92E+00	1,06E+00	1,44E-15	2,94E+00	3,68E+00
	MİNİMUM	-1,05E+01	-1,02E+01	-1,05E+01	-1,05E+01	-1,05E+01	-1,05E+01	-1,05E+01	-1,05E+01	-1,05E+01	-1,05E+01
	MAKSİMUM	-1,05E+01	-1,53E+00	-3,84E+00	-1,05E+01	-2,43E+00	-2,42E+00	-5,13E+00	-1,05E+01	-2,55E+00	-5,54E-01
	SIRALAMA	2	9	3	1	5	4	8	1	7	6

Çizelge 3.3.6 Test fonksiyonları karşılaştırması

ALGORİTMALAR	AO	AOA	ARO	AVOA	BWO	COA	HHO	MGO	PDO	STOA
TEK MODLU SIRALAMA TOPLAM	16	13	34	13	20	15	24	27	15	46
ÇOK MODLU SIRALAMA TOPLAM	15	28	15	10	31	22	14	7	29	29
FARKLI BOYUTLU ÇOK MODLU SIRALAMA TOPLAM	30	67	13	15	45	33	40	14	50	50
GENEL TOPLAM	61	108	62	38	96	70	78	48	94	125

Tek modlu test fonksiyon sonuçlarına göre aşağıdaki değerlendirmeler Tablo 3.3.1 ve Tablo 3.3.2' den çıkarılmıştır:

- F_1 , F_2 , F_{13} ve F_{14} fonksiyonlarında AOA, AVOA, BWO, COA ve PDO algoritmaları tüm koşmalarda optimum sonuca ulaşmıştır.
- Algoritmaların başarı sıralamasını değiştiren iki fonksiyon F_5 ve F_6 dır. F_5 ' te MGO en başarılı olurken, F_6 ' da AOA ve STOA en başarısız olmuştur.
- STOA genel olarak bakıldığında ya sonuncu ya da sondan bir önceki olmuştur. Ayrıca başarı sıralamalarında 46 değeri ile en kötü sıralamaya sahiptir.
- AOA ve AVOA başarı sıralamasında eşit puanlar alarak 1. olmuşlardır. Bu iki algoritmayı 15 sıralama değeri ile PDO, 16 sıralama değeri ile AO takip etmektedir.
- F_5 ve F_7 ' de hiçbir algoritma F_{min} değerine ulaşamamıştır. F_7 ' de ortalamada sırasıyla en iyi ve en kötü değeri üreten AOA ve STOA arasında 0,0015' lik çok küçük bir fark bulunmaktadır.

Çok modlu test fonksiyon sonuçlarına göre aşağıdaki değerlendirmeler Tablo 3.3.3' den çıkarılmıştır:

- F_8 fonksiyonunun optimum değeri olan $-12569,5$ ' i hiçbir algoritma elde edememiştir; ancak MGO yaklaşık 0,01' lik farkla bu değere yaklaşmıştır.
- Sıralama toplamlarına bakıldığında MGO, 6 fonksiyonun sadece 1 tanesinde 2. diğerlerinde 1. olmuştur.
- MGO' yu en yakın 3 puan farkla AVOA takip etmektedir.
- F_9 ve F_{11} için sadece STOA optimum değeri elde edememiştir.
- Tek modlu fonksiyonlarda PDO 15 sıralama toplamı ile 2. sırada tamamlarken çok modlu fonksiyonlarda 29 sıralama puanı ile 7. sırada tamamlamıştır.

Farklı boyutlu çok modlu test fonksiyon sonuçlarına göre aşağıdaki değerlendirmeler Tablo 3.3.4 ve Tablo 3.3.5' ten çıkarılmıştır:





- F_{16} , F_{17} ve F_{18} fonksiyonlarında neredeyse tüm algoritmalar optimum sonucu elde etmiştir.
- F_{20} fonksiyonunda sadece optimum değere ulaşan algoritma ARO olmuştur.

- F_{21} , F_{22} ve F_{23} fonksiyonlarında AVOA ve MGO optimum deęerleri elde etmiřlerdir.
- Sıralama toplamlarına bakıldıęında ilk üç sırasıyla ARO, MGO ve AVOA' dır.





Tek modlu, çok modlu ve farklı boyutlu çok modlu fonksiyon sıralama deęeri birlikte deęerlendirildięinde 1. AVOA olmuřtur. AVOA' yı sırasıyla MGO, AO, ARO ve COA takip etmiřtir. Tüm algoritmalar ierisinde toplam 125 sıralama puanı ile en bařarısız olan algoritma STOA' dır

3.3.2 Yakınsama Grafikleri Analizi





Yakınsama grafikleri, bir algoritmanın bařlangı çözümlerinin iterasyonlar boyunca gelişimini takip ederek çözümlerin deęişimini gösteren grafiklerdir. Bu alt bölümde çalışmada kullanılan tüm algoritmaların her bir test fonksiyonu üzerindeki yakınsama grafikleri çizilerek řekillerle sunulmuřtur. Yakınsama grafikleri algoritmaların tüm kořmalarının her iterasyondaki ortalamaları alınarak çizdirilmiřtir.







Şekil 3.3.1 Fonksiyonların yakınsama grafikleri ($F_1 - F_4$)







Şekil 3.3.2 Fonksiyonların yakınsama grafikleri ($F_5 - F_8$)






Şekil 3.3.3 Fonksiyonların yakınsama grafikleri ($F_9 - F_{12}$)



Şekil 3.3.4 Fonksiyonların yakınsama grafikleri ($F_{13} - F_{16}$)



Şekil 3.3.5 Fonksiyonların yakınsama grafikleri ($F_{17} - F_{20}$)



Şekil 3.3.6 Fonksiyonların yakınsama grafikleri ($F_{21} - F_{23}$)

Yakınsama grafiklerine göre aşağıdaki yorumlar çıkarılabilir.

- F_1 fonksiyonu için yakınsama grafiği incelendiği en hızlı yakınsayan algoritma COA' dır. COA' yı sırasıyla BWO ve AVOA takip etmiştir. AO yaklaşık 650. iterasyondan itibaren, HHO yaklaşık 750. iterasyondan itibaren kendi optimum değerlerine ulaşarak yakınsamalarını tamamlamışlardır. PDO ve STOA ilk iterasyonlardan itibaren çok yavaş yakınsama hızlarına sahiptir. 3. en yavaş yakınsama hızına sahip olan ARO' dur.
- F_2 fonksiyonunda F_1 ile benzer olarak sırasıyla COA ve BWO en hızlı yakınsayan algoritmalarıdır. Bu iki algoritmayı AOA ve AVOA takip etmiştir. Diğer algoritmalar bu 4 dört algoritma kadar hızlı yakınsayamamıştır.
- F_3 fonksiyonunda MGO, STOA' dan sonra en yavaş yakınsayan ikinci algoritmadır.
- F_4 fonksiyonunda diğer üç fonksiyonda olduğu gibi PDO yakınsayamamıştır.
- F_5 fonksiyonunda rakiplerine göre çok hızlı yakınsayan MGO' dur. Diğer algoritmalar çok daha yavaş yakınsama hızına ve daha yüksek amaç fonksiyonu değerine sahiptir.
- F_6 fonksiyonunda MGO ve ARO en hızlı yakınsayan algoritmalarıdır. Bu iki algoritmayı AVOA takip eder.
- F_7 fonksiyonunda STOA ve PDO haricindeki tüm algoritmalar ilk 300 iterasyonda çok hızlı yakınsamışlardır. Ancak daha sonrasında daha yavaş yakınsama hızlarına sahiplerdir. Burada en hızlı yakınsayanlar COA ve AOA' dır.
- F_8 fonksiyonunda MGO ilk iterasyonlarda optimum değere ulaşmıştır. Bu nedenle bir yakınsama hızına sahip değildir. İlk 100 iterasyonda HHO ve AVOA çok yüksek yakınsama hızına sahiptir.
- F_9 fonksiyonunda STOA, PDO, AOA ve HHO hariç tüm algoritmalar yaklaşık ilk 200 iterasyonda çok hızlı yakınsama göstermişlerdir.
- F_{10} fonksiyonunda en hızlı yakınsayan ilk üç algoritma sırasıyla COA, BWO ve AVOA' dır.
- F_{11} fonksiyonunda F_{10} ile benzer şekilde algoritmaların neredeyse tamamı çok hızlı yakınsamıştır. En yavaş yakınsayan iki algoritma sırasıyla STOA ve PDO' dur.

- F_{12} ve F_{13} fonksiyonunda MGO rakiplerine nazaran oldukça yüksek bir yakınsama hızı ile birinci olmuştur.
- F_{14} fonksiyonunda MGO ve ARO optimum değere ilk 100 iterasyonda ulaşmışlardır. Bu iki algoritmayı sırasıyla AVOA ve HHO takip eder.
- Farklı boyutlu çok modlu fonksiyon sonuçları tablosu F_{15} fonksiyonu yakınsama grafiğini doğrulamaktadır. Buna göre HHO, ARO, MGO, AVOA algoritmalarının yakınsama hızları benzer ve ulaştıkları optimum değerler birbirlerine oldukça yakındır.
- F_{16} fonksiyonunda tüm algoritmaların bütün koşmaları optimum değere benzer hızlarla ulaştığından hız eğrileri kesişmiştir.
- F_{17} fonksiyonunda tüm algoritmalar optimum değere ulaşsa da AOA ve STOA en yavaş yakınsayan algoritmalarlardır.
- F_{18} fonksiyonunda AOA' nın iterasyonlar boyunca yakınsama hızı sahiptir. Burada en hızlı yakınsayan algoritma MGO' dur.
- F_{19} ' da algoritmaların çoğu çok hızlı yakınsama hızları ile birbirlerine yakın amaç fonksiyonu değerlerine ulaşmışlardır. Burada en yavaş yakınsayanlar AO ve AOA' dır.
- F_{20} ' de ARO, MGO ve COA en hızlı yakınsayan algoritmalarlardır. Burada en yavaş yakınsayan AO olmuştur.
- F_{21} ve F_{22} ve F_{23} fonksiyonunda ilk 100 iterasyonda çok hızlı yakınsayarak amaç fonksiyonu değerine ulaşan dört algoritma MGO, AO, AVOA ve ARO' dur.

3.4 İstatistiksel Test Sonuçları

T testi, iki bağımsız örneklem arasındaki farkın istatistiksel olarak belirgin olup olmadığını test etmek için kullanılan parametrik bir tekniktir [48]. Bu çalışmada algoritmaların koşmalarda elde ettiği değerler kullanılarak t test yapılmıştır. Her bir algoritma 100 kez bağımsız koşturulduğundan burada örneklem büyüklüğü 100 olarak belirlenmiştir. Bu çalışmada tek kuyruklu ve anlamlılık düzeyi %5 olarak belirlenmiş t test kullanılmıştır. Sonuçlarda h değerinin 1' e eşit olması ve p değerinin 0,05'ten küçük olması karşılaştırılan iki örneklem arasında anlamlı bir fark olduğunu gösterir [49]. Ancak Çizelge 3.3.1- Çizelge 3.3.5'deki farklı fonksiyonlarda anlamlı fark olduğu düşünülen algoritma çiftlerinin istatistiksel test sonuçları Çizelge 3.4.1' de verilmiştir.

Çizelge 3.4.1 Fonksiyon t test sonuçları

Algoritmalar						
	STOA-AVOA	AO-AVOA	PDO-AVOA			
Fonksiyonlar	p	h	p	h	p	h
F_1	3,16E-04	1	0,00E+00	1		
F_2	1,27E-10	1	1,60E-01	0	1,00E+00	0
F_3	1,33E-06	1	0,00E+00	1		
F_4	4,80E-08	1	1,59E-01	0		
F_5	1,52E-164	1	3,57E-08	1	2,09E-11	1
F_6	5,46E-66	1				
F_7	1,23E-21	1	9,95E-01	0	1,00E+00	0
F_8	2,71E-104	1	1,09E-12	1	2,07E-139	1
F_9	5,15E-04	1				
F_{10}	0,00E+00	1				
F_{11}	2,98E-07	1				
F_{12}	8,95E-35	1	2,09E-07	1	3,62E-19	1
F_{13}	7,57E-86	1	6,94E-10	1	2,26E-111	1
F_{14}	6,21E-03	1	2,02E-03	1	1,44E-10	1
F_{15}	2,11E-59	1	2,75E-07	1	1,45E-25	1
F_{16}	1,12E-16	1	1,84E-13	1	1,48E-01	0
F_{17}	1,33E-13	1	1,42E-05	1	2,34E-02	1
F_{18}	1,51E-07	1	2,48E-17	1	1,00E+00	0
F_{19}	1,00E-93	1	1,42E-16	1	5,12E-26	1
F_{20}	2,08E-16	1	1,95E-11	1	2,26E-13	1
F_{21}	1,73E-20	1	4,51E-10	1	8,76E-37	1
F_{22}	1,84E-12	1	1,00E-05	1	2,19E-27	1
F_{23}	1,54E-10	1	6,28E-11	1	8,97E-29	1

Çizelgedeki t test sonuçlarına göre tüm fonksiyonlar için AVOA, STOA' dan daha düşük amaç fonksiyonu değerleri ile daha iyi sonuçlar ürettiği kanıtlanmıştır. Bununla birlikte AVOA 16 fonksiyonla AO' dan, 12 fonksiyonla PDO' dan daha düşük değerler sahiptir.

4. MÜHENDİSLİK PROBLEMLERİNİN METASEZGİSELLER İLE ÇÖZÜMÜ

4.1 Giriş

Bu bölümde metasezgiseller ile 6 farklı mühendislik problemi çözülmüştür. İlerleyen alt bölümlerde çözülen mühendislik tasarım problemleri detaylı olarak anlatılmış; simülasyon sonuçları, yakınsama grafikleri ve algoritmaların elde ettiği parametreler sunulmuştur.

4.2 Mühendislik Problemleri


Gerçek dünya mühendislik tasarım problemleri çok sayıda kısıtı olan oldukça karmaşık amaç fonksiyonlarına sahip, çözümü zor olan problemlerdir. Yaygın olarak kullanılan bu problemler özellikle endüstriyel alanlar ve disiplinler arası çalışmalarda oldukça kullanılmaktadır [50]. Burada en çok kullanılan 6 gerçek dünya mühendislik tasarım problemi ele alınarak bunlar hakkında detaylı bilgi verilmiştir.

4.2.1 Germe/Sıkıştırma Yayı Tasarımı

Germe/sıkıştırma yay tasarım problemi, minimum ağırlığa sahip bir yay tasarımı oluşturmayı amaçlayan bir problemidir [51]. Germe/sıkıştırma yayı probleminin üç adet karar değişkeni bulunmaktadır [52].

- d x_1 : Tel çapı
- D x_2 : Ortalama bobin çapı
- N x_3 : Aktif bobin sayısı

Germe/sıkıştırma yayı tasarımı probleminin şematik yapısı Şekil 4.2.1'de aşağıdaki gibi gösterilmiştir.



Şekil 4.2.1 Germe/Sıkıştırma Yayı Tasarımı

Burada dört adet kısıtlama yer alır. Bunlar: Minimum sapma (g_1), kayma gerilimi (g_2), darbe frekansı (g_3) ve dış çap sınırı (g_4). Problemin matematiksel tanımı aşağıdaki gibidir [52].

Amaç fonksiyonu(minimize):

$$f(x) = (x_3 + 2)x_2x_1^2 \quad [4.1]$$

Kısıtlayıcılar:

$$g_1(x) = 1 - \frac{x_2^3x_3}{71785x_1^4} \leq 0 \quad [4.2]$$

$$g_2(x) = \frac{4x_2^2 - x_1x_2}{12566(x_2x_1^3 - x_1^4)} + \frac{1}{5108x_1^2} - 1 \leq 0 \quad [4.3]$$

$$g_3(x) = 1 - \frac{140.45x_1}{x_2^2x_3} \leq 0 \quad [4.4]$$

$$g_4(x) = \frac{x_1 + x_2}{1.5} - 1 \leq 0 \quad [4.5]$$

Değişken aralıkları:

$$0,05 \leq x_1 \leq 2 \quad [4.6]$$

$$0,25 \leq x_2 \leq 1,3 \quad [4.7]$$


$$2 \leq x_3 \leq 15 \quad [4.8]$$

4.2.2 Basınçlı Kap Tasarımı

Basınçlı kap tasarım probleminde amaç silindirik basınçlı kapların toplam maliyetini en aza indirmektir [17]. Bu tasarım probleminin dört adet karar değişkeni bulunmaktadır [52].

- $T_s (X_1)$: Kabuğun kalınlığı
- $T_h(X_2)$: Kafanın kalınlığı
- $R (X_3)$: İç yarıçap
- $L (X_4)$: Kafa göz alınmadan silindirik bölümün uzunluğu

Basınçlı kap tasarım probleminin şematik yapısı Şekil 4.2.2' de aşağıdaki gibi gösterilmiştir.



Şekil 4.2.2 Basınçlı Kap Tasarımı

Problemin matematiksel modeli aşağıdaki gibidir [17]. Basınçlı kap tasarım probleminin karar değişkenleri ve kısıtlayıcıları ile birlikte modeli Denklem 4.9 ile aşağıdaki gibi gösterilmiştir.

$$\vec{x} = [x_1 \ x_2 \ x_3 \ x_4] = [T_s \ T_h \ R \ L] \quad [4.9]$$

Amaç fonksiyonu:

$$f(\vec{x}) = 0.6224x_1x_2x_3 + 1.7781x_2x_3^2 + 3.1661x_1^2x_4 + 19.84x_1^2x_3 \quad [4.10]$$

Kısıtlar:

$$g_1(\vec{x}) = -x_1 + 0.0193x_3 \leq 0 \quad [4.11]$$

$$g_2(x) = -x_2 + 0.00954x_3 \leq 0 \quad [4.12]$$

$$g_3(x) = -\pi x_3^2 x_4 - \frac{4}{3} \pi x_3^3 + 1296000 \leq 0 \quad [4.13]$$

$$g_4(x) = x_4 - 240 \leq 0 \quad [4.14]$$

Değişken aralıkları:

$$0 \leq x_1 \leq 99, 0 \leq x_2 \leq 99, 10 \leq x_3 \leq 200, 10 \leq x_4 \leq 200 \quad [4.15]$$

4.2.3 Kaynaklı Kiriş Tasarım Problemi

Kaynaklı kiriş tasarım probleminin temel amacı, belirli kısıtlar altında minimum maliyete bir kiriş üretimi sağlamaktır [53]. Problem, dört tasarım değişkeninden ve beş kısıtlamadan oluşmaktadır. Tasarım değişkenleri şunlardır [50]:

- $h(x_1)$: Kaynak kalınlığı
- $l(x_2)$: Kaynak bağlantı uzunluğu
- $t(x_3)$: Kirişin genişliği
- $b(x_4)$: Kiriş kalınlığı

Problemin matematiksel modeli aşağıdaki gibidir [50]. Kaynaklı kiriş tasarım probleminin karar değişkenleri ve kısıtlayıcıları ile birlikte modeli Denklem 4.16 ile aşağıdaki gibi gösterilmiştir.

$$\vec{x} = [x_1 \ x_2 \ x_3 \ x_4] = [h \ l \ t \ b] \quad [4.16]$$

Amaç fonksiyonu:

$$f(x) = 1.10471x_1^2x_2 + 0.04811x_3x_4(14.0 + x_2) \quad [4.17]$$

Kısıtlar:

$$g_1(x) = \tau(x) - \tau_{max} \leq 0 \quad [4.18]$$

$$g_2(x) = \sigma(x) - \sigma_{max} \leq 0 \quad [4.19]$$

$$g_3(x) = x_1 - x_4 \leq 0 \quad [4.20]$$

$$g_4(x) = 1.10471x_1^2 + 0.04811x_3x_4(14.0 + x_2) - 5.0 \leq 0 \quad [4.21]$$

$$g_5(x) = 0.125 - x_1 \leq 0 \quad [4.22]$$

$$g_6(x) = \delta(x) - \delta_{max} \leq 0 \quad [4.23]$$

$$g_7(x) = P - P_c(x) \leq 0 \quad [4.24]$$

Burada;

$$\tau(x) = \sqrt{(\tau')^2 + (2\tau'\tau'')\frac{x_2}{2R} + (\tau'')^2} \quad [4.25]$$

$$\tau' = \frac{6000}{\sqrt{2}x_1x_2} \quad [4.26]$$

$$\tau'' = \frac{MR}{J} \quad [4.27]$$

$$M = 6000 \left(14.0 + \frac{x_2}{2} \right) \quad [4.28]$$

$$R = \sqrt{\frac{x_2^2}{4} + \left(\frac{x_1 + x_3}{2} \right)^2} \quad [4.29]$$

$$J = \left\{ x_1x_2\sqrt{2} \left[\frac{x_2^2}{12} + \left(\frac{x_1 + x_3}{2} \right)^2 \right] \right\} \quad [4.30]$$

$$\sigma(x) = \frac{504000}{x_4x_3^2} \quad [4.31]$$

$$\delta(x) = \frac{2.1952}{x_4x_3^3} \quad [4.32]$$

$$P_c(x) = \frac{4.013E\sqrt{\frac{x_3^2x_4^6}{36}}}{196} \left(1 - \frac{x_3\sqrt{\frac{E}{4G}}}{28} \right) \quad [4.33]$$

$$P_c(x) = \frac{4.013E\sqrt{\frac{\sqrt{2}x_4^6}{36}}}{196} \left(1 - \frac{x_3\sqrt{\frac{E}{4G}}}{28} \right) \quad [4.34]$$

$$\begin{aligned} \tau_{max} &= 13600psi \\ \sigma_{max} &= 30000psi \\ \delta_{max} &= 0.25in \\ E &= 30 \times 10^6psi \\ G &= 12 \times 10^6psi \end{aligned} \quad [4.35]$$

Değişken aralıkları:

$$0.125 \leq x_1 \leq 5 \text{ ve } 0.1 \leq x_2, x_3, x_4 \leq 10 \quad [4.36]$$

4.2.4 Hız Düşürücü Tasarımı

Hız düşürücü tasarım problemi, hava taşıtı motorunun en verimli hızda dönmesini sağlayan basit bir vites kutusu problemidir. Bu tasarım problemi, hız düşürücünün minimum maliyet ağırlığını bulmayı amaçlamaktadır [54]. Tasarım değişkenleri şunlardır [50]:

- b x_1 : Yüz genişliği
- m x_2 : Diş modülü
- z x_3 : Pinyondaki diş sayısı
- l_1 x_4 : Yataklar arasındaki ilk milin uzunluğu
- l_2 x_5 : Yataklar arasındaki ikinci milin uzunluğu
- d_1 x_6 : Birinci milin çapı
- d_2 x_7 : İkinci milin çapı

Problemin matematiksel modeli aşağıdaki gibidir [50]. Hız düşürücü tasarım probleminin karar değişkenleri ve kısıtlayıcıları ile birlikte modeli Denklem 4.37 ile aşağıdaki gibi gösterilmiştir.

$$x = [x_1, x_2, x_3, x_4, x_5, x_6, x_7] = [b, m, z, l_1, l_2, d_1, d_2] \quad [4.37]$$

Amaç fonksiyonu:

$$f(x) = 0.785x_1x_2^2(3.333x_3^2 + 14.9334x_3 - 42.0934) - 1.508x_1(x_6^2 + x_7^2) + 7.4777x_1(x_6^3 + x_7^3) + 1.508x_1(x_4x_6^2 + x_5x_7^2) \quad [4.38]$$

Kısıtlar:

$$g_1(\vec{x}) = \frac{27}{x_1 \times x_2^2 \times x_3} - 1 \leq 0 \quad [4.39]$$

$$g_2(\vec{x}) = \frac{397.5}{x_1 \times x_2^2 \times x_3^2} - 1 \leq 0 \quad [4.40]$$

$$g_3(\vec{x}) = \frac{1.93 \times x_4^3}{x_2 \times x_3 \times x_6^4} - 1 \leq 0 \quad [4.41]$$

$$g_4(\vec{x}) = \frac{1.93 \times x_5^3}{x_2 \times x_3 \times x_7^4} - 1 \leq 0 \quad [4.42]$$

$$g_5(\vec{x}) = \frac{1}{110 \times x_6^3} \times \sqrt{\left(\frac{745 \times x_4}{x_2 \times x_3}\right)^2 + 16.9 \times 10^6} - 1 \leq 0 \quad [4.43]$$

$$g_6(\vec{x}) = \frac{1}{85 \times x_7^3} \times \sqrt{\left(\frac{745 \times x_5}{x_2 \times x_3}\right)^2 + 16.9 \times 10^6} - 1 \leq 0 \quad [4.44]$$

$$g_7(\vec{x}) = \frac{x_2 \times x_3}{40} - 1 \leq 0 \quad [4.45]$$

$$g_8(\vec{x}) = \frac{5 \times x_2}{x_1} - 1 \leq 0 \quad [4.46]$$

$$g_9(\vec{x}) = \frac{x_1}{12 \times x_2} - 1 \leq 0 \quad [3.47]$$

$$g_{10}(x) = \frac{1.5x_6 + 1.9}{x_4} - 1 \leq 0 \quad [4.48]$$

$$g_{11}(\vec{x}) = \frac{1.1 \times x_7 + 1.9}{x_5} - 1 \leq 0 \quad [4.49]$$

Değişken aralıkları:

$$2.6 \leq x_1 \leq 3.6, 0.7 \leq x_2 \leq 0.8, 17 \leq x_3 \leq 28, 7.3 \leq x_4 \leq 8.3, \\ 7.3 \leq x_5 \leq 8.3, 2.9 \leq x_6 \leq 3.9, 5 \leq x_7 \leq 5.5. \quad [4.50]$$

4.2.5 Dişli Takımı Tasarım Problemi

Dişli takımı tasarım problemi, kısıtsız ayrık bir tasarım optimizasyon problemidir. Bu problemde amaç dişli takımının dişli oran maliyetini en aza indirmektir. Bu problemdeki tasarım değişkenleri T_a, T_b, T_c, T_d sırasıyla olmak üzere dişli çarkların diş sayılarıdır. Problemin matematiksel modeli aşağıdaki gibidir [16].

Dişli takımı tasarım probleminin tasarım değişkenleri yapısının modeli Denklem 4.51 ile aşağıdaki gibi gösterilmiştir.

$$\vec{x} = [x_1, x_2, x_3, x_4] = [T_a, T_b, T_d, T_f] \quad [4.51]$$


Amaç fonksiyonu:

$$\text{Minimize } f_5(\vec{x}) = \left(\frac{1}{6.931} - \frac{T_b \cdot T_d}{T_a \cdot T_f} \right)^2 \quad [4.52]$$

Değişken aralıkları:

$$x_1, x_2, x_3, x_4 \in \{12, 13, 14, \dots, 60\} \quad [4.53]$$

Dişli takımı tasarım probleminin şematik yapısı Şekil 4.2.3' te aşağıdaki gibi gösterilmiştir [14].



Şekil 4.2.3 Dişli Takımı Tasarımı

4.2.6 Üç Çubuklu Kafes Tasarım Problemi

Üç çubuklu kafes tasarım problemi, statik olarak yüklenen üç çubuklu bir kafes kirişin ağırlığını en aza indirmektir [55]. Bu problemdeki tasarım değişkenleri x_1, x_2 olmak üzere çapraz kesit alanlarıdır [52]. Problemin matematiksel modeli aşağıdaki gibidir [12].

Üç çubuklu kafes tasarım probleminin tasarım değişkenleri yapısının modeli Denklem 4.54 ile aşağıdaki gibi gösterilmiştir.

$$\vec{X} = [x_1 x_2] = [A_1 A_2] \quad [4.54]$$

Amaç fonksiyonu:

$$f(\vec{X}) = (2\sqrt{2}X_1 + X_2) \times L \quad [4.55]$$

Kısıtlar:

$$g_1(x) = \frac{\sqrt{2}x_1 + x_2}{\sqrt{2}x_1^2 + 2x_1x_2} P - \sigma \leq 0 \quad [4.56]$$

$$g_2(x) = \frac{x_2}{\sqrt{2}x_1^2 + 2x_1x_2} P - \sigma \leq 0 \quad [4.57]$$


$$g_3(x) = \frac{1}{\sqrt{2}x_2 + x_1} P - \sigma \leq 0 \quad [4.58]$$

Değişken aralıkları:

$$0 \leq x_i \leq 1, i = 1,2 \quad [4.59]$$

Burada; $l = 100\text{cm}$, $P = 2\text{kN/cm}^2$, $\sigma = \text{kN/cm}^2$, dir.

Üç çubuklu kafes tasarım probleminin şematik yapısı Şekil 4.2.4' te aşağıdaki gibi gösterilmiştir [55].



Şekil 4.2.4 Üç Çubuklu Kafes Tasarımı

4.3 Sonuçlar

Çalışmada tüm algoritmalar 100 kez bağımsız koşturulmuştur. Algoritmalar MATLAB 2024a platformu kullanılarak yazılmıştır. Kullanılan bilgisayar, 13th Gen Intel(R) Core (TM) i9-13900H 2.60 GHz hıza ve 16 GB RAM özelliklerine sahiptir. Tezin 3.bölümünde kullanılan parametreler ve değerleri Çizelge 3.4' te yer aldığı şekliyle bu çalışma içinde aynı kullanılmıştır.


4.3.1 Simülasyon sonuçları

Problemlere göre algoritmaların ortalama, standart sapma, en iyi, en kötü ve sıralama değerleri Çizelge 4.3.1-4.3.6’ da sunulmuştur. Tabloda ortalama ve en iyi değerler renklendirilerek sunulmuştur. Çizelge 4.3.1-4.3.6’ ya göre aşağıdaki çıkarımlara ulaşılır:


- Tüm problemler için ARO oldukça düşük amaç fonksiyonları değerlerine sahiptir. Ayrıca toplamda 9 sıralama puanına sahiptir. Bu da tüm algoritmalar içerisinde mühendislik problemlerinin en iyi çözen algoritma olduğunun göstergesidir. ARO’ dan sonra en başarılı 3 algoritma BWO, MGO ve AVOA dır.
- Dişli takımı tasarımı problemini tüm algoritmalar başarı ile çözmüştür.
- Test fonksiyonlarının aksine STOA, germe sıkıştırma yayı tasarım problemi için oldukça düşük bir amaç fonksiyonu değeri ile 6. sırada yer almaktadır.
- Algoritmalar içerisinde en yüksek sıralama puanına (55) sahibi olan AOA mühendislik problemleri çözümünde sonuncudur.

4.3.2 Yakınsama Grafikleri Analizi


Mühendislik problemleri için çıkarılan yakınsama grafikleri Şekil 4.3.1-4.3.6’ da sunulmuştur.




Şekil 4.3.1 Germe Sıkıştırma yayı tasarımı yakınsama grafiği




Şekil 4.3.2 Basınçlı kap tasarımı yakınsama grafiği




Şekil 4.3.3 Kaynaklı kiriş tasarımı yakınsama grafiği



Şekil 4.3.4 Hız düşürücü tasarım problemi yakınsama grafiği



Şekil 4.3.5 Dişli takımı tasarımı problemi yakınsama grafiği



Şekil 4.3.6 Üç çubuklu kafes tasarım problemi yakınsama grafiği

Yakınsama grafiklerine göre aşağıdaki yorumlar yapılabilir:

- Germe sıkıştırma yayı tasarım problemi için PDO ve AO hariç diğer tüm algoritmalar minimum amaç fonksiyonu değerlerine yaklaşık 30. iterasyonda ulaşmışlardır.
- Basıncılı kap tasarımı problemi için en hızlı yakınsayan iki algoritma MGO ve AVOA olmuştur; ancak ARO bu algoritmalarından daha yavaş yakınsamasına rağmen daha düşük amaç fonksiyonu değerine ulaşmıştır.
- Kaynaklı kiriş tasarımı problemi için BWO, STOA ve AO hariç diğer algoritmalar çok hızlı yakınsayarak amaç fonksiyon değerini elde etmiştir. Bu algoritmalarda yavaş yakınsamalarına rağmen daha sonra benzer amaç fonksiyon değerleri elde etmişlerdir.
- Hız düşürücü tasarım problemi için en yavaş yakınsayan algoritma sırasıyla PDO, AO ve BWO' dur.
- Dişli takımı tasarımı probleminde diğer problemlere nazaran algoritmalar farklı yakınsama hızları göstermişlerdir. BWO' dan daha yavaş yakınsayan HHO ve AVOA daha düşük amaç fonksiyonu değerine ulaşabilmişlerdir.
- Üç çubuklu kafes tasarım problemi için STOA en yavaş yakınsayan algoritma olmasına rağmen AO ve AOA daha düşük amaç fonksiyon değeri elde edebilmiştir.
- Tüm problemler birlikte değerlendirildiğinde AO'nun en yavaş yakınsama hızına sahip olduğu görülebilir.

4.3.3 En İyi Modellerin Analizi

Mühendislik tasarım problemleri için algoritmaların 100 kořma sonucunda çıkarılan en iyi modellerinin optimize ettięi parametre deęerleri ve ama fonksiyonu deęerleri izelge 4.3.1- izelge 4.3.7 da sunulmuřtur.



Çizelge 4.3.1 Germe sıkıştırma yayı tasarım problemi sonuçları

Algoritmalar	x1	x2	x3	Amaç Fonksiyonu Değerleri	Rank
AO	0,052592491	0,37470729	10,48502	0,012939839	9
AOA	0,05	0,3168629	14,649187	0,013188774	10
ARO	0,051680393	0,35650922	11,301204	0,012665238	2
AVOA	0,051834953	0,36023768	11,085547	0,01266562	4
BWO	0,051692255	0,35679458	11,284462	0,012665233	1
COA	0,051509285	0,35240065	11,549537	0,012668704	5
HHO	0,052900223	0,3865607	9,7321911	0,012691467	7
MGO	0,05160305	0,35465206	11,411106	0,012665368	3
PDO	0,050777043	0,33517065	12,695232	0,012699225	8
STOA	0,051987112	0,36377502	10,893929	0,012676797	6

Çizelge 4.3.2 Basınçlı kap tasarımı problemi sonuçları

Algoritmalar	x_1	x_2	x_3	x_4	Amaç Fonksiyonu Değerleri	Sıralama
ARO	0,778168652	0,38464917	40,319619	200	5885,332823	1
BWO	0,778168753	0,38464922	40,319622	200	5885,333375	2
MGO	0,778316101	0,38472205	40,327259	199,894	5885,584879	3
AVOA	0,77851532	0,38482053	40,337581	199,75	5885,925625	4
COA	0,77962882	0,38542321	40,38514	199,091	5889,372289	5
STOA	0,780186935	0,38738763	40,416082	198,677	5895,266668	6
AO	0,787601938	0,40980793	40,667112	196,283	6004,018483	7
HHO	0,806719602	0,43650485	41,780412	180,618	6055,476821	8
PDO	0,880778106	0,4352173	45,620253	137,421	6086,984962	9
AOA	0,791275935	0,44601592	40,554178	200	6199,048644	10

Çizelge 4.3.3 Kaynaklı giriş tasarımı problemi sonuçları

Algoritmalar	x_1	x_2	x_3	x_4	Amaç Fonksiyonu Değerleri	Sıralama
ARO	0,2057296	3,4704887	9,0366239	0,20572964	1,72485230860	1
MGO	0,2057296	3,4704887	9,0366239	0,20572964	1,72485230861	2
BWO	0,2057296	3,4704888	9,0366241	0,205729639	1,72485234090	3
AVOA	0,2057288	3,4704997	9,03664	0,20572956	1,72485473370	4
COA	0,2057105	3,4709241	9,0366253	0,205730396	1,72488747435	5
STOA	0,2060635	3,4678117	9,0281662	0,206160973	1,72682471051	6
HHO	0,2040826	3,4891408	9,0808917	0,20571622	1,73235128058	7
PDO	0,1995249	3,6002381	9,058884	0,205618841	1,73555097437	8
AO	0,2009556	3,5984309	9,0545819	0,20772722	1,75300142909	9
AOA	0,202386	3,2197822	10	0,206040794	1,85262409521	10

Çizelge 4.3.4 Hız düşürücü tasarımı problemi sonuçları

Algoritmalar	x_1	x_2	x_3	x_4	x_5	x_6	x_7	Amaç Fonksiyonu Değerleri	Sıralama
ARO	3,5	0,7	17	7,3	7,715	3,35	5,287	2994,471066	1
MGO	3,5	0,7	17	7,3	7,715	3,35	5,287	2994,471066	1
AVOA	3,5	0,7	17	7,3	7,715	3,35	5,287	2994,471068	2
BWO	3,5	0,7	17	7,3	7,715	3,35	5,287	2994,471073	3
COA	3,5	0,7	17	7,3	7,716	3,35	5,287	2994,499611	4
HHO	3,5	0,7	17	7,3	7,901	3,351	5,287	2998,88129	5
AO	3,507	0,7	17	7,397	7,783	3,351	5,292	3003,015979	6
STOA	3,502	0,7	17	7,372	7,746	3,363	5,295	3005,315459	7
PDO	3,522	0,7	17	7,3	8,299	3,454	5,302	3052,735098	8
AOA	3,6	0,7	17	7,602	8,3	3,354	5,297	3056,678063	9

Çizelge 4.3.5 Dişli takımı tasarımı problemi sonuçları

Algoritmalar	x_1	x_2	x_3	x_4	Amaç Fonksiyonu Değerleri	Sıralama
AVOA	38,89793379	16,8804144	12,455453	37,46381	0	1
BWO	31,87277374	12,7180715	12,718071	35,17374	0	1
HHO	40,26331843	16,6614264	20,868086	59,85234	0	1
PDO	52,2103518	19,52835	14,157349	36,70175	0	1
MGO	42,62577039	18,5483072	14,911688	44,9733	1,11101E-21	2
ARO	48,66466943	13,2402823	13,667962	25,77408	1,44834E-21	3
COA	59,51160909	42,6073522	12,091286	60	7,07504E-21	4
STOA	59,79186347	12	42,455804	59,0571	1,28743E-16	5
AO	58,39378178	15,9832017	26,984379	51,1924	1,76985E-16	6
AOA	60	21,1917568	12,510427	30,62561	1,07693E-13	7

Çizelge 4.3.6 Üç çubuklu tasarım problemi sonuçları

Algoritmalar	x_1	x_2	Amaç Fonksiyonu Değerleri	Sıralama
ARO	0,788675137	0,40824828	263,8958434	1
BWO	0,788675134	0,40824829	263,8958434	1
PDO	0,788713316	0,40814031	263,8958444	2
MGO	0,788634467	0,40836333	263,8958446	3
AVOA	0,788600311	0,40845997	263,8958475	4
HHO	0,7885911	0,40848603	263,8958486	5
COA	0,788664618	0,40827811	263,8958505	6
STOA	0,789159675	0,40688784	263,896847	7
AO	0,790004005	0,40451246	263,8981219	8
AOA	0,794775673	0,39132284	263,9287907	9

Çizelge 4.3.7 Mühendislik tasarım problemleri başarı sıralamaları

Başarı Sıralamaları							
Algoritmalar	Germe Sıkıştırma Yayı Tasarım	Basınçlı Kap Tasarımı	Kaynaklı Kiriş Tasarımı	Hız Düşürücü Tasarımı	Dişli Takımı Tasarımı Problemi	Üç Çubuklu Tasarım Problemi	Sıralama Toplam
ARO	2	1	1	1	3	1	9
BWO	1	2	3	3	1	1	11
MGO	3	3	2	1	2	3	14
AVOA	4	4	4	2	1	4	19
COA	5	5	5	4	4	6	29
HHO	7	8	7	5	1	5	33
PDO	8	9	8	8	1	2	36
STOA	6	6	6	7	5	7	37
AO	9	7	9	6	6	8	45
AOA	10	10	10	9	7	9	55

Tablolarda amaç fonksiyonu değeri en iyiden en kötüye doğru sıralanmıştır. Örneğin; germe sıkıştırma yayı tasarım problemi için en iyi amaç fonksiyonu değerine sahip algoritma BWO' dur. Tablolardan aşağıdaki yorumlar çıkarılabilir:

- Germe sıkıştırma yayı tasarım problemi için AOA ve AO hariç diğer algoritmalar birbirlerine oldukça yakın amaç fonksiyonu değeri bu üç parametreyi optimize etmişlerdir.
- Basıncılı kap tasarımı problemi için diğerlerine nazaran başarısız olan 4 algoritma AO, HHO, PDO ve AOA' dır.
- Kaynaklı kiriş tasarımı probleminde AOA' nın amaç fonksiyon değerleri en yakın rakibi olan AO' dan yaklaşık 0,1 yüksek amaç fonksiyon değerine sahip olarak en başarısız algoritma olmuştur.
- Hız düşürücü tasarım problemi için sırasıyla PDO ve AOA en yakın rakipleri STOA' dan oldukça yüksek bir farkla (47 sıralama değeri) sonuncu olmuşlardır.
- Dişli takımı tasarımı problemi ve üç çubuklu kafes tasarım problemlerini tüm algoritmalar başarıyla çözmüştür.

En iyi modeller amaç fonksiyon değerine göre en iyiden en kötüye sıralandığında elde edilen sıralama toplamaları Çizelge 4.3.7' de sunulmuştur. Bu tabloya göre ortalamalarda olduğu gibi en iyi modellerde de ARO mühendislik problemlerini en iyi tahmin eden algoritma olmuştur. BWO ortalama değerler sıralamasında (Çizelge 4.3.7) 5. Sırada olmasına rağmen en iyi modellerde 2. sırada yer almaktadır.

4.4 T-Test Sonuçları

3.bölümde olduğu gibi bu bölümde t testinden yararlanılarak algoritmaların başarıları arasında istatistiksel anlamlı bir farkın olup olmadığı değerlendirilmiştir. Burada ortalamalarda fark gözüken AOA-ARO, AO-ARO ve PDO-ARO istatistiksel test sonuçları Çizelge 4.4.1' de sunulmuştur.

Tüm mühendislik problemleri için ARO, AOA ve AO' dan daha düşük amaç fonksiyon değerleri ile anlamlı olarak daha iyi sonuçlar üretmiştir. F5 için PDO-ARO çiftinin kıyaslamasında ise F5 problemi hariç diğer tüm problemlerde ARO anlamlı olarak PDO dan daha iyidir.

Çizelge 4.4.1 t testi sonuçları

Algoritma	AOA-ARO		AO-ARO		PDO-ARO	
	p	h	p	h	p	h
F1	1,18E-31	1	8,29E-144	1	1,10E-27	1
F2	3,93E-28	1	9,51E-14	1	9,24E-08	1
F3	8,20E-25	1	1,06E-41	1	2,46E-11	1
F4	1,51E-51	1	1,65E-53	1	1,60E-80	1
F5	3,79E-06	1	8,65E-10	1	1,00E+00	0
F6	1,08E-15	1	8,93E-27	1	2,28E-03	1

5. TARTIŞMA, SONUÇ VE ÖNERİLER

5.1 Tartışma ve Sonuç

Bu tez çalışmasında öncelikle metasezgisel algoritmaların öneminden ve son 5 yılda geliştirilen 10 güncel metasezgisel hakkında literatür taraması yapılmış ve bu metasezgisel algoritmalar ayrıntılı olarak verilmiştir. Tez kapsamında bu 10 algoritmanın test fonksiyonları ve mühendislik tasarım problemleri karşısındaki başarı oranları ilk kez ortaya koyulmuştur.

Tezin birinci bölümünde amaç, kapsam ve katkıları açıklanmıştır. Ek olarak tezde kullanılan metasezgisel algoritmaların çalışmaları hakkında kısa bir açıklama yapılmıştır.

İkinci bölümde, bu çalışmada yer alan metasezgiseller hakkında detaylı bir literatür çalışması yapılmıştır. Burada metasezgisel algoritmaların her birinin çalışma yapıları ve sözde kodları yer almaktadır.

Tezin üçüncü bölümünde, çalışmada kullanılan optimizasyon algoritmaların performanslarını ölçmek amacıyla 23 farklı test fonksiyonu ile kıyaslamaları yapılmıştır. Kıyaslama sonucunda her fonksiyon için koşmaların ortalama, standart sapma, en iyi ve en kötü sonuçları ortaya çıkarılmıştır. Ayrıca tez çalışmasında kullanılan tüm algoritmaların her bir test fonksiyonu üzerindeki yakınsama grafikleri çizilerek şekillerle sunulmuştur. Çalışmada yer alan metasezgisellerin önerildiği makalelerdeki kalite test fonksiyonları için tavsiye edilen değerleri olan parametre değerleri almaktadır. Test fonksiyonları ile bu algoritmaların kıyaslanmasında tüm algoritmaların popülasyon büyüklüğü 50, maksimum iterasyon sayısı 1000 olarak belirlenmiştir. Çalışmada algoritmaların koşmalarda elde ettiği değerler arasındaki farkın anlamlı olup olmadığını daha net ortaya koyabilmek için t test yapılmış ve sonuçlar ortaya çıkarılmıştır. Bu çalışmada kullanılan 23 farklı test fonksiyonları (Tek modlu, çok modlu ve farklı boyutlu çok modlu fonksiyon) sıralama değerleri birlikte değerlendirildiğinde 1. AVOA olmuştur. AVOA' yı sırasıyla MGO, AO, ARO ve COA takip etmiştir. Tüm algoritmalar içerisinde toplam 125 sıralama puanı ile en başarısız olan algoritma STOA olduğu gözlemlenmiştir.

Dördüncü bölümde, gerçek dünya mühendislik tasarım problemleri ele alınmış ve ayrıntılı bir literatür taraması yapılmıştır. Çalışmada yer alan mühendislik tasarım problemleri 10 metasezgisel ile bu problemler optimize edilmiş ve problemlere göre algoritmaların ortalama, standart sapma, en iyi, en kötü ve sıralama değerlerine yer verilmiştir. Çalışma sonuçlarına göre tüm problemlerde ARO oldukça düşük amaç fonksiyonları değerlerine (9 sıralama puanına) sahiptir. Bu da tüm algoritmalar içerisinde mühendislik problemlerinin en iyi çözen algoritma olduğunun göstergesidir. ARO' dan sonra en başarılı 3 algoritmanın BWO, MGO ve AVOA olduğu ortaya çıkarılmıştır. Ayrıca mühendislik problemleri için çıkarılan yakınsama grafikleri ortaya çıkarılmıştır. 3.bölümde olduğu gibi bu bölümde de t testinden yararlanılarak algoritmaların başarıları arasında istatistiksel anlamlı bir farkın olup olmadığı değerlendirilmiştir.

Bu çalışmada son 5 yılda önerilen metasezgisellerin test fonksiyonlarını ve mühendislik problemlerini çözme kabiliyeti değerlendirilmiştir. Çalışma kapsamında yapılan tüm değerlendirmeler sonucunda sırasıyla AVOA, MGO ve ARO' nun en yüksek başarıya sahip algoritmalarıdır. Gelecekteki çalışmalarda bu algoritmalar farklı mühendislik problemlerine uyarlanabilir. Ayrıca algoritmaların keşif ve sömürü aşamalarında iyileştirmeler yapılarak daha iyi amaç fonksiyonu değerlerine ve daha yüksek yakınsama hızlarına ulaşılabilir. Ek olarak, algoritmalar güncel metasezgisellerin başarı kıyaslamalarında kullanılabilir.

KAYNAKLAR

- [1] **Emel, Gül Gökay, and Ç. Taşkın.** "Genetik algoritmalar ve uygulama alanları." *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi* 21.1 (2002): 129-152.
- [2] **Mitchell, Melanie, and StephanieForrest.** "Genetic algorithm sand artificial life." *Artificial Life* 1.3 (1994): 267-289. doi:10.1162/artl.1994.1.3.267
- [3] **Öznur, İ. Ş. Ç. İ., &Korukoğlu, S.** (2003). Genetik algoritma yaklaşımı ve yöneylem araştırmasında bir uygulama. *Yönetim ve Ekonomi Dergisi*, 10(2), 191-208.
- [4] **Albadr, M. A., Tiun, S., Ayob, M., & Al-Dhief, F.** (2020). Genetic algorithm based on natural selection the oryfor optimization problems. *Symmetry*, 12(11), 1758.
- [5] **Karaboga, D., &Basturk, B.** (2007). Sayısal fonksiyon optimizasyonu için güçlü ve verimli bir algoritma: Yapay arı kolonisi (ABC) algoritması. *Journal Of Global Optimazition*, 39(3).
- [6] **Özdemir, R.** (2012). *Yapay arı kolonisi algoritması için yeni seçme ve arama mekanizmalarının geliştirilmesi* (Doctoraldissertation, Yüksek lisans Tezi. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Ana Bilim Dalı, Kayseri 69s).
- [7] **Jia, H., Rao, H., Wen, C., & Mirjalili, S.** (2023). Crayfish optimization algorithm. *Artificial Intelligence Review*, 56(Suppl 2), 1919-1979.
- [8] **Heidari, A. A., Mirjalili, S., Faris, H., Aljarah, I., Mafarja, M., &Chen, H.** (2019). Harris hawksoptimization: Algorithm and applications. *Futur egeneration computer systems*, 97, 849-872.
- [9] **Dhiman, G., &Kaur, A.** (2019). STOA: a bio-inspired based optimization algorithm for industrial engineering problems. *Engineering Applications of ArtificialIntelligence*, 82, 148-174.
- [10] **Hayyolalam, V., & Kazem, A. A. P.** (2020). Black widow optimization algorithm: a novel meta-heuristic approach for solving engineering optimization problems. *Engineering Applications of Artificial Intelligence*, 87, 103249.
- [11] **Abualigah, L., Diabat, A., Mirjalili, S., Abd Elaziz, M., & Gandomi, A. H.** (2021). The arithmetic optimization algorithm. *Computer methods in applied mechanics and engineering*, 376, 113609.
- [12] **Abdollahzadeh, B., Gharehchopogh, F. S., & Mirjalili, S.** (2021). African vultures optimization algorithm: A new nature-inspired metaheuristic algorithm for global optimization problems. *Computers & Industrial Engineering*, 158, 107408.
- [13] **Abualigah, L., Yousri, D., Abd Elaziz, M., Ewees, A. A., Al-Qaness, M. A., & Gandomi, A. H.** (2021). Aquila optimizer: a novel meta-heuristic optimization algorithm. *Computers & Industrial Engineering*, 157, 107250.
- [14] **Wang, L., Cao, Q., Zhang, Z., Mirjalili, S., & Zhao, W.** (2022). Artificial rabbits optimization: A new bio-inspired meta-heuristic algorithm for solving engineering optimization problems. *Engineering Applications of Artificial Intelligence*, 114, 105082.
- [15] **Abdollahzadeh, B., Gharehchopogh, F. S., Khodadadi, N., & Mirjalili, S.** (2022). Mountain gazelle optimizer: a new nature-inspired metaheuristic

- algorithm for global optimization problems. *Advances in Engineering Software*, 174, 103282.
- [16] **Ezugwu, A. E., Agushaka, J. O., Abualigah, L., Mirjalili, S., & Gandomi, A. H.** (2022). Prairie dog optimization algorithm. *Neural Computing and Applications*, 34(22), 20017-20065.
- [17] **Jia, H., Rao, H., Wen, C., & Mirjalili, S.** (2023). Crayfish optimization algorithm. *Artificial Intelligence Review*, 56(Suppl 2), 1919-1979.
- [18] **Altay, O.** (2022). Güncel Metasezgisel Yöntemlerin Standart Kalite Testi Fonksiyonlarında Karşılaştırılması. *International Journal of Pure and Applied Sciences*, 8(2), 286-301.
- [19] **JC Bednarz,** Harris'in şahinlerinde kooperatif avcılığı (parabuteunicinctus), *Science* 239 (1988) 1525.
- [20] **Kuyu, Y. Ç.** (2023). *Optimizasyon Problemleri İçin Yeni Metasezgisel Yaklaşımlar* (Doctoral dissertation, Bursa Uludağ University (Turkey)).
- [21] **Singh, A., Sharma, A., Rajput, S., Mondal, A. K., Bose, A., & Ram, M.** (2022). Parameter extraction of solar module using the sooty tern optimization algorithm. *Electronics*, 11(4), 564.
- [22] **Hu, G., Du, B., Wang, X., & Wei, G.** (2022). An enhanced black widow optimization algorithm for feature selection. *Knowledge-Based Systems*, 235, 107638.
- [23] **Li, X. D., Wang, J. S., Hao, W. K., Zhang, M., & Wang, M.** (2022). Chaotic arithmetic optimization algorithm. *Applied Intelligence*, 52(14), 16718-16757.
- [24] **Dhal, K. G., Sasmal, B., Das, A., Ray, S., & Rai, R.** (2023). A comprehensive survey on arithmetic optimization algorithm. *Archives of Computational Methods in Engineering*, 30(5), 3379-3404.
- [25] **Fan, J., Li, Y., & Wang, T.** (2021). An improved African vultures optimization algorithm based on tent chaotic mapping and time-varying mechanism. *Plos one*, 16(11), e0260725.
- [26] **Sasmal, B., Das, A., Dhal, K. G., & Saha, R.** (2024). A Comprehensive Survey on African Vulture Optimization Algorithm. *Archives of Computational Methods in Engineering*, 31(3), 1659-1700.
- [27] **Zhang, J., Khayatnezhad, M., & Ghadimi, N.** (2022). Optimal model evaluation of the proton-exchange membrane fuel cells based on deep learning and modified African Vulture Optimization Algorithm. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 44(1), 287-305.
- [28] **Turgut, O. E., & Turgut, M. S.** (2023). Local search enhanced Aquila optimization algorithm ameliorated with an ensemble of Wavelet mutation strategies for complex optimization problems. *Mathematics and Computers in Simulation*, 206, 302-374.
- [29] **AKYOL, S.** (2021). Global optimizasyon için yeni bir hibrit yöntem: kaya kartalı optimizasyonu-tanjant arama algoritması. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 33(2), 721-733.
- [30] **Zhang, Y. J., Yan, Y. X., Zhao, J., & Gao, Z. M.** (2022). AOAAO: The hybrid algorithm of arithmetic optimization algorithm with aquila optimizer. *IEEE Access*, 10, 10907-10933.
- [31] **AYDEMİR, S. B.** (2022). Küresel optimizasyon için gauss kaotik haritası ile kartal optimizasyonu. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 34(1), 85-104.

- [32] **Sasmal, B., Hussien, A. G., Das, A., & Dhal, K. G.** (2023). A comprehensive survey on aquila optimizer. *Archives of Computational Methods in Engineering*, 30(7), 4449-4476.
- [33] **Bakır, H.** (2024). Dynamic fitness-distance balance-based artificial rabbits optimization algorithm to solve optimal power flow problem. *Expert Systems with Applications*, 240, 122460.
- [34] **Wang, Y., Xiao, Y., Guo, Y., & Li, J.** (2022). Dynamic chaotic opposition-based learning-driven hybrid aquila optimizer and artificial rabbits optimization algorithm: framework and applications. *Processes*, 10(12), 2703.
- [35] **Alsaieri, A. O., Moustafa, E. B., Alhumade, H., Abulkhair, H., & Elsheikh, A.** (2023). A coupled artificial neural network with artificial rabbits optimizer for predicting water productivity of different designs of solar stills. *Advances in Engineering Software*, 175, 103315.
- [36] **Gülmez, B.** (2023). Stock price prediction with optimized deep LSTM network with artificial rabbits optimization algorithm. *Expert Systems with Applications*, 227, 120346.
- [37] **Khodadadi, N., El-Kenawy, E. S. M., De Caso, F., Alharbi, A. H., Khafaga, D. S., & Nanni, A.** (2023). The Mountain Gazelle Optimizer for truss structures optimization. *Applied Computing and Intelligence*, 3(2), 116-144.
- [38] **Abbassi, R., Saidi, S., Urooj, S., Alhasnawi, B. N., Alawad, M. A., & Premkumar, M.** (2023). An Accurate Metaheuristic Mountain Gazelle Optimizer for Parameter Estimation of Single-and Double-Diode Photovoltaic Cell Models. *Mathematics*, 11(22), 4565.
- [39] **Ekinci, S., & Izci, D.** (2023). Enhancing IIR system identification: Harnessing the synergy of gazelle optimization and simulated annealing algorithms. *e-Prime-Advances in Electrical Engineering, Electronics and Energy*, 5, 100225.
- [40] **Sarangi, P., & Mohapatra, P.** (2023). Evolved opposition-based mountain gazelle optimizer to solve optimization problems. *Journal of King Saud University-Computer and Information Sciences*, 35(10), 101812.
- [41] **Alomoush, W., Houssein, E. H., Alrosan, A., Abd-Alrazaq, A., Alweshah, M., & Alshinwan, M.** (2024). Joint opposite selection enhanced Mountain Gazelle Optimizer for brain stroke classification. *Evolutionary Intelligence*, 1-19.
- [42] **Sahoo, G. K., Choudhury, S., Rathore, R. S., & Bajaj, M.** (2023). A novel prairie dog-based meta-heuristic optimization algorithm for improved control, better transient response, and power quality enhancement of hybrid microgrids. *Sensors*, 23(13), 5973.
- [43] **Abualigah, L., Diabat, A., Thanh, C. L., & Khatir, S.** (2023). Opposition-based Laplacian distribution with Prairie Dog Optimization method for industrial engineering design problems. *Computer Methods in Applied Mechanics and Engineering*, 414, 116097.
- [44] **Izci, D., Ekinci, S., & Hussien, A. G.** (2024). Efficient parameter extraction of photovoltaic models with a novel enhanced prairie dog optimization algorithm. *Scientific Reports*, 14(1), 7945.
- [45] **Shikoun, N. H., Al-Eraqi, A. S., & Fathi, I. S.** (2024). BinCOA: An Efficient Binary Crayfish Optimization Algorithm for Feature Selection. *IEEE Access*, 12, 28621-28635.
- [46] **Daulat, H., Varma, T., & Chauhan, K.** (2024, April). Augmenting the Crayfish Optimization with Gaussian Distribution Parameter for Improved

- Optimization Efficiency. In *2024 International Conference on Cognitive Robotics and Intelligent Systems (ICC-ROBINS)* (pp. 462-470). IEEE.
- [47] **Xiao, B., Wang, R., Deng, Y., Yang, Y., & Lu, D.** (2024, March). Simplified Crayfish Optimization Algorithm. In *2024 IEEE 7th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC)* (Vol. 7, pp. 392-396). IEEE.
- [48] **Kim, T. K.** (2015). T test as a parametric statistic. *Korean journal of anesthesiology*, 68(6), 540-546.
- [49] **Browne, R. H.** (2010). The t-test p value and its relationship to the effect size and $P(X > Y)$. *The American Statistician*, 64(1), 30-33.
- [50] **Altay, E. V.** (2022). Gerçek dünya mühendislik tasarım problemlerinin çözümünde kullanılan metasezgisel optimizasyon algoritmalarının performanslarının incelenmesi. *International Journal of Innovative Engineering Applications*, 6(1), 65-74.
- [51] **Arora, J. S.** (2004). *Introduction to optimum design*. Elsevier.
- [52] **ÖZBAY, F. A., & Özbay, E.** MARTİ OPTİMİZASYON ALGORİTMASININ KISITLI MÜHENDİSLİK TASARIM PROBLEMLERİ İÇİN PERFORMANS ANALİZİ. *Adıyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 8(15), 469-485.
- [53] **He, X., & Zhou, Y.** (2018). Enhancing the performance of differential evolution with covariance matrix self-adaptation. *Applied Soft Computing*, 64, 227-243.
- [54] **Dhiman, G.** (2021). ESA: a hybrid bio-inspired metaheuristic optimization approach for engineering problems. *Engineering with Computers*, 37, 323-353.
- [55] **Zhao, W., Wang, L., & Mirjalili, S.** (2022). Artificial hummingbird algorithm: A new bio-inspired optimizer with its engineering applications. *Computer Methods in Applied Mechanics and Engineering*, 388, 114194.